

ROTEAMENTO EM REDES ÓPTICAS TRANSPARENTES BASEADO EM OTIMIZAÇÃO POR COLÔNIAS DE FORMIGAS COM TREINAMENTO POR OTIMIZAÇÃO POR ENXAMES DE PARTÍCULAS

Trabalho de Conclusão de Curso

Engenharia da Computação

Renato Morais Fernandes da Silva

Orientador: Prof. Dr. Carmelo José Albanez Bastos Filho



UNIVERSIDADE
DE PERNAMBUCO

RENATO MORAIS FERNANDES DA SILVA

**ROTEAMENTO EM REDES ÓPTICAS
TRANSPARENTES BASEADO EM OTIMIZAÇÃO
POR COLÔNIAS DE FORMIGAS COM
TREINAMENTO POR OTIMIZAÇÃO POR
ENXAMES DE PARTÍCULAS**

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia da Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Recife, novembro de 2008.

*Dedico este trabalho aos meus avós,
Luiz e Elvira.*

Agradecimentos

Agradeço aos meus pais, Maria Morais e Eraldo Fernandes, por terem proporcionado uma formação que me permitiu chegar à conclusão da minha graduação. À minha mãe pela generosa publicidade feita a cada conquista minha, até mesmo para as menores delas.

Ao professor Carmelo Bastos Filho que me orientou de forma exemplar, se fazendo disponível sempre que precisei de ajuda, me dando conselhos e apoio para que eu pudesse cumprir com todos os objetivos estabelecidos para este trabalho.

A Danilo Carvalho e Daniel Chaves pela atenção dispensada e apoio oferecido para solucionar os problemas que surgiram durante o desenvolvimento das atividades deste trabalho.

Aos amigos que fiz ao longo do curso de Engenharia da Computação, principalmente a Ailton Sousa, Antonio Felipe, Bruno Carvalho, Henrique Bezerra, Marcos Álvares e Murilo Pontes por estarem ao meu lado nos momentos de esforços, dificuldades, conquistas e diversão. Espero tê-los sempre ao meu lado para vivermos momentos tão importantes como os que já passamos.

Ao amigo Claudio Silva que foi decisivo na minha formação profissional, despertando em mim o interesse pela área de comunicações e redes de computadores.

Aos docentes do Departamento de Sistemas e Computação da Universidade de Pernambuco, em especial aos professores Carlos Alexandre de Mello, Carmelo Bastos Filho e Fernando Buarque que não se limitam a repassar conhecimentos relativos às disciplinas lecionadas, pois possuem o dom de abrir os olhos dos seus alunos para que esses sejam capazes de enxergar além e se tornar não só grandes profissionais, mas também grandes seres humanos. Professores brilhantes são aqueles que formam pessoas brilhantes.

A Chênia Herculano por estar sempre ao meu lado, oferecendo apoio e afeto, me ajudando a estar sempre centrado nos meus objetivos e participando ativamente do meu crescimento profissional e, principalmente, pessoal.

Aos meus avós, Luiz e Elvira, pessoas admiráveis, que tomo como exemplo. Para mim, é uma alegria imensa saber que minhas conquistas felicitam essas duas pessoas tão especiais.

Resumo

A utilização de redes de computadores para estudo, trabalho e negócios vem crescendo de forma exponencial nos últimos anos. Assim, serviços de rede devem ter qualidade, para que as pessoas possam executar suas atividades de forma segura e adequada. Redes ópticas transparentes são escaláveis, tolerantes a falhas, capazes de suportar grandes volumes de dados e prover alta velocidade nas transmissões, além de ter alcance físico extenso, atendendo aos requisitos atuais para serviços de comunicação em redes de longa distância.

Redes totalmente ópticas têm capacidade de transmitir dados através de múltiplos canais de comunicação, utilizando comprimentos de onda distintos em uma única fibra, com o mínimo de interferência entre eles. Para que a qualidade nas comunicações seja garantida, é necessário que sejam selecionados os melhores caminhos ópticos para a transmissão dos dados. Para isso, são utilizados algoritmos de RWA (*Routing and Wavelength Assignment*) que estabelecem caminhos e alocam comprimentos de onda nos enlaces, tentando minimizar as taxas de bloqueio de chamadas, ou seja, maximizar o atendimento das solicitações de conexões feitas pelos usuários.

Algoritmos de roteamento baseados somente em parâmetros como, por exemplo, número de saltos entre origem e destino, ou taxa de transmissão de bits dos enlaces, não são a melhor alternativa para estabelecer caminhos ópticos. Neste trabalho, foram avaliados os desempenhos de algoritmos de RWA que são capazes de considerar propriedades e efeitos da camada óptica durante o processo de seleção de caminho, utilizando técnicas de otimização, como ACO (*Ant Colony Optimization*) e PSO (*Particle Swarm Optimization*), que reproduzem os padrões de inteligência emergente de colônias de formigas e enxames de partículas, respectivamente.

No estudo de caso efetuado durante este trabalho, os algoritmos inteligentes de RWA tiveram desempenhos aproximados ou superiores aos algoritmos oriundos da Computação Clássica. Além disso, ficou comprovado que a consideração de propriedades e efeitos da camada óptica resulta em ganho de desempenho no RWA com algoritmos inteligentes.

Abstract

Recently, the use of computer networks for study, work and business has grown exponentially. Thus, network services must have quality, so people can do their activities safely and properly. All-optical networks are scalable, fault-tolerant and capable of handling large data volumes and provide high-speed transmissions, besides having extensive physical reach, meeting the current requirements for networking services.

All-optical networks are capable of transmitting data through multiple communication channels in just one optical fiber, using separate wavelengths, with minimum interference between them. To guarantee quality in communications, lightpaths must be selected for the data transmission. Aiming that, RWA (Routing and Wavelength Assignment) algorithms are used for establish routes and allocate wavelengths inside the links, trying to minimize blocking calls rates, *i.e.*, maximizing attendance of users' connections requests.

Routing algorithms based only on network measures, such as hopcount or bandwidth, are not the best alternative for lightpaths establishment. This work presents a performance analysis of RWA algorithms that are able to consider properties and effects of optical layer during the routing process, using optimization techniques, such as ACO (Ant Colony Optimization) and PSO (Particle Swarm Optimization), which reproduces ant colonies and particle swarms collective intelligence patterns, respectively.

In the case study performed in this work, intelligent RWA algorithms performed equally or even better than classical algorithms. Moreover, it was shown that take into account optical layer properties and effects results in performance improvement in terms of blocking probability.

Índice de Figuras

Figura 2.1 Estrutura de um enlace óptico genérico.	11
Figura 3.1 Estrutura de troca de informações em um modelo global de enxame.....	28
Figura 3.2 Estrutura de troca de informações em um enxame com topologia em anel (modelo <i>Lbest</i> anel).....	29
Figura 4.1 Topologia da rede Regular. Os valores associados aos enlaces representam o comprimento físico em quilômetros.....	33
Figura 5.1 Curvas de convergência do PSO na fase de treinamento dos algoritmos de RWA baseados em ACO com a rede Regular. (a) 16 comprimentos de onda, 40 Erlangs e RWA por ACO Padrão. (b) 32 comprimentos de onda, 85 Erlangs e RWA por ACO Padrão. (c) 16 comprimentos de onda, 40 Erlangs e RWA por ACO Proposto. (d) 32 comprimentos de onda, 85 Erlangs e RWA por ACO Proposto.....	39
Figura 5.2 Gráfico comparativo dos desempenhos dos algoritmos de RWA na rede Regular com: (a) 16 comprimentos de onda; (b) 32 comprimentos de onda.....	41
Figura 5.3 Gráfico estatístico dos desempenhos dos algoritmos de RWA por ACO na rede Regular com 16 comprimentos de onda. (a) ACO Padrão; (b) ACO Proposto.....	42
Figura 5.4 Gráfico estatístico dos desempenhos dos algoritmos de RWA por ACO na rede Regular com 32 comprimentos de onda. (a) ACO Padrão; (b) ACO Proposto.....	43
Figura 5.5 Gráficos comparativos de probabilidades de bloqueio por indisponibilidade de comprimentos de onda nos enlaces da rede Regular com: (a) 16 comprimentos de onda; (b) 32 comprimentos de onda.....	43
Figura 5.6 Gráficos comparativos de probabilidades de bloqueio por OSNR insuficiente nos receptores dos enlaces da rede Regular com: (a) 16 comprimentos de onda; (b) 32 comprimentos de onda.	44

Índice de Tabelas

Tabela 1 Configuração do computador utilizado para executar as simulações de treinamento e teste de desempenho.	31
Tabela 2 Lista de parâmetros dos enlaces ópticos definidos como constantes nas simulações.....	32
Tabela 3 Parâmetros das simulações de treinamento por PSO dos algoritmos de RWA baseados em ACO.	36
Tabela 4 Parâmetros das simulações de teste de desempenho dos algoritmos de RWA baseados em ACO, treinados por PSO.....	37
Tabela 5 Valores de pesos das equações de indução obtidos nas simulações de treinamento dos algoritmos de RWA por ACO com a rede Regular.....	40

Lista de Acrônimos

ACO – <i>Ant Colony Optimization</i>	3
ANN – <i>Artificial Neural Networks</i>	14
ASE – <i>Amplified Spontaneous Emission</i>	12
DLE – <i>Dynamic Lightpath Establishment</i>	10
EDFA – <i>Erbium-Doped Fiber Amplifier</i>	8
GA – <i>Genetic Algorithms</i>	14
ICBR – <i>Impairment Constraint Based Routing</i>	10
IP – <i>Internet Protocol</i>	5
IRWA – <i>Impairment Aware Routing and Wavelength Assignment</i>	9
ISP – <i>Internet Service Provider</i>	2
JWR – <i>Joint Wavelength-Route</i>	11
LRW – <i>Least Resistance Weight</i>	37
MAS – <i>Multi-agent System</i>	15
OADM – <i>Optical Add-Drop Multiplexers</i>	8
OSNR – <i>Optical Signal to Noise Ratio</i>	12
OXC – <i>Optical Crossconnect</i>	8
PMD – <i>Polarization-Mode Dispersion</i>	33
PSO – <i>Particle Swarm Optimization</i>	3
QoS – <i>Quality of Service</i>	2
RAM – <i>Random Access Memory</i>	31
RWA – <i>Routing and Wavelength Assignment</i>	2
SATA II – <i>Serial Advanced Technology Attachment II</i>	31
SBRC 2009 – 27º Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos	47
SLE – <i>Static Lightpath Establishment</i>	10
SP – <i>Shortest Path</i>	5
WA – <i>Wavelength Assignment</i>	10
WDM – <i>Wavelength Division Multiplexing</i>	2
WXC – <i>Wavelength Crossconnect</i>	9

Sumário

1 INTRODUÇÃO	1
2 ROTEAMENTO EM REDES DE COMUNICAÇÕES	5
2.1 Classificação de Algoritmos de Roteamento	6
2.2 Roteamento em Redes Ópticas Transparentes	8
2.2.1 Redes Ópticas WDM	9
2.2.2 Roteamento e Alocação de Comprimentos de Onda	10
2.2.3 Efeitos e Propriedades da Camada Física de Redes Ópticas Transparentes	11
2.3 Roteamento Baseado em Otimização por Colônias de Formigas	14
2.3.1 Otimização por Colônias de Formigas	14
2.3.2 Algoritmo de Roteamento <i>AntNet</i>	15
2.3.2.1 Características e Parâmetros do <i>AntNet</i>	16
2.3.2.2 Criação de Agentes e Seleção de Caminhos com <i>AntNet</i>	17
2.4 Roteamento Baseado em ACO Aplicado a Redes Ópticas Transparentes	19
3 OTIMIZAÇÃO POR ENXAMES DE PARTÍCULAS	23
3.1 Modelo Computacional de Enxames	23
3.2 Algoritmo de Otimização por Enxames de Partículas	24
3.2.1 Coeficiente de Construção	27
3.3 Estruturas Sociais de Enxames	27
3.3.1 Modelo Global	28
3.3.2 Modelo Local	28
4 ANÁLISE DE DESEMPENHO DO ALGORITMO DE RWA BASEADO EM ACO 31	31
4.1 Rede Óptica Simulada	32
4.2 Função de Custo com Valor de Distância Normalizado	34
4.3 Treinamento do Algoritmo de RWA baseado em ACO Utilizando PSO	34
4.4 Teste de Desempenho dos Algoritmos de RWA por ACO treinados por PSO	36
5 RESULTADOS	38
5.1 Fase de Treinamento	38
5.2 Testes de Desempenho	40
6 CONCLUSÃO E TRABALHOS FUTUROS	46
BIBLIOGRAFIA	49

1 Introdução

Em 1972, uma organização sem fins lucrativos, chamada *Japan Computer Usage Development Institute*, apresentou ao governo japonês o “Plano para **Sociedade da Informação** – Uma meta nacional rumo ao ano 2000” (*The Plan for Information Society – A national goal toward the year 2000*). O objetivo do plano era promover a formação de uma sociedade onde o crescimento da criatividade intelectual humana estivesse à frente do consumo material, que representa o objetivo de uma sociedade industrial¹. O economista Fritz Machlup² foi um dos precursores do conceito de Sociedade da Informação, através do estudo onde ele relacionou o sistema de patentes ao crescimento da economia dos Estados Unidos. Machlup definiu em sua publicação o termo **Economia do Conhecimento**. Em uma Sociedade da Informação, criar, distribuir, utilizar, integrar e manipular informações são atividades econômicas, políticas e culturais significativas. Em uma Economia do Conhecimento, riquezas são produzidas a partir da exploração das informações. Com a globalização, esse modelo de sociedade foi adotado de forma integral ou parcial por grande parte dos países, e sua adoção continua em expansão.

Redes de computadores são ideais para o desenvolvimento de uma Sociedade da Informação, pois permitem aos seus usuários criar, distribuir e acessar novas informações de forma simples e rápida. Nos últimos 10 anos, a quantidade de computadores conectados à Internet cresceu mais de 18.000%, sendo atualmente cerca de 541,5 bilhões de dispositivos interconectados pela grande rede [1]. As pessoas utilizam os serviços de internet para lazer, estudo, trabalho, negócios, *etc.* Em todos os casos, as informações estão/são publicadas em dispositivos conectados a redes de computadores e dependem do funcionamento correto delas para que estejam sempre disponíveis e possam ser acessadas rapidamente. Com o aumento dessa dependência, surge a necessidade de garantir **qualidade de**

¹ Masuda, Yoneji. **The Information Society as Post-industrial Society**. Washington: World Future Society, 1981.

² Machlup, Fritz. **The Production and Distribution of Knowledge in The United States**. Princeton, Nova Jérsei: Princeton University Press, 1962.

serviço (QoS – *Quality of Service*) nas redes, ou seja, elas devem funcionar de forma que o usuário obtenha as informações sempre que precisar, de forma rápida e com garantia de integridade. Portanto, as redes de computadores devem ser escaláveis, tolerantes a falhas, capazes de suportar grandes volumes de dados, prover alta velocidade nas transmissões e ter alcance físico extenso.

Redes ópticas transparentes são capazes de atender a esses requisitos, pois possuem características que permitem aos provedores de serviços (ISP – *Internet Service Provider*) oferecerem alta velocidade de transmissão em conexões entre pontos separados por grandes distâncias³, mantendo os níveis de QoS desejados. Nesse tipo de rede, a transmissão dos dados é feita através de fibras ópticas. Uma forma de aumentar a taxa de transmissão de uma rede óptica seria adicionar novas fibras entre as localidades, no entanto, essa opção pode apresentar custo financeiro e complexidade que podem torná-la inviável. Com isso, surgiu a necessidade do desenvolvimento de técnicas que aumentassem a capacidade de transmissão das fibras. Uma dessas técnicas é denominada **Multiplexação por Divisão de Comprimentos de Onda** (WDM – *Wavelength Division Multiplexing*) [2]. A idéia central da tecnologia WDM é a transmissão simultânea de dados através de múltiplos canais de comunicação, utilizando comprimentos de onda distintos, sem que haja interferência entre eles.

Sendo uma rede óptica formada por um conjunto de caminhos possíveis entre os nós, com múltiplos canais de comunicação pelos quais os dados podem ser transmitidos, surgem dois problemas: (i) selecionar os enlaces que devem ser utilizados para transmitir dados entre um par origem e destino; (ii) selecionar comprimentos de onda disponíveis nos enlaces. A combinação desses dois problemas é chamado de **Roteamento e Alocação de Comprimento de Onda** (RWA – *Routing and Wavelength Assignment*) [3]. Algoritmos desenvolvidos para solucionar esse problema têm como objetivo a minimização da probabilidade de

³ Em fevereiro de 2008, a empresa Alcatel-Lucent [4] anunciou ter alcançado uma velocidade de transmissão de 16,4 Terabits por segundo (Tb/s) através de uma distância de 2550 km, utilizando 164 canais WDM.

bloqueio de chamadas nas redes, ou seja, maximizar o atendimento das solicitações de conexões feitas pelos usuários.

Algoritmos de roteamento que tomam por base somente elementos como, por exemplo, número de saltos entre origem e destino, ou taxa de transmissão de bits dos enlaces, não são a melhor alternativa para solucionar o problema de RWA. Carvalho [5] desenvolveu um algoritmo de roteamento e alocação de comprimentos de onda com o objetivo de utilizar a técnica de **Otimização por Colônias de Formigas** (ACO – *Ant Colony Optimization*) [6], [7] para considerar efeitos da camada física das redes ópticas. Esse algoritmo consiste em um processo estocástico onde agentes inteligentes selecionam os caminhos ópticos com base em uma **equação de indução**. Essa equação é baseada no processo de acúmulo de ferômonio utilizado por formigas para demarcar caminhos percorridos e em uma **função de custo** que inclui características da rede no processo de indução dos agentes. Em seu estudo, Carvalho [5] considerou os seguintes parâmetros na função de custo: (i) o valor normalizado referente à disponibilidade de comprimentos de onda nos enlaces; (ii) a distância física entre os nós de origem e destino. Cada um dos parâmetros da equação de indução possui um peso que define sua relevância no processo decisório. Carvalho [5] comparou duas abordagens de RWA por ACO, sendo que, uma inclui na função de custo somente (i) e a outra considera (i) e (ii).

O objetivo da pesquisa desenvolvida durante este trabalho foi avaliar os desempenhos das duas abordagens do algoritmo de RWA proposto por Carvalho [5], comparando-as a algoritmos que utilizam computação clássica. Na função de custo, o valor referente à distância física entre os nós de origem e destino foi normalizado, para que todos os parâmetros estivessem na mesma escala e, assim, as relevâncias dos parâmetros na equação de indução fossem balanceadas de forma mais precisa.

Para ponderar os parâmetros da equação de indução de forma a maximizar o desempenho do algoritmo, foram executadas simulações de treinamento dos agentes inteligentes, com a técnica de **Otimização por Enxames de Partículas** (PSO – *Particle Swarm Optimization*) [8]. Após a fase de treinamento, foram executadas simulações de RWA utilizando uma topologia de rede óptica, com

variações nos valores de carga e de quantidade de comprimentos de onda nos enlaces, onde os algoritmos baseados em ACO e treinados por PSO foram comparados com algoritmos que solucionam o problema de seleção de rotas e alocação de canais baseados em quantidade de saltos, menor caminho e balanceamento de carga.

No capítulo seguinte, serão apresentados os conceitos de roteamento em redes de computadores, redes ópticas WDM, a técnica de Otimização por Colônias de Formigas e sua aplicação no problema de roteamento e alocação de comprimentos de onda. No capítulo 3 serão abordadas as características da técnica de otimização por enxames de partículas. No capítulo 4 será descrita a metodologia utilizada nos experimentos e em seguida, no capítulo 5, os resultados obtidos. No capítulo 6 serão apresentadas as conclusões e listados possíveis trabalhos futuros.

2 Roteamento em Redes de Comunicações

O serviço de roteamento se faz necessário nas redes de comunicações devido à existência de várias rotas possíveis entre os nós. Isso implica na necessidade de tomada de decisão sobre qual dos caminhos deve ser utilizado para cada mensagem a ser encaminhada. Em redes de computadores, os dispositivos responsáveis por esse serviço são denominados roteadores ou comutadores e, em geral, executam roteamento de caminho mais curto (SP – *Shortest Path*) baseado em destino. Para executar tal função, o roteador precisa conhecer o destino da mensagem. A forma utilizada para identificar o destino de uma mensagem é dependente do tipo de rede. Em redes de comutação de pacotes por circuitos virtuais, o identificador de destino é o circuito virtual através do qual a mensagem é recebida. Tabelas de roteamento mantêm mapeamentos entre números de circuitos virtuais de entrada, números de circuitos virtuais de saída e as interfaces pelas quais os pacotes devem ser encaminhados. Em redes de datagramas, os destinos são identificados pelo endereço lógico do destinatário (por exemplo, endereço IP – *Internet Protocol*) extraído diretamente do pacote a ser encaminhado. As tabelas de roteamento mapeiam os endereços de destino com o endereço do próximo nó da rede para o qual a mensagem deve ser encaminhada e a interface de saída através da qual esse nó pode ser alcançado [9], [10], [11].

As tabelas de roteamento devem conter apenas os mapeamentos que permitam aos roteadores encaminhar as mensagens pelas rotas consideradas melhores. Surge daí a necessidade de um mecanismo de comparação entre as rotas possíveis. Cada caminho possível para um determinado destino conhecido pelo roteador terá associado a si um valor de custo. Este custo é calculado de acordo com um ou múltiplos parâmetros de desempenho da rede (métricas) e a melhor rota é aquela que apresenta o menor custo. A métrica utilizada no cálculo do custo é definida de acordo com a função objetivo que se deseja otimizar. O objetivo pode ser, por exemplo, minimizar a quantidade de nós pelos quais a mensagem passa até chegar ao destino. Nesse caso, o parâmetro utilizado é o número de saltos. O

melhor caminho pode também ser definido com base na taxa de transmissão, latência total entre origem e destino, sobrecarga no enlace, confiabilidade do enlace ou uma combinação desses parâmetros.

Para que seja possível ao roteador definir as melhores rotas, é necessário que ele obtenha informações sobre o estado da rede. Protocolos de roteamento permitem a obtenção dessas informações de forma dinâmica, sendo assim, responsáveis pela criação e manutenção das tabelas de roteamento. Com eles, os roteadores trocam entre si, constantemente, mensagens de controle contendo informações conhecidas sobre a rede. Após serem coletadas todas as informações, um algoritmo de roteamento entra em ação para efetuar o cálculo dos custos de cada rota, avaliando uma ou várias métricas. Em seguida, o algoritmo seleciona as melhores opções e as insere nas tabelas de roteamento. Nesse momento, é dito que a rede convergiu, ou seja, todos os roteadores possuem as informações corretas sobre o estado da rede e estão aptos a encaminhar mensagens através das melhores rotas. Caso ocorra alguma alteração de estado devido a mudanças ou falhas na rede, os algoritmos de roteamento serão executados novamente, após o roteador receber novas informações, para que novas rotas sejam selecionadas.

A qualidade de um algoritmo de roteamento é definida pela sua função objetivo, que por sua vez deve atender a um ou mais dos seguintes requisitos:

- a) adaptabilidade frente às possíveis mudanças de estado da rede,
 - congestionamentos em enlaces;
 - falhas em nós ou enlaces;
 - sobrecarga de tráfego entre pares origem e destino.
- b) capacidade de determinar a alcançabilidade dos destinos;
- c) gerar o mínimo possível de sobrecarga computacional nos roteadores e de tráfego nos enlaces;
- d) rapidez e precisão na busca pelas melhores rotas.

2.1 Classificação de Algoritmos de Roteamento

O roteamento pode ser classificado como **estático** ou **dinâmico**. O roteamento estático tem maior aplicabilidade em redes de baixa complexidade e que

não sofrem alterações freqüentes de topologia, pois as rotas são definidas com base na topologia inicial da rede e inseridas manualmente nas tabelas de roteamento, não havendo, portanto, adaptabilidade. Por outro lado, não é gerada sobrecarga de tráfego ou computacional, pois os roteadores não trocam mensagens de controle entre si, nem buscam novas rotas após a ocorrência de alterações no estado da rede. O roteamento dinâmico é mais adequado a cenários que apresentam alto nível de redundância de rotas, assim como mudanças freqüentes de estado. Nesse caso, é feito uso de um protocolo de roteamento para que os roteadores mantenham comunicação constante com seus pares adjacentes, tendo assim as informações sobre a rede sempre atualizadas. Dessa forma, o roteamento é feito de forma adaptativa, devido ao fato de os algoritmos serem capazes de selecionar, rapidamente, caminhos alternativos após alterações de estado. A desvantagem desse segundo tipo de roteamento é a sobrecarga gerada nos enlaces devido à troca de mensagens de controle, assim como nos roteadores, resultante da computação que se faz necessária após as alterações de estado da rede.

Algoritmos de roteamento dinâmico podem ser subclassificados de acordo com o modo pelo qual as rotas são computadas. As subclasses são: **centralizado** e **distribuído**. Na primeira, um único roteador é definido como controlador central da rede e se torna responsável pela seleção de todos os melhores caminhos e pela difusão dos resultados para os demais roteadores. No roteamento distribuído, os roteadores trabalham de forma cooperativa, sendo cada um responsável pela seleção das suas próprias rotas e por manter os vizinhos atualizados sobre as mudanças de estado da rede, através da troca de mensagens de controle. O envio dessas mensagens pode ser periódico e/ou acionado imediatamente após serem detectadas mudanças de estado da rede. Uma desvantagem do roteamento distribuído é a possibilidade de haver inconsistência nos resultados das computações individuais de rotas, o que pode gerar *loops* de roteamento, ou seja, um pacote ser encaminhado entre dois ou mais roteadores indefinidamente, não chegando ao destino desejado [10].

As características descritas anteriormente são encontradas em algoritmos de roteamento por caminho mais curto baseado em destino. É importante observar que existem outros tipos de algoritmos de roteamento (por exemplo, baseado em origem), mas o estudo deles não é necessário para o entendimento deste trabalho.

2.2 Roteamento em Redes Ópticas Transparentes

Redes ópticas são assim denominadas por transmitirem os dados através da propagação de ondas de luz. Elas podem ser divididas em duas gerações. Na primeira, a camada física, também chamada de **camada óptica**, serve exclusivamente como um meio de transmissão de dados com alto desempenho. Operações de comutação e gerência são feitas em dispositivos dotados de circuitos eletrônicos. Isso implica na necessidade de converter os sinais do domínio óptico para o domínio elétrico (conversão eletro-óptica), para que eles possam ser processados e as decisões de controle, sejam tomadas. Por esse motivo, os enlaces são opticamente isolados por dispositivos denominados *transponders*, responsáveis pelas conversões eletro-ópticas, e capazes de regenerar e reformatar os sinais, assim como efetuar o reajuste temporal dos pulsos. O uso dos *transponders* faz com que redes ópticas de primeira geração não sejam transparentes ao tipo de modulação dos sinais, à taxa de transmissão de bits e aos protocolos utilizados. Isso significa que alterações nessas características exigem a substituição dos *transponders*. Além disso, esses dispositivos não suportam enlaces que propagam sinais em múltiplos comprimentos de onda [13].

Redes de segunda geração, denominadas **redes totalmente ópticas**, permitem que a comunicação entre pares origem e destino seja feita sem conversões eletro-ópticas. Isso só se tornou possível devido à criação de dispositivos que permitiram o controle e a amplificação dos sinais em domínio óptico, e substituíram os *transponders*. Entre eles, podem ser citados: amplificadores ópticos EDFA (*Erbium-Doped Fiber Amplifier*), multiplexadores ópticos de inserção/remoção de comprimentos de onda (OADM – *Optical Add-Drop Multiplexers*) e comutadores ópticos (OXC – *Optical Crossconnect*). Essas redes são ditas **transparentes**, pois são capazes de transmitir sinais independentemente da taxa de transmissão de bits e do protocolo de encapsulamento utilizados, podendo ainda transmitir dados modulados em sinais analógicos [2].

Apesar de as redes totalmente ópticas oferecerem diversas vantagens em comparação às de primeira geração, a remoção dos *transponders* elimina o processo de regeneração dos sinais durante a propagação. Algumas das soluções para esse problema são: utilização de dispositivos que geram pouco ruído; adição

de regeneradores em alguns nós; desenvolvimento de algoritmos de roteamento capazes de considerar os efeitos da camada óptica na seleção das melhores rotas.

A utilização de algoritmos de roteamento que consideram as propriedades da camada física das redes ópticas no processo de seleção de caminhos (**IRWA – Impairment Aware Routing and Wavelength Assignment**) é o foco deste trabalho. Na seção seguinte, será apresentada uma arquitetura de rede óptica de segunda geração, e em seguida serão descritos alguns dos efeitos e propriedades da camada óptica que devem ser considerados no processo de roteamento e alocação de comprimentos de onda.

2.2.1 Redes Ópticas WDM

Em redes ópticas com arquitetura WDM, o roteamento e a comutação dos sinais são feitos baseados nos comprimentos de onda (λ) existentes nos enlaces. Em geral, a topologia desse tipo de rede consiste em uma malha composta por nós, denominados *Wavelength Crossconnect* (WXC), interconectados por enlaces de fibras ópticas. A comunicação entre pares de nós é feita através de caminhos ópticos (*lightpaths*), que são formados a partir da alocação de comprimentos de onda nos enlaces entre a origem e o destino [2].

Um caminho óptico pode ser formado pelo mesmo comprimento de onda em todos os enlaces entre um par de nós, ou por comprimentos de onda distintos. Nesse segundo caso, é necessário que a rede possua conversores de comprimento de onda, que são dispositivos capazes de receber sinais em um comprimento de onda e retransmiti-los em outro. Essa conversão pode reduzir a taxa de bloqueios de chamadas, mas tem custo relativo alto.

O roteamento em redes WDM é diferente do que é feito nas redes não ópticas, pois é necessário alocar comprimentos de onda nos enlaces que formam uma rota, para que os dados sejam transmitidos. Na seção seguinte será detalhado o processo de **Roteamento e Alocação de Comprimento de Onda** (RWA) [3], [12], que é feito nas redes WDM.

2.2.2 Roteamento e Alocação de Comprimentos de Onda

Em uma rede óptica WDM, o roteamento dos dados pode ser feito em conjunto com a alocação de comprimentos de onda (WA – *Wavelength Assignment*). Esse segundo processo deve obedecer às seguintes regras:

- a) dois caminhos ópticos podem compartilhar um mesmo enlace, porém, não podem ser associados ao mesmo comprimento de onda em um mesmo enlace;
- b) se conversões de comprimento de onda não forem permitidas, o caminho óptico deve ser associado ao mesmo comprimento de onda em todos os enlaces da rota.

Algoritmos de RWA têm como função objetivo selecionar o melhor caminho óptico entre um par origem e destino, e alocar um ou vários comprimentos de onda disponíveis nesse caminho. Em redes totalmente ópticas, os algoritmos devem ser capazes de considerar em suas decisões os efeitos e propriedades da camada física. Nesse caso, os algoritmos são conhecidos como **IRWA** ou **ICBR** (*Impairment Constraint Based Routing*) [13].

Um fator importante para o processo de RWA é a forma pela qual os usuários da rede óptica solicitam conexões. Três tipos de chamadas são possíveis: estática, incremental e dinâmica. Chamadas estáticas são feitas quando todos os pares origem e destino possíveis são previamente conhecidos. Assim, o objetivo do algoritmo de RWA é selecionar caminhos ópticos, minimizando o uso de recursos da rede como, por exemplo, a quantidade de comprimentos de onda. Para chamadas estáticas, o problema de WA é conhecido como **SLE** (*Static Lightpath Establishment*). No caso incremental, um caminho óptico é estabelecido quando uma nova chamada é feita e é mantido ativo indefinidamente. Já no caso dinâmico, os caminhos ópticos também são estabelecidos à medida que pedidos de conexões são feitos, entretanto, eles são mantidos ativos apenas por um período de tempo determinado. Para essas duas últimas abordagens, o problema de WA é conhecido como **DLE** (*Dynamic Lightpath Establishment*) [3]. No DLE, o objetivo do algoritmo de RWA é encontrar caminhos ópticos para cada solicitação de conexão, minimizando a probabilidade de bloqueio, ou seja, atendendo ao máximo possível de chamadas. O bloqueio de uma chamada ocorre quando os recursos da rede são

esgotados por chamadas anteriores, o que implica que a rede não é capaz, momentaneamente, de atender novas requisições.

O DLE é, geralmente, solucionado através de métodos heurísticos. Podem ser citados como exemplos desses métodos:

- a) **alocação aleatória**: são selecionados os comprimentos de onda inativos, em seguida, um deles é alocado aleatoriamente a partir de uma distribuição uniforme;
- b) **first-fit**: é criado um índice onde todos os comprimentos de onda são listados. O algoritmo aloca o primeiro comprimento de onda inativo da lista. Esse algoritmo é preferido na prática, pois apresenta bom desempenho, baixa complexidade e baixo custo computacional [3];

Essas técnicas são responsáveis apenas pela alocação de comprimentos de onda isoladamente. Algoritmos capazes de executar os processos de roteamento e alocação de comprimentos de onda em conjunto, denominados **JWR** (*Joint Wavelength-Route*), em geral, proporcionam melhor desempenho às redes [12].

2.2.3 Efeitos e Propriedades da Camada Física de Redes Ópticas Transparentes

Chaves [13] descreveu e implementou um simulador com a configuração de enlace óptico apresentada na Figura 2.1. Ela engloba uma série de elementos utilizados em redes ópticas transparentes reais. Com isso, é possível considerar nas simulações diversos efeitos e propriedades da camada óptica que interferem diretamente na QoS das redes. A estrutura do enlace é formada pelos seguintes dispositivos ópticos: transmissor (TX), comutador (*switch*), multiplexador (*mux*), amplificador de potência (*booster*), fibra, pré-amplificador, demultiplexador (*demux*) e receptor (RX).

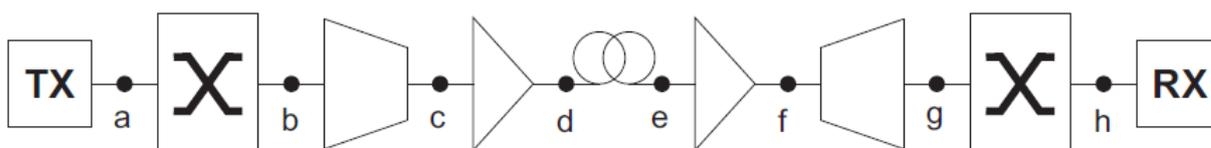


Figura 2.1 Estrutura de um enlace óptico genérico.

A avaliação da qualidade do sinal transmitido na rede é feita através da relação entre a potência do sinal óptico (P) e a potência do ruído óptico (N), que é

denominada OSNR (*Optical Signal to Noise Ratio*) [2]. O cálculo dessa relação é feito com

$$OSNR = 10 \log \left(\frac{P}{N} \right). \quad (2.1)$$

Um importante efeito que deve ser considerado em análises de desempenho de rede ópticas é a diafonia (*crosstalk*) nas saídas dos comutadores (pontos **b** e **h** da Figura 2.1). Esse tipo de ruído ocorre durante a transmissão dos sinais nos canais WDM, onde parte da potência do sinal transmitido em um canal é transferida para o canal adjacente [2]. Isso ocorre devido às características físicas que limitam o comutador. A potência do ruído produzido pela diafonia, $N_{sw}(\lambda)$, é modelada em cada canal de comunicação por

$$N_{sw}(\lambda) = \varepsilon \sum_{j=1}^M P_{sw_j}(\lambda), \quad (2.2)$$

onde $P_{sw_j}(\lambda)$ é a potência do sinal na j -ésima porta de entrada do comutador, com comprimento de onda λ , ε é o fator de isolamento no comutador e M é a quantidade de sinais recebidos nas portas de entrada com o mesmo comprimento de onda do sinal propagado.

O sinal óptico também sofre atenuações após passar pelo multiplexador e pelo demultiplexador (pontos **c** e **g** da Figura 2.1), assim como na fibra óptica (ponto **e** da Figura 2.1). Nesse último caso, a degradação do sinal pode ocorrer, por exemplo, por pequenas imperfeições no material da fibra ou pela presença de emendas.

Enlaces muito longos exigem o uso de amplificadores ópticos para compensar as perdas que o sinal sofre durante a propagação na fibra. Um tipo de amplificador bastante utilizado é o EDFA [13]. Apesar de serem dispositivos utilizados para aumentar a potência dos sinais, os amplificadores também geram os seguintes ruídos: ruído ASE (*Amplified Spontaneous Emission*), saturação de ganho e saturação de ruído ASE [13]. O ruído e a saturação de ganho gerados pelos amplificadores são medidos em suas saídas (pontos **d** e **f** da Figura 2.1).

A potência do sinal de saída do enlace (P_{out}) (ponto **h** da Figura 2.1) depende das perdas e ganhos adicionados ao sinal durante sua propagação, e é calculada por

$$P_{out} = \frac{G_{amp1} e^{-\alpha d} G_{amp2}}{L_{mux} L_{demux} L_{sw1} L_{sw2}} P_{in}, \quad (2.3)$$

onde G_{amp1} e G_{amp2} são os ganhos gerados pelos amplificadores, $e^{-\alpha d}$ é a perda por atenuação na fibra, L_{sw1} e L_{sw2} são as perdas nos comutadores e L_{mux} e L_{demux} são as perdas no multiplexador e no demultiplexador, respectivamente. P_{in} é a potência do sinal de entrada do enlace.

Além da potência do sinal, é possível calcular a potência de ruído na saída do enlace, N_{out} , que engloba os ruídos adicionados em cada ponto do enlace apresentado na Figura 2.1. Seu valor é obtido por

$$N_{out} = \frac{P_{out}}{P_{in}} N_{in} + \frac{G_{amp1} e^{-\alpha d} G_{amp2}}{L_{mux} L_{demux} L_{sw2}} N_{sw1}(\lambda) + \frac{G_{amp1} e^{-\alpha d} G_{amp2}}{L_{mux} L_{demux} L_{sw2}} \frac{h\nu(\lambda)B_o}{2} \left(F_{amp1} + \frac{F_{amp2}}{e^{-\alpha d} G_{amp1}} \right) + N_{sw2}(\lambda), \quad (2.4)$$

onde h é a constante de Planck¹ ($h = 6,626068 \times 10^{-34} Js$), $\nu(\lambda)$ é a frequência do sinal no canal WDM com comprimento de onda λ , B_o é a faixa de frequência de operação do filtro óptico, e F_{amp1} e F_{amp2} são os fatores de ruído dinâmico dos amplificadores.

Com P_{out} e N_{out} calculados, é possível definir a OSNR na saída do enlace ($OSNR_{out}$). O nível aceitável de QoS da rede pode ser estabelecido pelo limiar da $OSNR_{out}$, denominado $OSNR_{QoS}$.

A carga (L_{net}) é a medida estatística de utilização da rede, dada por

$$L_{net} = \mu H, \quad (2.5)$$

¹ Constante de proporcionalidade entre a energia (E) de um fóton e sua frequência (ν).

onde μ é a frequência de chamadas na rede, e H é o tempo médio de duração das chamadas. A carga tem valor adimensional, no entanto, foi adotada a unidade de medida denominada Erlang, que também é utilizada na medição de intensidade de tráfego em sistemas de telefonia.

Apesar de existirem diversos outros parâmetros que definem a camada física das redes ópticas, eles não foram considerados no escopo deste trabalho.

2.3 Roteamento Baseado em Otimização por Colônias de Formigas

Pesquisadores vêm aplicando técnicas de inteligência computacional no processo de roteamento em redes de computadores, para que seja possível considerar diversas características da rede como, por exemplo, ruídos, ocupação e alterações de topologia, de forma mais eficiente que os algoritmos utilizados atualmente e, assim, os níveis de QoS desejados possam ser garantidos. Entre essas técnicas, podem ser citadas: Redes Neurais Artificiais (ANN – *Artificial Neural Networks*) [15], [16], Algoritmos Genéticos (GA – *Genetic Algorithms*) [17], Otimização por Colônias de Formigas (ACO – *Ant Colony Optimization*) [4], [18], [19], [20], [21], [22], Otimização por Enxames de Partículas (PSO – *Particle Swarm Optimization*) [23] e algoritmos híbridos que combinam técnicas distintas [24], [25].

Nesta seção, serão apresentados os conceitos de ACO e sua aplicação em redes ópticas transparentes.

2.3.1 Otimização por Colônias de Formigas

As formigas, assim como outros insetos, apresentam uma forma particular de comunicação indireta, denominada estigmergia [26], que é feita através da liberação de uma substância química chamada feromônio [27], [28]. O feromônio induz mudanças ambientais que outras formigas podem perceber e, assim, as atividades de cada indivíduo de uma colônia são coordenadas. A partir da exploração desse método de coordenação, pesquisadores puderam desenvolver algoritmos para solucionar problemas de otimização e controle distribuído como, por exemplo, roteamento em redes de comunicação [18], otimização discreta [29], problema do caixeiro viajante [30], balanceamento de carga em redes [31], *etc.* Para solucionar

problemas complexos, técnicas de Otimização por Colônias de Formigas (ACO) podem ser criadas com base na inteligência emergente gerada pelo comportamento das colônias [6]. Essas técnicas podem ser classificadas como sistemas multiagentes (MAS – *Multi-agent System*), e suas principais características são: (i) o uso de simulações repetitivas e concorrentes executadas por uma população de agentes artificiais, chamados de formigas², para gerar novas possíveis soluções para um problema; (ii) o uso de buscas estocásticas locais por parte dos agentes para construir soluções de forma incremental; (iii) o uso de informações coletadas em simulações passadas para direcionar buscas futuras para melhores soluções.

Em colônias artificiais, seguindo um processo iterativo, cada formiga constrói uma solução utilizando informações específicas do problema e informações adicionadas por outras formigas durante iterações passadas do algoritmo. Durante a construção da solução, cada formiga coleta informações sobre as características do problema e sobre seu próprio desempenho e as utiliza para modificar a representação do problema, que é vista localmente por outras formigas. Essa representação é modificada de forma que as informações contidas em boas soluções construídas no passado, são exploradas para se construir melhores soluções no futuro. De tal forma, as atividades dos agentes são coordenadas através de comunicação indireta intermediada pelo ambiente.

2.3.2 Algoritmo de Roteamento AntNet

O desenvolvimento do algoritmo de roteamento *AntNet* [18] foi inspirado em estudos das técnicas de ACO. Nele, as idéias centrais do paradigma de colônias de formigas artificiais foram aplicadas para solucionar de forma dinâmica o problema de roteamento em redes de computadores. Abaixo estão sumarizadas as principais características do algoritmo:

- a) em intervalos regulares e em concorrência com o tráfego de dados, a partir de cada nó da rede, agentes móveis são encaminhados em direção a nós

² A partir deste ponto, os termos “agente” e “formiga” serão utilizados no texto com o mesmo significado.

de destino selecionados aleatoriamente. Esses agentes são denominados formigas de encaminhamento (*forward ants*);

- b) os agentes atuam concorrentemente e individualmente e comunicam-se de forma indireta, através das informações que são lidas e escritas localmente nas tabelas de roteamento dos nós;
- c) cada agente busca um caminho de menor custo entre seus nós de origem e destino. Esse caminho deve ser encontrado durante o tempo de vida do agente, caso contrário, ele é destruído;
- d) cada agente se move iterativamente em direção a um nó de destino pré-determinado. Em cada nó intermediário, uma política estocástica é aplicada na escolha do próximo nó para o qual o agente irá se mover. A política faz uso de (i) informações locais geradas e mantidas por agentes, (ii) informações heurísticas dependentes do problema e (iii) informações privadas dos agentes;
- e) durante a movimentação, os agentes coletam informações sobre o tempo de viagem, as condições de congestionamento e os identificadores dos nós no caminho percorrido;
- f) ao alcançar seu destino, o agente gera uma formiga de retorno (*backward ant*), transfere sua memória para ela e, em seguida, é destruído. O novo agente retorna ao nó de origem, pelo mesmo caminho percorrido pela *forward ant*, porém na direção contrária;
- g) durante a viagem de retorno, os modelos de estado da rede e as tabelas de roteamento locais de cada nó visitado são modificadas pelos agentes em função do caminho percorrido, dependendo da qualidade do mesmo;
- h) ao alcançar o nó de origem, o agente *backward ant* é destruído.

2.3.2.1 Características e Parâmetros do AntNet

A estigmergia entre os agentes é estabelecida através das informações que são lidas e escritas em duas estruturas de dados que são armazenadas em cada nó k da rede. Essas estruturas são definidas da seguinte maneira:

- a) uma tabela de roteamento (T_k) é organizada de forma semelhante às tabelas dos algoritmos de vetor de distância como, por exemplo, o Bellman-Ford [32], [33]. No entanto, os valores armazenados são estabelecidos e

modificados através de um processo semelhante ao acúmulo de feromônio que formigas reais fazem para demarcar caminhos. Esses valores são usados como probabilidades no processo de seleção de caminhos. T_k define a política de roteamento probabilístico adotada pelo nó k , onde para cada destino d possível e cada nó n vizinho, é armazenado um valor P_{nd} que consiste na probabilidade de um nó n ser escolhido como próximo salto quando o destino for d ;

- b) um *array* $M_k(\mu_d, \sigma_d^2, W_d)$ define um modelo paramétrico estatístico simples para a distribuição de tráfego que é vista a partir do nó k . Esse modelo é adaptativo e descrito por amostragens estatísticas, como média (μ_d) e variância (σ_d^2), computadas a partir do tempo que um agente leva para trafegar até seu destino (*trip time*) em uma janela de observação móvel W_d , que é utilizada para armazenar o melhor valor entre as amostras de tempo de viagem dos agentes.

T e M são definidos como memórias locais dos nós e seus dados representam diferentes aspectos da dinâmica da rede. O modelo M mantém as estimativas de tempo para cada nó, enquanto as tabelas de roteamento armazenam medidas probabilísticas para cada par enlace-destino com base na política de roteamento global da rede.

2.3.2.2 Criação de Agentes e Seleção de Caminhos com AntNet

Em intervalos de tempo regulares, a partir de cada nó o , agentes móveis $F_{o \rightarrow d}$ (*forward ant*) são encaminhados em direção ao nó de destino d para descobrir um caminho viável de baixo custo e investigar as condições de carga da rede. Esses agentes são alocados nas mesmas filas de encaminhamento que os dados. Por não haver priorização, os agentes enfrentam a mesma carga que o tráfego de dados da rede. Os destinos são selecionados de forma probabilística de acordo com o padrão de tráfego local em cada nó da rede, definido da seguinte forma: sendo f_{od} uma medida (em bits ou número de pacotes) do fluxo de dados entre o e d , a probabilidade de uma *forward ant* com destino d ser criada no nó o é definida por

$$P_d = \frac{f_{od}}{\sum_{d'=1}^N f_{od'}}, \quad (2.6)$$

onde d' pertence ao conjunto de nós vizinhos de o , diferentes de d . Assim, a exploração da rede é adaptada com as variações de distribuição de tráfego de dados.

Durante a viagem ao destino, os agentes armazenam as informações sobre o caminho percorrido e as condições de tráfego. O identificador de cada nó k visitado e o tempo passado do momento de encaminhamento do agente na origem o até a chegada ao k -ésimo nó são armazenados na pilha $S_{o \rightarrow d}(k)$.

A seleção do nó n de próximo salto é feita de acordo com um valor de probabilidade, P'_{nd} , que consiste na soma normalizada da entrada P_{nd} da tabela de roteamento com um fator de correção heurística l_n . Esse cálculo é feito através de

$$P'_{nd} = \frac{P_{nd} + \alpha l_n}{1 + \alpha(|N_k| - 1)}, \quad (2.7)$$

onde N_k é o conjunto de nós vizinhos de k , e α define o peso que l_n tem em relação a P_{nd} . Caro e Dorigo [18] concluíram em seus experimentos que o valor ideal de α varia de acordo com as características do problema ao qual o algoritmo é aplicado, porém, recomendam o uso de valores entre 0,2 e 0,5. O valor de l_n é definido entre 0 e 1 e é proporcional ao comprimento (em bits aguardando por envio) da fila de encaminhamento (q_n) do enlace entre os nós k e n . O cálculo de l_n é feito através de

$$l_n = 1 - \frac{q_n}{\sum_{n'=1}^{|N_k|} q_{n'}}. \quad (2.8)$$

A seleção de próximo salto é feita entre os nós não visitados anteriormente, ou todos os nós, caso não haja mais nenhum não-visitado. Caso ocorra *loop*, ou seja, o agente precise retornar a um nó já visitado, o nó no qual a formiga se encontra é removido da sua pilha e todas as informações sobre ele são descartadas. Caso o *loop* dure mais tempo que a meia-vida do agente, ele é destruído.

Ao alcançar o destino d , o algoritmo efetua os passos descritos na seção 2.3.2, alíneas f , g e h . Para percorrer o caminho de retorno correto, o agente *backward ant* ($B_{d \rightarrow o}$) remove o nó do topo da sua pilha para saber qual o próximo salto e repete esse processo ao chegar a cada nó intermediário k . Esses agentes são alocados em filas com prioridade maior que as filas de encaminhamento de

dados, para que, assim, possam propagar rapidamente as informações coletadas por $F_{o \rightarrow d}$ (*forward ant*).

Ao chegar a um nó intermediário k , o agente $B_{d \rightarrow o}$ atualiza todas as entradas correspondentes ao nó de destino d no modelo local de tráfego M_k e na tabela de roteamento T_k . É possível que sejam feitas, também, atualizações nas entradas referentes a todo nó k' intermediário entre k e d ($k' \in S_{k \rightarrow d}, k' \neq d$), desde que o tempo de viagem de k até k' seja considerado curto em relação às taxas de transmissão usadas na rede de comunicação.

O agente de retorno que chega a um nó n através de um nó d reforça a probabilidade P_{nd} na tabela de roteamento T_k . Esse reforço é feito baseado no tempo de viagem total da formiga e nas medidas estatísticas armazenadas em M_k . As demais probabilidades $P_{nd'}$ sofrem reforço negativo, através de um processo de normalização dos valores, que é feito após atualizações em P_{nd} . Este processo de atualizações é semelhante ao acúmulo de feromônio que formigas reais fazem para demarcar caminhos percorridos, pois um enlace para o qual a probabilidade é reforçada com mais frequência será preferido pelas próximas *forward ants*.

2.4 Roteamento Baseado em ACO Aplicado a Redes Ópticas Transparentes

Carvalho [4] apresentou em sua dissertação de mestrado uma nova abordagem de roteamento e alocação de canais de comunicação em redes ópticas que utiliza a técnica de ACO para considerar efeitos da camada física no processo de seleção de caminhos. O algoritmo proposto gera, com frequência f_c , grupos contendo n formigas responsáveis pela busca dos melhores caminhos para pares origem e destino. Os parâmetros do algoritmo são definidos da seguinte forma:

- a) T_{busca} : tempo de vida das formigas. Quantidade máxima de iterações em que as formigas podem se movimentar na rede buscando o melhor caminho para um par origem e destino. O tempo deve ser suficiente para que uma formiga possa chegar ao nó de destino, portanto, o valor mínimo para esse parâmetro pode ter valor igual ao número de nós da rede. Valores muito maiores que o tamanho da rede não são recomendados,

pois, com isso, formigas que entram em *loop* demoram a ser descartadas e podem atrapalhar o processo de busca;

- b) T_c : intervalo de tempo entre as criações de grupos de formigas;
- c) f_c : frequência de criação dos grupos de formigas;
- d) n : quantidade de formigas por grupo. O valor desse parâmetro deve ser adequado ao tamanho da rede [4];
- e) Q : constante que define a quantidade de feromônio depositada por *backward ants* nos enlaces. Em geral, esse parâmetro assume valores entre 1 e 100 [7].

Para evitar estados de estagnação³, as formigas analisam outros fatores além da quantidade de feromônio detectada nos enlaces durante o processo de seleção de melhor caminho. Esses fatores adicionais são definidos por uma função de custo [22]. Assim, a equação de indução utilizada por uma formiga k para decidir se deverá escolher o enlace entre dois nós i e j é

$$P_{ij}^k = rand(Ph_{ij})^\alpha (n_{ij})^\beta, \forall j \in N_i^k, \quad (2.9)$$

onde N_i^k é o conjunto de nós que a formiga k visualiza a partir do nó i , Ph_{ij} é a concentração de feromônio para o enlace entre i e j , e $rand$ é um número aleatório gerado por uma distribuição uniforme com valor entre 0 e 1, utilizado para adicionar um fator de aleatoriedade ao processo estocástico de seleção de caminho [4].

A função de custo n_{ij} é denominada **visibilidade** e pode ser definida por características do enlace como, por exemplo, distância física entre nós, latência e taxa de transmissão [22], assim como em algoritmos de estado de enlace [9].

Os parâmetros α e β definem a relevância que a concentração de feromônio e a função de custo têm nas decisões das formigas. Esses parâmetros influenciam diretamente na qualidade dos resultados obtidos pelo algoritmo e têm valores definidos entre 0 e 5 ($\alpha \in [0,5]$, $\beta \in [0,5]$) [7].

³ Condição em que todas as novas formigas escolhem apenas um caminho ótimo selecionado no passado. Implica na perda da capacidade de detectar novos e melhores caminhos, ou seja, gera convergência prematura.

Outro fator adicionado ao algoritmo para evitar estados de estagnação é a evaporação do feromônio. Esse fator reduz, a cada iteração do algoritmo, a quantidade de feromônio acumulada pelas formigas durante experiências passadas. Isso permite que a colônia selecione novos caminhos em casos de falhas ou alterações na rede, pois o acúmulo de feromônio para um enlace que deixa de fazer parte de um melhor caminho é reduzido gradativamente. O **Fator de Evaporação** é definido por

$$\epsilon = (1 - \rho), \quad (2.10)$$

onde a constante ρ é a **Taxa de Evaporação** e possui valor entre 0 e 1.

Carvalho [4] analisou duas abordagens de RWA baseado em ACO, tendo em uma das abordagens a função de custo definida como

$$n_{ij} = \frac{1}{d_{ij}}, \forall j \in N_i^k, \quad (2.11)$$

onde d_{ij} é o comprimento físico do enlace entre os nós i e j . Assim, (2.9) assume a forma

$$P_{ij}^k = \text{rand} \left[\frac{(Ph_{ij})^\alpha}{(d_{ij})^\beta} \right], \forall j \in N_i^k. \quad (2.12)$$

Na segunda abordagem, o autor propôs a inclusão da disponibilidade de comprimentos de onda na função de custo, que passou a ser definida por

$$n_{ij} = \frac{\Delta\lambda_{ij}}{d_{ij}}, \forall j \in N_i^k, \quad (2.13)$$

sendo $\Delta\lambda_{ij}$ o valor normalizado referente à quantidade de comprimentos de onda disponíveis no enlace óptico, calculado a partir de

$$\Delta\lambda_{ij} = \frac{\lambda_{ij}^T - \lambda_{ij}^U}{\lambda_{ij}^T}, \quad (2.14)$$

em que λ_{ij}^T e λ_{ij}^U são as quantidades de comprimentos de onda total e indisponíveis, respectivamente, no enlace entre i e j . Com isto, (2.9) assume a forma

$$P_{ij}^k = rand \left[\frac{(Ph_{ij})^\alpha (\Delta\lambda_{ij})^\gamma}{(d_{ij})^\beta} \right], \forall j \in N_i^k, \quad (2.15)$$

onde γ é a relevância de $\Delta\lambda_{ij}$ na seleção de caminhos e, assim como α e β , tem valor definido entre 0 e 5.

Nas duas abordagens propostas, a alocação de comprimentos de onda para os caminhos ópticos selecionados é feita através da heurística de *first-fit*.

3 Otimização por Enxames de Partículas

Como visto no capítulo anterior, o algoritmo de RWA baseado em ACO possui parâmetros cujos valores precisam ser definidos previamente. Essas definições podem ser dependentes do cenário ao qual o algoritmo está sendo aplicado e influenciam diretamente no desempenho dele. Escolher os valores ideais manualmente exige muito esforço, além de ser uma abordagem suscetível a erros. Sendo assim, esse é um problema onde técnicas de busca que utilizam computação inteligente podem ser aplicadas para tornar a seleção dos valores dos parâmetros um trabalho mais preciso e menos dispendioso.

Técnicas inspiradas no comportamento social de grupos, entre elas a Otimização por Enxames de Partículas (PSO), vêm sendo aplicadas para solucionar diversos tipos de problemas da computação [23], [34], [35]. Neste capítulo, as principais características da técnica de PSO serão apresentadas.

3.1 Modelo Computacional de Enxames

O algoritmo de PSO foi desenvolvido por Kennedy e Eberhart [8], durante uma pesquisa em que o objetivo inicial era simular o comportamento imprevisível de um bando de pássaros, através de agentes inteligentes. Trata-se de um algoritmo que se baseia no comportamento de enxames para encontrar regiões ótimas em espaços de busca complexos. Essa técnica apresenta como raízes duas metodologias: Computação Evolucionária; e vida artificial, em particular, a Teoria dos Enxames. Millonas [36] listou categorias de comportamento que podem ser classificadas como inteligência coletiva. Os princípios básicos da inteligência de enxames são:

- a) **princípio da proximidade:** o grupo deve ser capaz de efetuar computações elementares no espaço e no tempo;
- b) **princípio da qualidade:** o grupo deve ser capaz de considerar não só o espaço e o tempo, mas também fatores de qualidade do ambiente;

- c) **princípio da diversidade de respostas:** o grupo não deve alocar todos os seus recursos fazendo explorações com escopo muito pequeno;
- d) **princípio da estabilidade:** o grupo não deve mudar seu comportamento para cada alteração observada no ambiente, pois mudanças consomem energia e nem sempre produzem um retorno que indica a melhor resposta;
- e) **princípio da adaptabilidade:** o grupo deve estar apto a ter seu comportamento influenciado, quando o retorno parecer ser válido.

O paradigma de Otimização por Enxames de Partículas adere a esses princípios, através das seguintes características:

- f) as partículas se movimentam, iterativamente, através de espaços hiperdimensionais em busca da melhor solução;
- g) os movimentos das partículas são baseados na qualidade das respostas de cada indivíduo e de todo o enxame. A consideração dos desempenhos individuais e globais garante a diversidade de respostas;
- h) só há mudança de comportamento do enxame quando a melhor resposta global é alterada, o que garante a estabilidade;
- i) o comportamento do enxame é adaptável, pois muda quando uma nova melhor resposta global é encontrada.

3.2 Algoritmo de Otimização por Enxames de Partículas

A Otimização por Enxames de Partículas é semelhante aos Algoritmos Genéticos [37], pois o sistema é inicializado com um conjunto de soluções aleatórias. No entanto, essa técnica se diferencia dos GA, pois cada potencial solução é associada a uma partícula que possui uma velocidade, definida de forma aleatória, e se move em um espaço hiperdimensional em busca do melhor resultado possível [38], [39].

Cada partícula mantém registradas as coordenadas do hiperespaço que definem a melhor solução (*fitness*¹) que ela já encontrou. Esse resultado é denominado como ***pbest***. Além do melhor resultado individual, o algoritmo também mantém o registro do melhor resultado global, ou seja, o melhor *fitness* de todo o enxame, que é denominado ***gbest***.

Uma partícula i é composta por três vetores:

- a) posição no espaço de busca D -dimensional: $\vec{x}_i = (x_{i1}, x_{i2}, \dots, x_{iD}), \forall x_{id} \in \{\min(x_d), \max(x_d)\} | d \in \{1, 2, \dots, D\}$;
- b) melhor posição já encontrada (*pbest*): $\vec{p}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$;
- c) velocidade: $\vec{v}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$.

O espaço de busca consiste no conjunto de intervalos de busca de cada dimensão que o problema possui. Esses intervalos são limitados em cada dimensão por $\min(x_d)$ e $\max(x_d)$.

O tamanho de um enxame (quantidade de partículas) pode influenciar no desempenho do algoritmo, dependendo do problema que está sendo otimizado. Bratton e Kennedy [38] efetuaram um estudo onde foram definidos padrões para PSO. Aplicando PSO para otimizar diversos problemas, eles puderam observar que nenhum enxame com tamanho entre 20 e 100 apresentou desempenho claramente inferior ou superior a qualquer outro.

A cada iteração do algoritmo, as velocidades e as posições das partículas são atualizadas em todas as dimensões. A atualização das velocidades das partículas no algoritmo de PSO é feita através de

$$\vec{v}_i(t+1) = \vec{v}_i(t) + c_1 \text{rand}_1 [\vec{p}_i(t) - \vec{x}_i(t)] + c_2 \text{rand}_2 [\vec{p}_g(t) - \vec{x}_i(t)], \quad (3.1)$$

onde t é o instante atual de tempo discreto. Os vetores $\vec{p}_i(t)$ e $\vec{p}_g(t)$ são as coordenadas de *pbest* e *gbest*, respectivamente.

Como pode ser visto em (3.1), as partículas utilizam na atualização de velocidade uma combinação da atração para a melhor solução encontrada

¹ O conceito de *fitness* é utilizado por paradigmas da Computação Evolucionária. Trata-se da valoração da função objetivo que quantifica a qualidade de uma solução encontrada.

individualmente e a atração para a melhor solução encontrada por qualquer partícula da vizinhança². O termo $c_1 rand_1 [\vec{p}_i(t) - \vec{x}_i(t)]$ define a distância entre a posição atual da partícula e o seu *pbest*. Esse termo é denominado **Componente Cognitivo** e representa a experiência individual da partícula. O termo $c_2 rand_2 [\vec{p}_g(t) - \vec{x}_i(t)]$ define a distância entre a posição atual da partícula e o *gbest* e é chamado de **Componente Social**, pois representa a influência da experiência de toda a vizinhança no comportamento da partícula *i* [40].

c_1 e c_2 são **Constantes de Aceleração**. Elas têm valores positivos e são utilizadas para balancear a relevância dos componentes cognitivo e social. Caso c_1 tenha um valor maior que c_2 , as partículas tenderão a efetuar buscas em profundidade, caso contrário, a tendência será para buscas em amplitude. Nas buscas em profundidade, as partículas tendem a explorar um espaço de busca limitado, pois o *pbest* gera maior atração que o *gbest*. Sendo assim, buscas em profundidade também podem ser denominadas por buscas locais, enquanto as buscas em amplitude podem ser chamadas de buscas globais.

$rand_1$ e $rand_2$ são valores aleatórios entre 0 e 1, gerados a cada iteração a partir de uma distribuição uniforme. Com eles, é adicionado um fator de aleatoriedade ao processo de atualização de velocidade das partículas do enxame, o que é importante, pois ajuda a evitar convergências prematuras do algoritmo.

A atualização da posição de uma partícula é obtida através de

$$\vec{x}_i(t+1) = \vec{x}_i(t) + \vec{v}_i(t+1). \quad (3.2)$$

A velocidade da partícula é limitada por um valor v_{max} em cada dimensão. Sem esse limite, o sistema de otimização poderia entrar em um estado de explosão (*overflight*), onde os valores de velocidade e posição das partículas tenderiam para infinito.

² Conjunto de partículas capazes de se intercomunicar. Pode ser formada por todas as partículas do enxame ou por grupos menores, a depender do tipo de topologia utilizado (ver seção 3.3)

Com o objetivo de melhorar o desempenho e a eficiência do algoritmo de PSO, pesquisadores propuseram alterações na forma como é feita a atualização de velocidade das partículas [41], [42]. Na seção seguinte, será apresentada uma abordagem de PSO onde o elemento denominado **Coefficiente de Constrição** foi adicionado a (3.1).

3.2.1 Coeficiente de Constrição

A adição do Coeficiente de Constrição (χ) à equação de atualização de velocidade das partículas foi proposta por Clerc e Kennedy [41] para evitar *overflight*, realizar balanceamento entre buscas em amplitude e profundidade, melhorar o tempo de convergência e aumentar a qualidade das soluções obtidas. Nessa abordagem, (3.1) foi modificada para

$$\vec{v}_i(t+1) = \chi \{ \vec{v}_i(t) + c_1 \text{rand}_1 [\vec{p}_i(t) - \vec{x}_i(t)] + c_2 \text{rand}_2 [\vec{p}_g(t) - \vec{x}_i(t)] \}, \quad (3.3)$$

sendo χ definido por

$$\chi = \frac{2k}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|}, \quad (3.4)$$

onde $\varphi = c_1 + c_2$ e k é um parâmetro utilizado para controlar a relação entre busca em amplitude e em profundidade. Se $k \approx 1$, o enxame tenderá a efetuar buscas em amplitude, conseqüentemente a convergência será mais lenta. Para que o enxame efetue buscas em profundidade e atinja a convergência mais rapidamente, k deve ser definido com valores positivos e baixos ($k < 1$). Utilizando essa abordagem, o algoritmo de PSO opera sem *overflight* se $\varphi \geq 4$ e $k \in [0,1]$.

Apesar de existir outra abordagem para a equação de atualização de velocidade das partículas, denominada Fator de Inércia [42], que, assim como o Coeficiente de Constrição, torna o algoritmo de PSO mais eficiente, a descrição dela não é necessária para o entendimento deste trabalho.

3.3 Estruturas Sociais de Enxames

Como visto na seção anterior, partículas utilizam informações de desempenho das outras integrantes do enxame para ajustar sua velocidade e,

conseqüentemente, sua posição. Para que essas informações sejam distribuídas, o enxame possui um mecanismo de comunicação que funciona de acordo com o tipo de vizinhança implementado e que influencia diretamente na qualidade dos resultados obtidos pelo algoritmo, assim como na velocidade de convergência [43]. A vizinhança pode ser formada por toda a população do enxame ou por grupos de partículas conectadas através de diferentes topologias. Nesta seção, serão descritos os mecanismos de comunicação dos dois principais modelos de enxames.

3.3.1 Modelo Global

O modelo **Global** de enxame, também chamado de modelo **Gbest** ou **topologia global**, consiste na proposição original do algoritmo de PSO [8]. Nesse tipo de vizinhança, as partículas integrantes do enxame obtêm informações sobre o desempenho global através de uma estrutura totalmente conectada como a apresentada na Figura 3.1. Portanto, o tamanho da vizinhança é igual ao número de partículas que formam o enxame. Com isso, as partículas são atraídas pela melhor solução encontrada pela população do enxame. A principal vantagem desse modelo é a velocidade de convergência do algoritmo, entretanto, essa característica pode torná-lo suscetível a convergir para mínimos locais.

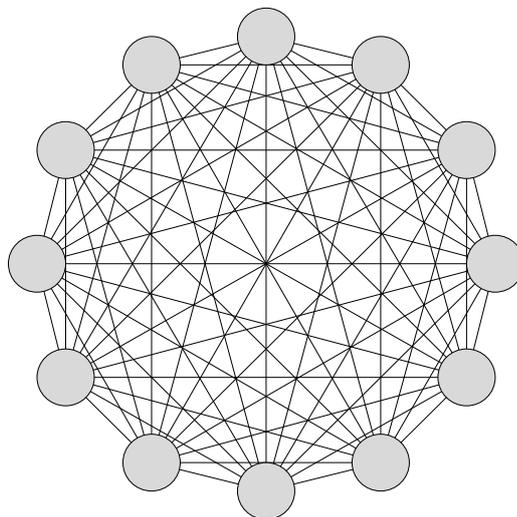


Figura 3.1 Estrutura de troca de informações em um modelo Global de enxame.

3.3.2 Modelo Local

O modelo **Local** de enxame, também chamado de modelo **Lbest** ou **topologia local**, foi proposto por Eberhart e Kennedy [39] como um novo paradigma

de implementação da técnica de PSO. O termo topologia local é utilizado na literatura não somente para descrever um único modelo de enxame, mas sim para qualquer modelo que não utilize comunicação global. Um deles é o modelo **Anel**, no qual cada partícula se comunica com apenas duas outras partículas do enxame, como na estrutura apresentada na Figura 3.2.

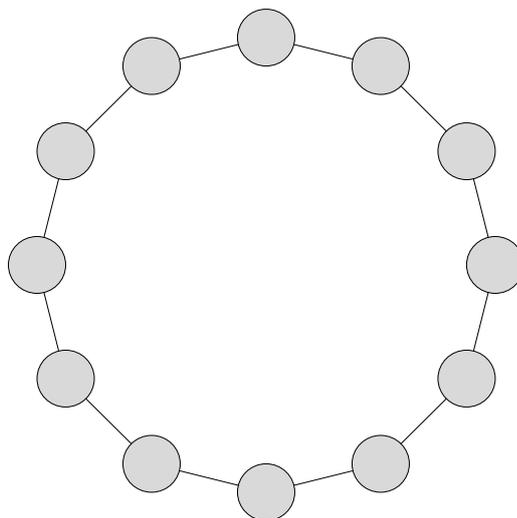


Figura 3.2 Estrutura de troca de informações em um enxame com topologia em anel (modelo *Lbest* Anel).

Em enxames com topologia local, as partículas obtêm informações somente sobre o desempenho dos seus vizinhos. Portanto, as partículas são atraídas pela melhor solução encontrada na vizinhança, que nesse caso é formada por um número de partículas menor que o enxame. É importante destacar que as conexões entre partículas não são estabelecidas de acordo com seus parâmetros espaciais. Quando criada, cada partícula recebe um índice e estabelece vizinhança com as que possuem valores de índice mais próximos, independente da distância entre elas no hiperespaço.

Implementações de PSO utilizando o modelo local de enxame, em geral, apresentam convergência mais lenta que as que utilizam o modelo global. No entanto, essa característica nem sempre representa uma desvantagem, pois o *Lbest* geralmente produz resultados de melhor qualidade que os do *Gbest*, quando aplicado a alguns tipos de problemas, em particular os multimodais [38].

Além dos modelos descritos nesta seção, existem diversas outras abordagens de modificação na estrutura de comunicação das partículas que integram os enxames como, por exemplo, topologias formadas por grupos de partículas [44],

onde cada grupo tem tamanho menor que o do exame, ou modelos inspirados na hierarquia existente em clãs de indivíduos [45]. Entretanto, esses modelos não serão descritos, pois não fazem parte do escopo deste trabalho.

4 Análise de Desempenho do Algoritmo de RWA baseado em ACO

Neste capítulo serão detalhadas as simulações feitas durante este trabalho para treinar o algoritmo de RWA baseado em ACO, analisar o seu desempenho e compará-lo a outros algoritmos desenvolvidos para solucionar esse tipo de problema.

Os simuladores de PSO e RWA utilizados foram desenvolvidos a partir de um trabalho conjunto do Grupo de Computação Inteligente do Departamento de Sistemas e Computação da Universidade de Pernambuco e do Grupo de Fotônica do Departamento de Eletrônica e Sistemas da Universidade Federal de Pernambuco. A dissertação de mestrado de Chaves [13] contém uma descrição detalhada sobre o simulador de RWA.

As simulações foram executadas em um computador com as configurações apresentadas na Tabela 1. Cada simulação de treinamento durou cerca de três semanas e meia. Cada simulação de teste de desempenho teve duração de cerca de dez horas.

Tabela 1 Configuração do computador utilizado para executar as simulações de treinamento e teste de desempenho.

Componente	Descrição
Unidade Central de Processamento	Intel® Core™2 Quad Q6600 2,4 GHz
Velocidade de barramento	1066 MHz
Memória Cache – Nível 2	8 MB
Memória RAM (<i>Random Access Memory</i>)	4 GB
Disco Rígido	250 GB, 7.200 RPM, SATA II (<i>Serial Advanced Technology Attachment II</i>)
Sistema Operacional	Windows Vista™ Ultimate x64 Service Pack 1

4.1 Rede Óptica Simulada

Os efeitos e propriedades da camada óptica considerados nas simulações de treinamento e análise de desempenho dos algoritmos de RWA estão listados na Tabela 2. Esses parâmetros foram definidos com valores constantes que representam condições aproximadas de uma rede óptica transparente real.

Além dos parâmetros listados na Tabela 2, também foi considerada a quantidade de comprimentos de onda por enlace (λ). Foram executadas simulações com λ igual a 16 e 32. Nos dois casos, apenas uma fibra óptica foi utilizada nas conexões entre os nós.

Tabela 2 Lista de parâmetros dos enlaces ópticos definidos com valores constantes nas simulações.

Parâmetro	Valor	Definição
P_{in}	-3 dBm	Potência do sinal de entrada em cada canal de
P_{sat}	19 dBm	Potência de saturação óptica de saída do amplificador
F_{amp}	5 dB	Fator de ruído dinâmico do amplificador
$OSNR_{in}$	40 dB	Relação sinal-ruído de entrada
$OSNR_{QoS}$	23 dB	Relação sinal-ruído mínima para o critério de QoS
B	40 Gbps	Taxa de transmissão de bits
α	0,2 dB/Km	Coeficiente de perda da fibra
L_{mux}	2 dB	Perda no multiplexador
L_{demux}	2 dB	Perda no demultiplexador
L_{sw}	3 dB	Perda no comutador
ε	-40 dB	Fator de isolamento do comutador

A rede utilizada, denominada **Regular**, tem como característica baixa complexidade, pois é formada por apenas oito nós e possui rotas simétricas, como pode ser observado na Figura 4.1. Devido à esta simetria, o tráfego entre alguns pares origem e destino pode ser encaminhado por dois caminhos distintos, mas com mesmo custo.

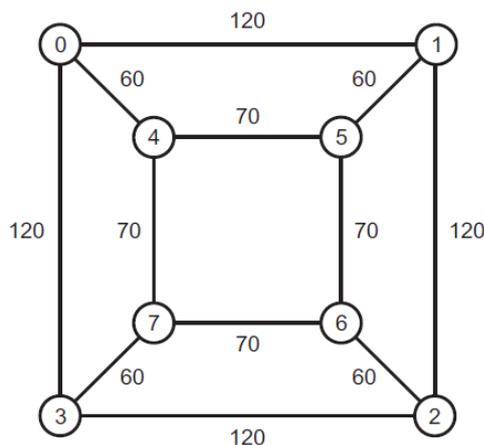


Figura 4.1 Topologia da rede Regular. Os valores associados aos enlaces representam o comprimento físico em quilômetros.

Para o treinamento do algoritmo de RWA baseado em ACO, o valor de carga da rede foi estabelecido a partir de simulações de RWA utilizando o algoritmo de menor caminho (Dijkstra) [46]. A carga que gerava probabilidade de bloqueio igual a 1%, era adotada nas simulações. No entanto, em alguns casos esse valor de carga permitiu que o algoritmo baseado em ACO atingisse probabilidade de bloqueio igual a zero logo nas primeiras iterações do PSO. Estes resultados não eram interessantes para a pesquisa, pois como o processo em análise é estocástico, valores de probabilidade de bloqueio iguais a zero podem não representar verdadeiramente o desempenho do algoritmo. Nesses casos, o valor de carga foi aumentado gradativamente até que os resultados obtidos deixassem de ser iguais a zero ou muito próximos disso.

Nas simulações feitas para analisar o desempenho do algoritmo, o valor de carga na rede era incrementado em 5 Erlangs ao fim de cada iteração. Os intervalos de variação das cargas foram definidos, para cada simulação, a partir do valor de carga utilizado na fase de treinamento.

Os valores de probabilidade de bloqueio obtidos nas simulações de treinamento e teste foram calculados a partir da quantidade de bloqueios por indisponibilidade de comprimento de onda, por níveis inaceitáveis de dispersão por modo de polarização (PMD – *Polarization-Mode Dispersion*) e por OSNR insuficiente no receptor ($OSNR_{out} < OSNR_{QoS}$) [2].

4.2 Função de Custo com Valor de Distância Normalizado

As abordagens para a função de custo, descritas em (2.11) e (2.13), tornam os agentes inteligentes do algoritmo de RWA baseado em ACO capazes de considerar efeitos da camada física das redes ópticas nas tomadas de decisões. No entanto, o fato de o valor de d_{ij} ser na maioria dos casos maior que Ph_{ij} e $\Delta\lambda_{ij}$ pode torná-lo mais relevante que os demais fatores do processo de indução das formigas, mesmo após o ajuste dos pesos. A partir dessa hipótese, foi definido o objetivo deste trabalho, que foi avaliar o desempenho do algoritmo de RWA por ACO utilizando as funções de custo propostas por Carvalho [4], com o valor de d_{ij} normalizado. Assim, d_{ij} foi substituído por d'_{ij} em (2.11) e (2.13), onde

$$d'_{ij} = \frac{d_{ij}}{\max(d)}, \forall d \in N, \quad (4.1)$$

sendo N o conjunto de enlaces da rede óptica em questão. Com essa modificação, (2.12) e (2.15) assumiram, respectivamente, as formas

$$P_{ij}^k = rand \left[\frac{(Ph_{ij})^\alpha}{(d'_{ij})^\beta} \right], \forall j \in N_i^k; \quad (4.2)$$

$$P_{ij}^k = rand \left[\frac{(Ph_{ij})^\alpha (\Delta\lambda_{ij})^\gamma}{(d'_{ij})^\beta} \right], \forall j \in N_i^k. \quad (4.3)$$

Para obter valores ótimos de α e β em (4.2) e α , β e γ em (4.3), foi aplicada a técnica de PSO. A abordagem de RWA por ACO com a equação de indução (4.2) é denominada ACO Padrão e a que utiliza (4.3), ACO Proposto [4].

4.3 Treinamento do Algoritmo de RWA baseado em ACO Utilizando PSO

Como visto na seção 2.4, os parâmetros da equação de indução das formigas têm suas relevâncias balanceadas através dos valores de pesos que precisam ser

pré-definidos. No capítulo 3, a técnica de PSO foi apresentada como uma forma eficaz para a busca dos valores que aumentam a eficiência dos agentes inteligentes. Neste trabalho, foram executadas simulações do problema de RWA, com o algoritmo baseado em ACO sendo treinado por PSO. O objetivo dessas simulações era obter valores de peso que permitissem ao algoritmo minimizar a quantidade de chamadas bloqueadas na rede.

O número de dimensões do espaço de busca do enxame de partículas foi definido de acordo com a equação de indução utilizada. Para (4.2), duas dimensões representavam os possíveis valores de α e β . Nas simulações em que (4.3) foi utilizada, as partículas efetuaram buscas em um espaço tridimensional, que representava os valores de α , β e γ .

Tendo em vista que o RWA é um problema multimodal, foi utilizado o PSO com modelo Local de enxame e com topologia em anel. Para obter melhor desempenho do algoritmo, foi utilizada a equação de atualização de velocidade das partículas com Coeficiente de Construção, com $k = 1$, forçando os enxames a efetuarem buscas em amplitude. Os valores de c_1 e c_2 foram definidos como 2,05, assim, a condição $\varphi \geq 4$ foi atendida e, conseqüentemente, o algoritmo operou sem *overflight*. Os enxames foram definidos contendo 21 partículas, pois, em trabalhos futuros, serão executadas simulações do mesmo problema analisado neste trabalho, utilizando topologia baseada em clãs de indivíduos [45], com três grupos de sete partículas, para comparar o desempenho desse modelo de enxame com os modelos local e global. Além disso, esse tamanho de enxame minimiza o custo computacional das simulações e atende ao padrão estabelecido por Bratton e Kennedy [38]. Inicialmente, foi definido que seriam feitas 500 iterações do PSO para buscar os valores desejados, porém, foi observado que com menos de 150 iterações o algoritmo já encontrava valores ótimos. Isso pode ser justificado pelo fato de que a busca é feita em um espaço de possibilidades não muito grande. Assim, foi estabelecido o limite de 150 iterações para o treinamento do algoritmo de RWA baseado em ACO.

A cada iteração do PSO, as partículas realizavam cinco simulações do problema de RWA, com 10.000 chamadas na rede a cada repetição. As simulações por partículas foram executadas de forma repetitiva, para minimizar a possibilidade

de que os resultados obtidos não representassem verdadeiramente o comportamento do algoritmo. O valor de probabilidade de bloqueio obtido por cada partícula era calculado como a média aritmética dos resultados obtidos em cada uma das cinco simulações.

O tempo de vida das formigas foi definido como $T_{busca} = 2N$, sendo N a quantidade de nós conectados à rede. Assim, a colônia tinha tempo suficiente para encontrar as melhores rotas, com baixa taxa de erros [4], e formigas que entravam em *loop* eram descartadas rapidamente, permitindo que novas formigas fossem adicionadas ao grupo. Dado que em redes complexas a quantidade de formigas que são destruídas a cada iteração pode ser muito alta, as colônias utilizadas nas simulações continham 50 formigas. A cada iteração do PSO, cinco novas formigas eram adicionadas à colônia para substituir as formigas destruídas ($f_c = 1$). *Backward ants* incrementavam com $Q = 1$ os valores de feromônio relacionados aos enlaces das rotas encontradas. O valor do fator de evaporação de feromônio utilizado foi $\epsilon = 0,67$, definido por Carvalho [4] como ideal. A Tabela 3 contém os parâmetros utilizados nas simulações de treinamento das formigas.

Tabela 3 Parâmetros das simulações de treinamento por PSO dos algoritmos de RWA baseados em ACO.

Parâmetros	Simulações			
	1	2	3	4
Comprimentos de onda (λ^T)	16	16	32	32
Carga (Erlangs)	40	40	85	85
Abordagem de RWA por ACO	Padrão	Proposto	Padrão	Proposto

4.4 Teste de Desempenho dos Algoritmos de RWA por ACO treinados por PSO

Após a fase de treinamento, os parâmetros obtidos pelo PSO foram aplicados ao ACO Padrão e ao ACO Proposto, e em seguida foram feitas simulações para avaliar os seus desempenhos e compará-los a outros algoritmos. As condições da camada óptica das redes utilizadas foram as mesmas aplicadas anteriormente, na fase de treinamento. Porém, como dito na seção 4.1, ao invés de valores constantes

de carga, foram utilizados intervalos de cargas variáveis. Para cada valor de carga, eram feitas 1.000.000 de chamadas na rede, o que tornou os resultados mais precisos que os obtidos nas simulações de treinamento. Cada simulação foi repetida cinco vezes, para garantir que os resultados obtidos representam verdadeiramente o desempenho do algoritmo. A Tabela 4 apresenta a lista de parâmetros utilizados nas simulações executadas para testar o desempenho do algoritmo.

Os resultados obtidos pelo ACO Padrão e o ACO Proposto foram comparados com os resultados alcançados pelo algoritmo baseado em quantidade de saltos, de menor caminho [46] e balanceamento de carga (LRW – *Least Resistance Weight*) [47]. Para todos os algoritmos, foi aplicada a heurística de *first-fit* para alocar comprimentos de onda nos caminhos ópticos selecionados.

Tabela 4 Parâmetros das simulações de teste de desempenho dos algoritmos de RWA baseados em ACO, treinados por PSO.

Parâmetros	Simulações			
	1	2	3	4
Comprimentos de onda (λ^T)	16	16	32	32
Intervalo de Cargas (Erlangs)	20-60	20-60	60-100	60-100
Abordagem de RWA por ACO	Padrão	Proposto	Padrão	Proposto

5 Resultados

Neste capítulo serão apresentados os resultados obtidos nas simulações de treinamento e teste de desempenho do algoritmo de RWA por ACO utilizando as duas abordagens de função de custo apresentadas por Carvalho [4]. Os desempenhos dos algoritmos por ACO foram comparados com algoritmos de RWA baseados em quantidade de saltos, caminho mais curto e balanceamento de carga.

5.1 Fase de Treinamento

A Figura 5.1 apresenta as curvas de convergência do PSO, durante a fase de treinamento dos algoritmos de RWA por ACO com a rede Regular. No cenário da Figura 5.1(a) e da Figura 5.1(c), os algoritmos ACO Padrão e ACO Proposto foram treinados com carga de 40 Erlangs e 16 comprimentos de onda em cada enlace. No cenário da Figura 5.1(b) e da Figura 5.1(d), o treinamento dos algoritmos foi feito com carga de 85 erlangs e 32 comprimentos de onda por enlace.

No cenário da Figura 5.1(a), a convergência ocorreu por volta da 80ª iteração do PSO, com valor de probabilidade de bloqueio de 0,013, aproximadamente. No cenário da Figura 5.1(c), o PSO convergiu mais cedo (por volta da 30ª iteração), alcançando probabilidade de bloqueio em torno de 0,009. No cenário da Figura 5.1(b), ocorreu a convergência mais rápida do PSO entre as quatro simulações. Na segunda iteração dessa simulação, a probabilidade de bloqueio obtida foi de aproximadamente 0,0026, e assim se manteve durante as iterações seguintes. Como as posições iniciais das partículas são definidas aleatoriamente, é possível que em alguns casos ocorra convergência do PSO já nas primeiras iterações, pois uma partícula pode ter posição inicial muito próxima de um valor ótimo. No cenário da Figura 5.1(d), o PSO atingiu probabilidade de bloqueio igual a 0,001 na 15ª iteração, não alcançando valor inferior até o fim da simulação.

Tendo em vista a quantidade relativamente pequena de iterações necessárias para a convergência do PSO, ficou comprovada a eficiência dessa técnica na busca de valores que ponderam os parâmetros utilizados no processo de indução dos

agentes inteligentes do RWA por ACO, de forma que o desempenho desse algoritmo é maximizado.

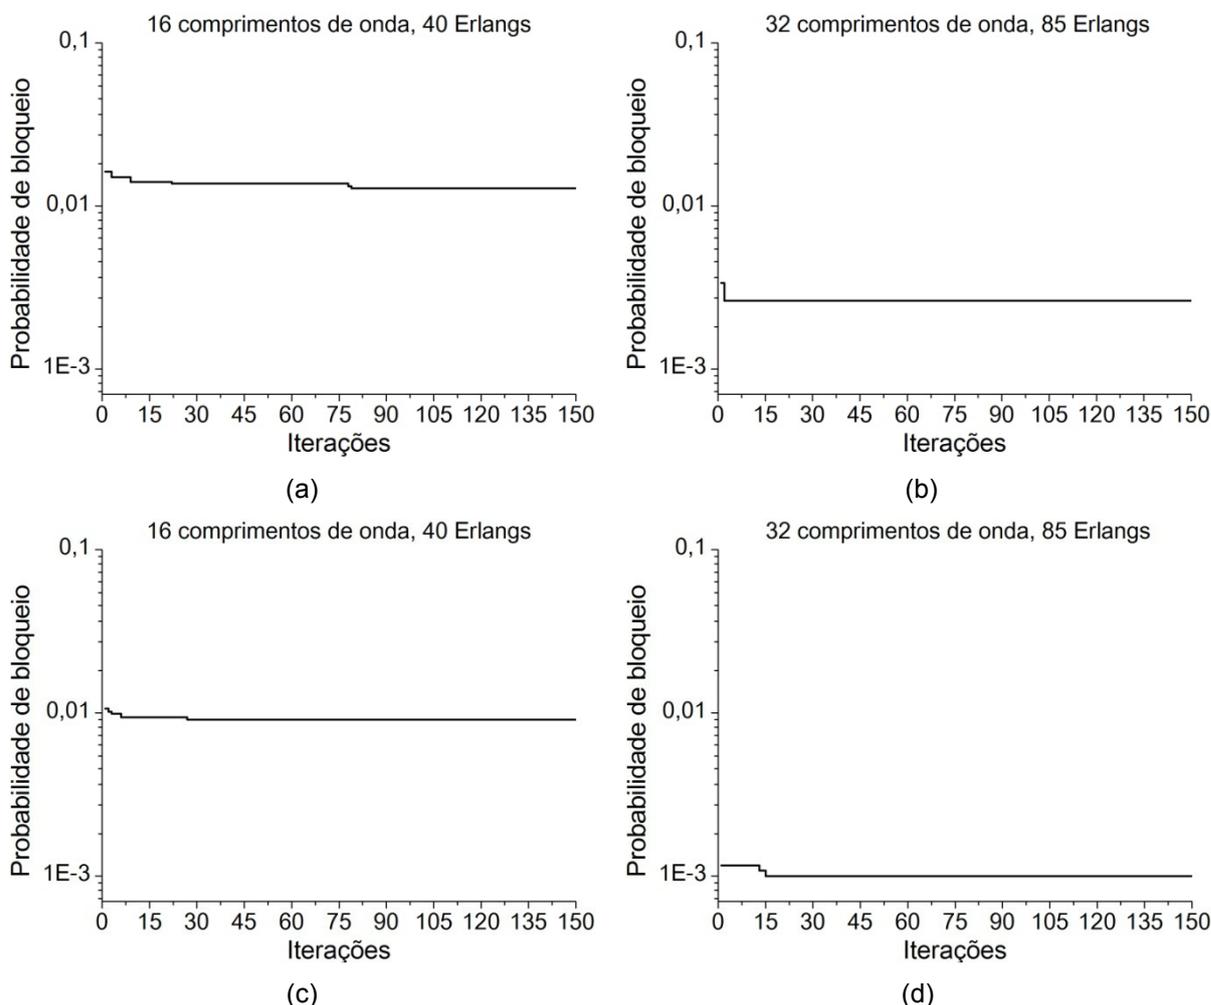


Figura 5.1 Curvas de convergência do PSO na fase de treinamento dos algoritmos de RWA baseados em ACO com a rede Regular. (a) 16 comprimentos de onda, 40 Erlangs e RWA por ACO Padrão. (b) 32 comprimentos de onda, 85 Erlangs e RWA por ACO Padrão. (c) 16 comprimentos de onda, 40 Erlangs e RWA por ACO Proposto. (d) 32 comprimentos de onda, 85 Erlangs e RWA por ACO Proposto.

A Tabela 5 apresenta os valores de peso das equações de indução obtidos nas simulações de treinamento com PSO. No cenário com 32 comprimentos de onda, 85 Erlangs e RWA por ACO Proposto, três partículas com configurações distintas obtiveram o mesmo valor de probabilidade de bloqueio. Através das simulações de teste de desempenho com 1.000.000 de chamadas, foi confirmado que as três combinações de valores de peso realmente geram resultados semelhantes. Os valores ($\alpha = 3.50144$, $\beta = 3.01474$, $\gamma = 3.48118$) foram escolhidos para a avaliação de desempenho do ACO Proposto na rede Regular com 32

comprimentos de onda, pois a partícula com essa configuração foi a primeira a alcançar a menor taxa de bloqueios de chamadas durante o treinamento.

Tabela 5 Valores de pesos das equações de indução obtidos nas simulações de treinamento dos algoritmos de RWA por ACO com a rede Regular.

Cenário	α	β	γ
16 comprimentos de onda, 40 Erlangs e RWA por ACO Padrão	1,46175	1,92726	-
16 comprimentos de onda, 40 Erlangs e RWA por ACO Proposto	2,08252	2,20869	2,96475
32 comprimentos de onda, 85 Erlangs e RWA por ACO Padrão	2,67244	3,39465	-
	3,50144	3,01474	3,48118
32 comprimentos de onda, 85 Erlangs e RWA por ACO Proposto	1,19588	1,56004	3,98344
	0,110748	1,99878	3,99688

5.2 Testes de Desempenho

A Figura 5.2 ilustra os desempenhos obtidos pelos algoritmos de RWA na rede Regular com (a) 16 comprimentos de onda e (b) 32 comprimentos de onda. Os valores apresentados consistem na média das probabilidades de bloqueio totais obtidas em cada simulação (total de cinco repetições para cada algoritmo).

A Figura 5.2(a) apresenta o comparativo de desempenho na rede Regular com 16 comprimentos de onda. O ACO Proposto obteve o melhor desempenho para cargas de 25 e 30 Erlangs. Quando a carga foi aumentada para 35 Erlangs, os algoritmos de RWA por quantidade de saltos, balanceamento de carga e ACO Proposto tiveram desempenho semelhante. A partir da carga 40 até 65 Erlangs, o algoritmo por balanceamento de carga obteve o melhor desempenho, seguido do algoritmo baseado em quantidade de saltos e o ACO Proposto, sendo que os três geraram taxas de bloqueio de chamadas muito próximas. O ACO Padrão teve os maiores valores de probabilidade de bloqueio nas simulações com carga de 25 e 30 Erlangs. A partir da carga de 40 Erlangs, ele superou o algoritmo baseado em caminho mais curto, obtendo resultados inferiores, porém, próximos aos desse

segundo algoritmo. Com esses resultados, é possível observar a melhora no desempenho do algoritmo de RWA baseado em ACO com adição da disponibilidade de comprimentos de onda na função de custo, quando comparado ao ACO Padrão.

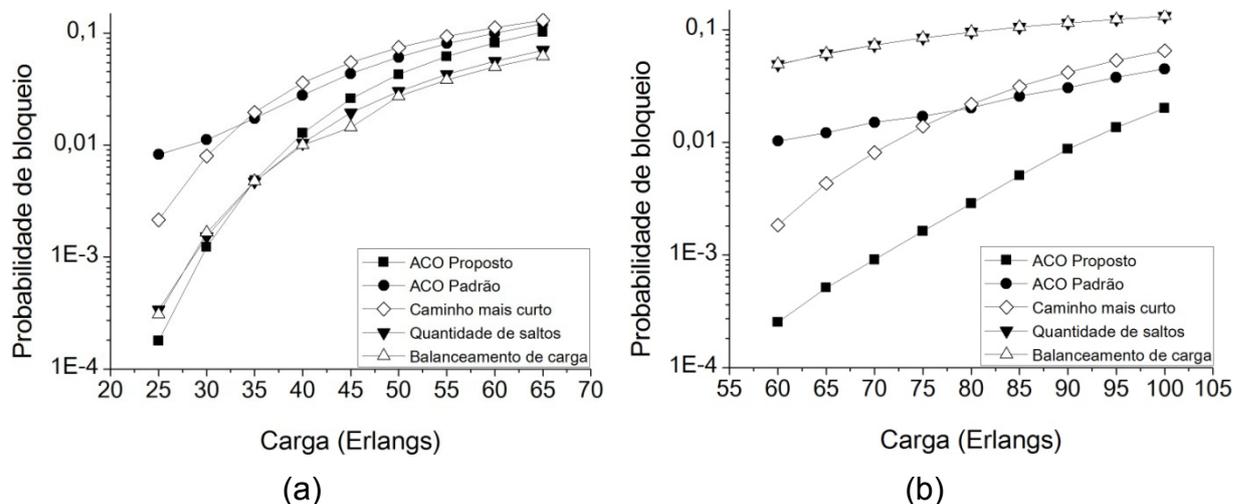


Figura 5.2 Gráfico comparativo dos desempenhos dos algoritmos de RWA na rede Regular com: (a) 16 comprimentos de onda; (b) 32 comprimentos de onda.

A Figura 5.2(b) apresenta o comparativo de desempenho na rede Regular com 32 comprimentos de onda. O ACO Proposto obteve o melhor desempenho para todos os valores de carga utilizados na simulação. O ACO Padrão teve desempenho inferior ao algoritmo de RWA por caminho mais curto no intervalo de cargas entre 60 e 75 Erlangs. A partir do teste com carga igual a 80 Erlangs, o ACO Padrão obteve taxas de bloqueios de chamadas menores que o algoritmo por caminho mais curto, porém, aproximadas. Os algoritmos baseados em quantidade de saltos e balanceamento de carga geraram resultados similares e tiveram desempenho inferior aos demais algoritmos em todos os casos.

A Figura 5.3 contém gráficos do tipo *box plot* que apresentam dados estatísticos das simulações de teste de desempenho dos algoritmos (a) ACO Padrão e (b) ACO Proposto na rede Regular com 16 comprimentos de onda por enlace. O maior valor de desvio padrão obtido nas simulações com ACO Padrão foi de 0,00228, para a carga de 60 Erlangs. A maior variação percentual entre os limites inferiores e superiores foi de 33,2%, para a carga de 30 Erlangs. Nas simulações com ACO Proposto, o maior valor de desvio padrão obtido foi de 0,00158, para a carga de 60 Erlangs. A maior variação percentual entre os limites inferiores e superiores foi de 23,49%, para a carga de 25 Erlangs. Essas variações podem ser

consideradas desprezíveis quando comparadas às variações nos valores de probabilidades de bloqueio resultantes dos aumentos de carga na rede.

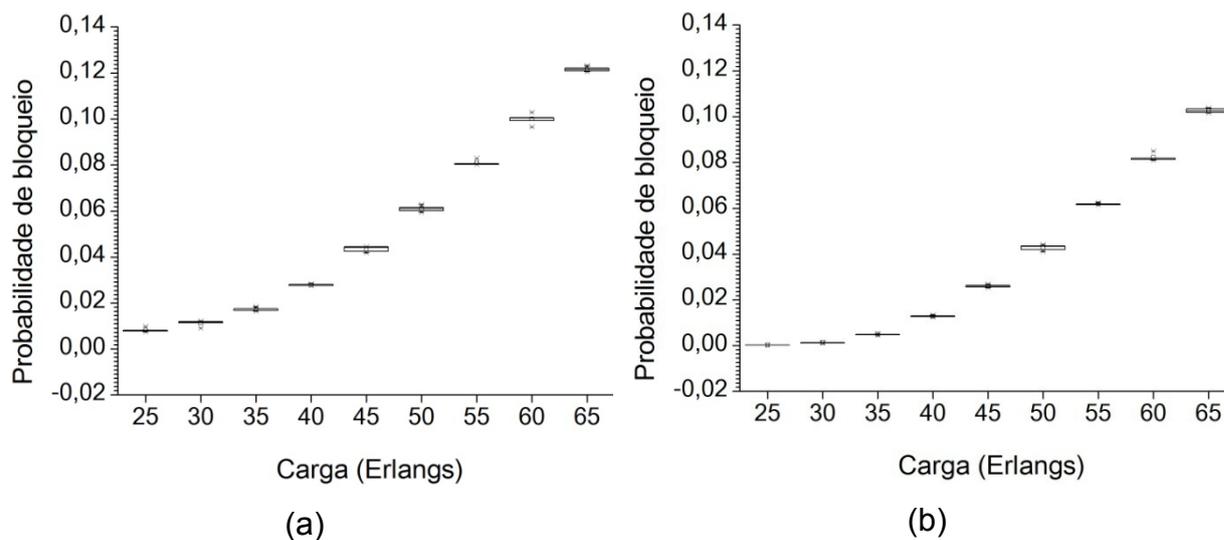


Figura 5.3 Gráfico estatístico dos desempenhos dos algoritmos de RWA por ACO na rede Regular com 16 comprimentos de onda. (a) ACO Padrão; (b) ACO Proposto.

A Figura 5.4 contém gráficos estatísticos das simulações de teste de desempenho dos algoritmos (a) ACO Padrão e (b) ACO Proposto na rede Regular com 32 comprimentos de onda por enlace. O valor máximo de desvio padrão obtido nas simulações com ACO Padrão foi de 0,00168, para a carga de 95 Erlangs. A maior variação percentual entre os limites inferiores e superiores foi de 28,09%, para a carga de 60 Erlangs. Nas simulações com ACO Proposto, o maior valor de desvio padrão obtido foi de 0,00043, para a carga de 90 Erlangs. A maior variação percentual entre os limites inferiores e superiores foi de 17,26%, para a carga de 65 Erlangs. Assim como no cenário com 16 comprimentos de onda por enlace, as variações obtidas no cenário com 32 comprimentos de onda também podem ser consideradas desprezíveis quando comparadas às variações nos valores de probabilidades de bloqueio resultantes dos aumentos de carga na rede.

Além das probabilidades de bloqueio calculadas a partir das quantidades totais de chamadas bloqueadas, também foram registradas as taxas de bloqueio geradas por indisponibilidade de comprimentos de onda nos enlaces, nível de ruído acima do limite máximo estabelecido e níveis inaceitáveis de dispersão por modo de polarização (PMD), que somadas formam a taxa total de bloqueios.

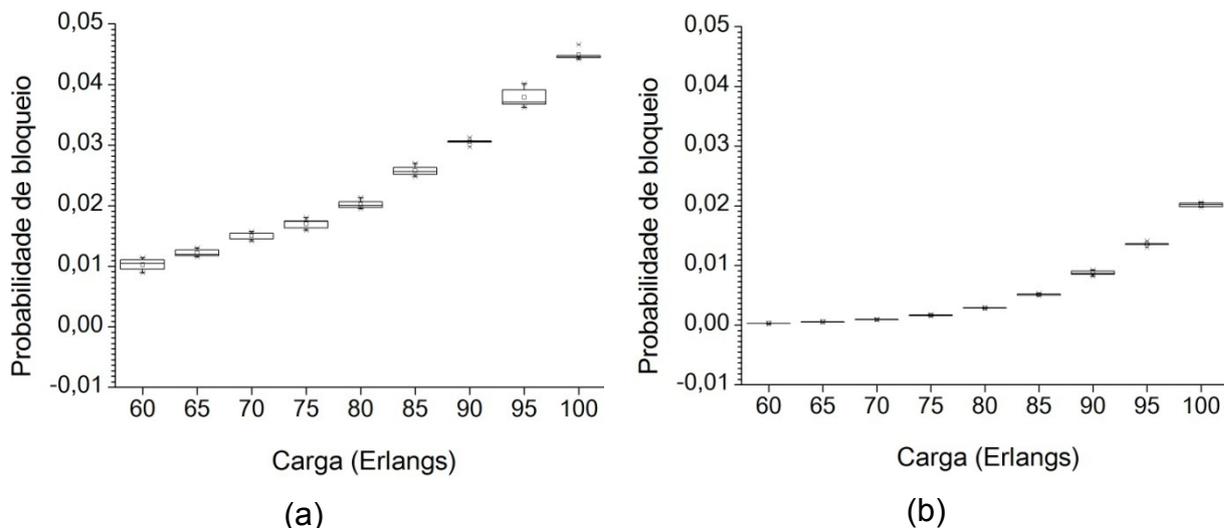


Figura 5.4 Gráfico estatístico dos desempenhos dos algoritmos de RWA por ACO na rede Regular com 32 comprimentos de onda. (a) ACO Padrão; (b) ACO Proposto.

A Figura 5.5 apresenta os gráficos de probabilidade de bloqueio por indisponibilidade de comprimentos de onda nos enlaces. A Figura 5.5(a) contém os resultados obtidos na rede Regular com 16 comprimentos de onda. É possível observar que os algoritmos de RWA por caminho mais curto, ACO Proposto e ACO Padrão são mais suscetíveis à baixa disponibilidade de comprimentos de onda que os algoritmos baseados em quantidade de saltos e balanceamento de carga.

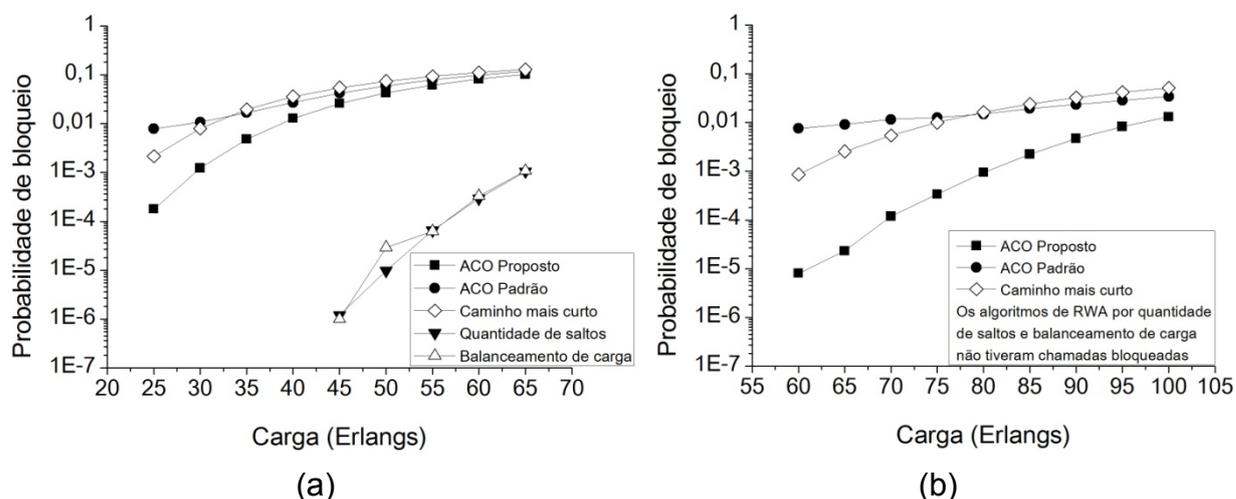


Figura 5.5 Gráficos comparativos de probabilidades de bloqueio por indisponibilidade de comprimentos de onda nos enlaces da rede Regular com: (a) 16 comprimentos de onda; (b) 32 comprimentos de onda.

A Figura 5.5(b) ilustra os resultados obtidos na rede Regular com 32 comprimentos de onda por enlace. Os algoritmos de RWA baseados em quantidade de saltos e balanceamento de carga não tiveram chamadas bloqueadas por indisponibilidade de comprimentos de onda nesse cenário. O ACO Proposto obteve

melhores resultados com o aumento da quantidade de comprimentos de onda nos enlaces. Já os algoritmos ACO Padrão e de caminho mais curto mantiveram os resultados com valores próximos aos obtidos no cenário com 16 comprimentos de onda.

A Figura 5.6 apresenta as probabilidades de bloqueio por nível de ruído nos enlaces acima do limite máximo estabelecido, ou seja, OSNR insuficiente nos receptores ($OSNR_{out} < OSNR_{QoS}$).

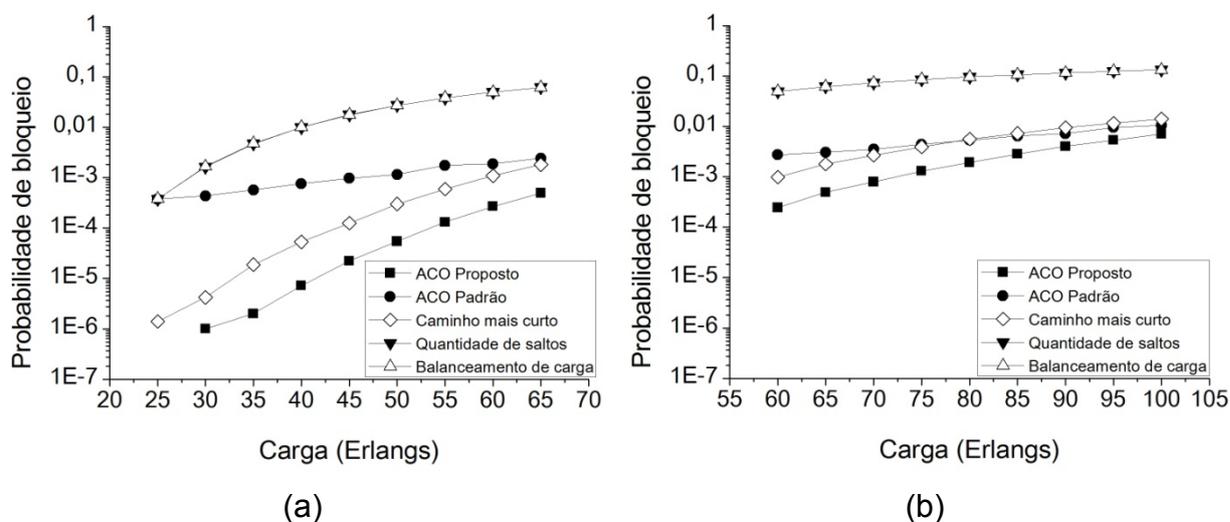


Figura 5.6 Gráficos comparativos de probabilidades de bloqueio por OSNR insuficiente nos receptores dos enlaces da rede Regular com: (a) 16 comprimentos de onda; (b) 32 comprimentos de onda.

Os dados apresentados na Figura 5.6(a) consistem nos resultados obtidos pelos algoritmos de RWA na rede Regular com 16 comprimentos de onda. Os algoritmos baseados em quantidade de saltos e balanceamento de carga se mostraram mais suscetíveis ao ruído no enlace que os demais algoritmos. O ACO Proposto obteve os melhores resultados, seguido pelo algoritmo de caminho mais curto. O ACO Padrão teve resultado similar aos algoritmos de quantidade de saltos e balanceamento de carga quando a rede estava com carga igual a 25 Erlangs, mas nas simulações seguintes apresentou melhor desempenho que esses dois algoritmos.

A Figura 5.6(b) ilustra os resultados obtidos na rede Regular com 32 comprimentos de onda. Os algoritmos de RWA baseados em quantidade de saltos e balanceamento de carga mantiveram taxas de bloqueio superiores às dos demais algoritmos, enquanto o ACO Proposto manteve os valores mais baixos. O algoritmo

baseado em caminho mais curto teve resultados próximos aos do ACO Padrão, chegando a ter desempenho ligeiramente inferior a partir da carga de 80 Erlangs. O ACO Padrão teve comportamento semelhante ao do cenário da Figura 5.6(a), apenas com valores de probabilidade de bloqueio um pouco maiores.

Apesar de os algoritmos ACO Proposto e de caminho mais curto apresentarem aumento de probabilidade de bloqueio mais acelerado que os demais algoritmos, há uma tendência de todos apresentarem desempenhos similares para valores de carga acima dos apresentados na Figura 5.6, devido ao esgotamento dos recursos da rede.

Em nenhuma das simulações houve chamadas bloqueadas por níveis inaceitáveis de PMD. Esse resultado já era esperado para a rede Regular com os parâmetros de taxa de transmissão e variação do coeficiente de PMD estabelecidos para os enlaces ($B = 40 \text{ Gbps}$, $\Delta\text{PMD} = 10\%$).

6 Conclusão e Trabalhos Futuros

Este trabalho foi desenvolvido com o propósito de avaliar o desempenho de algoritmos de roteamento e alocação de comprimentos de onda (RWA – *Routing and Wavelength Assignment*) que funcionam utilizando técnicas de otimização, denominadas por ACO (*Ant Colony Optimization*) e PSO (*Particle Swarm Optimization*), que reproduzem a inteligência emergente de colônias de formigas e enxames de partículas, respectivamente.

A técnica de Otimização por Enxames de Partículas (PSO – *Particle Swarm Optimization*) foi aplicada para buscar os valores de peso dos parâmetros que maximizam o desempenho do ACO Padrão e do ACO Proposto. Assim, antes que esses algoritmos fossem avaliados e comparados com outros, foi executada uma fase de treinamento, onde o PSO testou diferentes configurações dos algoritmos aplicados ao cenário que foi posteriormente utilizado para estudo de caso. Os resultados comprovaram a eficácia dessa técnica na solução do problema de ponderação dos parâmetros utilizados no processo de indução dos agentes inteligentes, sendo necessárias poucas iterações para encontrar valores que otimizam o desempenho do RWA.

Com os pesos dos parâmetros definidos, o ACO Padrão e o ACO Proposto foram testados e comparados com algoritmos de RWA baseados em quantidade de saltos, caminho mais curto e balanceamento de carga. O estudo de caso foi feito com uma topologia de rede de baixa complexidade e com rotas simétricas. Os testes foram feitos através de simulações repetitivas e com diferentes níveis de carga na rede. Além disso, a rede foi utilizada com 16 e 32 comprimentos de onda por enlace, para que fosse possível avaliar o impacto da disponibilidade desses elementos no desempenho dos algoritmos.

O ACO Padrão teve desempenho similar ao algoritmo de RWA por caminho mais curto. Ele se mostrou suscetível à indisponibilidade de comprimentos de onda nos enlaces, o que implicou em desempenho inferior aos dos algoritmos baseados em quantidade de saltos e balanceamento de carga no cenário com 16 comprimentos de onda, pois esses dois últimos sofrem pouco ou nenhuma interferência pela escassez de comprimentos de onda. A taxa de bloqueios de

chamadas por nível de ruído inaceitável nos receptores foi maior no ACO Padrão que no ACO Proposto nos dois cenários. O ACO Padrão se mostrou inferior ao algoritmo por caminho mais curto no cenário com 16 comprimentos de onda.

Os testes feitos com o ACO Proposto comprovaram que há ganho expressivo de desempenho quando se adiciona propriedades da camada óptica no processo de seleção de caminhos. No cenário com 32 comprimentos de onda, ele se mostrou mais adequado que os demais algoritmos, e na rede com 16 comprimentos de onda, obteve taxa de bloqueio total equivalente às obtidas pelos algoritmos baseados em quantidade de saltos e balanceamento de carga, superando os desempenhos do ACO Padrão e do algoritmo por caminho mais curto. Os resultados mostraram que o ACO Proposto é menos sensível ao ruído nos receptores que os demais algoritmos. Na comparação das taxas de bloqueio de chamadas por indisponibilidade de comprimentos de onda, ele foi superado apenas pelos algoritmos de RWA por quantidade de saltos e balanceamento de carga. Assim, é possível concluir que o ACO Proposto é um algoritmo de RWA de alto rendimento, capaz de garantir QoS em redes ópticas transparentes, e que a consideração de outros efeitos e propriedades da camada física pode produzir algoritmos IRWA baseados em ACO ainda mais eficientes.

Além do estudo de caso descrito neste trabalho, foram executadas simulações com os algoritmos ACO Padrão e ACO Proposto aplicados a outros cenários, de maior complexidade, para possibilitar conclusões mais precisas a respeito dos seus desempenhos. Os resultados foram descritos em artigo [48] submetido ao 27º Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC 2009).

Propostas de trabalhos futuros incluem a simplificação da fase de treinamento aplicando-se outras técnicas de inteligência computacional ou outras topologias de PSO para que seja possível identificar aquela que melhor pondera os parâmetros de indução dos agentes inteligentes dos algoritmos de RWA por ACO. Além disso, o PSO pode ser aplicado para localizar valores genéricos de pesos que maximizem o desempenho dos algoritmos de forma independente de cenário.

Simulações de redes não estáticas, onde nós e enlaces podem deixar de operar de forma intermitente ou definitiva, podem ser feitas para que seja possível verificar os níveis de tolerância a falhas dos algoritmos.

O aperfeiçoamento dos algoritmos de RWA baseados em ACO pode ser feito através da inclusão de outros efeitos e propriedades da camada física no processo de indução dos agentes inteligentes, sendo necessária a execução de um estudo para avaliar o ganho obtido pela consideração de novos fatores.

Bibliografia

- [1] Internet Systems Consortium. **Internet Domain Survey Host Count**. Disponível em: < <http://www.isc.org/ops/ds/> >. Acesso em: 09 de set. 2008.
- [2] Ramaswami, R.; Sivarajan, K. N. **Optical Networks (a practical perspective)**. California: Morgan Kaufmann Publishers Inc., 2002.
- [3] Zang, H.; Jue, J. P.; Mukherjee, B. **A Review of Routing and Wavelength Assignment Approaches for Wavelength-Routed Optical WDM Networks**. In: Optical Networks Magazine. vol. 1, nº 1, pp. 47–60. Springer Netherlands, jan. 2000.
- [4] Alcatel-Lucent. **Alcatel-Lucent Announces New Breakthroughs for Optical Networking and Optoelectronic Components at OFC 2008**. Disponível em: <http://www.alcatel-lucent.com/wps/portal/NewsReleases/Detail?LMSG_CABINET=Docs_and_Resource_Ctr&LMSG_CONTENT_FILE=News_Releases_2008/News_Article_000890.xml>. Acesso em: 10 de set. 2008.
- [5] Carvalho, D. F. **Roteamento em Redes Ópticas Transparentes Utilizando Otimização por Colônias de Formigas**. Dissertação (Mestrado em Engenharia da Computação). Escola Politécnica de Pernambuco, Universidade de Pernambuco. Recife: 10 de jul. 2008.
- [6] Dorigo, M.; Bonabeau, E.; Theraulaz, G. **Ant Algorithms and Stigmergy**. In: Future Generation Computer Systems, vol. 16, nº 9, pp. 851–871, 2000.
- [7] Dorigo, M.; Maniezzo, V.; Colomi, A. **Ant System (optimization by a colony of cooperating agents)**. In: IEEE Transactions on Systems, Man, and Cybernetics, Part B, vol. 26, nº 1, pp. 29–41, fev. 1996.
- [8] Kennedy, J.; Eberhart, R. **Particle Swarm Optimization**. In: Proceedings of the IEEE International Conference on Neural Networks, vol. 4, pp. 1942-1948, 1995.

- [9] Kurose, J. F.; Ross, K. W. **Redes de Computadores e a Internet (uma abordagem top-down)**. Tradução: Arlete Simille Marques. 3. Ed. São Paulo: Pearson Addison Wesley, 2006.
- [10] Leon-Garcia, A.; Widjaja, I. **Communication Networks (fundamentals concepts and key architectures)**. 1. Ed. Nova Iorque: McGraw-Hill, 2001.
- [11] Medhi, D.; Ramasamy, K. **Network Routing (algorithms, protocols, and architectures)**. California: Morgan Kaufmann Publishers Inc., 2007.
- [12] Dutta, A. K.; Dutta, N. K.; Fujiwara, M. **WDM Technologies (optical networks)**. Vol. 3. California: Elsevier Academic Press, 2004.
- [13] Chaves, D. A. R. **Algoritmos Rápidos de IRWA para Redes Totalmente Ópticas**. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal de Pernambuco. Recife: fev. 2008.
- [14] Becker, P. C.; Olsson, N. A.; Simpson, J. R. **Erbium-Doped Fiber Amplifiers (fundamentals and technology)**. Califórnia: Academic Press, 1999.
- [15] Bastos Filho, C. J. A.; Alcântara, R. S.; Oliveira, A. L. I. **A Novel Approach for a Routing Algorithm Based on a Discrete Time Hopfield Neural Network**. In: The First IEEE Symposium on Foundations of Computational Intelligence (FOCI'07), 2007, Honolulu. Proceedings of the 2007 IEEE Symposium Series on Computational Intelligence (IEEE SSCI 2007), 2007. pp. 363-369.
- [16] Rauch, H.E.; Winarske, T. **Neural Networks for Routing Communication Traffic**. In: Control Systems Magazine, IEEE, vol. 8, nº 2, pp. 26–31, abr. 1988.
- [17] Bisbal, D. **Dynamic Routing and Wavelength Assignment in Optical Networks by Means of Genetic Algorithms**. In: Photonic Network Communications, vol. 7, nº 1, pp. 43–58, 2004.
- [18] Caro, G. D.; Dorigo, M. **AntNet (distributed stigmergetic control for communications networks)**. In: Journal of Artificial Intelligence Research, vol. 9, pp. 317–365, 1998.

- [19] Ngo, S. H.; Jiang, X.; Horiguchi, S. **Adaptive Routing and Wavelength Assignment Using Ant-Based Algorithm**. In: Proc. 12th IEEE International Conference on Networks, vol. 2, pp. 482–486, nov. 2004.
- [20] Pavani, G. S.; *et al.* **Distributed Approaches for Impairment-Aware Routing and Wavelength Assignment Algorithms in GMPLS Networks**. In: Computer Networks, vol. 52, n° 10, pp. 1905–1915, jul. 2008.
- [21] Pavani, G. S.; Waldman, H. **Adaptive Routing and Wavelength Assignment with Power Constraints Using Ant Colony Optimization**. In: VI International Telecommunications Symposium (ITS2006), pp. 637–642, set. 2006.
- [22] Sim, K. M.; Sun, W. H. **Ant Colony Optimization for Routing and Load Balancing (Survey and New Directions)**. In: IEEE Transactions on Systems, Man, and Cybernetics, Part A, vol. 33, n° 5, pp. 560–572, 2003.
- [23] Mohemmed, A. W.; Sahoo, N. C.; Tan, K. G. **Solving Shortest Path Problem Using Particle Swarm Optimization**. In: Applied Soft Computing, jan. 2008.
- [24] Bastos Filho, C. J. A.; *et al.* **Routing Algorithm Based on Swarm Intelligence and Hopfield Neural Network Applied to Communication Networks**. Electronics Letters, v. 44, p. 995, 2008.
- [25] Yuan, Y.-W.; Zhan, H.-H.; Yan, L.-M. **An Adaptive QoS Route Selection Algorithm Based on Genetic Approach in Combination with Neural Network**. In: Proc. of the Second Int. Conf. on Machine Learning and Cybernetics, pp. 69–73. IEEE Service Center, 2003.
- [26] Grassé, P.-P. **La Reconstruction du Nid et Le Coordinations Interindividuelles Chez Bellicositermes Natalensis et Cubitermes Sp. La Théorie de La Stigmergie (Essai D'interpretation du Comportement des Termites Constructeurs)**. Insectes Sociaux, vol. 6, pp. 41–81, 1959.
- [27] Deneubourg, J.; Aron, S.; Goss, S. **The Self-Organizing Exploratory Pattern of the Argentine Ant**. Journal of Insect Behavior, vol. 3, pp. 159–169, 1990.
- [28] Goss, S.; *et al.* **Self-Organized Shortcuts in the Argentine Ant**. Naturwissenschaften, vol. 76, n° 12, pp. 579–581, dez. 1989.

- [29] Dorigo, M.; Caro, G. D.; Gambardella, L. M. **Ant Algorithms for Discrete Optimization**. *Artificial Life*, vol. 5, nº 2, pp. 137–172, 1999.
- [30] Dorigo, M.; Gambardella, L. M. **Ant Colony System (a cooperative learning approach to the traveling salesman problem)**. In: *IEEE Transactions on Evolutionary Computation*, vol. 1, nº 1, pp. 53–66, 1997.
- [31] Schoonderwoerd, R.; Holland, O.; Bruten, J. **Ant-Like Agents for Load Balancing in Telecommunications Networks**. In: *Proc. 1st International Conference on Autonomous Agents*, pp. 209–216, California. Nova Iorque: ACM Press, 1997.
- [32] Bellman, R. **On a Routing Problem**. In: *Quarterly of Applied Mathematics*, vol. 16, nº 1, pp. 87-90. Abr. 1958.
- [33] Ford, L. R., Jr. **Network Flow Theory**. In: Report P-923. California: The Rand Corporation, 14 de ago. 1956.
- [34] Shi, X. H.; *et al.* **Particle Swarm Optimization-Based Algorithms for TSP and Generalized TSP**. In: *Information Processing Letters*, vol. 103, nº 5, pp. 169–176, 2007.
- [35] Satapathy, S. C.; *et al.* **Particle Swarm Optimized Multiple Regression Linear Model for Data Classification**. In: *Applied Soft Computing*, jun. 2008.
- [36] Millonas, M. M. **Swarms, Phase Transitions, and Collective Intelligence**. In: *3. Artificial Life Conference*, Santa Fe Institute, 30 p., jun. 1992.
- [37] Davis, L. **Handbook of Genetic Algorithms**. 1. Ed. Nova Iorque: Van Nostrand Reinhold Company, jan. 1991. 385 p.
- [38] Bratton, D.; Kennedy, J. **Defining a Standard for Particle Swarm Optimization**. In: *Swarm Intelligence Symposium, 2007 (SIS 2007)*. IEEE. pp. 120–127. Honolulu: abr. 2007.
- [39] Eberhart, R.; Kennedy, J. **A New Optimizer Using Particle Swarm Theory**. In: *Proceedings of the Sixth International Symposium on Micro Machine and Human Science, 1995 (MHS'95)*. pp. 39–43, Nagoya: 4–6 de out. 1995.

- [40] Kennedy, J. **The Particle Swarm (social adaptation of knowledge)**. In: IEEE International Conference on Evolutionary Computation, 1997 (ICEC 1997). pp. 303–308, Indianapolis: abr. 1997.
- [41] Clerc, M.; Kennedy, J. **The Particle Swarm (explosion, stability, and convergence in a multidimensional complex space)**. In: IEEE Transactions on Evolutionary Computation. vol. 6, nº 1, pp; 58–73, fev. 2002.
- [42] Shi, Y.; Eberhart, R. **A Modified Particle Swarm Optimizer**. In: Proceedings of IEEE International Conference on Evolutionary Computation, 1998. pp. 69–73. Alasca: mai. 1998.
- [43] Kennedy, J.; Mendes, R. **Population Structure and Particle Swarm Performance**. In: Proceedings of the 2002 Congress on Evolutionary Computation (CEC 2002). pp. 1671–1676. IEEE Press, 2002.
- [44] Mendes, R.; Kennedy, J.; Neves, J. **Watch Thy Neighbor or How the Swarm Can Learn from its Environment**. In: Proceedings of the 2003 IEEE Swarm Intelligence Symposium (SIS'03). pp. 88–94, Portugal: abr. 2003.
- [45] Carvalho, D. F.; Bastos-Filho, C. J. A. **Clan Particle Swarm Optimization**. In: Proceedings of the 2008 IEEE World Congress on Computational Intelligence (WCCI 2008). Hong Kong: jun. 2008.
- [46] Dijkstra, E. W. **A Note on Two Problems in Connection with Graphs**. In: Numerische Mathematik, vol. 1, pp. 269–271, 1959.
- [47] Wen, B.; Shenai, R.; Sivalingam, K. **Routing, Wavelength and Time-slot-assignment Algorithms for Wavelength-routed Optical WDM/TDM Networks**. In: Journal of Lightwave Technology, vol. 23, nº 9, pp. 2598–2609. Washington: set. 2005.
- [48] Bastos-Filho, C. J. A.; *et. al.* **Intelligent Impairment Aware Routing Algorithm for All-Optical Networks based on Ant Colony Optimization Trained by Particle Swarm Optimization**. In: 27º Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC 2009). Recife, 2009. Submetido.