



Avaliação de Robustez a Variações de Carga de Um Estimador de Probabilidade de Bloqueio para Redes Ópticas Baseado em Redes Neurais

**Trabalho de Conclusão de Curso
Engenharia da Computação**

**José Cleyton da Silva
Orientador: Prof. Dr. Carmelo José Albanez Bastos Filho**



**Universidade de Pernambuco
Escola Politécnica de Pernambuco
Graduação em Engenharia de Computação**

JOSÉ CLEYTON DA SILVA

**Avaliação de Robustez a Variações de
Carga de Um Estimador de Probabilidade de
Bloqueio para Redes Ópticas Baseado em
Redes Neurais**

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

Recife, Julho/2014.

MONOGRAFIA DE FINAL DE CURSO

Avaliação Final (para o presidente da banca)*

No dia 2 de 7 de 2014, às 13:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente JOSE CLEYTON DA SILVA, orientado pelo professor Carmelo José Albanez Bastos Filho, sob título Avaliação de Robustez a Variações de Carga de Um Estimador de Probabilidade de Bloqueio para Redes Ópticas Baseado em Redes Neurais, a banca composta pelos professores:

Daniel Augusto Ribeiro Chaves

Carmelo José Albanez Bastos Filho

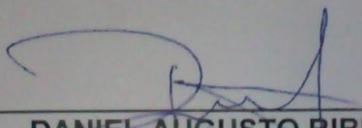
Após a apresentação da monografia e discussão entre os membros da Banca, a mesma foi considerada:

Aprovada Aprovada com Restrições* Reprovada

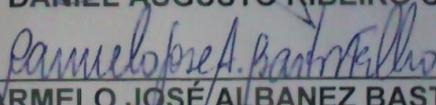
e foi-lhe atribuída nota: 9,5 (NINVE E MEIO)

*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

O discente terá 10 dias para entrega da versão final da monografia a contar da data deste documento.



DANIEL AUGUSTO RIBEIRO CHAVES



CARMELO JOSÉ ALBANEZ BASTOS FILHO

Dedico este trabalho a toda minha família, namorada, amigos e em especial ao meu avô José Severino (in memoriam) que sempre foi um grande exemplo na minha vida.

Agradecimentos

Agradeço primeiramente a Deus, por ter me concedido a oportunidade de completar esta etapa da minha vida e proporcionar ótimos momentos durante todo este período.

Agradeço aos meus pais, Joselito Rodolfo e Maria Cristina, e também a minhas irmãs por todo apoio e sacrifícios que tiveram que ser feitos durante a minha graduação. Vocês são muito importantes na minha vida e, com toda certeza, eu não teria conseguido sem a ajuda de vocês.

Agradeço também a toda minha família e a minha namorada Jéssica pela ajuda, paciência e amor. A todos meus amigos de turma, que batalharam junto comigo durante toda essa etapa. Todos são muito especiais para mim, e espero que nossa amizade e parceria continue por muito tempo.

Agradeço a toda equipe de professores da Universidade de Pernambuco pelo seu empenho em proporcionar uma ótima qualidade de ensino para todos os alunos. E um agradecimento especial ao meu orientador Carmelo Bastos e a Danilo Araújo por toda ajuda e ótimos conselhos durante todo o período deste projeto.

Resumo

Em um mundo cada vez mais necessitado de serviços de telecomunicações de banda larga, as redes ópticas se apresentam como a melhor alternativa. O custo benefício também é um atrativo para que esse tipo de tecnologia seja, cada vez mais, alvo de pesquisas e desenvolvimento. Como em qualquer outra área da engenharia, os projetos de redes ópticas passam por vários processos antes de serem implantados de fato. Uma das etapas mais importantes é o projeto validado por simulação. Nessa fase do planejamento, geralmente são utilizadas ferramentas computacionais que verificam o desempenho da rede projetada. Esse tipo de abordagem tem um ponto negativo, que é o tempo de processamento. Simulações de projetos de redes reais podem durar até semanas devido a complexidade computacional do problema. Pensando nisso, algumas propostas alternativas estão sendo estudadas para estimar o desempenho de redes ópticas. Este trabalho de conclusão de curso tem como objetivo principal analisar a robustez de uma abordagem que utiliza redes neurais para realizar a estimativa da probabilidade de bloqueio em uma rede óptica. Foram feitos experimentos para verificar o desempenho desse estimador quando existe uma variação de carga na rede. Os resultados obtidos foram promissores e a taxa de erro apresentada ficou abaixo de 0,1%. Estes resultados indicam que a utilização de métodos alternativos podem poupar muito tempo de processamento e conseqüentemente proporcionar uma economia considerável para empresas que fazem uso desse processo de planejamento.

Abstract

In a world where telecommunications broadband services become increasingly a necessity, optical networks are presented as the best alternative. The cost of this technology is also an attraction that increases interest in research and development in that area. As in any other area of engineering, projects in optical networks undergo various processes before being implanted in fact. One of the most important steps is the design validated by simulation. At this stage of planning, usually are used computational tools that verify the performance of the designed network. This approach has a downside, which is the processing time. Simulations of real networks projects can last weeks due to the computational complexity of the problem. Thinking about it, some alternative proposals are being studied to estimate the performance of optical networks. This monograph aims to analyze the robustness of an approach that uses neural networks to realize the estimated blocking probability in an optical network. We did experiments to verify the performance of this tool when there is a variation in network load. The results were promising and the error rate presented was below was 0.1%. These results indicate that the use of alternative methods can save much processing time and therefore provide considerable savings for companies that make use of this planning process.

Sumário

Capítulo 1 <i>Introdução</i>	1
1.1 Motivação e Caracterização do Problema.....	1
1.2 Hipóteses e Objetivos.....	3
1.3 Organização do Documento.....	3
Capítulo 2	5
<i>Fundamentação Teórica</i>	5
2.1 Redes Neurais Artificiais	5
2.1.1 História	5
2.1.2 O Neurônio Biológico.....	6
2.1.3 Neurônio Artificial	7
2.1.4 Redes MLP	8
2.1.5 Algoritmo de <i>Backpropagation</i>	9
2.1.6 Validação Cruzada	9
2.2 Redes Ópticas.....	10
2.2.1 Dispositivos da Camada Óptica.....	11
2.2.2 Formas de Degradação do Sinal na Camada Física	12
2.2.3 Métricas para Qualidade do Sinal e na Rede	13
2.3 Métricas de Ciência da Redes.....	14
2.3.1 Coeficiente de Clusterização	14
2.3.2 Densidade	15
2.3.3 Comprimento médio do caminho.....	16
2.3.4 Entropia	16
2.3.5 Diâmetro	16

Capítulo 3 Contribuição e Propostas	17
3.1 Proposta	17
3.2 Base de Dados	18
3.2.1 Obtenção da Base de Dados para os Experimentos	19
Capítulo 4 Experimentos e Resultados	22
4.1 Arranjo Experimental	22
4.1.1 Características Gerais da Camada Física para a MLP	22
4.1.2 Treino e Avaliação da Rede Neural	23
4.2 Resultados	24
Capítulo 5 Conclusões e Trabalhos Futuros	27
5.1 Conclusões.....	27
5.2 Trabalhos Futuros	28
Referências	29

Índice de Figuras

Figura 1. Gráfico de treino e validação da MLP utilizada por Araújo	2
Figura 2. Representação básica de um neurônio natural	6
Figura 3. Representação do neurônio artificial	7
Figura 4. Estrutura ilustrativa de uma rede MLP	8
Figura 5. Ilustração da evolução dos erros de treinamento e validação no processo de validação cruzada.	10
Figura 6. Exemplo de valores do coeficiente de clusterização para três casos.....	15
Figura 7. Densidade para rferentes redes	16
Figura 8. Arquitetura proposta para a RNA	18
Figura 9. EMQ para o conjunto de teste de 100 e 200 erlangs	24
Figura 10. EMQ para todos os conjuntos de carga	25
Figura 11. Comparativo entre a PB estimada pelo SIMTON e pela RNA.....	26

Índice de Tabelas

Tabela 1. Parâmetros de simulação de rede.....	19
Tabela 2. Conjuntos de dados utilizados nos experimentos	20
Tabela 3. Subconjuntos relacionados a probabilidade de bloqueio.....	21
Tabela 4. Rótulos e especificações dos OXCs utilizados.....	22

Tabela de Símbolos e Siglas

ASE - *Amplified Spontaneous Emission.*

BER - *Bit Error Rate.*

BPRNA - Probabilidade de Bloqueio Estimada pela RNA.

BPSIMTON - Probabilidade de Bloqueio Estimada pelo SIMTON.

CC - Coeficiente de Clusterização.

DWDM - *Dense Wavelength Division Multiplexing.*

EDFA - *Erbium Doped Fiber Amplifier.*

EMQ - Erro Médio Quadrático.

FWM - *Four Wave Mixing.*

I_{max} - Numero Máximo de Iterações da RNA.

LASER - *Light Amplification by Stimulated Emission of Radiation.*

LED - *Light-Emitting Diode.*

MLP - *Multi-Layer Perceptron.*

NAEXISTENTES - Número de arestas existentes entre os nós vizinhos.

NAPOSSIVEIS - Número máximo de arestas possíveis entre os nós vizinhos.

OADMs - *Optical Add and Drop Multiplexers.*

OSNR - *Optical Signal to Noise Ratio.*

OXCs - *Optical Cross-Connect.*

QoS - *Quality of Service.*

RFA - *Raman Fiber Amplifiers.*

RNA - Rede Neural Artificial.

SPM - *Self Phase Modulation.*

SSE - *Source Spontaneous Emission.*

WDM - *Wavelength Division Multiplexing.*

XPM - *Cross Phase Modulation.*

Capítulo 1

Introdução

Neste trabalho de conclusão de curso é feita uma análise de uma ferramenta baseada em redes neurais que tem por objetivo realizar estimativas de probabilidade de bloqueio em redes ópticas. Esse tipo de ferramenta pode proporcionar uma grande redução no tempo de execução do processo de planejamento, que pode envolver semanas em decorrência do alto custo de processamento computacional requerido.

Este capítulo está dividido em 3 seções. Na Seção 1.1 é apresentado o escopo do problema e a motivação para o estudo proposto neste projeto. A Seção 1.2 apresenta os objetivos e hipóteses para este trabalho e por fim, na Seção 1.3 é apresentada a organização do restante do documento.

1.1 Motivação e Caracterização do Problema

Nos últimos anos estamos presenciando muitas mudanças na área de telecomunicações em todo o mundo. Com o surgimento de novas tecnologias que demandam taxas de transmissão muito elevadas, as redes ópticas vem se tornando a melhor opção para suprir esta necessidade [13]. Por esse motivo as redes DWDM (*Dense Wavelength Division Multiplexing*) se tornaram grande alvo de pesquisas na indústria e no meio acadêmico. Ela permite utilizar de forma mais eficiente a banda passante das fibras ópticas. Em uma única fibra pode-se utilizar de forma simultânea um grande número de canais ópticos que trabalham de forma independente em comprimentos de onda diferentes. Em cada comprimento de onda é possível atingir taxas bastante altas, que chegam a 40Gbps ou 100Gbps em equipamentos disponíveis atualmente no mercado [14].

A prática de simulações de aplicações em engenharia é algo bastante utilizado. Em redes ópticas não é diferente, a utilização de ferramentas para

simulação e extração de métricas desse tipo de projeto é freqüente. Desenvolvida por Chaves [6], o SIMTON é um exemplo de ferramenta computacional que realiza simulações para redes ópticas transparentes, e por meio dos seus resultados é possível analisar algumas características da rede, como por exemplo, a probabilidade de bloqueio, que é uma medida estatística referente as requisições de chamadas que não foram estabelecidas devido a falta de recursos da rede [10].

Aplicações de simulação do tipo Monte Carlo, como no SIMTON, podem ajudar bastante. Porém, dependendo do tipo de simulação, pode necessitar de um longo tempo de execução para que se obtenham os resultados desejados. Pensando nisso, Araújo e colaboradores [2] propuseram um método alternativo utilizando Redes Neurais Artificiais (RNAs) para minimizar o tempo necessário para estimar a probabilidade de bloqueio em redes ópticas. Esse método consiste basicamente em obter vários padrões de redes com suas respectivas probabilidades de bloqueio por simulações no SIMTON e a partir deles realizar o treinamento supervisionado de uma Rede Neural MLP (*Multi-Layer Perceptron*). Utilizando a rede neural já treinada, é possível realizar uma regressão que aproxima de forma satisfatória os resultados obtidos com a ferramenta de simulação. A Figura 1 apresenta o erro médio quadrático (EMQ) em função do número de iterações para treinamento e validação da MLP utilizada no trabalho de Araújo [2].

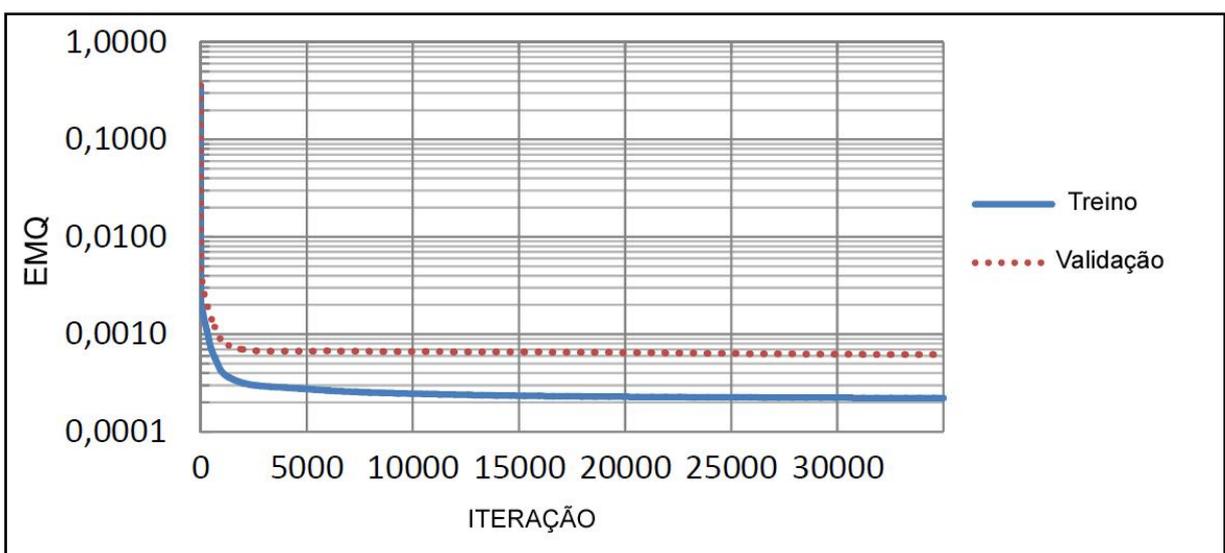


Figura 1 - Gráfico de treino e validação da MLP utilizada por Araújo [2].

Entretanto, no trabalho de Araújo [2], só foram realizados experimentos com valores de carga fixa, e como essa métrica influencia bastante na probabilidade de bloqueio, não pode ser ignorada nesse tipo de estudo [10]. Neste trabalho foi feita uma avaliação do estimador proposto por Araújo [2] utilizando uma Rede Neural treinada com padrões de redes ópticas e suas probabilidades de bloqueio que possuem diferentes valores de carga. Usando a rede Neural treinada foi avaliado se é possível obter estimativas confiáveis de probabilidade de bloqueio para redes ópticas com cargas que nunca foram apresentadas a RNA a partir de processos de interpolação não lineares.

1.2 Hipóteses e Objetivos

No trabalho apresentado em [2] já ficou comprovado que a ferramenta baseada em RNAs funciona e apresenta resultados com taxas de erro na ordem de 10^{-4} . Esses resultados mostraram o grande potencial que as RNAs possuem para este tipo de problema. Como uma grande característica das redes neurais é a capacidade de generalização [3], pressupõe-se que ao apresentar novas configurações de redes ópticas com cargas que nunca foram mostradas para a RNA, a mesma consiga realizar uma estimativa satisfatória por interpolação.

Com base nessa hipótese, este trabalho de conclusão de curso tem como objetivo realizar um processo experimental que inclui a reprodução do trabalho original. Por fim, será analisada a robustez da rede apresentando padrões gerados no SIMTON com cargas que ainda não são conhecidas pela rede. O processo será reproduzido várias vezes de forma independente para que seja possível avaliar a robustez do processo.

1.3 Organização do Documento

Este documento está dividido em 5 capítulos. No capítulo 2 serão abordados temas para uma melhor compreensão do estudo, tais como Redes Neurais Artificiais e conceitos de redes ópticas. O capítulo 3 é responsável por descrever a

contribuição e a proposta deste trabalho. No capítulo 4 serão mostrados os experimentos realizados e os resultados obtidos a partir deles. Por fim, no capítulo 5 serão discutidos as principais conclusões e trabalhos que podem vir a serem feitos a partir das conclusões deste projeto de conclusão de curso.

Capítulo 2

Fundamentação Teórica

Neste capítulo serão apresentados os conceitos necessários para uma melhor compreensão do problema tratado nesta monografia. Ele está dividido em 3 subseções. A Seção 2.1 explica os conceitos básicos de Redes Neurais, tendo como foco os tipos de RNAs utilizadas neste projeto. Na Seção 2.2 é apresentada uma revisão sobre os principais conceitos de redes ópticas, e por fim, na Seção 2.3 é explicado alguns conceitos e métricas de ciência das redes que serão utilizadas neste estudo.

2.1 Redes Neurais Artificiais

Redes Neurais Artificiais são ferramentas computacionais que tentam resolver problemas inspirados no sistema nervoso central humano. Ao invés de programar a máquina de forma estática para executar uma única função, esse tipo de abordagem cria uma estrutura que tem a capacidade de aprender a resolver um problema de forma mais generalizada [3].

2.1.1 História

McCulloch (neurofisiologista) e Pitts (matemático) foram os primeiros a apresentar um modelo de para um neurônio artificial. Esse estudo foi apresentado em 1943 e sugeria a construção de uma máquina que simulasse o cérebro humano.

Donald Hebb, após o trabalho de McCulloch e Pitt, propõe a regra de aprendizagem que é a base para todas as outras regras em 1949 no seu livro, *The organization of Behavior* [15].

Todavia, apenas em 1958 foi realizada a primeira aplicação prática de redes neurais. Frank Rosenblatt desenvolveu uma rede neural *Perceptron* que era capaz de reconhecer padrões baseado em uma regra de aprendizagem. Após esse acontecimento, o interesse em redes neurais aumentou bastante. Outros trabalhos surgiram, porém percebeu-se que uma rede *Perceptron* e suas extensões podiam

apenas resolver problemas linearmente separáveis, o que fez com que as redes neurais fossem um pouco desacreditadas por volta da década de 1970.

O ressurgimento das redes neurais ocorreu em 1982, em decorrência do trabalho do físico John Hopfield. Neste trabalho, Hopfield tratou sobre as propriedades associativas das RNAs e sobre o algoritmo de *backpropagation* [15].

2.1.2 O Neurônio Biológico

O modelo dos neurônios utilizados em RNAs são baseados nos neurônios naturais dos animais. Essas células estão presentes no sistema nervoso central e desempenham funções indispensáveis como raciocínio, comportamento e transmissão do impulso nervoso através das sinapses [11]. O neurônio é capaz de receber vários estímulos de outras células e ponderá-los a partir do seu grau de importância. Ao receber esses sinais, o neurônio realiza o processamento, e se o nível de excitação atingir um certo limiar ele dispara neurotransmissores pelo seu axônio que está ligado a dendritos de uma outra célula [12]. A Figura 2 representa de forma simplificada a estrutura de um neurônio biológico.

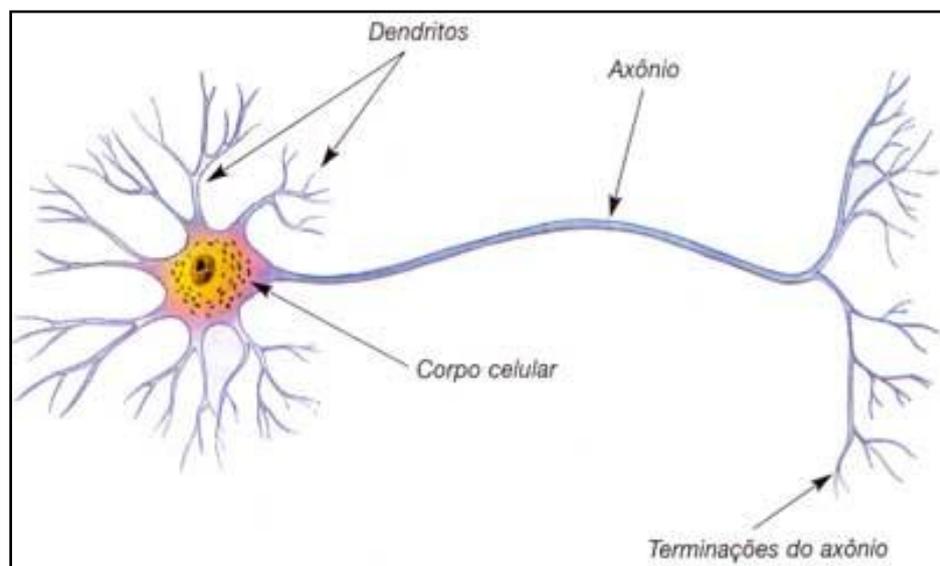


Figura 2 - Representação básica de um neurônio natural.

2.1.3 Neurônio Artificial

O modelo geral para um neurônio artificial é mostrado na Figura 3 e é baseado na proposta inicial feita por McCulloch e Pitts.

Este modelo procura representar de forma bastante simples o neurônio natural através de uma regra de propagação e uma função de ativação. A transmissão do sinal adiante, como no neurônio biológico, depende de um limiar de ativação, ou seja, o impulso só será transmitido se atingir um certo valor pré-definido.

Considere $x_1, x_2, x_3, \dots, x_n$, como sendo as entradas do neurônio, considere também $w_1, w_2, w_3, \dots, w_n$, como sendo os pesos de cada entrada, s como sendo a soma das entradas ponderadas e Θ , como sendo a polarização externa.

A entrada s é dada por:

$$s = \sum_{i=1}^n x_i * w_i + \Theta, \quad (2.1)$$

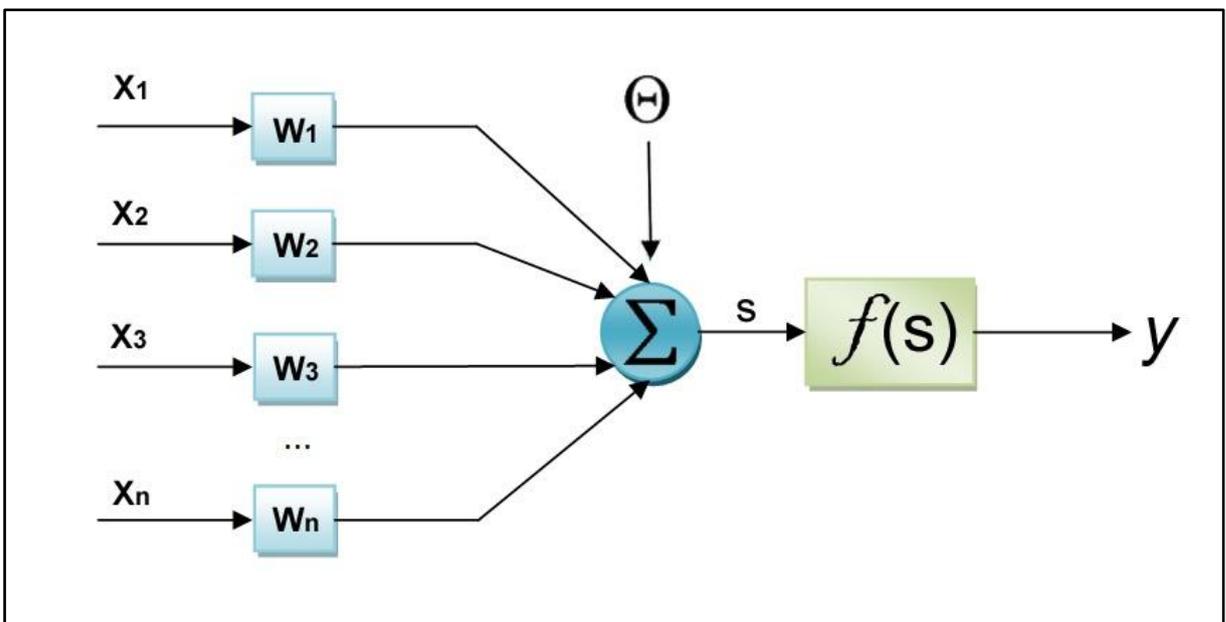


Figura 3 - Representação do neurônio artificial.

Se a função de ativação $f(s)$ for uma função do tipo degrau, a saída é discreta, e pode assumir os valores 0 ou 1. Entretanto, as funções de ativação mais comuns para aplicações práticas, inclusive de regressão, são a sigmóide logística ou tangente hiperbólica.

2.1.4 Redes MLP

Redes MLP (*Multi Layer Perceptron*) podem ser consideradas como uma generalização da rede *Perceptron* simples, exceto pela adição de uma ou mais camadas intermediárias, que são conhecidas como camadas escondidas.

Esse tipo de rede possui como características ter no mínimo três camadas, onde a primeira seria a camada de entrada, a última seria a camada de saída e as demais seriam as camadas intermediárias. A camada de entrada é a responsável por receber as informações dos padrões passados para a rede, ou seja o *input* do sistema. Já a camada intermediária é responsável pela não linearização da rede e seus neurônios geralmente utilizam como função de ativação a tangente hiperbólica ou a sigmóide logística. Na camada de saída estão os resultados ao qual o sistema se propões a classificar ou prever. A Figura 4 mostra um modelo da estrutura básica de uma rede MLP.

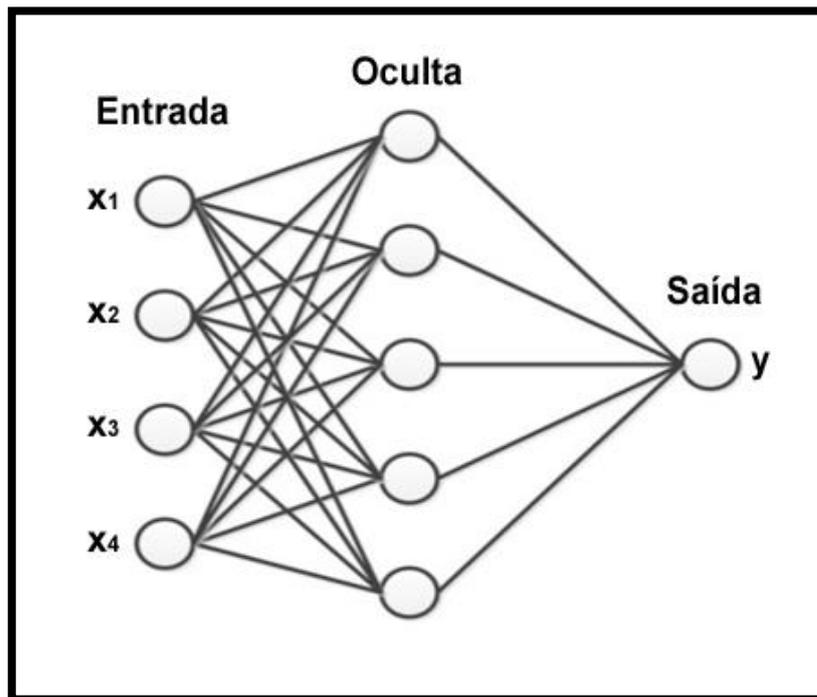


Figura 4 - Estrutura ilustrativa de uma rede MLP.

Assim como as outras redes neurais, na MPL é necessário que exista um processo de aprendizagem, onde é selecionado um conjunto de pesos ótimos para que a rede apresente a maior taxa de acertos possíveis. Para este processo de

treinamento de redes MLP, geralmente utiliza-se o algoritmo de *backpropagation* [15].

2.1.5 Algoritmo de *Backpropagation*

No algoritmo de *backpropagation* são realizadas duas fases principais, que são chamadas de *forward* e *backforward*. Na fase de *forward* ocorre a propagação dos estímulos (padrões de treinamento) da camada de entrada até a camada de saída. Após isso, é calculado o erro correspondente ao sinal. A fase seguinte é a de *backward*, onde os erros são propagados de forma recursiva da última camada para a camada de entrada através da rede. Nesse processo, os pesos são reajustados utilizando a regra delta. Essa regra tem como objetivo reajustar os pesos fazendo com que haja uma redução da distância entre a saída desejada e a atual [15].

2.1.6 Validação Cruzada

Uma rede Neural pode perder a sua capacidade de generalização caso seja treinada em excesso decorando os padrões apresentados (*overfitting*). Neste caso de treinamento em excesso, a rede acaba memorizando os padrões. Para evitar este problema é utilizado uma técnica chamada de validação cruzada. Neste método é utilizado um subconjunto de padrões diferentes do de treino, onde em cada ciclo de treino também é calculado o erro do conjunto de validação. Normalmente este erro vai diminuindo à medida que vão sendo feitos os ciclos de treino. Quando esse erro do conjunto de validação cruzada começa a aumentar, é interrompido o treinamento com a intenção de manter o melhor poder de generalização da RNA [11]. A Figura 5 representa de forma ilustrativa o procedimento da validação cruzada

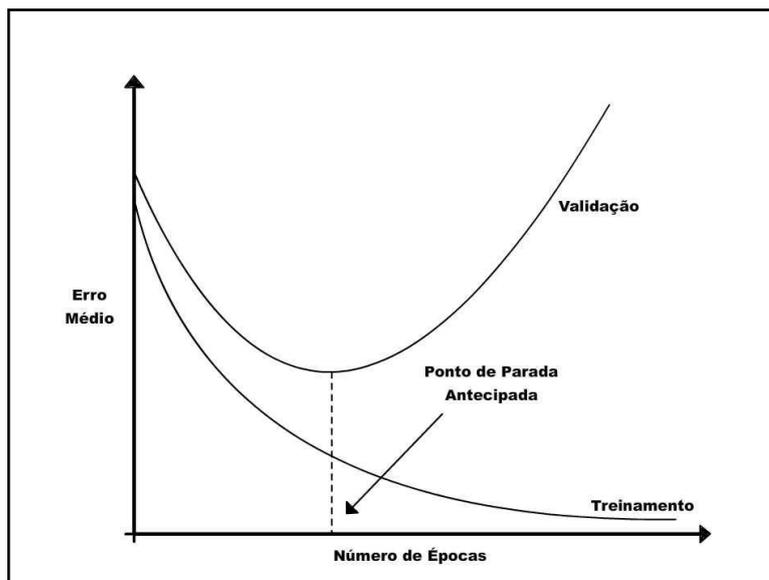


Figura 5 - Ilustração da evolução dos erros de treinamento e validação no processo de validação cruzada.

2.2 Redes Ópticas

As redes ópticas oferecem uma largura de banda superior a outras tecnologias, como por exemplo, transmissão via fios de cobre. Além dessa vantagem, elas também evitam interferências eletromagnéticas. As primeiras implementações desse tipo de rede WDM (*Wavelength Division Multiplexing*) foram feitas ponto-a-ponto, com a finalidade de aumentar a capacidade de transmissão por fibra óptica. Redes WDM utilizam dispositivos eletrônicos para desempenhar as funções de roteamento e serviços de gerenciamento. Esses tipos de redes são conhecidas como redes de primeira geração. Com o desenvolvimento de equipamentos mais precisos, amplificadores ópticos e lasers de melhor qualidade foi possível transmitir canais WDM de forma simultânea, aumentando a capacidade total de transmissão. Com isso, surgiu a tecnologia conhecida como DWDM (*Dense Wavelength Division Multiplexing*).

Com o tempo, os sistemas ópticos estão deixando de ser apenas enlaces de alta capacidade para se tornar uma tecnologia de redes de alta capacidade. Isso ocorreu após o desenvolvimento de equipamentos como OADMs (*Optical Add and Drop Multiplexers*) e OXCs (*Optical Cross-Connect*). Nesse novo modelo de rede são utilizados serviços que operam apenas no domínio óptico, ao contrário das

tecnologias anteriores que utilizavam dispositivos optoeletrônicos para conversão de domínio [1].

2.2.1 Dispositivos da Camada Óptica

- **Transmissores:** Existem dois principais tipos de transmissores em redes de comunicação ópticas, que são o LED (*Light-Emitting Diode*) e o LASER (*Light Amplification by Stimulated Emission of Radiation*). A utilização de cada um depende do escopo do projeto que for utilizado. Os lasers possuem um melhor desempenho, mas em contrapartida possuem um custo mais elevado [13].
- **Fibra Óptica:** É o meio pelo qual o sinal óptico é transmitido pela rede. Possui um núcleo constituído de um material com índice de refração maior do que o da casca. Essa característica cria um efeito de "espelho" no interior da fibra, fazendo com que o núcleo sirva como meio de passagem do sinal. Além do revestimento interno, existe também uma capa de proteção que cobre toda a estrutura. Fibras ópticas possuem uma largura de banda maior do que cabos de cobre e não sofrem com os efeitos causados pelo eletromagnetismo, porém apresentam alguns efeitos negativos característicos desse tipo de tecnologia, como o espalhamento estimulado de Raman e o efeito Kerr [1].
- **Receptores Ópticos:** Esses dispositivos são responsáveis pela conversão do sinal óptico para sinal elétrico [13]. Esse sistema possui um componente bastante importante, o fotodetector. Esse componente gera uma corrente proporcional à potência do sinal óptico de entrada.
- **Amplificadores Ópticos:** Com a propagação da luz na fibra óptica, o sinal óptico sofre um efeito de atenuação. Esta perda de potência do sinal pode ser tão alta que torna impossível o reconhecimento do sinal pelo receptor [13]. Duas soluções para este problema é a utilização de amplificadores ou regeneradores. Os regeneradores convertem o sinal do domínio óptico para o elétrico antes de uma degradação que interfira na recepção e depois o converte novamente para o domínio óptico. Já os amplificadores são dispositivos que podem amplificar o

sinal sem precisar convertê-lo para o domínio elétrico [1]. Os amplificadores mais utilizados são os amplificadores Raman (RFA - *Raman Fiber Amplifiers*) e o EDFA (*Erbium Doped Fiber Amplifier*).

- **Comutadores Ópticos:** Estes dispositivos conhecidos como OXC (*Optical Crossconnect*) permitem que uma rede óptica possa sofrer mudanças de configuração quando necessário, fazendo com que a rede não possua um modelo estático. Ele permite que *Lightpaths* sejam criados ou eliminados dependendo da necessidade. Um OXC também pode detectar falhas na rede e realocar *lightpaths* que apresentam falhas [1].

2.2.2 Formas de Degradação do Sinal na Camada Física

À medida que o sinal óptico se propaga pela rede totalmente transparente, ele sofre uma determinada degradação. Isso acontece porque não existe regeneração nos nós intermediários do *lightpath* [1]. Nesta seção serão descritas algumas dessas formas de degradação nesse tipo de rede.

- **Atenuação:** É um efeito que está relacionado à redução da potência do sinal à medida que é transmitido. Este tipo de penalidade pode prejudicar bastante o alcance do enlace [13].
- **Dispersão:** É um efeito que altera a forma do sinal à medida que é propagada em uma fibra. Ao longo da propagação o pulso pode se alargar gerando interferência entre bits transmitidos. Por esse motivo, este tipo de degradação limita a taxa de transmissão máxima na fibra. Como exemplo, tem-se a dispersão intermodal e a dispersão cromática [1].
- **Ruído:** É um sinal aleatório que tem origem geralmente de um fenômeno ou propriedade da natureza e geralmente influencia bastante na comunicação digital, pois pode facilitar uma má interpretação dos bits transmitidos [7]. Em comunicações ópticas, os tipos de ruídos mais importantes são o SSE (*Source spontaneous Emission*) que ocorre nos lasers, o ASE (*Amplified Spontaneous Emission*) que ocorre nos amplificadores, o ruído balístico, que pode ser

detectado nos receptores ópticos e o ruído térmico que é característico do equipamento utilizado [1].

- **Interferência:** É um processo semelhante ao ruído, porém nesse caso o sinal de interesse sofre influência de outros sinais ou sistemas [7]. Em comunicações ópticas, existem muitos tipos de interferências, as mais importantes são: o *crosstalk*, a modulação de fase cruzada (XPM - *Cross Phase Modulation*), a auto modulação de fase (SPM - *Self Phase Modulation*) e a mistura das quatro ondas (FWM - *Four Wave Mixing*).

2.2.3 Métricas para Qualidade do Sinal e na Rede

A qualidade de um sinal em uma rede pode ser medida utilizando como referência várias métricas de desempenho de rede. Nesta seção serão descritos os indicadores mais utilizados para esta finalidade.

- **Probabilidade de Bloqueio:** É uma medida estatística que indica a quantidade de chamadas requisitadas que não foram atendidas por falta de recursos na rede. Quanto maior a probabilidade de bloqueio, menor a qualidade de serviço na mesma, pois menos usuários serão atendidos [1]. A probabilidade de bloqueio pode ser estimada pela Eq. (2.2):

$$PB = \frac{C_{bloqueadas}}{C_{total}}, \quad (2.2)$$

onde $C_{bloqueadas}$ é a quantidade de chamadas bloqueadas e C_{total} é o número total de chamadas.

- **Relação Sinal Ruído:** É uma medida utilizada para monitorar a quantidade de ruído que foi adicionada por um canal de comunicação. Esta métrica é importante porque influencia na qualidade de serviço da rede. A OSNR (*Optical Signal to Noise Ratio*) representa a razão entre a potência do sinal de interesse e a potência do ruído. A qualidade do sinal entregue pelo canal de comunicação será melhor para valores menores de OSNR.
- **Taxa de Erro de Bit do Sinal:** É uma métrica de desempenho utilizada para quantificar a qualidade de serviço (QoS - *Quality of Service*) da rede, tanto na

transmissão quanto na recepção. A BER (*Bit Error Rate*) é calculada contando-se a quantidade de bits errados em uma determinada seqüência de informações. Por exemplo, uma BER de $2 \cdot 10^{-6}$ significa que em 10^6 bits transmitidos, 2 estavam errados [1].

2.3 Métricas de Ciência da Redes

A ciência das redes é um campo acadêmico interdisciplinar, e pode ser definida como o estudo dos fundamentos teóricos do comportamento dinâmico e estrutural das redes e suas aplicações [16]. Dentre os principais pontos analisados, estão as propriedades encontradas na redes. Nesta seção serão apresentadas as definições e características de algumas destas propriedades.

2.3.1 Coeficiente de Clusterização

O coeficiente de clusterização (CC), na teoria dos grafos, é definida como a razão entre o número de arestas existentes entre os vizinhos de um nó e o total de arestas possíveis entre estes mesmos vizinhos [8]. A Figura 6 demonstra três casos de redes com diferentes coeficientes de clusterização. Nos três casos tem-se a possibilidade da existência de três arestas entre os vizinhos do nó em destaque, entretanto, no primeiro caso temos três arestas de fato sendo utilizadas, no segundo caso temos apenas uma aresta entre os vizinhos e no terceiro caso temos nenhuma aresta que conecte os vizinhos. Com isso, os coeficientes de clusterização para estes casos seriam 1, 1/3 e 0, respectivamente. O cálculo do CC por nó é dado pela seguinte equação:

$$CC = \frac{NA_{existentes}}{NA_{possiveis}}, \quad (2.3)$$

Onde $NA_{EXISTENTES}$ é a quantidade de arestas existentes entre os vizinhos do nó e $NA_{POSSIVEIS}$ é o número máximo de arestas que poderiam existir entre estes mesmos vizinhos.

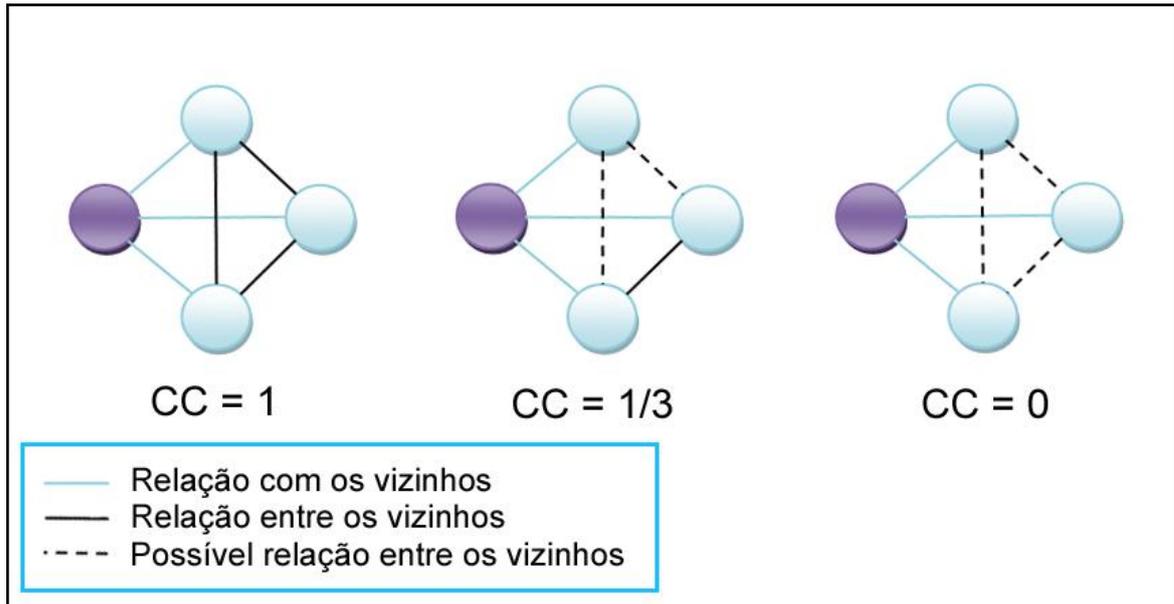


Figura 6 - Exemplos de valores do coeficiente de clusterização.

O coeficiente de clusterização da rede é dada pela média do coeficiente de clusterização de todos os nós da mesma [4].

2.3.2 Densidade

A densidade da rede é relacionada a quantidade de ligações existentes na rede. Redes são consideradas de alta densidade quando apresentam muitas conexões entre os seus nós. O cálculo da densidade da rede é definido pela razão entre a quantidade de ligações existentes na rede e a quantidade máxima de ligações que poderiam existir considerando todos os nós da rede. Na Figura 7 são mostrados três cenários para uma rede de quatro nós. No primeiro não existe nenhuma conexão entre os nós, logo, a densidade da rede é igual a 0. Já no segundo caso, todos os nós estão interligados, caracterizando uma rede com o seu máximo de conexões, e portanto, apresenta densidade igual a 1. No terceiro caso existem apenas quatro conexões, logo a densidade da rede é aproximadamente 0,67 [9].

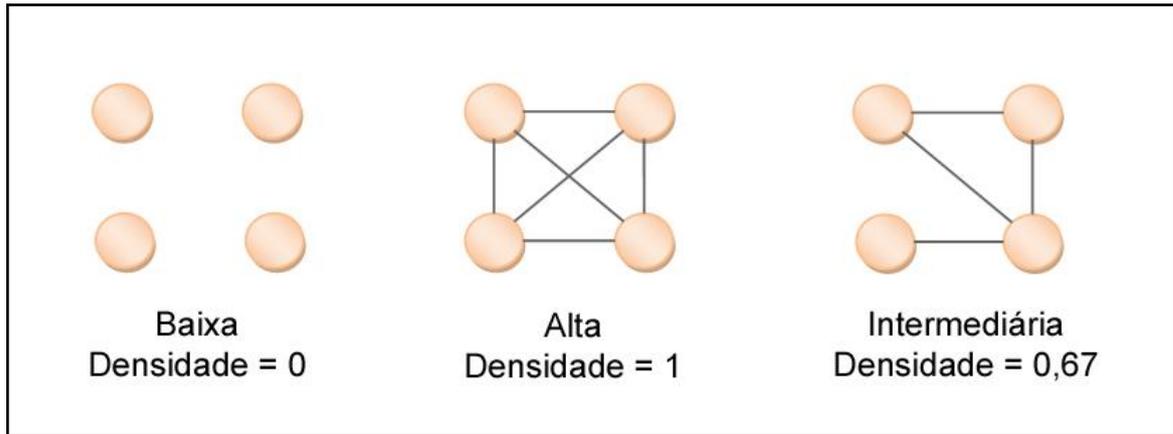


Figura 7 - Densidade para diferentes redes.

2.3.3 Comprimento médio do caminho

A rota de uma rede é dada pela seqüência de arestas (*links*) que conecta um nó a outro. O comprimento da rota é dado pela soma dos pesos de todas as arestas pertencentes a ela. O comprimento médio de uma rota pode ser definido como sendo a média das distâncias de todas as rotas pertencentes a rede, utilizando para este cálculo, os percursos com a menor distância entre os nós [5].

2.3.4 Entropia

Outra característica estudada pela ciência das redes é a entropia. O conceito de entropia pode sofrer variações dependendo do contexto em que é aplicado. Para o estudo apresentado neste trabalho a entropia pode ser definida como sendo uma métrica que mede o nível médio de heterogeneidade da rede baseada nas ligações existentes. É verificado se estas ligações estão organizadas ou dispostas de forma mais aleatória.

2.3.5 Diâmetro

O diâmetro é outra medida observada na teoria dos grafos e que considera as rotas existentes na rede. Para se obter o seu valor, calcula-se o conjunto de menores caminhos entre os nós da rede. Com essa informação, pode-se definir o valor do diâmetro como sendo a maior rota, em termos de *hops*, dentre o conjunto de menores rotas [16].

Capítulo 3

Contribuição e Propostas

Este capítulo tem como objetivo mostrar as contribuições que este estudo oferece, como também, descrever as propostas que foram feitas para solucionar o problema tratado neste projeto de conclusão de curso.

3.1 Proposta

A proposta deste estudo é verificar a robustez à variação de carga de uma ferramenta baseada em redes neurais que tem como objetivo prever métricas de desempenho de redes ópticas, neste caso mais especificamente, a probabilidade de bloqueio de chamadas.

Para que se tenha uma economia de tempo de simulação é interessante a possibilidade de utilização de RNAs. Com o estudo proposto, será possível verificar e validar a qualidade dos resultados obtidos pela ferramenta. Uma vez confirmada a eficácia do estimador, ele poderá ser utilizado com mais segurança como base para outros estudos ou até mesmo ser adotado em projetos industriais de engenharia.

Para a realização do experimento foram utilizadas métricas de redes DWDM que são características que tendem a influenciar na probabilidade de bloqueio que a rede apresenta. As métricas utilizadas no projeto foram o coeficiente de clusterização, a densidade, o comprimento médio das rotas na rede, a entropia, o diâmetro e a carga da rede. Como no experimento proposto em [2], também foram utilizadas como entradas para a RNA duas características da camada física, que são o número máximo de comprimentos de onda, devido a sua relação com os *links* da rede, e o tipo do OXC utilizado por possuir relação com os nós da rede.

Como já foi visto na seção 2.1 deste trabalho, as Redes Neurais Artificiais (RNAs), são poderosas ferramentas computacionais que podem ser utilizadas para resolução de vários problemas, inclusive de predição. Neste projeto foi utilizada uma rede MLP que possui oito entradas na primeira camada, onde cada uma representa uma das métricas mencionadas anteriormente, uma camada escondida com uma

quantidade de 17 neurônios e uma camada de saída, composta por um neurônio artificial que representa a probabilidade de bloqueio estimada. A arquitetura descrita pode ser visualizada na Figura 8.

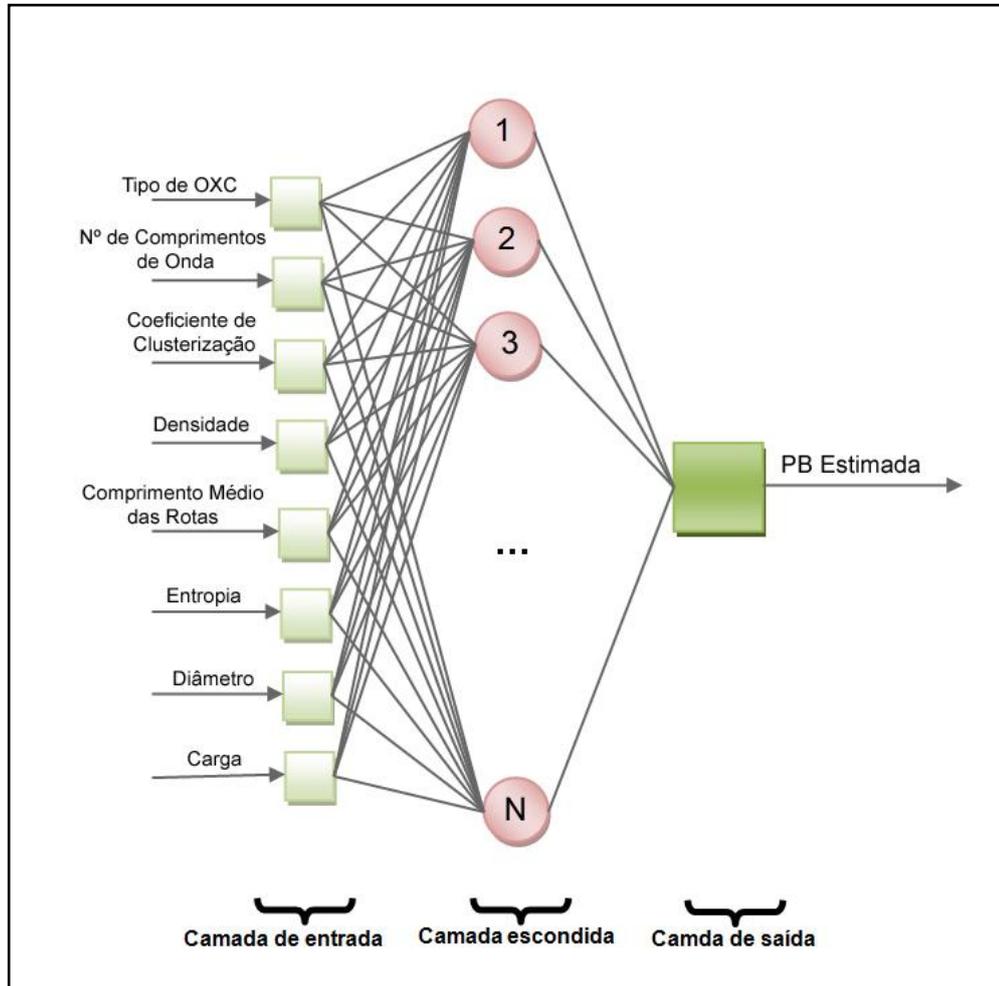


Figura 8 - Arquitetura proposta para a RNA.

3.2 Base de Dados

Como mencionado no capítulo 1 e Araújo [2], existem outras ferramentas que simulam e avaliam o comportamento de redes DWDM. Uma destas ferramentas utilizadas para simulação de redes ópticas transparentes é o SIMTON [6]. Ele é um software originalmente implementado em C++ e que tem como objetivo avaliar a probabilidade de bloqueio levando em consideração características inerentes da rede. Ele utiliza um modelo de camada física que considera alguns efeitos, dentre eles estão: atenuação na fibra, perda nos dispositivos, dispersão cromática residual, mistura de quatro ondas, entre outras.

A base de dados que foi utilizada para o treinamento da rede proposta neste estudo foi gerada a partir de uma versão do SIMTON implementada em Java. Esta base é composta por um conjunto de arquivos de texto que contem as informações sobre as configurações das redes geradas no simulador. Essas configurações, por sua vez, são compostas pelas métricas descritas na Seção 3.1 e também pela probabilidade de bloqueio referente a cada configuração de rede. Estes conjuntos de dados estão separados levando em consideração a carga utilizada na rede. Outra base foi gerada utilizando configurações com cargas intermediárias. Esta base foi utilizada para os testes finais do experimento, com a finalidade de validar a hipótese proposta neste estudo.

3.2.1 Obtenção da Base de Dados para os Experimentos

Para a obtenção dos exemplos de redes ópticas utilizados no experimento foi utilizado o SIMTON. Como no experimento proposto por Araújo [2], foram considerados os seguintes efeitos para a avaliação do OSNR nos *lightpaths*: O ruído ASE nos amplificadores, a saturação de ganho nos amplificadores, a saturação do ruído ASE em EDFAs, a dispersão cromática residual, o *crosstalk* no OXC e o efeito da mistura de quatro ondas. Na Tabela 1 estão apresentados os valores para os parâmetros de rede utilizados nas simulações.

Tabela 1. Parâmetros de simulação de rede.

Parâmetro	Valor	Definição
$OSNR_{in}$	30 dB	Relação Sinal-Ruído de Entrada
$OSNR_{QoS}$	23 dB	OSNR para o critério de QoS
B_o	100 GHz	Largura de Banda do Filtro Óptico
Δf	100 GHz	Espaçamento dos Canais
λ_i	1529,56 nm	Primeiro comprimento de onda
α	0,2 dB/Km	Coefficiente de Perda da Fibra
L_{Mux}	3 dB	Perda no Multiplexador
L_{Demux}	3 dB	Perda no Demultiplexador
L_{Switch}	3 dB	Perda na Chave Óptica
W_{MIN}	4	Número Mínimo de Comprimento de Ondas por Fibra
W_{MAX}	40	Número Máximo de Comprimento de Ondas por Fibra
P_{sat}	23 dBm	Potência de Saturação na Saída do Amplificador
F_0 (NF)	3,162 (5 dB)	Fator de Ruído no Amplificador (Figura de Ruído)

A partir do SIMTON foram gerados 8 conjunto de dados, onde cada um teve sua avaliação realizada considerando níveis de carga diferentes. Dois desses conjuntos foram utilizados no processo de treinamento da MLP, o conjunto com carga de 200 erlangs e o conjunto de 100 erlangs. Cada um desses conjuntos tinham o total de 24000 exemplos de redes, divididos em 12 subconjuntos de 2000 padrões distribuídos de acordo com o seu nível de probabilidade de bloqueio. Os demais conjuntos foram utilizados para a etapa de testes com a MLP. Cada conjunto restante possui um total de 100 padrões de redes, também divididos em 12 subconjuntos de acordo com a probabilidade de bloqueio apresentada. A Tabela 2 apresenta a divisão dos conjuntos gerados pelo SIMTON, classificando-os de acordo com a carga e quantidade de padrões. A Tabela 3, por sua vez, mostra a divisão dos conjuntos de acordo com a probabilidade de bloqueio apresentada pelo exemplo de rede.

Tabela 2. Conjuntos de dados utilizados nos experimentos.

Carga (erlangs)	Qnt. De Padrões	Finalidade
80	100	Teste
100	24000	Treino e Teste
120	100	Teste
140	100	Teste
160	100	Teste
180	100	Teste
200	24000	Treino e Teste
220	100	Teste

Tabela 3. Subconjuntos relacionados a probabilidade de bloqueio.

Rótulo do Subconjunto	Intervalos de Probabilidade de Bloqueio (%)
#1	0 - 0,1
#2	0,1 - 1
#3	1 - 10
#4	10 - 20
#5	20 - 30
#6	30 - 40
#7	40 - 50
#8	50 - 60
#9	60 - 70
#10	70 - 80
#11	80 - 90
#12	90 - 100

Capítulo 4

Experimentos e Resultados

Este capítulo tem como objetivo descrever todos os passos e configurações utilizadas para o treinamento da RNA utilizada nos experimentos, descrever o processo de avaliação de redes para determinar os valores de referência para probabilidade de bloqueio e também avaliar e comentar os resultados obtidos pela rede quando foram apresentados dados com cargas variadas.

4.1 Arranjo Experimental

4.1.1 Características Gerais da Camada Física para a MLP

Como foi mencionado na seção 3.1, serão utilizadas oito métricas de redes como entrada para a RNA. Em relação a camada física foram utilizados duas métricas, que foram o número de comprimentos de onda e o tipo do OXC utilizado. O número máximo de comprimentos de onda utilizado foi 40, e para utilização na rede neural, esse valor foi normalizado para o intervalo [0,1]. Foram considerados cinco tipos de OXC e o diferencial entre eles é o seu fator de isolamento. Para a representação dos OXC foram definidos rótulos numéricos de 1 à 5. Para serem utilizados na RNA esses valores também foram normalizados para o intervalo [0,1]. A Tabela 4 mostra as representações de cada OXC e as relaciona com o fator de isolamento.

Tabela 4. Rótulos e especificações dos OXCs utilizados.

Rótulo (r)	Rótulo Normalizado	Fator de Isolação
1	0	-30 dB
2	0,25	-33 dB
3	0,5	-35 dB
4	0,75	-38 dB
5	1	-40 dB

4.1.2 Treino e Avaliação da Rede Neural

Para o treinamento da Rede Neural foram utilizados os conjuntos de dados de 200 e 100 erlands. Esses conjuntos de redes foram divididos em três grupos: treino, validação e teste. Foram utilizados 24.000 topologias de redes para treino e 12.000 exemplos para validação durante o processo de treinamento da MLP. Os padrões de treino foram utilizados para o ajuste dos pesos durante o processo, já o conjunto de validação foi utilizado para o processo de validação cruzada, que verifica se a RNA não está em *overfitting*, ou seja, não está sendo treinada em excesso. O treinamento é interrompido quando o máximo de interações ($I_{\max} = 500.000$) é ultrapassado ou se o erro de validação começar a aumentar.

A métrica utilizada para verificar a performance da rede foi o Erro Médio Quadrático (EMQ), que é definido por:

$$EMQ = \frac{1}{n} \sum_{i=1}^n (BPSIMTON_i - BPRNA_i)^2, \quad (4.1)$$

em que n é o número de exemplos, $BPSIMTON_i$ é a probabilidade de bloqueio avaliada pelo SIMTON e $BPRNA_i$ é a probabilidade de bloqueio estimada pela rede neural.

Foi utilizada a função sigmóide logística com parâmetros randomicamente selecionados em um intervalo de 0 a 1. O algoritmo de treinamento utilizado foi o *backpropagation* com uma taxa de aprendizagem inicial igual a 0,02. Essa taxa de aprendizagem é multiplicada por $(I_{\max} - 1) / I_{\max}$ em cada interação, onde I_{\max} é o número máximo de iterações. O *bias* de cada neurônio é inicializado de forma pseudo-aleatória em um intervalo de 0 a 1, e é atualizado pelo algoritmo de *backpropagation* durante o processo de treinamento, assumindo sempre valores no mesmo intervalo. Para serem utilizados no processo de treinamento, todas as demais métricas utilizadas são ajustadas para o intervalo de 0 a 1. Foram utilizados 17 neurônios na camada oculta da MLP. Esse número foi escolhido baseado nos resultados obtidos por Araújo [2].

4.2 Resultados

Durante o experimento foram realizados o treinamento de 30 MLPs utilizando os parâmetros descritos na seção anterior. Esta quantidade de redes foi necessária para que a análise do experimento não ficasse dependente do resultado de uma só execução, já que na maioria dos casos, cada treino gera um conjunto de pesos diferentes para a RNA. Primeiramente foram realizados os treinamentos utilizando os conjuntos que foram gerados a partir das cargas de 100 e 200 erlangs. Após o treino foram feitos os testes, onde foram apresentadas à RNA, topologias de rede que foram avaliadas considerando cargas que variam de 80 a 220 erlangs. A Figura 9 mostra o EMQ para os conjuntos de 100 e 200 erlangs, que foram utilizados no treinamento da rede.

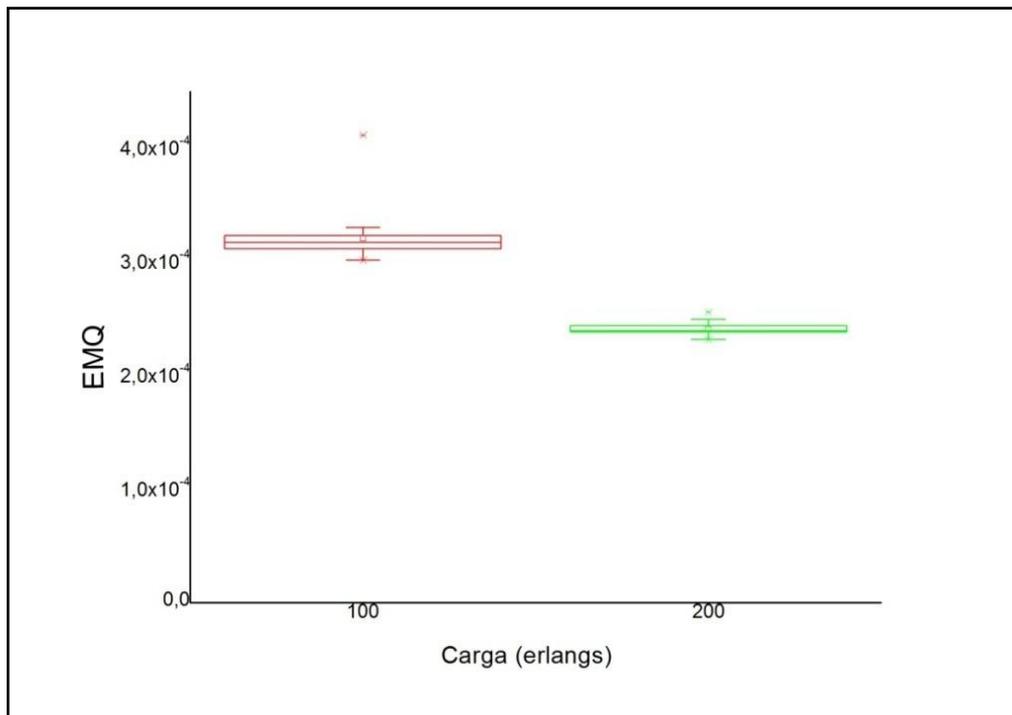


Figura 9 - EMQ para o conjunto de teste de 100 e 200 erlangs.

Percebe-se que os resultados para estes dois conjuntos apresentaram um bom EMQ, que se manteve entre 2×10^{-4} e 5×10^{-4} . Este resultado já era esperado, porque os conjuntos utilizados nos testes possuíam as mesmas cargas utilizadas na fase de treino. A Figura 10 mostra os resultados para todos os conjuntos, incluindo

os que foram gerados à partir da avaliação de cargas que não foram utilizadas no treinamento da RNA.

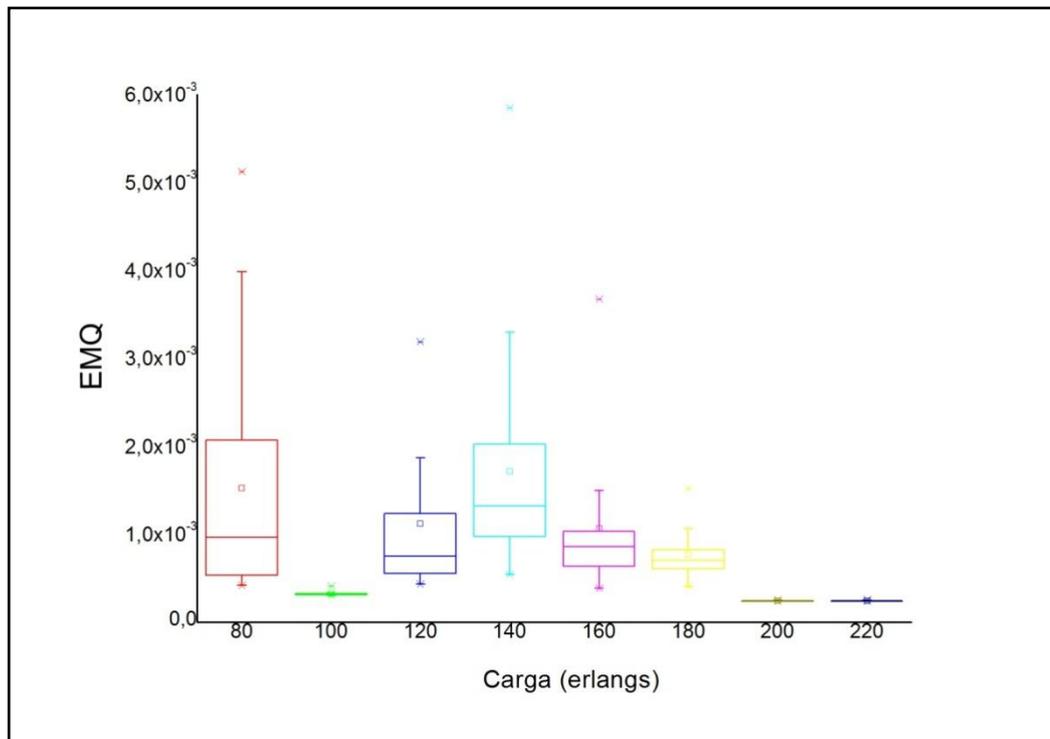


Figura 10 - EMQ para todos os conjuntos de carga.

Pode-se visualizar nos resultados para todos os conjuntos do experimento que os valores do erro não se mantiveram simétricos e a mediana de alguns conjuntos passaram para valores maiores que 1×10^{-3} , porém o EMQ se manteve em valores aceitáveis. Os resultados para cargas interpoladas podem não ter mantido a mesma qualidade em relação aos conjuntos de cargas utilizadas no treinamento pelo fato de ter sido apenas utilizado dois conjuntos para treino. Outro ponto que pode ter influenciado na qualidade dos resultados foi a quantidade de padrões utilizados nos testes para cargas intermediárias, que foi bem menor em relação às utilizadas no treino.

Por fim, a Figura 11 mostra um comparativo entre os valores de probabilidades de bloqueio estimados pela RNA e os resultados obtidos utilizando avaliações realizadas pelo SIMTON considerando 20 e 40 comprimentos de onda. Neste exemplo, foi selecionado um padrão de rede do conjunto de testes para ser avaliado. Percebe-se que, para este caso, a estimativa feita pela RNA ficou bem

próxima aos resultados das avaliações realizadas pelo SIMTON. A estimativa considerando 20 comprimentos de onda apresentou-se bastante semelhante em todo intervalo de cargas, já para 40 comprimentos de onda, a aproximação não ficou tão boa para cargas mais baixas.

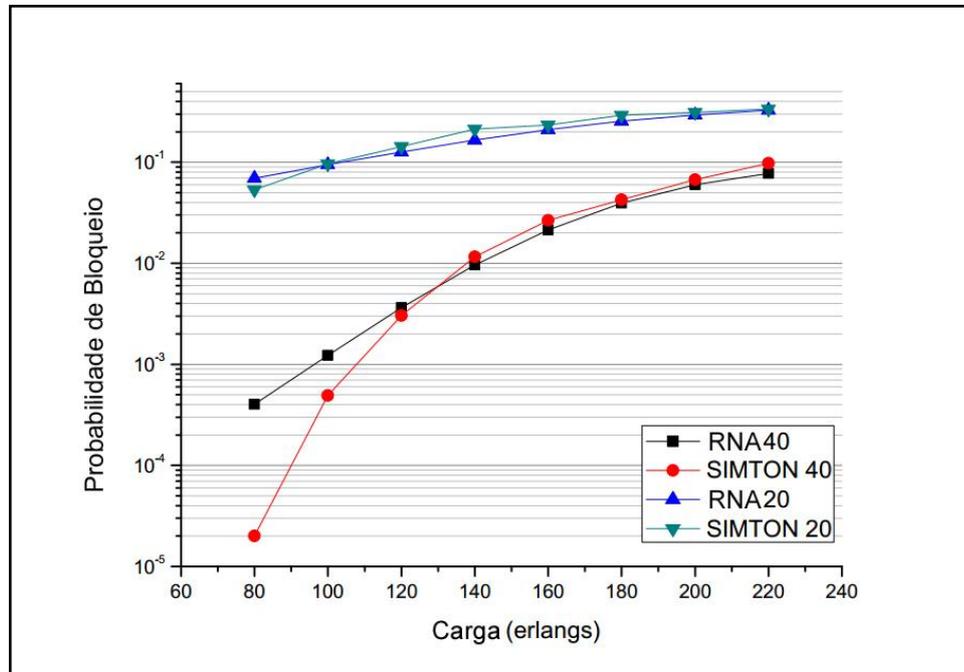


Figura 11 - Comparativo entre a PB estimada pelo SIMTON e pela RNA.

Capítulo 5

Conclusões e Trabalhos Futuros

Neste projeto de conclusão de curso foi realizado uma avaliação da robustez em função da carga de uma ferramenta que utiliza redes neurais artificiais para estimar a probabilidade de bloqueio em redes óptica DWDM. O principal fator avaliado foi a capacidade de interpolação da RNA quando existe uma variação de carga na rede.

Neste capítulo, serão feitas as considerações finais em relação aos resultados obtidos com o estudo sobre a ferramenta, e também serão discutidos os trabalhos futuros.

5.1 Conclusões

A utilização de ferramentas que aceleram um processo são sempre bem vistas em qualquer área de pesquisa e trabalho. A utilização da ferramenta avaliada neste trabalho, como foi visto no estudo realizado por Araújo [2], possibilita um grande ganho de velocidade no processo de avaliação de redes ópticas. Quanto mais robusta e flexível a ferramenta for, maior será a chance de que ela seja utilizada.

O estudo realizado neste projeto teve como principal meta, a avaliação da robustez da ferramenta baseada em RNAs que realiza estimativas da probabilidade de bloqueio em redes DWDM. Foram utilizadas diferentes topologias de rede e o principal ponto abordado foram os efeitos causados pela variação de carga. Os resultados obtidos por meio dos experimentos realizados neste estudo mostraram que a ferramenta consegue realizar a interpolação para padrões com cargas que nunca foram apresentadas a rede, porém com erro ligeiramente mais alto em relação aos resultados obtidos utilizando cargas fixas.

Baseado nesta análise, existe a possibilidade de uma melhoria nos resultados obtidos pela rede. Como neste estudo foram utilizados apenas dois conjuntos de dados representando duas cargas fixas, o poder de generalização da rede pode ter ficado reduzido. Como alternativa, poderiam ser utilizados cargas diferentes no treinamento da rede neural, para forçar um refinamento das estimativas. Outro fato que pode ter influenciado nos resultados foi a utilização de poucos dados na realização dos testes para as cargas interpoladas. Isso ocorreu em decorrência da grande demanda de tempo para a geração dos exemplos de redes.

5.2 Trabalhos Futuros

Como trabalhos futuros para esta avaliação podem ser feitos estudos de como melhorar o desempenho da ferramenta. Podem ser testados os seguintes aspectos:

1. Verificação do desempenho da RNA quando se utiliza uma número maior de cargas na fase de treinamento.
2. Utilizar um número maior de padrões de redes no conjunto de teste para as cargas interpoladas.
3. Verificar o desempenho da rede utilizando outras métricas de desempenho como parâmetros para a RNA.
4. Testar outros tipos de Redes Neurais para realizar a regressão.

Referências

- [1] Araújo, D. R. B. **Comparação de Algoritmos de Otimização Multiobjetivos Aplicados a Projeto de Redes Ópticas**. Dissertação de Mestrado, UPE, 2011
- [2] Araújo, D. R. B., J. F. Martins-Filho e C. J. A. Bastos-Filho. **Using Multi-Layer Perceptron and Complex Network Metrics to Estimate the Performance of Optical Networks**. Microwave & Optoelectronics Conference (IMOC), 2013.
- [3] Barreto, J. M. **Introdução às Redes Neurais Artificiais**, UFSC-Departamento de Informática e Estatística, 2002.
- [4] Benevenuto, F. **Redes Sociais Online: Técnicas de Coleta, Abordagens de Medição e Desafios Futuros**. Capítulo 2, SBSC, 2010.
- [5] Bessa, A. D., Santos, L. B. L. e Martinez, L. P. N. R. **Introdução à Redes Complexas**, UFBA, 2010.
- [6] D. A. R. Chaves, H. A. Pereira, C. J. A. Bastos-Filho, e J. F. Martins-Filho. **Simton: A simulator for transparent optical networks**. *Journal of Communication and Information systems*, 25:1-10, 2010.
- [7] D. A. R. Chaves. **Algoritmos Rápidos de IRWA para Redes Totalmente Ópticas**. *Dissertação de Mestrado*, UFPE, 2008.
- [8] Figueiredo, D. R. **Introdução à Redes Complexas**. Capítulo 7, CSBC, 2011.
- [9] Filho, M. F. **Análise de Redes Sociais**. Capítulo 2. <http://labspace.open.ac.uk/mod/resource/view.php?id=378355>, Último acesso em 25/06/2014.
- [10] França, C. P. **Análise de Desempenho de Redes Ópticas Transparentes com Roteamento Inteligente**. Trabalho de Conclusão de Curso, UPE, 2008.
- [11] Freitas, J. S. **Aplicação de Redes Neurais Artificiais em Simulações Computacionais de Modelos Neutros de Biodiversidade e Biogeografia**, Trabalho de Conclusão de Curso, UPE, 2012.

- [12] Menezes, B. A. M. ***Construindo Intervalos de Confiança na Previsão de Ventos Utilizando Reservoir Computing***, Trabalho de Conclusão de Curso, UPE, 2012.
- [13] Ramaswami, R., Sirvarajan, K. N. ***Optical Networks, A Pratical Perspective***, 3° Edição, 2010.
- [14] Soares, A. ***TONetS: Ferramenta para Avaliação de Desempenho de Redes Ópticas Transparentes***, 2008.
- [15] VALENÇA, M. J. S. ***Fundamentos das Redes Neurais: Exemplos em Java***. 1º ed. Recife: Livro Rápido, 2007.