

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ERICK DE ANDRADE BARBOZA

AMPLIFICADORES ÓPTICOS AUTÔNOMOS:
DESENVOLVIMENTO E ANÁLISE DE TÉCNICAS



RECIFE
2017

ERICK DE ANDRADE BARBOZA

AMPLIFICADORES ÓPTICOS AUTÔNOMOS:
DESENVOLVIMENTO E ANÁLISE DE TÉCNICAS

Tese submetida ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como parte dos requisitos para obtenção do grau de Doutor em Engenharia Elétrica.

Área de Concentração: Comunicações.

ORIENTADOR: PROF. JOAQUIM FERREIRA
MARTINS FILHO, PHD

CO-ORIENTADOR: PROF. CARMELO JOSÉ
ALBANEZ BASTOS FILHO, DOUTOR

RECIFE

2017

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

B239a Barboza, Erick de Andrade.
Amplificadores ópticos autônomos: desenvolvimento e análise de técnicas / Erick de Andrade Barboza. – 2017.
144 folhas, il., gráfs., tabs.

Orientador: Prof. Dr. Joaquim Ferreira Martins Filho.
Coorientador: Prof. Dr. Carmelo José Albanez Bastos Filho.
Tese (Doutorado) – Universidade Federal de Pernambuco. CTG.
Programa de Pós-Graduação em Engenharia Elétrica, 2017.
Inclui Referências e Apêndice.

1. Engenharia Elétrica. 2. Redes ópticas dinâmicas. 3. Amplificador óptico.
4. Auto-adaptação. 5. Ponto de operação. I. Martins Filho, Joaquim Ferreira.
(Orientador). II. Bastos Filho, Carmelo José Albanez. (Coorientador). III. Título.

UFPE

621.3 CDD (22. ed.) BCTG/2017-291



**PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE
TESE DE DOUTORADO DE**

TÍTULO

**“AMPLIFICADORES ÓPTICOS AUTÔNOMOS:
DESENVOLVIMENTO E ANÁLISE DE TÉCNICAS”**

A comissão examinadora composta pelos professores: JOAQUIM FERREIRA MARTINS FILHO, DES/UFPE; CARMELO JOSÉ ALBANEZ BASTOS FILHO, POLI/UPE; RAUL CAMELO DE ANDRADE ALMEIDA JÚNIOR, DES/UFPE; JULIANO RODRIGUES FERNANDES DE OLIVEIRA, CPqD; IGUATEMI EDUARDO DA FONSECA, CI/UFPE e BRUNO JOSÉ TORRES FERNANDES, POLI/UPE, sob a presidência do primeiro, consideram o candidato **ERICK DE ANDRADE BARBOZA APROVADO.**

Recife, 20 de julho de 2017.

MARCELO CABRAL CAVALCANTI
Coordenador do PPGEE

JOAQUIM FERREIRA MARTINS FILHO
Orientador e Membro Titular Interno

**JULIANO RODRIGUES FERNANDES DE
OLIVEIRA**
Membro Titular Externo

CARMELO JOSÉ ALBANEZ BASTOS FILHO
Coorientador e Membro Titular Interno

IGUATEMI EDUARDO DA FONSECA
Membro Titular Externo

RAUL CAMELO DE ANDRADE ALMEIDA
Membro Titular Interno

BRUNO JOSÉ TORRES FERNANDES
Membro Titular Externo

Agradecimentos

Agradeço,

Primeiramente a Deus por ser misericordioso com minhas falhas e, apesar da minha capacidade restrita, me permitir fazer grandes coisas. Agradeço por me guiar cada vez mais para perto dEle e por colocar todas as pessoas citadas abaixo como bênçãos em minha vida.

À minha família, por ser a minha base forte, de onde vem todo o meu sustento emocional e, principalmente, amoroso. Em especial, a minha esposa, Annye Barboza, que me incentivou durante todo este Doutorado e abriu mão de muitas coisas na sua vida para que esta Tese fosse criada. Também agradeço ao meu pai, Edson Barbosa de Souza, e minha mãe, Edna Maria de Andrade Barbosa, que dedicaram grande parte de suas vidas por mim, e hoje eu vejo a grande diferença que isso faz.

Ao professor e orientado Joaquim F. Martins-Filho, pois sempre me passou tranquilidade e segurança em suas orientações e isso foi fundamental para que essa fase tão difícil da carreira acadêmica fosse enfrentada com mais facilidade.

Ao professor e co-orientador Carmelo José Albanez Bastos-Filho, pela confiança que depositou em mim quando eu ainda era um aluno de graduação, e pelo empenho em me fazer avançar na carreira acadêmica e profissional.

Aos membros do grupo de pesquisa em redes ópticas da UFPE: Danilo Araújo, Raul Almeida, Leonardo Didier, Daniel Chaves e André Xavier; pelos comentários, críticas e sugestões que tanto contribuíram para o amadurecimento desta Tese. Em especial agradeço ao doutorando Marcionilo Silva por ter colaborado na condução de experimentos que foram importantíssimos para esta Tese.

Aos professores do Programa de Pós-Graduação em Engenharia Elétrica, e em especial, à nossa secretária Andrea Tenório pelo empenho e eficiência em resolver as necessidades dos alunos deste programa.

Aos colegas do CPqD Juliano Oliveira, Miquel Garrich, Uiara Oliveira e Heitor Carvalho, por terem contribuído com as informações valiosíssimas das máscaras dos amplificadores, por terem permitido a utilização da rede autônoma, e me ajudado intensamente durante o tempo que passei em Campinas.

Resumo

Redes ópticas dinâmicas estão desafiando os dispositivos a se tornarem autoadaptativos. Por ser um dispositivo crucial para as redes ópticas, é necessário que o amplificador óptico tenha a capacidade de alterar seu ponto de operação de acordo com as necessidades da rede. O problema do controle adaptativo do ponto de operação dos amplificadores ópticos (*Adaptive Control Operation Point* - ACOP) é recente e poucas técnicas foram propostas para resolvê-lo. O objetivo desta tese é propor técnicas para resolver o ACOP, o que permitirá que os amplificadores em uma cascata de amplificadores adaptem seu ponto de operação de forma a aumentar, ou ao menos manter, a qualidade da transmissão do enlace. Serão consideradas técnicas que realizam esta adaptação de forma local e global, para que se possa avaliar os prós e contras relativos a qualidade das suas soluções e seus tempos computacionais. As técnicas também deverão respeitar restrição na potência de saída da cascata para que seja possível existirem enlaces com e sem técnicas ACOP em uma mesma rede. As técnicas propostas serão avaliadas em comparação com outras técnicas encontradas na literatura considerando-se um cenário realístico, inclusive com efeitos não-lineares. Também será avaliado se o controle de outros dispositivos, além do amplificador óptico, é capaz de melhorar as soluções das técnicas ACOP. Além disso, os benefícios das redes definidas por software (SDN) serão utilizados para implementar as técnicas como aplicativos de um plano de controle SDN em um ambiente de rede real. Os resultados alcançados mostram que a definição correta do ponto de operação dos amplificadores ópticos pode melhorar o desempenho da cascata de amplificadores, principalmente, por conta da redução do ruído inserido no sinal óptico e melhora da planicidade do sinal, em comparação ao método tradicional que define os ganhos dos amplificadores para compensar as perdas do enlace.

Palavras-chave: Redes ópticas dinâmicas. Amplificador óptico. Auto-adaptação. Ponto de operação.

Abstract

Dynamic optical networks are challenging the network devices to become self-adaptive. Since the optical amplifier is a crucial device in optical networks, it is necessary to add in this device the capability to change its operating point according to the network conditions. The problem of adaptive control of optical amplifier operating point (ACOP) is recent and few approaches have been proposed to solve it. The aim of this thesis is to propose approaches to solve the ACOP problem, which will enable optical amplifiers to adapt their operating points in order to increase, or at least maintain, the quality of the transmission in the link. It is considered approaches that perform this adaptation locally and globally, to evaluate the pros and cons related to the quality of their solutions and their computational time. The approaches will also respect a restriction in the cascade output power in order to enable the coexistence of links with and without ACOP approaches in the same network. The proposed approaches will be evaluated in comparison with other approaches proposed in the literature in realistic scenarios that consider nonlinear noise as a physical impairment. It is also evaluated if the control of other devices, besides the optical amplifier, can enhance the results of the ACOP approaches. Moreover, the benefits of software defined networking (SDN) will be used to implement the approaches as an application that runs above a SDN control plane in a real network testbed. The achieved results show that the correct definition of the optical amplifiers operating points can enhance the transmission performance by reducing the inserted noise, and improving the gain flatness, when compared with the traditional method that defines the amplifier gains to compensate the link losses.

Keywords: Dynamic optical network. Optical amplifier. Self-adaptation. Operating point.

Lista de ilustrações

2.1	Representação gráfica da máscara de potência de um amplificador óptico, destacando determinado parâmetro do amplificador (Fonte: adaptado de [1]).	28
2.2	Arranjo experimental utilizado no processo de caracterização do amplificador apresentado em [2]. (Fonte: [2])	29
2.3	Ilustração do (a) esquema de organização dos equipamentos internos do EDFA de um estágio e (b) foto do equipamento com destaque para os equipamentos. (Fonte: adaptado de [3, 4])	30
2.4	Ilustração do (a) esquema de organização dos equipamentos internos do EDFA de dois estágios e (b) foto do equipamento com destaque para os equipamentos. (Fonte: adaptado de [3, 4])	31
2.5	Máscara de potência de um amplificador EDFA obtida pelo processo de caracterização para (a) figura de ruído (NF) (b) planicidade de ganho (<i>ripple</i>), ambos representados pelas barras de cores. (Fonte: elaboração própria)	32
2.6	Espaço de objetivos do AdGC formado a partir das máscaras de potência de NF e Rp.	34
2.7	Fluxograma representando o passo-a-passo do processo realizado pelo AdGC. (Fonte: elaboração própria)	35
2.8	Representação do fluxograma de funcionamento da técnica <i>Amplifier Cognitive CBR</i> (AcCBR). (Fonte: adaptado de [5])	37
2.9	Variação da potência de saída de um canal sobrevivente (a) após a remoção e adição de canais, nos casos com e sem AGC, (b) destacando-se o tempo de acomodação, o overshoot e o undershoot. (Fonte: Adaptado de [6])	39
3.1	Ilustração do método iterativo realizado pelo AsHB. Atualização direta atualiza as potências de saídas de acordo com as potências de entrada. Atualização inversa atualiza as potências de entrada de acordo com as potências de saída. (Fonte: elaboração própria)	43
4.1	Arquitetura da MLP utilizada para mapear NF e <i>ripple</i> (Rp) como uma função de P_{in} e P_{out} . (Fonte: elaboração própria)	56

4.2	Curva de convergência para o processo de validação e de teste para a máscara de potência com passo de 1dB e quatro neurônios na camada escondida, em função do número de épocas.	58
4.3	<i>Box-plot</i> do erro de teste em função do número de neurônios na camada escondida para a máscara de potência 1 dB.	59
4.4	<i>Box-plot</i> do erro de teste em função do número de neurônios na camada escondida para a máscara de potência 3 dB.	59
4.5	<i>Box-plot</i> do erro de teste em função do número de neurônios na camada escondida para várias máscaras de potência, considerando quatro neurônios na camada escondida.	60
4.6	Exemplo das curvas de NF e <i>ripple</i> geradas a partir da utilização da MLP, variando-se a potência de entrada e a potência de saída com resolução igual a 0,1 dB.	60
4.7	Representação da cascata de amplificadores definida em [7] e utiliza nas simulações de análise e validação da técnica AsHB. (Fonte: elaboração própria) . .	61
4.8	(a) $NF_{cascata}$ e $Rp_{cascata}$, e (b) $Erro_{entrada}$ and $Erro_{saida}$ em função do número de iterações do AsHB para quatro amplificadores com potência total de entrada igual a 3dBm.	63
4.9	Representação do cenário de simulação com quatro amplificadores com ganhos entre 15 e 25 dB e uma potência máxima de saída de 17 dBm; um VOA com 30 dB de atenuação máxima e um ROADM com perda de 10 dB. A potência de entrada é -20 dBm/ch e a perda da fibra é 18 dB. (Fonte: elaboração própria)	65
4.10	Espectro de potência na entrada e na saída do amplificador para caracterizações com (a) 10, (b) 20, (c) 40 e (d) 80 canais.	66
4.11	Média e desvio padrão do tempo de execução da técnica AsHB Flex, após 30 execuções, em função do número de iterações.	68
4.12	Curvas de planicidade de ganho e figura de ruído em função do número de iterações do AsHB Flex para (a) 10 (sólida), (b) 20 (traço), (c) 40 (ponto) e 80 (traço e ponto) canais.	68
4.13	Soluções obtidas pelas técnicas ME (todas elas como uma nuvem de pontos e a solução com o menor d como um quadrado), WAdGC (triângulo), AsHB Flex (pentágono), AsHB (círculo), MaxGain (estrela) e ComPerdas (diamante) em termos de figura de ruído, <i>ripple</i> e consumo de potência (barra de cores) da cascata com quatro amplificadores, para (a) 10, (b) 20, (c) 40 e (d) 80 canais.	70
4.14	Média e desvio padrão do tempo de execução após 30 execuções das técnicas MaxGain, WAdGC, AsHB Flex e ME, em função do número de amplificadores na cascata.	72
4.15	Arquitetura das redes definidas por software. (Fonte: adaptado de [8])	74

4.16	Topologia da rede autônoma do CPqD, ilustrando a conectividade óptica e também as conexões da rede de gerenciamento. (Fonte: adaptado de [9]) . . .	76
4.17	Foto da rede autônoma do CPqD, destacando os seus nós e alguns dos seus equipamentos. (Fonte: adaptado de [10])	77
4.18	Arquitetura do plano de controle SDN desenvolvido pelo CPqD para controle da rede autônoma. (Fonte: adaptado de [9]).	78
4.19	Representação gráfica dos módulos do controlador SDN envolvidos na implementação da técnica MaxGain como uma aplicação de rede. (Fonte: adaptado de [11])	79
4.20	Cenário considerado na validação do MaxGain. Os nós da rede são representados pelos círculos sendo o primeiro nó o círculo superior esquerdo. Os amplificadores são representados pelos triângulos. (Fonte: elaboração própria)	80
4.21	Gráficos de OSNR por comprimento de onda no <i>drop</i> do (a) nó 3 e do (b) nó 4 para MaxGain, AdGC e ComPerdas no cenário de rede da Figura 4.20. Em (a) ainda é apresentada a OSNR na entrada do primeiro amplificador (Entrada Rede).	82
4.22	Representação da cascata de amplificadores definida para as simulações da análise do impacto dos efeitos não-lineares nas técnicas. (Fonte: elaboração própria)	84
4.23	Média e desvio padrão da BER (a) considerando e (b) não considerando os efeitos não-lineares após 10 execuções das técnicas MaxGain, WAdGC, ComPerdas e AsHB Flex, em função da restrição de potência de saída do amplificador.	86
5.1	Ilustração mostrando um ponto de operação da máscara e os valores de ganho e figura de ruído (NF) ao longo do espectro de operação (Fonte: elaboração própria).	90
5.2	Ilustração da rede neural desenvolvida para a estimativa do ganho e da figura de ruído de uma canal, considerando os dados presentes na máscara de potência do amplificador. (Fonte: elaboração própria)	93
5.3	Erro médio quadrático das fases de treinamento e validação em função do número de épocas de treinamento.	93
5.4	Ilustração das duas estratégias utilizadas para dividir a máscara de potência em pontos que foram ou não apresentados à rede neural e ao método de interpolação. (Fonte: elaboração própria)	95
5.5	Distribuição do erro absoluto na estimativa do ganho e da NF dos canais, nos pontos não apresentados, utilizando a RN e o MI, considerando que a máscara foi dividida pelas (a) potências de entrada ou (b) frequências.	96

5.6	Curvas de (a) ganho e (b) figura de ruído armazenada na máscara de potência do amplificador (quadrado), retornada pelo MI (losango) e retornada pela RN (triângulo invertido), em função da frequência do canal.	97
5.7	Distribuição do erro de teste (absoluto) retornado pela RN na estimação do ganho e da figura de ruído de um EDFA de um estágio (1 STG) e de um EDFA de dois estágios (2 STG).	98
5.8	Curvas de OSNR ASE e de OSNR ASE+NLI em função da frequência, retornadas pelas técnicas locais.	101
5.9	Curvas de ganho em função da frequência retornadas pelas técnicas MaxGain e AdGC (quadrado), AsHB Flex (triângulo invertido) e CompPerdas (losango). 102	
5.10	Curvas do ganho agregado em função da frequência, retornadas pelas técnicas locais.	103
5.11	OSNR (a) ASE e (b) ASE+NLI do pior canal em função do <i>ripple</i> do sinal do último amplificador. Triângulos representam as soluções do método exaustivo, quadrado da técnica MaxGain, diamante da CompPerdas e triângulo invertido da AsHBFlex.	104
5.12	Valores de <i>ripple</i> e mínima OSNR ASE+NLI para as três técnicas locais em enlaces com diferentes números de amplificadores.	105
5.13	Ilustração do impacto da imposição de uma restrição de potência de lançamento na quantidade de pontos de operação possíveis de serem escolhidos, considerando a restrição igual a 15 dBm, a potência de entrada igual a -6 dBm e a aplicação da restrição sendo feita (a) diretamente pelo amplificador ou (b) pelo VOA. Esta máscara de potência é do amplificador EDFA de um estágio. (Fonte: elaboração própria)	107
5.14	Representação da cascata de amplificadores que é utilizada nas simulações deste trabalho, considerando uma VOA na saída de cada amplificador. (Fonte: elaboração própria)	107
5.15	Máscara de potência do amplificador EDFA de um estágio utilizado nas simulações, destacando em cores os valores de figura de ruído e <i>ripple</i> de cada ponto de operação. (Fonte: elaboração própria)	108
5.16	Curvas de OSNR ASE (quadrado), OSNR ASE+NLI (losango) e OSNR ASE+NLI após aplicação da restrição (triângulo invertido) em função da frequência, retornadas pelas técnicas MaxGain/AdGC e AsHB Flex.	108
5.17	Curvas de ganho em função da frequência na saída dos amplificadores de 1 a 4 (a),(b),(c),(d), retornadas pela técnica MaxGain (e AdGC) para os casos sem VOA e com VOA. Também é apresentada a curva de ganho na saída do VOA para o caso com VOA (e).	109

5.18	Posicionamento das soluções retornadas pelo método exaustivo (triângulos), pela MaxGain/AdGC (quadrado), pela AsHB Flex (triângulo invertido) e pela CompPerdas (losango); no espaço formado pelo ripple e a mínima (a)-(b) OSNR ASE e a (c)-(d) mínima OSNR ASE+NLI, considerando o caso (a)-(c) sem VOA/sem restrição e o caso (b)-(d) com VOA/com restrição. Para um amplificador EDFA de um estágio.	110
5.19	Máscara de potência do amplificador EDFA de dois estágios utilizado nas simulações, destacando em cores os valores de figura de ruído e <i>ripple</i> de cada ponto de operação. (Fonte: elaboração própria)	111
5.20	Posicionamento das soluções retornadas pelo método exaustivo (triângulos verdes), pela MaxGain/AdGC (quadrado azul), pela AsHB Flex (triângulo invertido amarelo) e pela CompPerdas (losango vermelho); no espaço formado pelo ripple e a mínima (a)-(b) OSNR ASE e a (c)-(d) mínima OSNR ASE+NLI, considerando o caso (a)-(c) sem VOA/sem restrição e o caso (b)-(d) com VOA/com restrição. Para um amplificador EDFA de dois estágios.	112
5.21	Um problema com duas funções objetivo: <i>ripple</i> e OSNR. A frente de Pareto está destacada pela linha que une os pontos entre A e E, o <i>datum point</i> W e a área definida entre este ponto e a frente de Pareto estão destacados. (Fonte: elaboração própria)	114
5.22	Ilustração da interação entre o SMPSO e o simulador do sistema óptico para a realização da otimização. (Fonte: elaboração própria)	117
5.23	Média e desvio padrão da métrica <i>Hypervolume</i> , após 30 execuções, em função do número de iterações para cascatas com número de amplificadores entre 2 e 8. Para cascata com 6 ou mais amplificadores a população do SMPSO foi aumentada de 100 para 200 partículas.	118
5.24	Representação das frentes de Pareto para um enlace com 2 amplificadores, retornadas pelo SMPSO e pelo método exaustivo (EM) considerando variáveis com precisão de uma casa decimal (0, 1dB), variáveis inteiras (1dB) e o SMPSO sem nenhuma restrição na precisão das variáveis.	120
5.25	Representação das frentes de Pareto, para um enlace com (a) 3 e (b) 4 amplificadores, retornadas pelo SMPSO e pelo método exaustivo (EM) considerando variáveis com precisão de 0,5dB, variáveis inteiras (1dB) e o SMPSO sem nenhuma restrição na precisão das variáveis.	121
5.26	Representação das curvas de (b) potência e (c) OSNR de (a) três soluções em locais distintos da Frente de Pareto retornada pelo SMPSO para uma cascata com 4 amplificadores EDFA de um estágio.	123

5.27	Representação das frentes de Pareto retornadas pelo SMP SO considerando 2 e 3 objetivos no processo de otimização e uma cascata com 4 amplificadores, para dois tipos de EDFAs.	124
5.28	Frente de Pareto retornada pelo SMP SO (ACOP MOO) no espaço objetivo formado pelos objetivos de otimização, em conjunto com a soluções retornadas pelo método exaustivo (triângulos verdes), pela MaxGain/AdGC (quadrado azul), pela AsHB Flex (triângulo invertido amarelo) e pela CompPerdas (losango vermelho), para dois tipos de EDFA.	126

Lista de tabelas

4.1	Número de pontos de operação utilizados em cada máscara para treinamento, validação e teste da MLP.	57
4.2	Comparação dos erros, da NF e Rp da cascata para diferentes números de iterações do AsHB	62
4.3	Comparação dos erros, da NF e da Rp da cascata para diferentes valores de potência de entrada da cascata.	64
4.4	Características dos amplificadores retornados pela AsHB.	64
4.5	Características dos amplificadores retornadas pelo AdGC.	64
4.6	Atributos dos amplificadores retornados pelas técnicas ME, MaxGain, AsHB Flex e CompPerdas para 80 canais.	71
4.7	Figura de ruído e o <i>ripple</i> da cascata retornado pelo MaxGain, AsHB Flex, WAdGC e CompPerdas para cascatas com números diferentes de amplificadores e considerando 40 canais.	73
4.8	Atributos dos amplificadores retornados pelas técnicas MaxGain, AdGC e CompPerdas considerando o cenário da Figura 4.20.	81
4.9	Atributos dos amplificadores retornados pelas técnicas WAdGC, CompPerdas, MaxGain e AsHB Flex considerando o cenário sem restrição de potência.	87
5.1	Parâmetros de entrada e valores de saída definidos pelo modelo IGN, juntamente com suas descrições.	100
5.2	Parâmetros de entrada e valores de saída definidos pelo modelo IGN, juntamente com suas descrições.	100
5.3	Valores de mínima $OSNR_{ASE+NLI}$ e de <i>ripple</i> da cascata retornados pelas técnicas locais para cenários com diferentes potências de entrada. O melhor valor de cada linha está destacado em negrito.	106
5.4	Organização das variáveis do problema em uma partícula do SMPSO. As primeiras N posições contém os valores dos ganhos dos amplificadores e as posições restantes contém os valores das perdas dos VOAs.	117

5.5	Valores em dB dos ganhos dos amplificadores e das perdas dos VOAs definidas pelas soluções escolhidas na Figura 5.26a.	122
5.6	Tempo gasto pelo Método Exaustivo e pelo SMPSO para retornar uma frente de Pareto considerando enlaces com 2, 3 e 4 amplificadores. Os valores entre parênteses representam a precisão das variáveis considerada em cada caso.	123
5.7	Valores de Ripple (dB) das soluções retornadas pelas técnicas locais e por três soluções da frente de Pareto retornada pelo SMPSO. Para cada coluna, o melhor valor encontrado está destacado em negrito.	127
5.8	Valores de OSNR (dB) das soluções retornadas pelas técnicas locais e por três soluções da frente de Pareto retornada pelo SMPSO. Para cada coluna, o melhor valor encontrado é destacado em negrito.	127

Lista de abreviaturas e siglas

- d*** Distância euclidiana entre um ponto de operação e a origem do plano cartesiano formado por NF e *ripple*
- ACOP** *Adaptive Control of Operating Point* - Controle Adaptativo do Ponto de Operação
- AdGC** *Adaptive Gain Control* - Controle de Ganho Adaptativo
- AGC** *Automatic Gain Control* - Controle Automático de Ganho
- ASE** *Amplified Spontaneous Emission* - Emissão Estimulada Amplificada
- AsHB Flex** *Annealing Search Heurist with Backpropagation Flex*
- AsHB** *Annealing Search Heuristic with Backpropagation*
- BER** *Bit Error Rate* - Taxa de Erro de bit
- BP** *Backpropagation* - método de treinamento de redes neurais artificiais
- DWDM** *Dense Wavelength Division Multiplexing* - Multiplexação por Divisão de Comprimento de onda
- EDFA** *Erbium-Doped Fiber Amplifiers* - Amplificadores de fibra dopada por Érbio
- Erro_{entrada}** Erro entre a potência deseje e a potência definida pela técnica ACOP na entrada da cascata
- Erro_{saida}** Erro entre a potência deseje e a potência definida pela técnica ACOP na saída da cascata
- GF** *Gain Flatness* - Planicidade de Ganho
- GM** *Gain Matching*
- IGN** *Incoherent Gaussian-noise Model*
- ME** Método Exaustivo

MI Método de Interpolação

MLP *Multilayer Perceptron - Perceptron* Multicamada

MOO *Multiobjective Optimization* - Otimização Multiobjetivo

NF_{cascata} Figura de ruído da cascata de amplificadores

NF *Noise Figure* - Figura de Ruído

NLI *Non-linear Impairments*

OSA *Optical Spectrum Analyzer* - Analisador de Espectro Óptico

OSNR *Optical Signal to Noise Ratio* - Relação Sinal Ruído Óptica

PSO *Particle Swarm Optimization* - Otimização por enxame de partícula

QoS *Quality of Service* - Qualidade de Serviço

QoT *Quality of Transmission* - Qualidade de transmissão

RNA Rede Neural Artificial

RNA Rede Neural Artificial

ROADM *Reconfigurable Optical Add-Drop Multiplexer* - Multiplexador Add-Drop Reconfigurável

Rp_{cascata} *Ripple* da cascata de amplificadores

Rp *Ripple*

SDK *System Development Kit* - Kit para desenvolvimento de sistema

SDN *Software Defined Networking* - Redes definidas por software

SMPSO *Speed-constrained Multi-objective PSO* - PSO Multiobjetivo com restrição de velocidade

SOD *Supervisory optical channel demultiplexer* - Demultiplexador do canal óptico de supervisão

SOM *Supervisory optical channel multiplexer* - Multiplexador do canal óptico de supervisão

SSMF *Standard Single Mode Fiber* - Fibra monomodo padrão

TIP *Total Input Power*

VOA *Variable Optical Attenuator* - Atenuador Óptico Variável

WAdGC *Weighed Adaptive Gain Control* - Controle de Ganho Adaptativo Ponderado

WSO *Wavelength Switched Optical Network* - Redes ópticas comutadas por comprimento de onda

WSS *Wavelength Selective Switch* - Comutadores de Comprimento de Onda Seletivo

Lista de algoritmos

Algoritmo 1	Pseudocódigo da <i>Annealing Search Heurist with Backpropagation</i> (AsHB).	45
Algoritmo 2	Pseudocódigo da <i>Annealing Search Heurist with Backpropagation Flex</i> (AsHB Flex).	48
Algoritmo 3	Pseudocódigo do Método Exaustivo (ME).	49
Algoritmo 4	Pseudocódigo da técnica MaxGain.	51
Algoritmo 5	Pseudocódigo da técnica SMPSO.	116

Sumário

1	INTRODUÇÃO	22
1.1	Amplificadores ópticos em redes ópticas dinâmicas	23
1.2	Motivação	26
1.3	Objetivos	26
1.3.1	<i>Objetivo geral</i>	27
1.3.2	<i>Objetivos específicos</i>	27
1.4	Organização do documento	27
2	CONTROLE ADAPTATIVO DO PONTO DE OPERAÇÃO	28
2.1	Processo de caracterização do amplificador	29
2.2	Exemplo geral da solução do problema ACOP	33
2.3	Técnicas para ACOP encontradas na literatura	34
2.3.1	<i>Técnica ACOP local para enlace ponto-a-ponto (AdGC)</i>	34
2.3.2	<i>Técnica ACOP global para cenário de rede</i>	37
2.4	Controle Automático de Ganho	39
3	DESENVOLVIMENTO DE TÉCNICAS PARA O ACOP	42
3.1	Heurística iterativa e com restrição de potência de saída baseada em aprendizado de máquina	43
3.1.1	<i>Aprendizado de Máquina</i>	43
3.1.2	<i>Detalhamento da proposta de aprendizado da AsHB</i>	44
3.1.3	<i>Adaptação considerando um VOA na saída do enlace (AsHB Flex)</i>	47
3.2	Método exaustivo global	50
3.3	Heurística do ganho máximo	51
4	AVALIAÇÃO DAS TÉCNICAS CONSIDERANDO MODELAGEM DE PIOR CASO PARA OS AMPLIFICADORES	53
4.1	Mapeamento das informações da máscara de potência utilizando redes neurais artificiais	54
4.1.1	<i>Redes Neurais Artificiais Multi-Camadas</i>	54
4.1.2	<i>Método desenvolvido para mapeamento das informações da máscara de potência</i>	56
4.1.3	<i>Cenário de simulação para validação da MLP</i>	57
4.1.4	<i>Resultados das simulações com a MLP</i>	58

4.2	Análise das técnicas propostas	62
4.2.1	<i>Análise e validação da técnica AsHB</i>	62
4.2.2	<i>Comparação entre técnicas locais e técnica global</i>	65
4.3	Desenvolvimento de um aplicativo para SDN	74
4.3.1	<i>SDN e redes ópticas</i>	75
4.3.2	<i>Rede autônoma do CPqD</i>	76
4.3.3	<i>Implementação do MaxGain na rede autônoma</i>	79
4.3.4	<i>Experimento para validação da técnica MaxGain em SDN</i>	81
4.4	Análise do impacto dos efeitos não-lineares nas técnicas ACOP	84
4.4.1	<i>Cenário de simulação utilizado para a análise do impacto dos efeitos não-lineares nas técnicas</i>	84
4.4.2	<i>Resultados da análise do impacto dos efeitos não-lineares nas técnicas para ACOP</i> ..	85
4.5	Considerações sobre o capítulo	88
5	AVALIAÇÃO DAS TÉCNICAS PARA ACOP CONSIDERANDO NÃO-LINEARIDADES E CANAIS INDEPENDENTES 90	
5.1	Modelagem do amplificador para canais independentes	91
5.1.1	<i>Estimadores encontrados na literatura</i>	92
5.1.2	<i>Adaptação da Rede Neural para Considerar Informações de Espectro</i>	93
5.2	Utilizando modelo analítico para cálculo de efeito não-linear	99
5.2.1	<i>Modelo analítico utilizado</i>	99
5.2.2	<i>Cenário considerado nas simulações</i>	100
5.2.3	<i>Resultados da utilização do modelo analítico com as técnicas ACOP</i>	102
5.3	Utilizando VOA na saída para minimizar o impacto dos efeitos não-lineares	107
5.4	Utilizando otimização multiobjetivo para definição dos ganhos e perdas dos VOAs	113
5.4.1	<i>Conceitos básicos de MOO</i>	114
5.4.2	<i>A técnica SMPSO</i>	115
5.4.3	<i>Organização das simulações</i>	117
5.4.4	<i>Resultados da utilização de MOO para ACOP</i>	118
5.5	Considerações sobre o capítulo	129
6	CONCLUSÃO	131
6.1	Limitações e Sugestões para Trabalhos Futuros	132
	REFERÊNCIAS	134
	Apêndice A: SUMÁRIO DE PUBLICAÇÕES	142

1 . INTRODUÇÃO

A massiva utilização de serviços e aplicações que precisam de muita banda de transmissão tem aumentado o tráfego de dados nas redes de telecomunicações, principalmente na Internet. O aparecimento de serviços como vídeo por demanda, IP-TV, voz sobre IP, entre outros, contribuiu para que o tráfego global da rede IP aumentasse mais de cinco vezes nos últimos cinco anos. Além disso, a perspectiva é de que este tráfego ainda irá aumentar em torno de três vezes nos próximos cinco anos [12].

Comunicações ópticas possuem vantagens que as têm tornado o principal meio de transmissão utilizado para suprir a atual demanda por dados. Uma das principais vantagens da fibra óptica é a sua enorme largura de banda de até 50 THz. Entretanto, os sistemas de comunicações atuais não atingem este limite devido ao limite de amplificação dos amplificadores ópticos a fibra dopada com Érbio (EDFA - *Erbium-Doped Fiber Amplifiers*) que são muito utilizados comercialmente ($\sim 5 THz$). Esta banda pode ser amplificada com amplificadores Raman, mas outros problemas aparecem. Outra vantagem é que a fibra sofre muito pouco com interferências e têm baixas perdas, permitindo que este meio de transmissão seja utilizado para prover comunicações em longa distância [13].

Com a evolução das tecnologias e das demandas, surgiram as rede ópticas. No princípio os sistemas de comunicações ópticas eram utilizados apenas para comunicações ponto-a-ponto, porém, atualmente estes sistemas são utilizados para formar redes que interligam vários dispositivos. Devido às suas vantagens, as redes ópticas são utilizadas como *backbone* de várias outras redes (*ex*: redes móveis/celulares, redes IP), o que faz com que, na maioria das transmissões, os dados trafeguem em algum momento através de uma rede óptica.

Atualmente as redes ópticas se encontram em um cenário no qual precisam dar suporte a diferentes tipos de tecnologias de transmissão e de serviços. Por serem utilizadas como redes que recebem os dados de outras redes, as redes ópticas precisam ser capazes de funcionar para uma enorme quantidade de serviços, cada um com seus requisitos individuais de qualidade de serviço (QoS - *Quality of Service*). Ao mesmo tempo, as redes ópticas possuem na sua camada de transporte muitas tecnologias de transmissão funcionando concorrentemente, tais como: diferentes formatos de modulação, taxas de dados, espaçamentos entre canais e esquemas de codificação [14, 15, 16].

O cenário descrito anteriormente está criando desafios para este novo tipo de redes (óp-

ticas heterogêneas e dinâmicas). Um dos principais problemas neste contexto é a criação de mecanismos eficientes para controle e gerenciamento dos dispositivos e configurações da rede. Com o intuito de tratar este problema, enquanto atende às demandas dos usuários e garante a qualidade dos serviços, a rede precisa apresentar algumas características como: auto-configuração, auto-restauração, auto-otimização e auto-proteção. A implementação de tais características implica na criação de uma rede automática e reconfigurável capaz de tomar decisões sem a intervenção humana [17].

Enfrentar os desafios de desenvolver redes ópticas automáticas está se mostrando um tópico de interesse para muitos pesquisadores. Trabalhos recentes mostraram algumas propostas como: reconhecimento automático de formatos de modulação [18], estimador automático de qualidade de transmissão (QoT - *Quality of Transmission*) [19] e projeto automático de topologia virtual [20]. Especificamente nestes trabalhos, é utilizado o conceito de redes ópticas cognitivas, que podem ser descritas como uma rede automática que melhora seu desempenho ao longo do tempo devido a processos de aprendizagem.

Em paralelo a isto, pesquisas têm mostrado que o conceito de redes definidas por software (SDN - *Software Defined Networking*) pode ser utilizado como uma ferramenta importante na solução dos desafios impostos pelas redes ópticas dinâmicas [21, 22]. O conceito de SDN torna o gerenciamento da rede mais simples, pois se propõe a definir os equipamentos da rede através de software, provendo interfaces simples entre estes equipamentos e um software global que controla todos os equipamentos, seguindo assim a ideia dos sistemas operacionais dos computadores. Dessa forma, é possível uma visualização global da rede, simplificando sua monitoração e facilitando a atuação nos equipamentos [8].

Um passo importante na direção das redes autônomas é habilitar os principais dispositivos da rede a se adaptarem às mudanças da rede. Um dos dispositivos cruciais para o funcionamento da rede óptica é o amplificador óptico. Portanto, faz-se necessário a adaptação destes dispositivos para funcionarem de forma autônoma.

1.1 Amplificadores ópticos em redes ópticas dinâmicas

Os amplificadores ópticos são equipamentos de extrema importância para o bom funcionamento da rede óptica, pois compensam as perdas de potência que o sinal sofre durante a transmissão, mantendo a potência dos sinais em níveis adequados à recepção. Além disso, esses equipamentos são fundamentais para o funcionamento das atuais redes WSON (*Wavelength Switched Optical Network*), pois, neste tipo de rede, comprimentos de ondas são utilizados para definir um conjunto de canais de comunicação e o amplificador óptico é capaz de prover ganho para vários canais simultaneamente. Os amplificadores EDFA têm sido utilizados de forma bem sucedida nestes sistemas multi-canais há décadas [23].

Por outro lado, o amplificador óptico também pode degradar o sinal ao alterar o formato

do sinal e inserir ruído. Em sistemas multi-canais, diferentes canais podem ser amplificados por ganhos distintos, devido às variações no espectro de ganho dos amplificadores ópticos. No EDFA essa variação ocorre, principalmente, devido à distribuição de sub-níveis de energia dentro da banda de transmissão do amplificador. Defini-se a planicidade de ganho (GF - *Gain Flatness*) como a variação máxima de ganho entre os canais dentro da banda de amplificação. Uma forma de calcular esta variação é medir a diferença entre o canal com a maior potência e o canal com a menor potência, considerando que as potências de entrada por canal são iguais. A essa métrica é dado o nome de *ripple*. Além disso, o amplificador EDFA insere ruído devido à Emissão Espontânea Amplificada (ASE - *Amplified Spontaneous Emission*) [23]. A relação sinal ruído óptica (OSNR - *Optical Signal to Noise Ratio*) é definida como a razão entre a potência do sinal e a potência do ruído em um ponto específico do sistema de transmissão. A degradação da OSNR gerada por um dispositivo é definida como a Figura de Ruído (NF - *Noise Figure*) do dispositivo, medida em decibéis.

Ripple e NF são métricas importantes para definir a qualidade dos amplificadores, pois impactam na QoT em sistemas de comunicações ópticas. Em redes ópticas dinâmicas, a necessidade de avaliar essas métricas é ainda mais importante, visto que o número de canais e suas potências podem variar dinamicamente e, às vezes, de forma imprevisível. Devido a isso, os amplificadores ópticos devem operar inserindo o menor ruído possível e provendo um ganho o mais plano possível para todos os comprimentos de ondas (canais) do sistema multi-canais.

Outro desafio para o amplificador neste cenário dinâmico é operar em um determinado ganho de forma estável. Como em redes dinâmicas canais são inseridos e removidos com certa frequência, isso significa que o amplificador recebe alterações na sua potência de entrada, e dado que o mesmo em redes WDM opera em modo de saturação, com o bombeamento fixo consequentemente os ganhos dos sinais são alterados na saída dado a variação de canais na entrada, requisita, assim, um controle de ganho para operar de forma estável. Trabalhos recentes mostraram que o correto controle de ganho dos amplificadores é importante para diminuir flutuações de potência no sistema de transmissão [24, 25]. Flutuações de potência podem interferir no funcionamento da comunicação de duas formas: ao aumentar a potência dos canais acima de um determinado limiar, o que pode danificar o equipamento receptor; ao diminuir muito a potência, e, assim, prejudicar o reconhecimento da informação enviada. Diante deste desafio, técnicas de controle automático de ganho (AGC - *Automatic Gain Control*) têm sido propostas com o objetivo de criar sistemas de controle que atuem na estrutura do amplificador para que, independente das condições externas (*e.g.*: potência de entrada), o amplificador entregue um ganho o mais próximo possível do ganho alvo definido [26, 27, 28, 29].

Apesar das técnicas de AGC garantirem um ganho estável para cada amplificador, o ganho precisa ser definido *a priori* e, em um cenário dinâmico, isto pode significar diminuição de desempenho do amplificador. O método tradicional para definir os ganhos dos amplificadores visa definir o ganho de cada amplificador de acordo com as perdas impostas pelos dispositivos

anteriores a este amplificador no sistema [30]. Apesar de garantir a compensação completa das perdas de potência, este método não garante o melhor desempenho em termos de NF e *ripple* no sistema de transmissão como um todo. Em uma rede dinâmica, visto que as necessidades da rede podem mudar, é importante obter um bom desempenho da cascata de amplificadores para garantir um melhor desempenho na transmissão. Portanto, um amplificador capaz de adaptar seu ponto de operação de acordo com as necessidades da rede pode melhorar o desempenho da rede, por exemplo, por meio da diminuição do ruído adicionado, e do impacto causado por efeitos não-lineares.

O problema de adicionar ao amplificador óptico a habilidade de mudar sua operação de acordo com as necessidades da rede é chamado de: controle adaptativo do ponto de operação (ACOP - *Adaptive Control of Operating Point*). É neste problema que este trabalho tem sua principal motivação.

No ACOP, o ponto de operação do amplificador envolve o seu ganho e outras características como a NF, o *ripple* e, até, o consumo de energia. É importante notar que a otimização do ponto de operação de cada amplificador em uma cascata que busca a minimização de NF, *ripple* e consumo é um problema de otimização multiobjetivo. A melhor figura de ruído, por exemplo, é geralmente obtida quando o amplificador está operando com uma alta potência de saída, o que, por outro lado, aumenta o consumo de energia do amplificador e piora a planicidade do ganho.

Tornar um amplificador óptico adaptável é um desafio recente e algumas abordagens foram propostas [31, 7, 1]. Entretanto, ainda existem algumas questões em aberto sobre qual é a melhor forma de desenvolver mecanismos que se proponham a realizar esta tarefa de forma adequada.

Um exemplo é a questão do controle da otimização, que pode ser global ou local. Uma otimização global de uma cascata de amplificadores é capaz de usar informações conjuntas de toda a cascata de amplificadores para realizar suas operações, tornando assim as soluções dessa abordagem mais eficientes quanto ao desempenho do enlace. Entretanto, para realizar uma otimização global da cascata, faz-se necessário a adição de novos componentes que sejam capazes de concentrar as informações, aumentando assim o custo de implantação dessa abordagem. Por outro lado, uma otimização local pode ser feita utilizando apenas as informações dos amplificadores vizinhos e o canal de comunicação que existe entre eles. Apesar de conseguir maior simplicidade na comunicação, esta é uma tarefa complicada, pois é preciso tomar decisões locais (amplificadores) de forma que a qualidade de transmissão do enlace melhore.

Outra questão é a necessidade de técnicas cognitivas, ou adaptativas. Uma técnica adaptativa é aquela que altera parâmetros e comportamento de acordo com informações recebidas. Por outro lado, uma técnica cognitiva observa, age, aprende com experiências passadas e otimiza o desempenho das suas respostas ao longo do tempo. Além de exibir as propriedades de uma técnica adaptativa, a técnica cognitiva é capaz de aprender. Técnicas com essas caracte-

rísticas mostram-se ideais para uso nas redes ópticas dinâmicas [5, 32, 33, 19], porém possuem uma implementação mais complexa, o que torna a sua utilização dependente da complexidade do problema.

Além disso, é fundamental para as técnicas ACOP que os pontos no qual o amplificador pode operar estejam definidos. Para realizar esta definição é necessário um processo de caracterização no qual os pontos de operação dos amplificadores são definidos para um intervalo de valores de potência de entrada, ganho e número de canais. Em [2], Moura e colaboradores apresentaram uma forma de realizar esta caracterização automaticamente retornando, ao fim, um conjunto de pontos de operação chamado de máscara do amplificador. Entretanto, para que se possa desenvolver técnicas ACOP com maior grau de liberdade na escolha dos pontos de operação, é necessário que o perfil do amplificador não seja limitado apenas aos pontos discretos pertencentes à máscara de potência. Portanto, outro desafio para o desenvolvimento das técnicas ACOP é a criação de regressores que possam transformar as informações discretas da máscara de potência em informações contínuas que possam ser utilizadas pelas técnicas.

Apesar de os trabalhos recentes focarem na solução do ACOP considerando apenas amplificadores do tipo EDFA, tais soluções podem ser expandidas para outros tipos de amplificadores. Esta expansão depende apenas do processo de caracterização do amplificador. Neste processo, são definidos os pontos de operação que o amplificador poderá operar dentro de um limite de potências de entrada e de ganhos [2]. Dessa forma, este processo pode ser executado, teoricamente, para qualquer tipo de amplificador.

1.2 Motivação

Diante de tudo isso, este trabalho se propõe a contribuir para a solução do seguinte questionamento:

Como definir, de forma autônoma, o ponto de operação de amplificadores ópticos em cascata, de forma a melhorar/manter o desempenho do enlace óptico em um cenário dinâmico?

1.3 Objetivos

Diante do contexto definido nas seções anteriores, nesta seção é apresentado o objetivo geral da tese que define a contribuição deste trabalho para o problema ACOP. Além disso, são apresentados os objetivos específicos que foram traçados para alcançar o objetivo geral.

1.3.1 *Objetivo geral*

Desenvolver e analisar técnicas para a definição autônoma do ponto de operação de amplificadores EDFA.

1.3.2 *Objetivos específicos*

1. Desenvolver mecanismos que facilitem a utilização da informação contida na máscara de potência;
2. Desenvolver técnicas para ACOP que utilizem as informações da máscara e do enlace para escolherem o ponto de operação, utilizando abordagem global e local;
3. Analisar o impacto das técnicas na qualidade de transmissão de um enlace óptico;
4. Incorporar informações e características de outros dispositivos e elementos de transmissão no processo de escolha do ponto de operação dos amplificadores;
5. Implementar as técnicas desenvolvidas como aplicativos de rede em uma rede com controle SDN.

1.4 **Organização do documento**

No Capítulo 2 o problema ACOP é discutido em detalhes por meio de uma revisão da literatura. No Capítulo 3 são apresentadas as técnicas propostas neste trabalho para a solução do ACOP. No Capítulo 4 são feitas análises acerca das técnicas propostas considerando um cenário no qual os canais do sinal óptico são impactados de forma uniforme pelo amplificador óptico, e que a transmissão é somente impactada pelo ruído ASE. Já no Capítulo 5, são feitas análises mais elaboradas considerando um cenário no qual o amplificador interfere em cada canal do sinal óptico de forma independente, e que os efeitos não-lineares também degradam a qualidade da transmissão. Por fim, no Capítulo 6 são apresentadas as conclusões e os possíveis trabalhos futuros decorrentes desta tese.

2 . CONTROLE ADAPTATIVO DO PONTO DE OPERAÇÃO

O problema do controle adaptativo do ponto de operação de amplificadores ópticos (ACOP) pode ser definido pela seguinte pergunta: como adaptar o ponto de operação dos amplificadores após uma alteração na potência recebida, aumentando, ou ao menos mantendo, a QoT? A solução deste problema se torna uma seleção guiada por um indicador de qualidade. Em geral, o indicador de qualidade é uma ou mais característica(s) do amplificador (NF, *ripple* ou consumo de potência) ou do sistema (OSNR).

Amplificadores ópticos possuem uma região de operação que é definida pelas potências de entrada e saída mínimas e máximas, o que define o ganho máximo e mínimo destes dispositivos. Essa região de operação é chamada de máscara de potência e o desempenho do amplificador dentro desta região pode ser medido por um processo de caracterização [2].

As técnicas que solucionam o problema ACOP usam a máscara de potência como dado de entrada, e retornam os ganhos de cada amplificador da cascata. Portanto, as técnicas funcionam de forma independente das especificações do amplificador, como: potência de bombeio, comprimento de onda de bombeio, número de estágios e etc. Estas informações são apenas importantes para o processo de caracterização dos amplificadores.

O objetivo das técnicas que solucionam o problema ACOP é definir o melhor ganho, enquanto que a implementação e controle deste ganho é são responsabilidades do controle automático de ganho. Portanto, assim como ter a máscara de potência é um pré-requisito para o funcionamento das técnicas ACOP, o controle automático de ganho é uma premissa que estas técnicas assumem em seu funcionamento.

Diante disso, na Seção 2.1 será detalhado o processo de caracterização do amplificador, destacando o conceito da máscara de potência. Na Seção 2.2 será descrito um exemplo do funcionamento de uma solução para o ACOP. Na Seção 2.3 serão apresentadas técnicas propostas na literatura para a solução do problema ACOP. Por fim, na Seção 2.4 serão discutidos os conceitos relativos ao controle automático de ganho em amplificadores EDFA para redes ópticas dinâmicas.

2.1 Processo de caracterização do amplificador

Como anunciado anteriormente, a máscara de potência é a região de operação do amplificador definida por suas potências de entrada e saída. A máscara de potência é representada pelo gráfico da Figura 2.1, no qual cada diagonal corresponde a um ganho constante, variando de um valor mínimo a um valor máximo (direita para a esquerda) ao longo da máscara. É possível identificar através deste gráfico outras informações como potência mínima de entrada e potência máxima de saída do amplificador. NF , *ripple* e outros parâmetros, como a potência consumida pelo amplificador e a temperatura do laser de bombeamento, também podem ser representados dentro da máscara de potência. Os valores destas métricas são codificados por cores de acordo com a barra de cores presente ao lado direito da Figura 2.1. Esta representação ajuda a visualizar o comportamento das métricas ao longo de toda a máscara de potência.

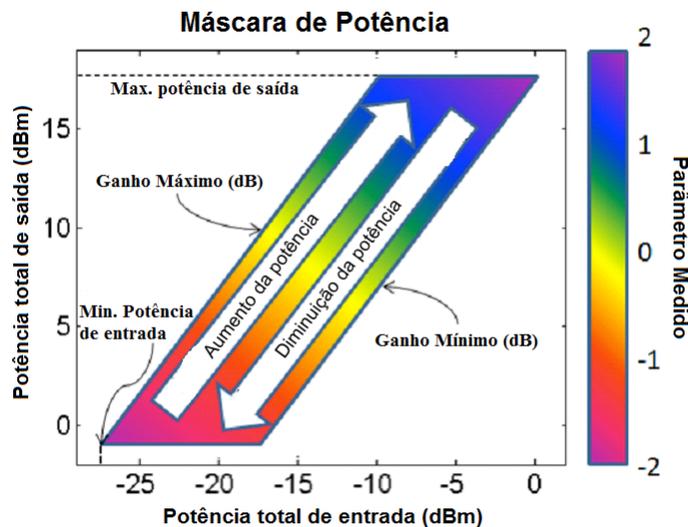


Figura 2.1: Representação gráfica da máscara de potência de um amplificador óptico, destacando determinado parâmetro do amplificador (Fonte: adaptado de [1]).

O processo de caracterização considerado neste trabalho é definido por Moura e colaboradores em [2]. Este processo é dividido em dois estágios: a fase experimental e a fase de processamento de dados. Na fase experimental, um determinado sinal de entrada é definido, como por exemplo: 40 canais não modulados, planos e espaçados por 100 GHz. O sinal de entrada é alterado juntamente com o ganho do amplificador para caracterização de toda a máscara de potência. A granularidade da caracterização é definida por duas variáveis ajustáveis, que são o tamanho do passo e o número de pontos a serem medidos. Para cada ponto, os espectros de entrada e de saída são medidos e armazenados.

O arranjo experimental é apresentado na Figura 2.2 e é composto por um banco de lasers

e uma chave seletiva em frequência – WSS (*Wavelength Selective Switch*) – para prover canais planos na banda C mediante a medida de uma amostra do espectro do sinal de entrada e o ajuste de cada potência de canal em um processo iterativo composto pelo analisador de espectro óptico (OSA - *Optical Spectrum Analyzer*), o computador e o WSS, todos eles controlados por um programa no Labview[®]. Um amplificador óptico auxiliar é utilizado para aumentar a potência total de entrada inserida no amplificador a ser caracterizado. Outro programa no Labview[®] é utilizado para controlar o atenuador óptico variável (VOA - *Variable Optical Attenuator*) e o ganho do amplificador, para percorrer toda a região da máscara de potência. Este mesmo programa do Labview[®] é utilizado para alterar a chave óptica para que o OSA obtenha o espectro de entrada e saída. Todas as conexões do computador e dos equipamentos são descritas na Figura 2.2.

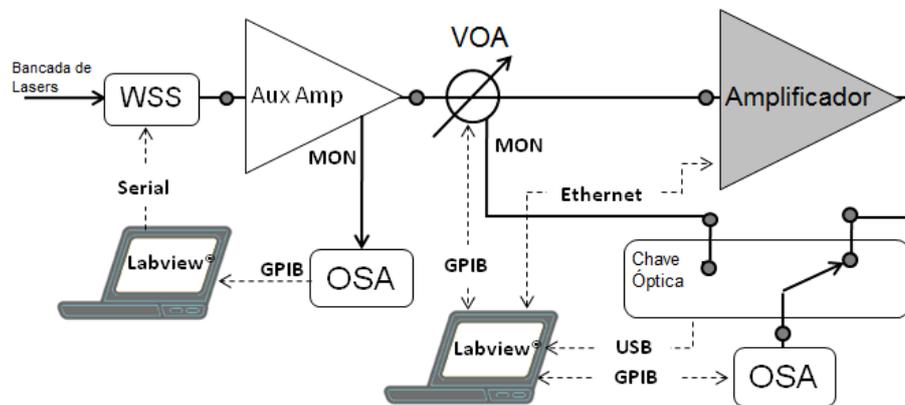
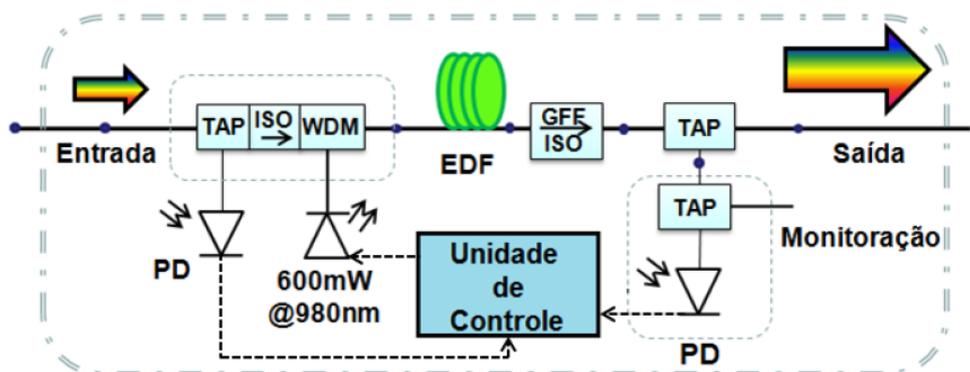
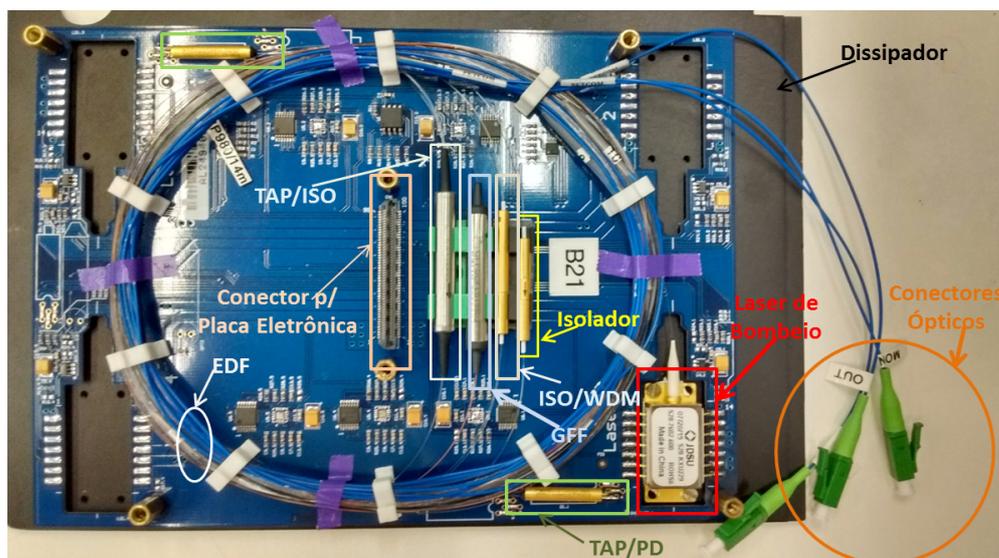


Figura 2.2: Arranjo experimental utilizado no processo de caracterização do amplificador apresentado em [2]. (Fonte: [2])

Nesta tese são considerados amplificadores EDFA de um e dois estágios. As Figuras 2.3a e 2.4a apresentam os esquemas interno dos EDFAs de um estágio e dois estágios, respectivamente, que foram considerados. Neste esquema é possível identificar o(s) laser(s) de bombeio, a(s) fibra(s) dopada(s) com Érbio (EDF - *Erbium Doped Fiber*), os fotodiodos (PD - *Photodiode*), utilizados como entrada para a unidade de controle, o *glass fiber filter* (GFF), além dos isoladores (ISO) e acopladores (TAP) necessários. Já as Figuras 2.3b e 2.4b apresentam as fotos dos amplificadores, destacando os equipamentos utilizados.



(a) Esquema de componentes internos



(b) Foto do amplificador

Figura 2.3: Ilustração do (a) esquema de organização dos equipamentos internos do EDFA de um estágio e (b) foto do equipamento com destaque para os equipamentos. (Fonte: adaptado de [3, 4])

A Figura 2.5 mostra o resultado do processo de caracterização em termos de figura de ruído e planicidade de ganho. Estes resultados são obtidos através de um conjunto de pontos chamados de pontos de operação. Cada ponto de operação é relacionado a uma potência de entrada e uma potência de saída, ou seja, a um ganho. Apesar da máscara de potência se referir à região completa de operação do amplificador, neste trabalho ela será considerada simplesmente como o resultado do processo de caracterização.

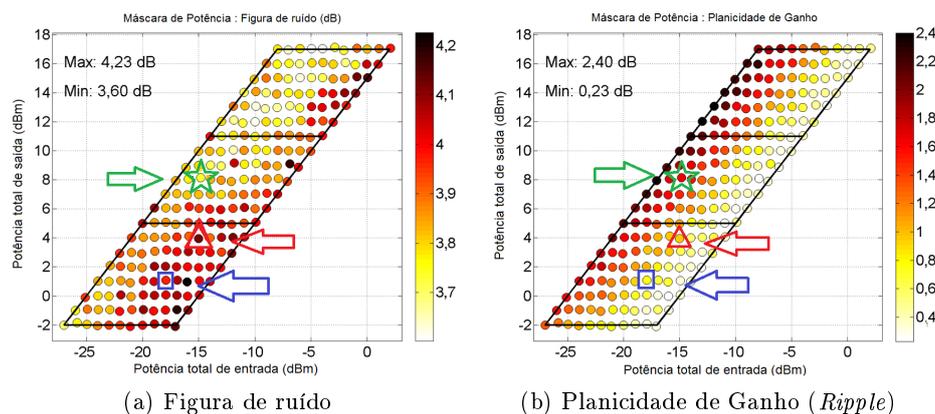


Figura 2.5: Máscara de potência de um amplificador EDFA obtida pelo processo de caracterização para (a) figura de ruído (NF) (b) planicidade de ganho (*ripple*), ambos representados pelas barras de cores. (Fonte: elaboração própria)

2.2 Exemplo geral da solução do problema ACOP

A partir do que foi descrito na seção anterior, é possível entender o processo de caracterização e a consequente formação da máscara. Sabendo que a máscara de potência é um conjunto de possíveis pontos de operação, pode-se definir um exemplo geral de como a solução do ACOP funcionaria.

Considere que um amplificador esteja operando com um ganho igual a 19 dB com uma potência total de entrada de -18 dBm. Neste ponto de operação (quadrado azul na Figura 2.5a) a NF do amplificador é igual a 3,96 dB. Suponha que novos canais sejam adicionados e, então, a potência total de entrada aumentou para -15 dBm. Se o ganho se mantiver, a NF do amplificador aumentará para 4,12 dB (triângulo vermelho na Figura 2.5a). Neste novo cenário, seria melhor mudar o ganho para 23 dB, o que diminuiria a NF para 3,73 dB (estrela verde na Figura 2.5a). O excesso de ganho causado pela mudança de um ponto de operação com ganho menor para um ponto de operação com ganho maior poderia ser reduzido utilizando-se VOAs em algum ponto do enlace, ou reduzindo-se o ganho de outros amplificadores no enlace. Apesar da melhora na NF, neste novo ponto de operação o amplificador apresenta uma pior planicidade de ganho, como pode ser visto na Figura 2.5b, o que reforça a característica

multiobjetivo do problema.

Toda vez que uma mudança for identificada na potência total de entrada do amplificador, cada amplificador da cascata poderá realizar esta adaptação, que tem como objetivo, neste exemplo, diminuir NF e *ripple* da cascata como um todo.

Apesar de terem como principal objetivo adaptar os ganhos em um cenário dinâmico, as técnicas ACOP também podem ser aplicadas em um cenário com tráfego estático. Neste caso, as técnicas seriam utilizadas de forma *offline* para a definição *a priori* dos ganhos dos amplificadores. Apesar de não existir a necessidade de adaptação destes ganhos durante o funcionamento da rede, a correta definição *a priori* dos ganhos também poderá ser relevante para a QoT do enlace.

2.3 Técnicas para ACOP encontradas na literatura

Como mencionado no Capítulo 1, o problema ACOP é recente e, devido a isso, são encontradas apenas duas técnicas na literatura que solucionam este problema da forma como é definido nesta tese. As duas técnicas se diferenciam no objetivo final da definição dos ganhos dos amplificadores. Uma foca apenas no impacto da definição de ganhos de um enlace óptico na QoT do próprio enlace, ou seja, é uma técnica ACOP para enlace ponto-a-ponto. Já a outra técnica visa a otimização da QoT média da rede, por meio da melhor escolha dos ganhos dos amplificadores presentes em um determinado caminho óptico (um ou mais enlaces ópticos).

Estes diferentes enfoques tornam as implementações das técnicas diferentes. A técnica ACOP para um cenário de redes precisa ser global, e também acessar informações sobre caminhos ópticos, o que a torna uma técnica de otimização multi-camadas. Por outro lado, a técnica ACOP para enlaces ponto-a-ponto se concentra apenas em informações da camada física e pode ser aplicada em vários enlaces da rede, tornando a melhora das QoTs dos enlaces em uma melhora da QoT média da rede.

Para melhor entendimento das duas técnicas ACOP encontradas na literatura, a Subseção 2.3.1 detalhará a técnica para enlaces ponto-a-ponto e a Subseção 2.3.2 detalhará a técnica para o contexto de rede.

2.3.1 Técnica ACOP local para enlace ponto-a-ponto (*AdGC*)

Em [7], Oliveira e colaboradores propuseram uma técnica que define de forma adaptativa o ponto de operação de amplificadores EDFA em uma cascata. Esta técnica se chama AdGC (*Adaptive Gain Control*) e visa selecionar o melhor ponto de operação para um amplificador em termos de NF e *ripple* (Rp) de acordo com a potência total de entrada atual e os pontos de operação definidos pela máscara de potência. O melhor ponto de operação é o que possui a menor distância euclidiana,

$$d_i = \sqrt{NF^2 + Rp^2}, \quad (2.1)$$

da origem do espaço de objetivos formado por NF e *ripple* como mostra a Figura 2.6.

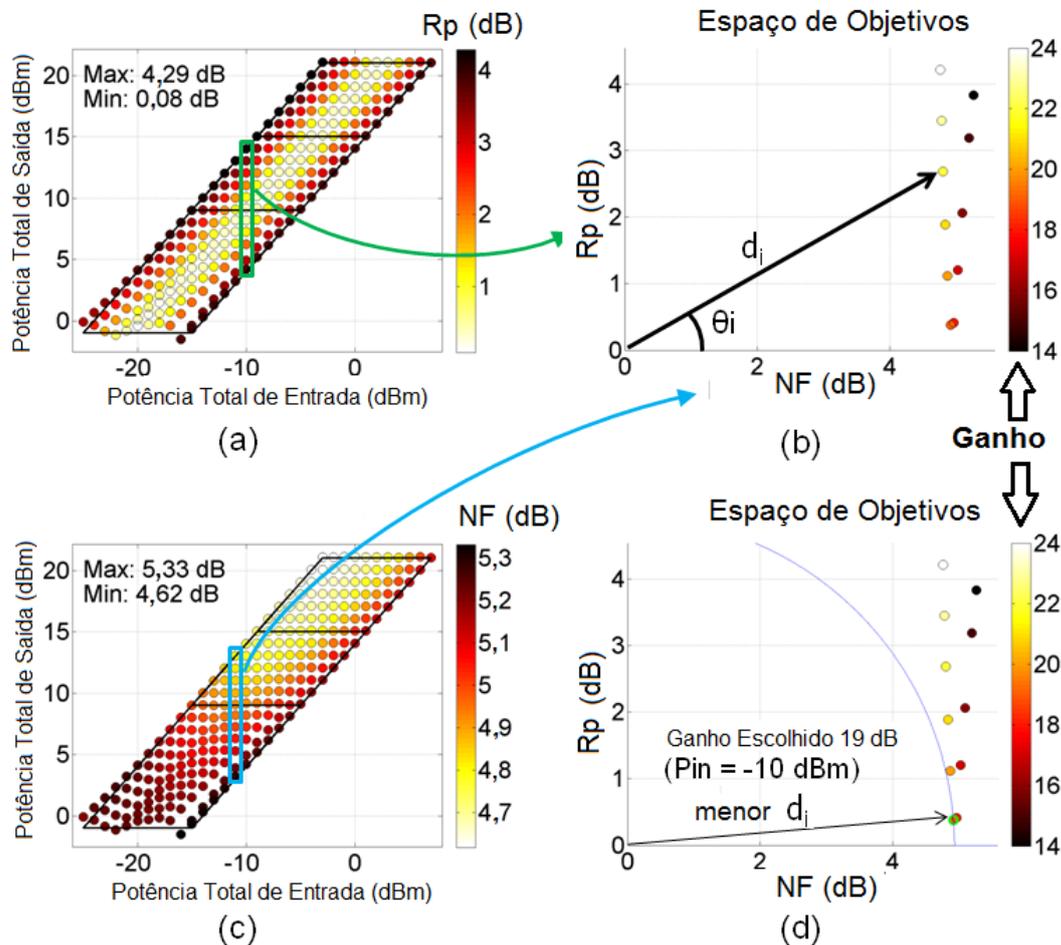


Figura 2.6: Espaço de objetivos do AdGC formado a partir das máscaras de potência de (a) NF e (c) Rp. Em (b) é representado o espaço para uma potência total de entrada igual a -10 dBm ilustrando a distância Euclidiana d_i e o ângulo θ_i , utilizados para calcular o valor de *fitness* e (d) mostra o ganho escolhido. (Fonte: adaptado de [1])

Além disso, quando dois pontos apresentam o mesmo valor de distância, o AdGC utiliza a inclinação da curva que conecta os pontos à origem. Essa inclinação pode ser associada ao ângulo calculado pela equação,

$$\theta_i = \arctan\left(\frac{NF}{Rp}\right) \quad (2.2)$$

e pode ser usado para escolher o ponto, priorizando um dos parâmetros. Se o parâmetro priorizado for NF, deve-se escolher o ponto com o maior ângulo. Caso contrário, deve-se escolher o ponto com menor ângulo.

Dessa forma, cada ponto terá um indicador de qualidade (*fitness*) que será construído pela

distância e pelo ângulo, como define a equação (2.3),

$$fitness_i = d_i \angle \theta_i. \quad (2.3)$$

A Figura 2.6 (d) exemplifica a seleção do ponto de operação considerando uma potência total de entrada igual a -10 dBm e que retornou como resultado um ganho de 19 dB, pois neste exemplo o ponto com este ganho apresenta o menor valor de d_i entre todos os outros ganhos possíveis. O fluxograma apresentado na Figura 2.7 descreve o passo-a-passo do processo realizado pelo AdGC.

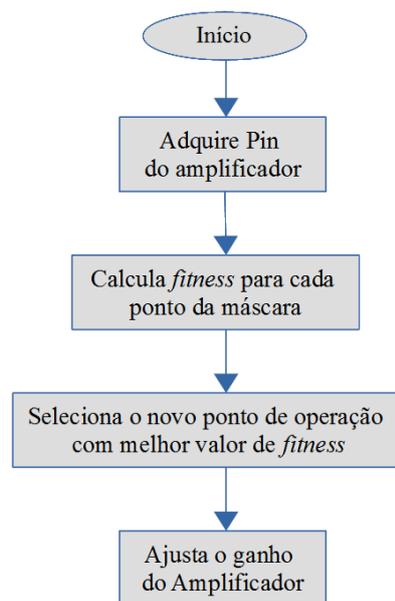


Figura 2.7: Fluxograma representando o passo-a-passo do processo realizado pelo AdGC. (Fonte: elaboração própria)

Para um sistema com amplificadores em cascata, os pontos de operação são encontrados a partir do primeiro amplificador até o último. Procedendo assim, é possível considerar o impacto do ajuste do ponto de operação do amplificador anterior no próximo, por meio da variação da potência de entrada. Então, o primeiro amplificador tem seu ponto de operação ajustado antes. Em seguida, com a nova potência de entrada atualizada, o segundo amplificador tem seu ponto de operação adaptado. Este processo pode ser expandido para três ou mais amplificadores.

AdGC com pesos

Apesar de o AdGC utilizar a distância Euclidiana para selecionar a solução com o melhor compromisso entre NF e *ripple*, muitas vezes existem soluções com um valor de NF bem melhor do que a solução escolhida, porém com um valor de *ripple* só um pouco pior. Isso

acontece pois – na maioria das máscaras – os valores de *ripple* variam em uma escala menor do que os valores de NF.

Diante deste problema, Moura e colaboradores propuseram em [1] uma alteração no cálculo do *fitness* das soluções do AdGC. A alteração inclui nas equações (2.1) e (2.2) pesos que balanceiam a influência de NF e *ripple* no cálculo do *fitness*. Assim, as novas fórmulas para cálculo do fitness são:

$$d_i^w = \sqrt{(W_{NF} \cdot NF)^2 + (W_{Rp} \cdot Rp)^2}, \quad (2.4)$$

$$\theta_i^w = \arctan \left(\frac{W_{NF} \cdot NF}{W_{Rp} \cdot Rp} \right). \quad (2.5)$$

Os resultados em [1] mostram que, se os pesos forem definidos de forma a privilegiar NF em detrimento a *ripple* na escolha das soluções, apesar de uma pequena degradação na planicidade do sinal, o desempenho da cascata, em relação à figura de ruído, pode melhorar consideravelmente. Neste trabalho, esta adaptação do AdGC será chamada de *Weigthed Adaptive Gain Control* (WAdGC).

2.3.2 Técnica ACOP global para cenário de rede

Em [34], experimentos conduzidos em uma rede em malha mostraram o impacto na OSNR devido a diferentes combinações na utilização de estratégias de: equalização de potência, alocação de comprimento de onda e definição autônoma de ganho (ACOP). Os resultados mostram que, apesar de as estratégias de equalização de potência e alocação de comprimento de onda influenciarem na QoT (OSNR), a influência destas estratégias é muito pequena se comparada à da técnica ACOP. A AdGC foi utilizada para definição dos ganhos, e em alguns experimentos foi possível alcançar uma melhora de até 1,6 dB na OSNR média da rede, em comparação à estratégia de definir os ganhos para compensar as perdas.

Com o intuito de melhorar ainda mais o desempenho da rede por meio de uma técnica ACOP, em [5] foi proposta uma técnica cognitiva global que define os ganhos dos amplificadores presentes em um caminho óptico (*lightpath* - LP), a cada novo caminho óptico estabelecido. Esta técnica busca otimizar a OSNR das conexões e utiliza o conceito de *case-based reasoning* (CBR) para aprender com cada novo LP estabelecido, e assim obter melhor valores de OSNR ao longo do tempo.

A técnica proposta em [5] é chamada de AcCBR (*Amplifier Cognitive CBR*) e seu fluxo de funcionamento é apresentado pela Figura 2.8. A AcCBR é acionada a cada nova requisição para o estabelecimento de um LP, a partir daí é executado o processo CBR, que é composto pelas fases de: retorno, reuso, revisão e retenção. O CBR é dependente de um banco de dados (BD) que armazena as informações dos *lightpath* previamente estabelecidos. Na fase

de retorno, são procurados no BD entradas (LP) que possuam características similares à do LP a ser estabelecido, como por exemplo: quantidade de amplificadores, potência total de entrada e perdas dos enlaces. Na fase de reuso, são realizadas algumas alterações de valores nos ganhos dos amplificadores retornados na fase anterior, assim são geradas alternativas de novas definições de ganhos nestes cenários. Em seguida, na fase de revisão, a nova possibilidade de ganhos (formada na fase anterior) é avaliada e um valor de OSNR lhe é atribuído. Por fim, a fase de retenção armazena no BD a nova possibilidade de ganhos juntamente com a OSNR calculada. Então, o AcCBBR seleciona a opção com a maior OSNR dentre todas presentes no BD – pode não ser a opção que acabou de ser criada no processo CBR – e estabelece que ganho do LP a ser estabelecido será igual ao desta opção.

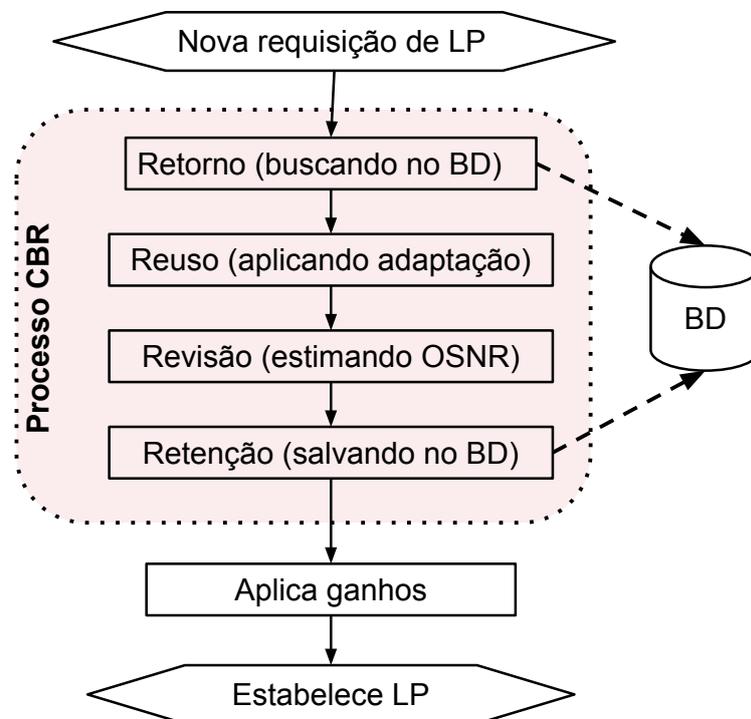


Figura 2.8: Representação do fluxograma de funcionamento da técnica *Amplifier Cognitive CBR* (AcCBBR). (Fonte: adaptado de [5])

Devido ao processo de aprendizagem, os resultados apresentados em [5] mostram que a AcCBBR retorna um bom desempenho em cenários com diferentes: tamanho/topologia de rede, modelos de amplificadores, tráfegos e tamanhos de enlaces. Nota-se que, com o aumento do número de entrada no BD, esta técnica é capaz de aumentar em até 2 dB a OSNR média da rede, comprovando que com o aprendizado vem o ganho no desempenho. Contudo, em alguns cenários o AdGC é suficiente e alcança resultados tão bons quanto o do AcCBBR. Por outro lado, em outros cenários o AcCBBR supera a OSNR média da rede em 4 dB se comparado ao AdGC. Outro ponto negativo da técnica AcCBBR é a não consideração dos efeitos não-lineares

na escolha dos ganhos, o que é colocado como uma sugestão de trabalho futuro em [5].

2.4 Controle Automático de Ganho

Existe uma dependência entre o ganho do amplificador e a sua potência de entrada, o que faz com que o ganho entregue pelo amplificador possa variar de acordo com a variação da potência de entrada. Caso o amplificador esteja trabalhando em regime de saturação, essa dependência é ainda maior e a variação do ganho se torna mais intensa. Nas atuais redes ópticas DWDM (*Dense Wavelength Division Multiplexing*) os amplificadores geralmente funcionam no regime de saturação, pois a grande quantidade de canais utilizados neste tipo de rede eleva o nível de potência na entrada dos amplificadores. Com o intuito de tornar o ganho independente da potência de entrada, foram criadas as técnicas de controle automático de ganho (AGC - *Automatic Gain Control*) que visam manter o ganho do amplificador estável em um valor pré-definido, independentemente das variações na potência de entrada.

Os eventos que causam maior variação na potência de entrada de um amplificador são a adição e a remoção de canais. Ao se adicionar canais, a potência total é dividida entre os canais que já estavam presentes na comunicação e os novos canais adicionados. Dessa forma, os canais sobreviventes sofrem um decaimento em sua potência. Por outro lado, ao se remover canais, os canais sobreviventes sofrem um aumento em sua potência, pois a potência dos canais removidos é repartida entre os canais sobreviventes. Sendo assim, se o ganho total do amplificador não for ajustado de acordo com a nova potência de entrada, os canais sobreviventes após a adição receberão um ganho menor do que o necessário para que se mantenha a mesma potência de saída anterior à adição. Da mesma forma, os canais sobreviventes após a remoção receberão um ganho maior do que o necessário. Portanto, a não utilização de técnicas AGC pode causar degradação na QoT devido a sinais com baixa potência (adição de canais) ou podem danificar *transponders* devido às altas potências recebidas (remoção de canais) [35], especialmente quando os amplificadores estão em cascata [36].

A Figura 2.9a mostra a variação da potência de um canal sobrevivente (na saída do amplificador) após a remoção e, em seguida, adição de canais para os casos com e sem AGC. Percebe-se que no caso sem AGC, após a remoção/adição de canais, o canal sobrevivente tem sua potência aumentada/reduzida, como dito no parágrafo anterior. Porém, no caso com AGC é possível perceber que após a remoção/adição de canais a potência do canal sobrevivente permanece, após um certo transiente, a mesma de antes.

Várias técnicas AGC foram propostas na literatura. As técnicas mais simples e diretas são as de controle de ganho totalmente óptico, na qual o EDFA é utilizado como um meio ativo para a criação de um laser (canal de controle), e o controle do ganho é feito por meio do controle da potência do novo canal criado. Se canais são adicionados, então a potência do canal de controle é diminuída, permitindo que mais elétrons Eb^{+3} estejam na banda excitada,

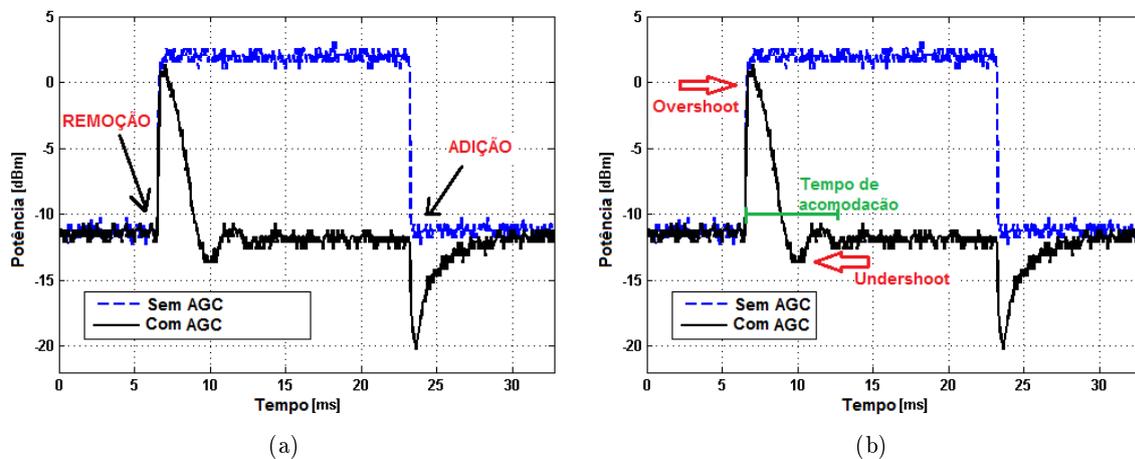


Figura 2.9: Variação da potência de saída de um canal sobrevivente (a) após a remoção e adição de canais, nos casos com e sem AGC, (b) destacando-se o tempo de acomodação, o overshoot e o undershoot. (Fonte: Adaptado de [6])

e assim disponíveis para os outros canais que sofreram uma queda de potência. Se canais são removidos, então a potência do canal de controle é aumentada, para que menos elétrons Eb^{+3} estejam disponíveis para os outros canais, evitando que os canais sobreviventes aumentem a sua potência. Este controle pode ser implementado utilizando-se realimentação óptica [37], que utiliza um filtro óptico sintonizável para definir o comprimento de onda do canal de controle, ou também pode ser implementado utilizando-se grades de Bragg [38]. As técnicas de controle de ganho totalmente óptico são rápidas, porém possuem um faixa de controle limitada para sinais de entrada com potências muito altas, o que torna estas técnicas indicadas para casos no qual o amplificador opera com potências de entrada baixas ($< -15dBm$) [39].

Uma alternativa às técnicas de controle de ganho totalmente óptico são as técnicas de controle de ganho eletrônico, na qual um dispositivo eletrônico realiza o controle do ganho por meio da alteração da potência do laser de bombeio do amplificador. Este controle utiliza parte do sinal de entrada (alimentação adiante), da saída (realimentação) ou ambos, como entrada para uma função de ajuste que retorna a potência de bombeio necessária para que determinado ganho seja atingido [40]. Um processo de caracterização é realizado previamente para que seja possível criar a relação entre potência de bombeio e ganho. O controle de ganho eletrônico pode ser implementado de forma digital quando utilizam-se alguns pontos da caracterização e uma função polinomial para aproximar a curva de potência de bombeio versus ganho, e esta função é implementada em um microcontrolador [41]. Por outro lado, o controle de ganho eletrônico pode ser implementado de maneira analógica, quando é estabelecida uma relação linear entre potência de entrada e potência de saída (ganho), e então o controle pode ser desempenhado por componentes eletrônicos analógicos (ex: amplificadores e inversores eletrônicos) [42]. A implementação analógica é mais rápida, porém a digital permite uma

gerência mais flexível, pois a cada modificação de amplificador é necessário um novo hardware na implementação analógica, enquanto que na implementação digital basta que o *firmware* do microcontrolador seja atualizado.

Em redes ópticas dinâmicas reconfiguráveis, a remoção e adição de canais é comum e ocorre de acordo com a necessidade dos clientes da rede. Portanto, a utilização de uma técnica AGC é um pré-requisito para os amplificadores ópticos que operam neste tipo de rede. Além disso, neste tipo de rede, as técnicas AGC precisam suprimir ao máximo o transiente causado pelo controle do ganho, pois as adições/remoções de canais podem acontecer rapidamente. Caso o transiente presente durante as alterações de canais tenha um tempo de acomodação longo (*settling time*) ou possua limites transitórios de erros superior/inferior (*undershoot/overshoot*) no canal sobrevivente muito altos (vide Fig. 2.9b), esse cenário poderá causar instabilidades na rede, principalmente quando existem vários amplificadores cascadeados em um caminho óptico. Portanto, as técnicas AGC para redes óptica dinâmica precisam ter como característica a supressão eficiente do transiente, o que significa um tempo de acomodação de dezenas de microssegundos e um transiente menor do que 1 dB [43]. Técnicas de controle de ganho que satisfaçam estes requisitos têm sido propostas [24, 6], inclusive para amplificadores híbridos [44] e sistemas ópticos com comutação de pacotes [45, 46]. Em [46], por exemplo, é apresentado um EDFA com AGC eletrônico capaz de controlar o transiente após a remoção/adição de 100 canais WDM com *undershoot/overshoot* de 0,2 dB em um tempo de acomodação inferior a dezenas de microssegundos.

3 . DESENVOLVIMENTO DE TÉCNICAS PARA O ACOP

Apesar da importância das técnicas ACOP para o cenário de rede como mostrado em [34], e também do bom desempenho demonstrado pela técnica global AcCBBR em relação à AdGC [5], está fora do escopo desta tese considerar o ACOP em um cenário de rede. Dessa forma, as técnicas que serão propostas e as análises que serão realizadas considerarão apenas o desempenho da QoT em um enlace ponto-a-ponto, ou seja, uma cascata de amplificadores.

Sendo assim, apenas a técnica AdGC será considerada em análises comparativas neste trabalho. Apesar de ser uma técnica promissora que tem apresentado bons resultados [7, 1], o AdGC possui algumas fraquezas e muitas considerações ainda podem (devem) ser feitas quanto à melhor forma de se desenvolver técnicas para o ACOP.

Por exemplo, considerando uma cascata de amplificadores, as técnicas AdGC implicam em um processo de “passo único”, no qual os amplificadores selecionam seu melhor ponto de operação imediatamente. Em uma perspectiva global, esse tipo de escolha pode não ser a melhor opção para a cascata de amplificadores como um todo, porque, quando um amplificador vai diretamente para o seu melhor ponto de operação, ele pode reduzir as chances de o seu vizinho alcançar um bom ponto de operação.

Outra fragilidade do AdGC é a não consideração de uma restrição na potência de saída da cascata. Apesar de ser uma técnica para enlace ponto-a-ponto, para a implementação desta técnica em um cenário de rede, é importante que a potência na saída da cascata seja regulada para que ela se mantenha dentro de um certo intervalo adotado pela rede. Essa restrição da potência de saída é necessária para que enlaces com amplificadores adaptáveis (AdGC) não interfiram no funcionamento de outros enlaces adjacentes e que podem não possuir amplificadores adaptáveis (compensação de perdas), além de evitar efeitos não-lineares.

Além disso, o AdGC é um técnica que se utiliza de informações locais (*e.g.*: potência de entrada e saída) para a tomada de decisão. Como mencionado no Capítulo 1, as técnicas para a solução do ACOP podem ser implementadas de forma global e/ou local. Então, existe a necessidade de se implementar técnicas globais para a solução do ACOP, de forma a se avaliar os impactos nas qualidades das soluções e no tempo de execução entre as técnicas locais e globais.

Nas seções a seguir são descritos os desenvolvimentos de novas técnicas para o ACOP. Na Seção 3.1 é apresentada uma técnica que utiliza um método iterativo, considera a restrição na potência de saída e é baseada em técnicas de aprendizado de máquina. Na Seção 3.2 é apresentada uma técnica global para a solução do ACOP. Por fim, na Seção 3.3 é apresentada uma heurística desenvolvida por meio do conhecimento adquirido a partir dos resultados das técnicas anteriores.

3.1 Heurística iterativa e com restrição de potência de saída baseada em aprendizado de máquina

Com o intuito de evitar a escolha do ganho em um “passo único”, apresenta-se aqui uma nova proposta para a criação técnicas para amplificadores ópticos auto-adaptáveis baseada em processos de aprendizado de máquina, que varia o ponto de operação de acordo com a máscara de potência dos amplificadores por meio de um processo de atualização iterativa.

O ponto de operação de cada amplificador é atualizado localmente com um passo controlado. O tamanho do passo diminui com o decorrer das iterações para garantir a convergência do processo. A cada iteração, o processo de atualização é realizado em duas etapas. Na primeira, os ajustes são realizados do primeiro ao último amplificador da cascata, e, em seguida, é executado um processo de retroalimentação no qual os ajustes são feitos do último amplificador até o primeiro da cascata. Dessa forma, busca-se obter a otimização global da cascata.

Além disso, esta proposta visa atender a restrição de potência de saída da cascata. A potência de total de saída do último amplificador da cascata será controlada para se manter igual a um valor pré-determinado. Resolvendo assim, uma das fraquezas da AdGC.

A técnica aqui proposta é nomeada de *Annealing Search Heuristic with Backpropagation* (AsHB), ou seja, uma heurística baseada em busca com resfriamento e retropropagação.

3.1.1 *Aprendizado de Máquina*

A AsHB tem seu funcionamento baseado em técnicas de aprendizado de máquina. Aprendizado de máquina (do inglês – *Machine Learning*) é uma subárea da inteligência computacional que busca provê capacidade de auto-adaptação a processos computacionais por meio de métodos de aprendizagem [47]. Neste contexto, aprendizagem trata de processos complexos de reconhecimento de padrões e tomada de decisão inteligente. Aprendizado de máquina tem sido amplamente aplicado em diferentes áreas como *web* semântica [48], análise de crédito financeiro [49] e diagnóstico médico [50].

Um dos mecanismos mais tradicionais de aprendizado é a regra delta. Esta regra foi desenvolvida por Widrow e Hoff em 1969 [51] e é um exemplo de aprendizado supervisionado

que utiliza o método do gradiente descendente para minimizar o erro entre a saída atual do sistema e a saída desejada. A aplicação mais conhecida para essa técnica é o treinamento da rede neural ADALINE [52]. A regra delta é dada pela equação (3.1)

$$\Delta w_{ij} = \alpha(d_i - y_i)x_j f'(net_i), \quad (3.1)$$

na qual o α é a taxa de aprendizado, w_{ij} é o peso entre o neurônio i e o neurônio j , d_i é a saída desejada, y_i é a saída atual, x_j é o valor da variável de entrada e $f'(net_i)$ é a derivada da função de saída. Caso a função de saída seja uma função linear, então a sua derivada será igual a um e a Equação (3.1) pode ser simplificada para

$$w_{ij}(new) = w_{ij}(old) + \alpha(d_i - y_i)x_j. \quad (3.2)$$

Backpropagation (BP) é uma generalização da regra delta e é utilizado para o treinamento de redes neurais artificiais multicamadas (MLP – *Multilayer Perceptron*). Esta generalização foi desenvolvida para propagar o erro na saída da rede neural de forma recursiva, e retroativa, através das camadas da MLP. O BP é dividido em dois passos. No primeiro, os valores são propagados da entrada para a saída e o erro entre a saída desejada e a saída atual é calculado. No segundo passo, os erros são propagados recursivamente da saída para a entrada e os pesos da rede são atualizados.

3.1.2 Detalhamento da proposta de aprendizado da AsHB

A AsHB é baseada no algoritmo *backpropagation*, porém propaga o erro em duas direções (direta e inversa) para atualizar o ponto de operação dos amplificadores na cascata e manter o nível de potência pré-definido na saída do enlace (Figura 3.1).

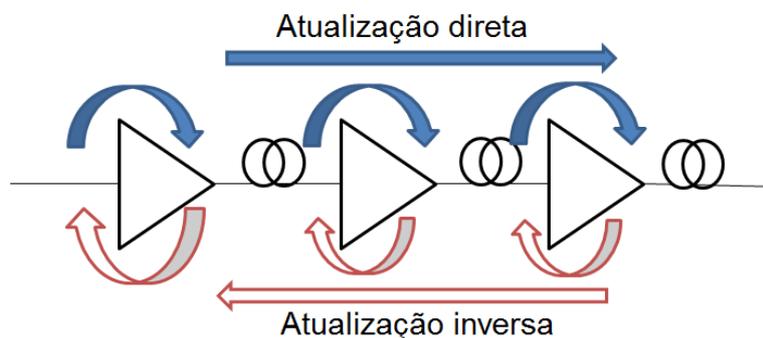


Figura 3.1: Ilustração do método iterativo realizado pelo AsHB. Atualização direta atualiza as potências de saídas de acordo com as potências de entrada. Atualização inversa atualiza as potências de entrada de acordo com as potências de saída. (Fonte: elaboração própria)

Foi definido um tamanho de passo máximo para o ajuste do ponto de operação dos am-

plificadores para que possa ser encontrada a configuração de cada amplificador que melhora o desempenho da cascata como um todo. A hipótese adotada é de que o melhor ponto de operação do amplificador não é necessariamente a melhor opção para a cascata. Portanto, um método iterativo poderá permitir um melhor compromisso entre o melhor ponto de operação do amplificador e o melhor ponto de operação dos seus amplificadores vizinhos. Neste método iterativo, a intensidade da mudança em cada amplificador (tamanho do passo) será definida através de uma técnica de otimização chamada de *Simulated Annealing*. É comum se utilizar processos de *annealing* (cozimento) para refinar o aprendizado e aumentar a capacidade de exploração em profundidade no decorrer do tempo [53].

O pseudocódigo da AsHB é descrito no Algoritmo 1. $P_{in}(i)$ e $P_{out}(i)$ são as potências totais de entrada e de saída do amplificador i , respectivamente. $P_{in}^{cascata}$ e $P_{out}^{cascata}$ são as potências totais, predeterminadas, de entrada e saída do enlace. Observa-se que o algoritmo tem um laço principal que contém dois laços internos, um para a atualização direta e outro para a atualização inversa. O laço principal é executado um número predeterminado de vezes e cada iteração é realizada com um determinado valor para o passo.

A estratégia de inicialização (linha 1 do Algoritmo 1) define o menor ganho possível para cada um dos amplificadores, apenas como forma de definir um valor inicial válido. Os pontos de operação utilizados como referência nas linhas 8 e 19 do Algoritmo 1 são aqueles que possuem a potência total de entrada P_{in} (ou a potência total de saída P_{out} no processo inverso) próxima à do amplificador atual. Utiliza-se uma margem de 0,5 dB para definir os pontos de operações aptos a serem utilizados como referência. Suponha que uma máscara de potência contém informações sobre o amplificador com resolução de 0,5 dB. Portanto, um amplificador operando com $P_{in} = 0 \text{ dBm}$ pode ter como referências os pontos com $P_{in} = -0,5 \text{ dBm}$ e $P_{in} = 0,5 \text{ dBm}$.

Algoritmo 1: Pseudocódigo da *Annealing Search Heurist with Backpropagation* (AsHB).

Entrada: Máscara de potências dos amplificadores;

```

1 Inicialize os amplificadores;
2  $Erro_{saida} = Erro_{entrada} = 0$ ;
3 enquanto O número total de iterações não foi alcançado faça
4   para cada Amplificador 1 até  $n - 1$  faça
5     se Primeiro Amplificador então
6        $P_{in}(1) = P_{in}^{cascata}$ ;
7        $P_{out}^{novo}(1) = P_{out}^{antigo}(1) - Erro_{entrada}$ ;
8       Selecione um conjunto de pontos de operações com  $P_{in}$  próximo ( $\pm 0,5dB$ ) ao
9        $P_{in}$  do amplificador atual;
10      Selecione o ponto de operação alvo, dentro deste conjunto, que tem a menor  $d_i$ 
11      (equação 2.1);
12      Calcule o passo;
13       $P_{out}^{novo}(i) = P_{out}^{antigo}(i) + passo$ ;
14      Defina o Ganho, NF e Rp deste amplificador;
15      Calcule a potência de entrada do próximo amplificador considerando as perdas
16      do enlace:  $P_{in}(i + 1) = P_{out}^{novo}(i) - perdaEnlace(i)$ ;
17  $Erro_{saida} = P_{out}(n) - P_{out}^{cascata}$ ;
18 para cada Amplificador  $n$  até 2 faça
19   se Último Amplificador então
20      $P_{in}^{novo}(n) = P_{in}^{antigo}(n) - Erro_{saida}$ ;
21   senão
22     Selecione um conjunto de pontos de operações com  $P_{out}$  próximo ( $\pm 0,5dB$ )
23     ao  $P_{out}$  do amplificador atual;
24     Selecione o ponto de operação alvo, dentro deste conjunto, que tem a menor
25      $d_i$  (equação 2.1);
26     Calcule o passo;
27      $P_{in}^{novo}(i) = P_{out}^{antigo}(i) + passo$ ;
28     Defina o Ganho, NF e Rp deste amplificador;
29     Calcule a potência de entrada do próximo amplificador considerando as perdas
30     do enlace:  $P_{out}(i - 1) = P_{in}^{novo}(i) + perdaEnlace(i)$ ;
31  $Erro_{entrada} = P_{in}(1) - P_{in}^{desejado}$ ;

```

Saída: Ganho de cada amplificador.

O cálculo do tamanho do passo (linha 10 e 21 do Algoritmo 1) é o procedimento mais importante no processo de adaptação. A AsHB utiliza o conceito de *annealing* para alterar o tamanho do passo ao longo das iterações. A principal ideia é diminuir o passo de forma a minimizar um comportamento “egoísta” do amplificador. O ponto de operação do amplificador é ajustado de forma a alcançar o ponto de operação alvo (*i.e.* o ponto com o menor d_i no conjunto dos pontos de operação de referência). O passo diminui ao longo das iterações de

acordo com a Equação

$$passo = (e^{-T} - e^{-1}) \cdot [P_{in}(i) - P_{in}(alvo)], \quad (3.3)$$

na qual o $P_{in}(i)$ é a potência total de entrada do amplificador i e $P_{in}(alvo)$ é a potência total de entrada do ponto de operação alvo. A equação (3.3) também é utilizada para atualizar a potência total de saída substituindo-se P_{in} por P_{out} .

O parâmetro T é o fator de temperatura do processo *annealing*. T é avaliado de acordo com 3.4.

$$T = \frac{iteracao_{atual}}{iteracao_{total}}, \quad (3.4)$$

na qual $iteracao_{atual}$ é o número da iteração atual e $iteracao_{total}$ é o número total de iterações. Portanto, T irá aumentar ao longo das iterações, alcançando $T = 1$ na última iteração. Então, o passo descrito na Equação (3.3) irá diminuir ao longo das iterações, alcançando o valor zero na última iteração.

Vale salientar que o processo de *annealing* utilizado aqui é uma adaptação do utilizado na técnica de busca *Simulated Annealing*. Na *Simulated Annealing*, este processo é utilizado em uma busca, o objetivo é utilizar o parâmetro T para definir, no início do processo, um busca em largura, que, com o passar das iterações, se torna uma busca em profundidade. Na adaptação utilizada no AsHB, este processo não será utilizado para busca, visto que o melhor ponto de operação é escolhido utilizando o valor de d_i , mas como um regulador do tamanho do passo dado pela técnica em direção ao melhor ponto.

A AsHB é guiada por uma função de *fitness* que depende de NF e *ripple*, e deve ser definida para qualquer par de valores de P_{in} e P_{out} dentro do intervalo de operação. Através da utilização do regressor apresentado na Seção 4.1, é possível ter valores contínuos de NF e *ripple* para avaliar d_i de acordo com a equação (2.1).

3.1.3 Adaptação considerando um VOA na saída do enlace (AsHB Flex)

Para atender a restrição na potência de saída da cascata, o AsHB ajusta o ganho do último amplificador para que se tenha a potência de saída desejada. Porém, em muitos casos esse ajuste leva a uma escolha de um ponto de operação muito ruim para o último amplificador da cascata, o que prejudica a qualidade da transmissão.

Com o intuito de atender a restrição de uma forma mais flexível, foi proposta uma adaptação ao AsHB chamada de AsHB Flex, que considera a existência de um atenuador óptico variável (VOA - *Variable Optical Attenuator*) após o último amplificador da cascata. Dessa forma, o último amplificador pode operar em um ponto de operação bom em termos de NF e *ripple*, e que tenha uma potência de saída maior do que a desejada para o enlace, já que, ajustando-se o VOA, será possível garantir a potência de saída desejada. Na prática, significa dar um grau de liberdade a mais para a cascata de amplificadores.

O Algoritmo 2 apresenta o pseudocódigo da AsHB Flex. O funcionamento básico é idêntico ao do AsHB, com um laço de repetição principal para desenvolver as iterações, e dois laços de repetição internos para os processos de atualização direta e inversa. As principais mudanças feitas na AsHB Flex, em comparação com a AsHB, estão na forma como a técnica gerencia as mudanças de potência no último amplificador.

A primeira mudança é a adição da linha 16 no Algoritmo 2 para limitar o processo de atualização inversa para as primeiras $n - 1$ iterações, prevenindo assim que o processo de atualização inversa altere a potência de entrada da cascata (primeiro amplificador) na última iteração.

A segunda mudança restringe a atuação do processo de atualização inversa apenas entre o último e o segundo amplificador da cascata (Algoritmo 2 linha 17), restringindo o primeiro amplificador a realizar apenas a correção do erro de entrada.

A última mudança é a adição do bloco de código da linha 18 à linha 24 para considerar a utilização do VOA no final da cascata. Este novo bloco de código define três regras condicionais para gerenciar a potência de saída do último amplificador de acordo com a potência de saída desejada para a cascata ($P_{out}^{cascata}$), que foi definida como a potência de entrada do primeiro amplificador mais as perdas do dispositivo ROADM (*Reconfigurable Optical Add-Drop Multiplexer*) (Algoritmo 2 linha 3). A primeira regra garante que o valor da potência total de saída não será menor do que $P_{out}^{cascata}$. A segunda regra garante que esse valor não será maior do que o valor desejado mais a atenuação máxima do VOA e a perda do ROADM, para que o VOA possa compensar a potência de saída. Se o valor da potência de saída esta dentro do intervalo aceitável, definido pelas duas primeiras regras, então o algoritmo irá alterar a potência de entrada de acordo com o erro de saída. Esta mudança será ponderada pela intensidade da restrição (*IntensidadeRestricao* - Algoritmo 1 linha 24). O fator *IntensidadeRestricao* diminui linearmente de 1 (restrição alta) até 0 (sem restrição) ao longo das iterações. A escolha deste decréscimo ao longo das iterações é para que esta restrição acompanhe a mesma tendência do tamanho do passo utilizado na atualização das potências, que também decresce ao longo das iterações. Assim, quando o valor do passo for grande, a restrição da potência de saída será mais forte para prevenir o aumento da potência nas primeiras iterações. Com o decorrer das iterações, a restrição se tornará menos rígida e não terá ação na última iteração.

Algoritmo 2: Pseudocódigo da *Annealing Search Heurist with Backpropagation Flex* (AsHB Flex).

Entrada: Máscara de potência dos amplificadores;

```

1 Inicialize os amplificadores;
2  $Erro_{entrada} = Erro_{saida} = 0$ ;
3  $P_{out}^{desejado} = P_{in}(1)$ ;
4 enquanto O número total de iterações não foi alcançado faça
5   para cada Amplificador 1 até  $n$  faça
6     se Primeiro Amplificador então
7        $P_{in}(1) = P_{in}^{cascata}$ ;
8        $P_{out}^{novo}(1) = P_{out}^{antigo}(1) - Erro_{input}$ ;
9     Selecione um conjunto de pontos de operações com  $P_{in}$  próximo ao  $P_{in}$  do
10      amplificador atual;
11     Selecione o ponto de operação alvo, dentro deste conjunto, que tem a menor  $d_i$ 
12      (equação 2.1);
13     Calcule o passo;
14      $P_{out}^{novo}(i) = P_{out}^{antigo}(i) + passo$ ;
15     Defina o Ganho, NF e Rp deste amplificador;
16     Calcule a potência de entrada do próximo amplificador considerando as perdas
17      do enlace:  $P_{in}(i + 1) = P_{out}^{novo}(i) - perdaEnlace(i)$ ;
18    $Error_{output} = P_{out}(n) - (P_{out}^{desejado} + maxPerdaVOA + perdaROADM)$ ;
19   se Não é a última iteração então
20     para cada Amplificador  $n$  até 2 faça
21       se Último Amplificador então
22         se  $P_{out}(n) < (P_{out}^{desejado} - perdaROADM)$  então
23            $P_{out}(n) = P_{out}^{desejado} + perdaROADM$ 
24         senão se  $P_{out}(n) > (P_{out}^{desejado} + maxPerdaVOA + perdaROADM)$ 
25           então
26              $P_{out}(n) = (P_{out}^{desejado} + maxPerdaVOA + perdaROADM)$ 
27           senão
28              $P_{in}^{novo}(n) = (P_{in}^{antigo}(n) - Error_{out}) \cdot IntensidadeRetricao$ ;
29       senão
30         Selecione um conjunto de pontos de operações com  $P_{out}$  próximo ao  $P_{out}$ 
31         do amplificador atual;
32         Selecione o ponto de operação alvo, dentro deste conjunto, que tem a
33         menor  $d_i$  (equação 2.1);
34         Calcule o passo;
35          $P_{in}^{novo}(i) = P_{out}^{antigo}(i) + passo$ ;
36         Defina o Ganho, NF e Rp deste amplificador;
37         Calcule a potência de entrada do próximo amplificador considerando as
38         perdas do enlace:  $P_{out}(i - 1) = P_{in}^{novo}(i) + perdaEnlace(i)$ ;
39    $Error_{input} = P_{in}(1) - P_{in}^{desejado}$ ;

```

Saída: Ganho de cada amplificador.

3.2 Método exaustivo global

Tanto AdGC quanto AsHB são técnicas ACOP locais, pois durante o seu processo cada amplificador toma sua decisão baseado em sua informação local (máscara de potência) e informação dos seus vizinhos (potência de entrada ou saída). Contudo, é possível desenvolver técnicas que tenham acesso a informação de todos os amplificadores da cascata, o que a possibilitaria guiar as decisões com uma visão mais completa do problema. Nesta seção será apresentada uma técnica ACOP global que tem como foco a otimização de um enlace ponto-a-ponto.

A técnica Método Exaustivo (ME) calcula todas as possíveis combinações de pontos de operação, considerando as máscaras de potência dos amplificadores da cascata. Em seguida, ela seleciona o ponto de operação que possui a menor distância euclidiana definida na Equação (2.1). Portanto, esta técnica pode ser vista como a solução de um problema combinatório no qual o número de amplificadores da cascata é o número de variáveis e os possíveis valores de ganho são os valores que as variáveis podem assumir.

O Algoritmo 3 mostra o pseudocódigo da implementação do ME. Considerando uma cascata com quatro amplificadores, cada um com ganho variando entre 15 e 25 dB, por exemplo, os valores de $Ganho_{max}$, $Ganho_{min}$ e n (número de amplificadores), no Algoritmo 3, será 15, 25 e 4, respectivamente. Neste Algoritmo, o conjunto *pontosOp* contém os ganhos que serão utilizados para definir os pontos de operação de cada amplificador. Já o conjunto *melhoresPontos* contém os melhores pontos de operação encontrados para os amplificadores durante o processo.

Algoritmo 3: Pseudocódigo do Método Exaustivo (ME).

Entrada: $Ganho_{max}$, $Ganho_{min}$ e $Tamanho_{passo}$

```

1  $d^{min} = Infinito$  e  $melhoresPontos = \emptyset$ ;
2 para  $G_1$  de  $Ganho_{max}$  até  $Ganho_{min}$  com  $Tamanho_{passo}$  faça
3   para  $G_2$  de  $Ganho_{max}$  até  $Ganho_{min}$  com  $Tamanho_{passo}$  faça
4     ...
5     para  $G_n$  de  $Ganho_{max}$  até  $Ganho_{min}$  com  $Tamanho_{passo}$  faça
6        $pontosOp = \{G_1, G_2, \dots, G_n\}$ ;
7       se  $pontosOp$  esta dentro da máscara então
8         Calcule NF e Rp da cascata;
9         Calcule  $d$  usando Equação (2.1);
10        se  $d < d^{min}$  então
11           $d^{min} = d$ ;
12           $melhoresPontos = pontosOp$ ;
13        ...

```

Saída: Todas as soluções e *melhoresPontos*

Por ser uma técnica global, o ME requer uma entidade externa no plano de controle que possua conhecimento sobre a máscara de potência de cada amplificador, e que possua comunicação com cada amplificador da cascata para obter suas potências de entrada e de saída. Este controle central calcula os possíveis pontos de operação como mostrado no Algoritmo 3, escolhendo a combinação com os melhores pontos (*melhoresPontos*) e alterando os amplificadores de acordo.

Além disso, por achar todas as possíveis soluções para o problema ACOP, o ME pode ser utilizado com uma função de *benchmark* para as outras técnicas ACOP.

Um fator chave que afeta a qualidade das soluções e o tempo de computação do ME é o tamanho do passo utilizado para ir de $Ganho_{max}$ para $Ganho_{min}$ (Algoritmo 3 linha 2-4). Um passo pequeno retorna resultados com uma melhor resolução, porém, consome mais tempo do que com um passo maior.

3.3 Heurística do ganho máximo

As técnicas já apresentadas nesta tese (AdGC, AsHB e ME) não assumem qualquer conhecimento prévio acerca do problema ACOP. Contudo, ao analisar as soluções retornadas por essas técnicas, principalmente a ME, que define todo o espaço de busca, é possível identificar alguns padrões que definem as melhores soluções em um cenário específico.

Em [54], Baney e colaboradores mostraram que o fator de ruído da cascata pode ser calculado pela Equação (3.5).

$$F_{cascata} = F_1 + \frac{F_2}{G_1 L_1} \dots + \frac{F_N}{G_1 L_1 \dots G_{N-1} L_{N-1}} + \dots + \frac{1}{G_1 L_1 \dots G_{N-1} L_{N-1} G_N}, \quad (3.5)$$

na qual F_i e G_i ($i = 1, 2, \dots, N$) são respectivamente o fator de ruído e o ganho do amplificador na posição i da cascata com N amplificadores, enquanto que L_i ($i = 1, 2, \dots, N - 1$) é a perda do enlace i da cascata. A figura de ruído da cascata ($NF_{cascata}$) é simplesmente o fator de ruído da cascata em escala logarítmica, como mostra a Equação (3.6)

$$NF_{cascata} = 10 \cdot \log(F_{cascata}). \quad (3.6)$$

É dessa forma que a figura de ruído do enlace é calculada nas simulações que são apresentadas no Capítulo 4.

Diante disso, após análise dos resultados de algumas simulações, foi possível perceber que as melhores soluções (menores NF e Rp) utilizam o maior ganho possível nos primeiros amplificadores da cascata. A explicação para esse padrão é que a minimização da $NF_{cascata}$ é mais importante para a qualidade das soluções do que a minimização do *ripple* da cascata ($Rp_{cascata}$), e essa priorização é decorrente de dois fatores. O primeiro é: a minimização

do valor final de $NF_{cascata}$ é muito dependente da figura de ruído e do ganho dos primeiros amplificadores; o que é evidente ao se analisar as Equações (3.5) e (3.6). O outro é: o intervalo dos valores de NF, na máscara de potência dos amplificadores considerados, geralmente possui uma variação maior do que os valores de *ripple*. Portanto, as soluções finais são mais sensíveis a NF do que a *ripple*.

Considerando estes aspectos, foi elaborada uma técnica que busca seguir este padrão, definindo para cada amplificador da cascata o ponto de operação que utiliza o maior ganho possível, do primeiro ao último amplificador da cascata. O Algoritmo 4 descreve o pseudocódigo desta técnica, que é chamada de MaxGain. Como a AdGC e a AsHB, a MaxGain é uma técnica local que realiza a troca de informação apenas entre os amplificadores vizinhos.

Algoritmo 4: Pseudocódigo da técnica MaxGain.

Entrada: Máscara de potência de cada amplificador da cascata

1 **para cada** *Amplificador* **faça**

2 Selecione um conjunto de pontos de operação com P_{in} próximo ao P_{in} atual do amplificador;

3 **se** *O conjunto é vazio* **então**

4 Diminua a potência total de saída do amplificador anterior:

$$P_{out}^{novo}(i-1) = P_{out}^{antigo}(i-1) - (P_{in}(i) - P_{in}^{MAX});$$

5 Defina o Ganho, NF e Rp deste amplificador;

6 Volte à linha 2;

7 Selecione o ponto de operação alvo, dentro deste conjunto, que tenha o maior ganho;

8 Ajuste o amplificador para o ponto de operação alvo;

9 $P_{in}(i+1) = P_{out}^{novo}(i) - perdaEnlace(i);$

Saída: O ganho de cada amplificador.

Contudo, ajustar o amplificador para o ganho máximo pode impor ao próximo amplificador da cascata uma potência total de entrada que é maior do que a máxima suportada pelo amplificador. A consequência é que nenhum ponto de operação estará disponível para este amplificador. Portanto, o bloco de código da linha 3 a 6 no Algoritmo 4 realiza a verificação e correção desta situação indesejada. Este procedimento verifica o tamanho do conjunto dos pontos de operação candidatos (linha 3) e, se o conjunto for vazio, diminui a potência total de saída do amplificador anterior de modo que a potência total de entrada do amplificador atual seja igual à potência máxima de entrada suportada (P_{in}^{MAX}) (linha 4). Então, o novo ponto de operação do amplificador anterior é atualizado, e o laço de repetição recomeça para o amplificador atual (linhas 5 e 6).

4 . AVALIAÇÃO DAS TÉCNICAS CONSIDERANDO MODELAGEM DE PIOR CASO PARA OS AMPLIFICADORES

Como esclarecido no Capítulo 2, a máscara de potência do amplificador é a principal entrada para as técnicas ACOP, portanto as informações presentes nesta máscara irão interferir no desempenho das técnicas. As análises realizadas neste capítulo considerarão que a máscara de potência do amplificador possui as informações de pior caso para os pontos de operação. Isso significa que as métricas definidas para cada ponto (NF e *ripple*) representam o pior valor dentre o conjunto de canais caracterizados. Essa consideração torna a utilização das informações da máscara mais simples.

Outro ponto importante é a necessidade de se criar um regressor linear que permita as técnicas ACOP utilizarem a informação da máscara de potência de uma forma contínua. Esse tipo de regressor permitirá que as técnicas utilizem diferentes granularidades no seu processo de adaptação, o que é fundamental para o funcionamento da técnica AsHB e influenciará na precisão da técnica ME. Ademais, tal regressor pode agilizar o processo de caracterização permitindo que a região de operação do amplificador seja bem definida sem que muitos pontos de operação sejam caracterizados.

Por fim, para validar as técnicas propostas e verificar suas vantagens e desvantagens, é preciso realizar análises quanto ao funcionamento e às soluções das técnicas. Também é importante realizar análises comparativas para que se esclareça as vantagens e desvantagens de uma técnica em relação à outra. As análises devem ser focadas no quanto as técnicas contribuem para a QoT através da diminuição de aspectos como: figura de ruído, planicidade de ganho, consumo de energia, manutenção dos níveis de potência na entrada e na saída da cascata; bem como métricas que avaliem a qualidade do sistema como: OSNR e BER (*Bit Error Rating*). Além disso, a implementação das técnicas em uma rede real proporciona uma validação de extrema confiabilidade quanto ao funcionamento das técnicas.

Diante disso, na Seção 4.1 é apresentada uma proposta de utilização de uma rede neural artificial como um regressor linear. Na Seção 4.2 são realizadas as análises para a avaliação da qualidade das técnicas ACOP propostas. Na Seção 4.3 são apresentados experimentos com

a técnica MaxGain realizados em uma rede óptica real que possui um controlador SDN. Na Seção 4.4 análises específicas são conduzidas com o intuito de avaliar o impacto dos efeitos não-lineares nas técnicas ACOP. Por fim, na Seção 4.5 são feitas algumas considerações sobre os resultados apresentados neste capítulo.

4.1 Mapeamento das informações da máscara de potência utilizando redes neurais artificiais

Como apresentado na Seção 2.1, o processo de caracterização é fundamental para viabilizar a criação da máscara de potência. Em redes ópticas reconfiguráveis, a necessidade de medir as características do amplificador para uma determinada região de operação é ainda mais importante, pois devido às variações na rede, é necessário que se saiba *a priori* como será o comportamento do amplificador em sua região de atuação. Diante disso, a máscara de potência se torna uma base de conhecimento estática acerca do desempenho do amplificador óptico. Entretanto, o processo de caracterização de um EDFA, por exemplo, é lento – demora cerca de 5 horas – e o resultado deste processo não provê curvas contínuas de NF e *ripple*, nem valores de ganhos em alta resolução.

Diante disso, a proposta apresentada nesta seção visa aplicar uma arquitetura simples e bem conhecida de Rede Neural Artificial (RNA), chamada *Multilayer Perceptron* (MLP), para realizar a tarefa de regressão na máscara de potência inteira com baixo erro.

Na Subseção 4.1.1, a MLP é detalhada, e na Subseção 4.1.2 o método desenvolvido é apresentado. Em seguida, na Subseção 4.1.3, é definido o cenário de simulação escolhido para a validação do método, e na Subseção 4.1.4 são apresentados os resultados obtidos a partir das simulações.

4.1.1 Redes Neurais Artificiais Multi-Camadas

Uma rede neural artificial (RNA) pode ser definida como uma estrutura composta por um conjunto de unidades de processamento simples interconectadas, chamadas de neurônios artificiais. Cada neurônio tem um conjunto de entradas mapeadas em uma única saída. O neurônio é responsável por realizar a soma ponderada dos valores das entradas e definir a saída de acordo com uma função de ativação [55].

O modelo de RNA mais simples foi proposto por Frank Rosenblatt em 1958 e é chamado Perceptron [56]. Neste modelo um conjunto de neurônios artificiais é conectado a apenas uma unidade de saída. Apesar de o Perceptron apresentar a capacidade de “aprender” através de exemplos, o que pode ser traduzido em um aumento na precisão das suas saídas ao longo do tempo, esse tipo de RNA não é capaz de resolver problemas que são não-linearmente separáveis. Esta limitação foi apresentada por Minsky e Papert em [57]. Então, uma configuração

de rede com perceptrons em múltiplas camadas (MLP) foi proposta como uma alternativa para resolver o problema do Perceptron.

A MLP é uma expansão do Perceptron que se utiliza de várias camadas de Perceptrons interconectadas. A MLP tradicional é composta por, pelo menos, três camadas, e cada camada realiza uma tarefa específica. Na camada de entrada, cada neurônio representa uma variável de entrada do problema, enquanto que os neurônios na camada de saída da MLP correspondem à saída do sistema. A camada escondida, ou o conjunto de camadas intermediárias, é responsável por adicionar a capacidade de representar não-linearidades na classificação da tarefa de regressão. Porém, para atingir este objetivo, os neurônios precisam utilizar uma função de ativação não-linear. Uma função comumente utilizada é a função sigmoide logística, porém também são utilizadas funções de base radial e tangente hiperbólica [58].

É necessário utilizar um algoritmo para encontrar o conjunto de pesos que otimiza o desempenho da MLP (treinamento da MLP). O problema no treinamento da MLP é que o erro na camada escondida é desconhecido, e este erro é necessário para a realização dos ajustes dos pesos. Em 1974, Werbos [59] propôs uma generalização da regra delta utilizada por Widrow e Hoff para realizar o treinamento da rede neural chamada ADALINE [51]. O algoritmo proposto por Werbos é atualmente chamado de *backpropagation*. A principal característica do *backpropagation* é a capacidade de propagar o erro recursivamente através das camadas da MLP. O algoritmo é dividido em dois passos. No primeiro passo, os valores dos neurônios (sinais) são propagados da camada de entrada para a camada de saída e o erro é calculado, mas os pesos não são atualizados. No segundo passo, os erros são recursivamente propagados da camada de saída para a camada de entrada e os pesos são atualizados de acordo com a regra de ajuste dos pesos (regra delta generalizada) [58]. Este processo funciona para treinamento supervisionado, pois é necessário o cálculo do erro considerando uma saída já conhecida do problema. O ajuste dos pesos é realizado com uma taxa de aprendizado que define a ponderação do ajuste dos pesos.

Em [60], Hornik e colaboradores mostraram que uma MLP com apenas uma camada escondida usando, por exemplo, uma sigmoide logística é capaz de aproximar qualquer função não-linear, desde que seja contínua. Isto implica que qualquer insucesso na aplicação de MLP como um aproximador deve ser decorrente de um aprendizado inadequado, número insuficiente de neurônios na camada escondida ou a falta de uma relação determinística entre entrada e saída. Alguns aspectos são importantes para aproximar funções com uma MLP:

1. **Pré-processamento dos dados:** os dados precisam ser processados antes da sua apresentação à MLP. Esse processamento consiste, geralmente, em: normalização dos valores, desordenação do conjunto de dados, e definição dos dados para: treinamento, validação e teste. A normalização é necessária para evitar discrepâncias entre os valores que serão processados pela MLP; a desordenação ajuda a MLP a aprender a partir de diferentes padrões do problema simultaneamente, evitando enviesamento; e a divisão

define quais dados serão utilizados para treinar, validar e testar a rede. Um divisão comum para o conjunto de dados é: 50% para treinamento, 25% para validação e 25% para teste.

2. **Condição de parada:** O processo de treinamento é executado através da apresentação dos dados de treinamento à MLP. O número de vezes que se apresenta os dados de treinamento para a rede é chamado de época. Definir o número correto de épocas é importante para evitar uma convergência prematura do processo de treinamento ou, por outro lado, evitar um estado de extrema memorização no qual a rede praticamente decora os dados e perde sua habilidade de generalização. A condição de parada pode ser definida de acordo com o erro de validação. Na maioria dos problemas, quando a MLP começa a “decorar”, o erro de validação começa a aumentar, indicando, assim, que o treinamento deve parar. Porém, existem problemas nos quais o erro de validação não aumenta, mas mantém o mesmo valor por várias épocas. Neste caso, o treino deve ser interrompido nesta fase de estabilidade.
3. **Número de neurônios na camada escondida:** Como definido em [51], a habilidade de uma MLP para resolver problemas não-lineares depende das características da sua camada escondida. Portanto, o número de neurônios impacta no desempenho da rede e depende do grau de não-linearidade das variáveis de entrada. Tipicamente, são utilizados $2N + 1$ neurônios na camada escondida, em que N é o número de entradas.

4.1.2 *Método desenvolvido para mapeamento das informações da máscara de potência*

Como mencionado no início desta seção, a granularidade da caracterização dos amplificadores ópticos depende do tamanho do passo utilizado para varrer as variáveis envolvidas no processo (*e.g.* Ganho, potência total). Se for preciso uma caracterização de alta precisão, muitas medidas serão necessárias e a caracterização demorará muito tempo. Por outro lado, se o passo utilizado na caracterização for aumentado, o processo se tornará mais rápido, entretanto, existirá um grande intervalo entre os pontos de operação medidos, o que pode levar a uma aproximação ruim das funções de mapeamento.

Como mostrado na Figura 2.5, os valores de NF e *ripple* dependem dos valores de potência total de entrada (P_{in}) e de saída (P_{out}). Portanto, a proposta desta parte da tese é utilizar uma MLP para interpolar e extrapolar os resultados do processo de caracterização do amplificador óptico de forma a criar um aproximador geral de função que expressa a dependência entre as entradas (P_{in} e P_{out}) e as saídas (NF e *ripple*).

A hipótese que guia esta proposta é de que o mapeamento de NF e *ripple* utilizando MLP pode evitar a necessidade de pequenos passos para obter uma alta resolução na caracterização. Dessa forma, a utilização da MLP como uma ferramenta auxiliar no processo de caracterização

pode reduzir o tempo gasto no processo experimental para caracterizar um amplificador, mantendo uma boa precisão, isto é, o erro gerado pelo processo de regressão sendo menor do que o erro da medida na camada física. Este processo de regressão pode ser aplicado a qualquer tipo de amplificador óptico. Isto ocorre porque, em princípio, uma MLP pode aproximar qualquer função não-linear diferenciável.

Para desenvolver tal ferramenta, foi criada uma MLP que recebe P_{in} e P_{out} como entradas, e retorna NF e *ripple* como saída. O esquema da MLP é apresentado na Figura 4.1. A MLP tem três camadas, compostas por dois neurônios na camada de entrada, dois neurônios na camada de saída, e o número de neurônios na camada escondida será definido na análise que será descrita nas subseções seguintes. Os neurônios na camada de entrada usam a função identidade como a sua função de ativação. Já os neurônios da camada escondida e de saída utilizam funções sigmoide logística para permitir que a MLP resolva problemas não-lineares.

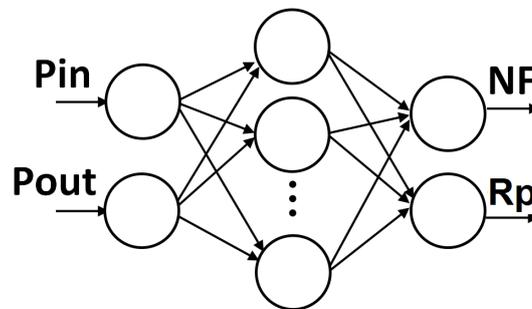


Figura 4.1: Arquitetura da MLP utilizada para mapear NF e *ripple* (R_p) como uma função de P_{in} e P_{out} . (Fonte: elaboração própria)

O erro utilizado em todos os estágios do processo (treinamento, validação e teste) foi o erro médio absoluto considerando NF e *ripple*. O número de épocas de treinamento foi definido após uma análise do comportamento do erro de treinamento e de validação.

4.1.3 Cenário de simulação para validação da MLP

Para avaliar a precisão da MLP para diferentes granularidades da caracterização, foram realizadas simulações utilizando máscaras de potência com diferentes passos de caracterização. Todas as máscaras foram geradas a partir de uma única máscara de um EDFA de um estágio. Nesta máscara existem pontos de operação com ganhos entre 14 e 24 dB, potência total de entrada entre 0,3 e -30 dBm, potência total de saída máxima de 14 dBm, figura de ruído entre 4,8 e 9,5 dB e *ripple* entre 2,3 e 5,1 dB. Foi utilizado um passo de ganho de 0,5 dB com 41 pontos de caracterização para cada ganho, o que resulta em um conjunto com 1107 pontos de operação. O valor dos passos, relativos à potência total de entrada, utilizados nas simulações foram: 1 dB; 1,5 dB; 2 dB; 2,5 dB; 3 dB; 4 dB e 6 dB. Foi utilizado um passo de 0,5 dB para a variação do ganho em todas as simulações.

Os dados foram divididos com o intuito de avaliar a habilidade da MLP proposta em achar valores que não estão incluídos no conjunto de treinamento. Como um exemplo, na máscara de potência com passo igual a 1 dB (chamada máscara de potência 1 dB), o conjunto de treinamento é composto pelos pontos de operação que estão igualmente espaçados de 1 dB para os seus pontos vizinhos. Isso significa que apenas metade dos pontos da máscara de potência 0,5 dB foram utilizados para o treinamento da MLP com o passo de 1 dB, *i.e.* 567 pontos. Os pontos que não foram incluídos no conjunto de treinamento foram utilizados para compor o conjunto de validação e de teste. Isso não significa que todos os pontos que não estão no conjunto de treinamento serão utilizados no conjunto de validação e de teste. O número de pontos utilizados para validação e para teste é a metade do número total de pontos no conjunto de treinamento. A Tabela 4.1 mostra os tamanhos dos conjuntos de dados para cada caso. Pode-se observar que, com o aumento do passo dentro da máscara de potência, um número menor de pontos de operação é necessário.

Tabela 4.1: Número de pontos de operação utilizados em cada máscara para treinamento, validação e teste da MLP.

Máscara de Potência	Número de pontos para o treinamento	Número de pontos para validação	Número de Pontos para teste
1 dB	567	257	257
1,5 dB	369	184	184
2 dB	277	138	138
2,5 dB	222	111	111
3 dB	186	93	93
3,5 dB	159	79	79
4 dB	139	69	69
6 dB	93	46	46

Todos os pontos foram desordenados e normalizados entre 0,15 e 0,85 antes da fase de treinamento da MLP, para evitar a ocorrência de *outliers*. Cada um dos resultados apresentados na Seção 4.1.4 foi obtido após 30 execuções independentes do processo de treinamento completo para a MLP.

4.1.4 Resultados das simulações com a MLP

A Figura 4.2 mostra a curva de convergência do processo de treinamento utilizando a máscara de potência 1 dB e quatro neurônios na camada escondida, em função do número de épocas utilizado no processo. A máscara de potência 1 dB foi a primeira escolhida, pois apresenta o maior conjunto de dados de treinamento, conseqüentemente, requer um maior número de épocas para a MLP aprender os padrões. Observa-se que o erro de validação não aumenta com o aumento do número de épocas, e que com 5000 épocas o processo alcançou um estado

estável. Devido a isto, serão utilizadas 5000 épocas nas simulações seguintes como um critério de parada.

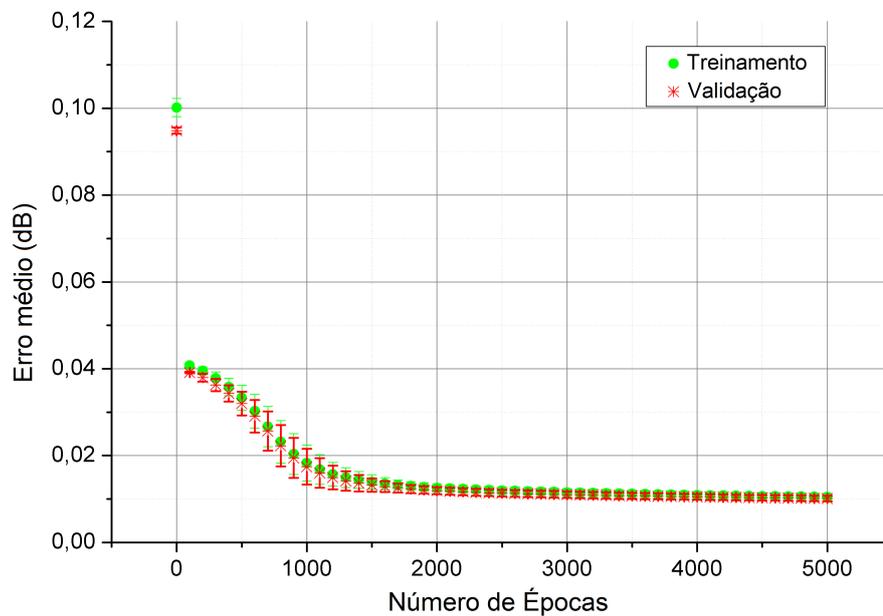


Figura 4.2: Curva de convergência para o processo de validação e de teste para a máscara de potência com passo de 1dB e quatro neurônios na camada escondida, em função do número de épocas.

A Figura 4.3 e a Figura 4.4 apresentam o gráfico *box-plot* do erro de teste para diferentes números de neurônios na camada escondida com a máscara de potência 1 dB e 3 dB, respectivamente. Observa-se que, nos dois casos, apenas alguns poucos neurônios são necessários para alcançar o processo de aprendizado. Então, serão utilizados quatro neurônios para evitar os *outliers* presentes nas configurações com menos neurônios.

A Figura 4.5 mostra os resultados do gráfico *box-plot* do erro de teste em função do passo utilizado dentro da máscara, considerando quatro neurônios na camada escondida e 5000 épocas. Pode-se observar que o erro da MLP aumenta pouco inicialmente com o aumento do passo da máscara, com o erro mantendo-se em torno de 0,1 dB para um tamanho máximo de passo de 3 dB. Porém, para um passo de 6 dB a média do erro sobe bastante, e a variação deste valor é bem maior.

Por fim, a Figura 4.6 mostra um exemplo das curvas de NF e *ripple* geradas a partir da utilização da MLP, variando-se a potência de entrada e a potência de saída com resolução igual a 0,1 dB.

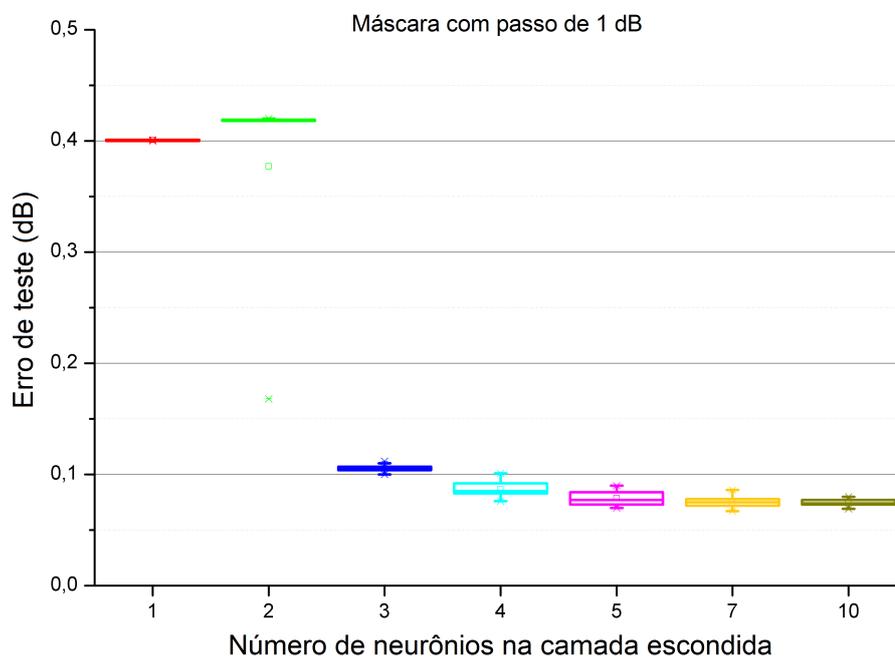


Figura 4.3: *Box-plot* do erro de teste em função do número de neurônios na camada escondida para a máscara de potência 1 dB.

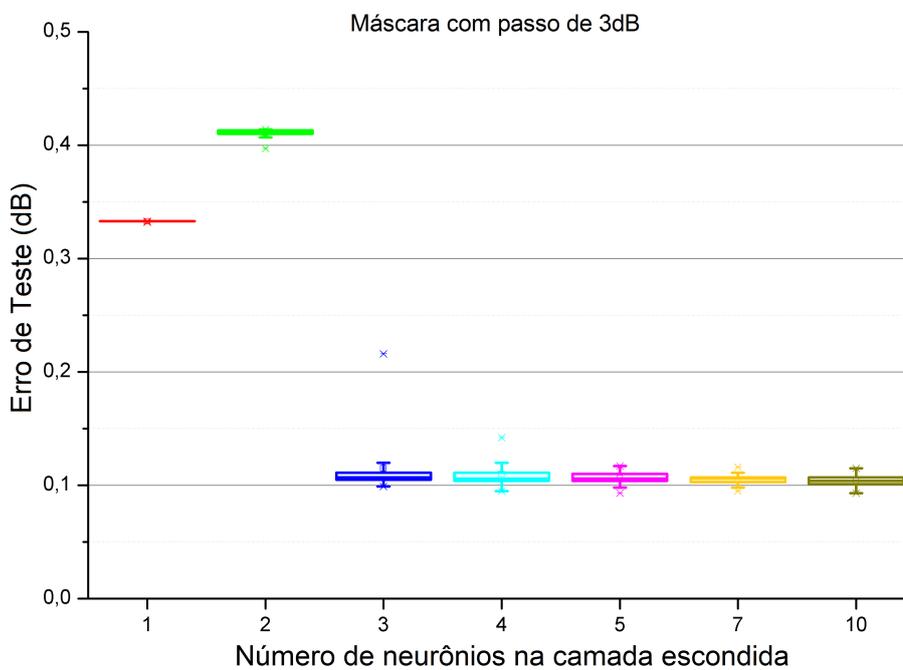


Figura 4.4: *Box-plot* do erro de teste em função do número de neurônios na camada escondida para a máscara de potência 3 dB.

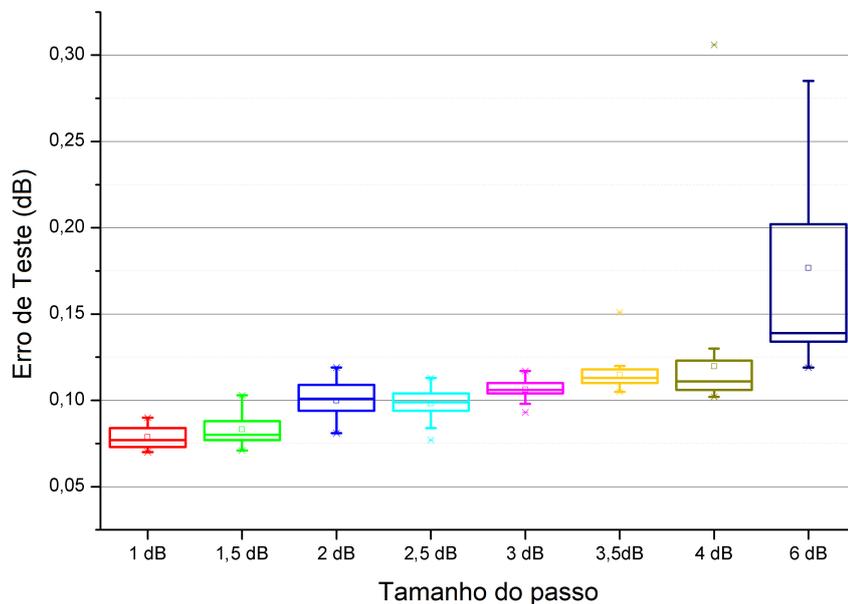


Figura 4.5: *Box-plot* do erro de teste em função do número de neurônios na camada escondida para várias máscaras de potência, considerando quatro neurônios na camada escondida.

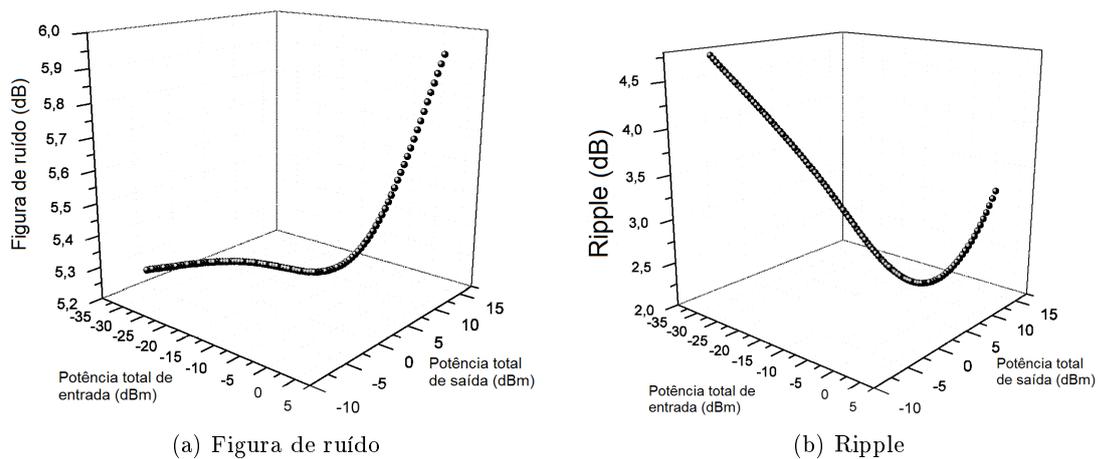


Figura 4.6: Exemplo das curvas de NF e *ripple* geradas a partir da utilização da MLP, variando-se a potência de entrada e a potência de saída com resolução igual a 0,1 dB.

4.2 Análise das técnicas propostas

Nesta seção o foco será a análise das técnicas propostas – AsHB, Método Exaustivo e MaxGain. Nas análises aqui realizadas foi utilizada a RNA apresentada na seção 4.1, após o treinamento com dados de uma máscara com passo de 1 dB. Todas as técnicas utilizam a RNA para o cálculo das métricas do amplificador. Na subseção 4.2.1 será descrita a análise realizada para validação da técnica AsHB. Na subseção 4.2.2 as técnicas propostas e a encontrada na literatura serão avaliadas comparativamente.

4.2.1 Análise e validação da técnica AsHB

Nesta subseção é apresentada a análise feita com o intuito de validar o funcionamento da proposta AsHB e verificar a qualidade dos seus resultados.

Cenário de simulação

Para realizar a análise, utilizou-se o mesmo cenário definido em [7], que considera uma cascata com seis amplificadores (vide Figura 4.7), para que possa haver uma comparação com o trabalho citado. Os amplificadores 1, 5 e 6 são amplificadores com potência máxima de saída igual a 24 dBm, figura de ruído entre 5 e 11,3 dB e *ripple* entre 0 e 4,39 dB. Já os amplificadores 2, 3 e 4 são amplificadores com potência máxima de saída igual a 21 dBm, figura de ruído entre 4,7 e 15,4 dB e *ripple* entre 2,4 e 8,6 dB. Todos os amplificadores tem ganho mínimo de 14 dB e ganho máximo de 24 dB, e os seus posicionamento seguiram os definidos em [7].

As perdas das fibras entre os amplificadores são: 17,22 dB (entre os amplificadores 1 e 2), 28,19 dB (entre 2 e 3), 13 dB (entre 3 e 4), 22,58 dB (entre 4 e 5) e 28,74 dB (entre 5 e 6).

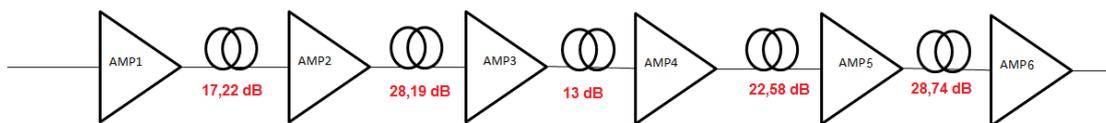


Figura 4.7: Representação da cascata de amplificadores definida em [7] e utilizada nas simulações de análise e validação da técnica AsHB. (Fonte: elaboração própria)

A $NF_{cascata}$ é calculada por meio das Equações (3.5) e (3.6). Como mencionado anteriormente, o *ripple* é a diferença de potência entre o canal com a maior potência e o canal com a menor potência. Nestes resultados, $Rp_{cascata}$ será a soma dos valores de *ripple* de cada amplificador da cascata. Quanto maior o *ripple*, menor será a planicidade de ganho do sinal.

Foram realizadas simulações variando o número de iterações do processo de otimização para que o melhor número de iterações possa ser definido. Foi analisada, também, a influência da restrição da potência de saída do enlace por meio de simulações com diferentes potências

de entrada da cascata. Em todos os casos, foi definido que a potência total de saída da cascata ($P_{out}^{cascata}$) deveria ser igual à potência total de entrada da cascata ($P_{in}^{cascata}$).

Análise paramétrica

Foi feita uma análise paramétrica considerando a influência do número de iterações utilizado no processo de otimização do AsHB no desempenho da cascata de amplificadores.

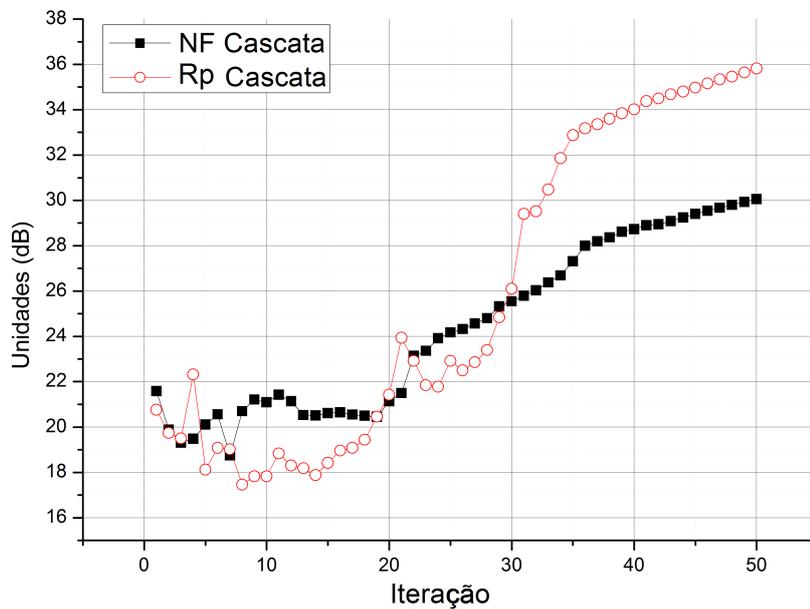
A Tabela 4.2 mostra os valores dos erros na entrada ($Erro_{entrada}$) e na saída ($Erro_{saida}$), da figura de ruído ($NF_{cascata}$) e da planicidade de ganho ($Rp_{cascata}$) da cascata, para quantidades diferentes de iterações. Estes valores foram obtidos considerando-se $P_{in}^{cascata} = 3$ dBm. Observa-se que a execução de 10 iterações não é suficiente para se obter um erro baixo, especialmente para a entrada. Por outro lado, não vale a pena utilizar mais de 50 iterações, pois os resultados são similares após essa quantidade de iterações. Portanto, serão utilizadas 50 iterações nas próximas simulações da AsHB nesta seção.

Tabela 4.2: Comparação dos erros, da NF e Rp da cascata para diferentes números de iterações do AsHB

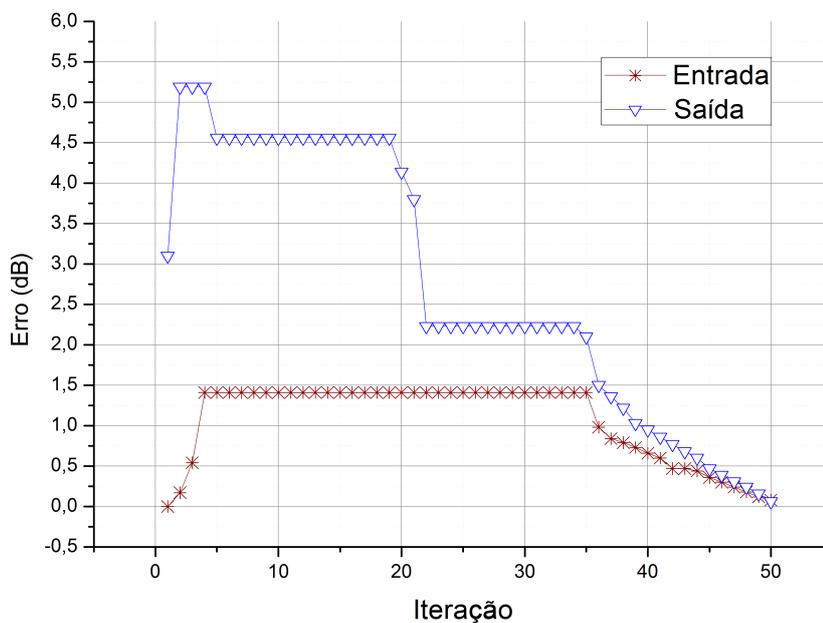
Iteração	$Erro_{entrada}$	$Erro_{saida}$	$NF_{cascata}$	$Rp_{cascata}$
10	2,03 dB	0,37 dB	22,09 dB	24,48 dB
20	0,19 dB	1,00 dB	27,93 dB	34,02 dB
50	0,08 dB	0,06 dB	30,06 dB	22,68 dB
100	0,03 dB	0,04 dB	30,06 dB	36,06 dB
200	0,02 dB	0,01 dB	30,12 dB	35,88 dB

Além disso, a partir da Tabela 4.2, pode-se observar que $NF_{cascata}$ é menor para um número menor de iterações. Para analisar a razão disso, a Figura 4.8 mostra os valores de $NF_{cascata}$, $Rp_{cascata}$, $Erro_{entrada}$ e $Erro_{saida}$, ao longo das 50 iterações. Observa-se que, durante as primeiras iterações, a $NF_{cascata}$ é menor, porém a cascata não está satisfazendo a restrição de potência de saída. Para obter erros baixos como 0,08 dB e 0,06 dB, o processo do AsHB aumenta a $NF_{cascata}$ e $Rp_{cascata}$ para 30,06 dB e 35,82 dB, respectivamente. Porém, se a restrição não fosse considerada, poderia-se alcançar $NF_{cascata}$ e $Rp_{cascata}$ em torno de 18,8 dB e 19,02 dB, respectivamente (vide iteração número 7).

Também é importante analisar se a AsHB funciona para diferentes valores de $P_{in}^{cascata}$. A Tabela 4.3 mostra os resultados para $P_{in}^{cascata} = P_{out}^{cascata}$ iguais a -3 dBm, 0 dBm e 3 dBm, considerando 50 iterações. Pode-se observar que pequenos erros foram obtidos para todos os casos.



(a) Métricas



(b) Erros

Figura 4.8: (a) $NF_{cascata}$ e $Rp_{cascata}$, e (b) $Erro_{entrada}$ and $Erro_{saida}$ em função do número de iterações do AsHB para quatro amplificadores com potência total de entrada igual a 3dBm.

Comparação das técnicas AsHB e AdGC

A Tabela 4.4 mostra as características de cada amplificador na cascata retornada pelo AsHB, enquanto que a Tabela 4.5 mostra as mesmas informações retornadas pela AdGC. A cascata

Tabela 4.3: Comparação dos erros, da NF e da Rp da cascata para diferentes valores de potência de entrada da cascata.

$P_{in}^{cascata}$	$Erro_{saida}$	$Erro_{entrada}$	$NF_{cascata}$	$Rp_{cascata}$
- 3 dBm	0,06	0,08	30,22 dB	36,66 dB
0 dBm	0,03	0,08	27,69 dB	31,32 dB
3 dBm	0,06	0,08	30,06 dB	35,64 dB

retornada pela técnica AdGC apresenta $NF_{cascata}$ e $Rp_{cascata}$ igual a 22,3 dB e 21,3 dB, respectivamente. Porém, essa técnica não considera a restrição de potência de saída e, por isso, retornou um $Erro_{saida}$ igual a 11,07 dB (considerando $P_{in}^{cascata} = 3dBm$), enquanto a abordagem proposta neste trabalho (AsHB) retornou um $Erro_{saida}$ igual a 3 dB. É importante observar que, se a restrição de potência de saída for relaxada, o AsHB retornaria $NF_{cascata} = 18,8 dB$ e $Rp_{cascata} = 19,2 dB$, com $Erro_{entrada} = 1,4 dB$ e $Erro_{saida} = 4,6 dB$ (vide Figura 4.8), que são resultados melhores do que os retornados pela AdGC.

Tabela 4.4: Características dos amplificadores retornados pela AsHB.

	P_{in} (dBm)	Ganho (dB)	P_{out} (dBm)	NF (dB)	Rp (dB)
Amp1	2,92	24,00	26,92	5,15	3,78
Amp2	9,70	14,00	23,70	15,90	8,15
Amp3	-4,49	14,00	9,51	6,61	4,81
Amp4	-3,49	17,41	13,92	7,29	5,24
Amp5	-8,66	16,40	7,74	5,41	9,64
Amp6	-21,00	24,00	3,00	5,64	4,18

Tabela 4.5: Características dos amplificadores retornadas pelo AdGC.

	P_{in} (dBm)	Ganho (dB)	P_{out} (dBm)	NF (dB)	Rp (dB)
Amp1	2,81	21,00	23,98	5,69	1,53
Amp2	7,21	14,00	20,96	15,49	8,37
Amp3	-6,82	15,00	8,12	5,70	4,71
Amp4	-4,95	24,00	19,14	6,30	2,42
Amp5	-2,97	23,00	20,06	4,64	3,75
Amp6	-9,09	20,00	11,07	5,49	0,51

4.2.2 Comparação entre técnicas locais e técnica global

Nesta subseção será apresentada a análise feita com o intuito de comparar o desempenho das técnicas locais e da técnica global propostas aqui, bem como da técnica local proposta na

literatura (AdGC).

Cenário de Simulação para a Comparação entre técnicas locais e técnica global

A Figura 4.9 ilustra o cenário de simulação para a comparação entre técnicas locais e técnica global. Este cenário possui quatro EDFAs de dois estágios com lasers de bombeio com comprimento de onda igual a 980 nm e potência de bombeamento de 220 mW (primeiro estágio) e 450 mW (segundo estágio). Os amplificadores têm uma potência total máxima de saída de 17 dBm, um ganho mínimo de 15 dB e um ganho máximo de 25 dB. A máscara de potência para este EDFA foi obtida utilizando o processo de caracterização apresentado em [2] e pode ser vista na Figura 2.5. Em seguida, a rede neural artificial apresentada na Seção 4.1 foi treinada com esta máscara.

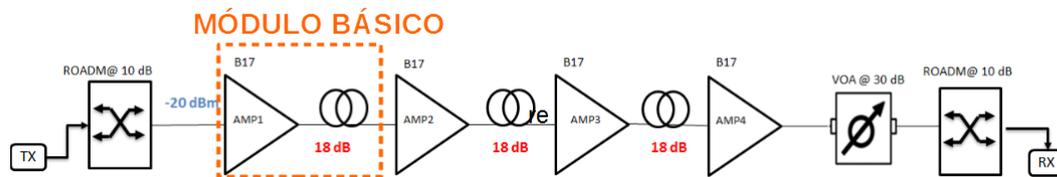
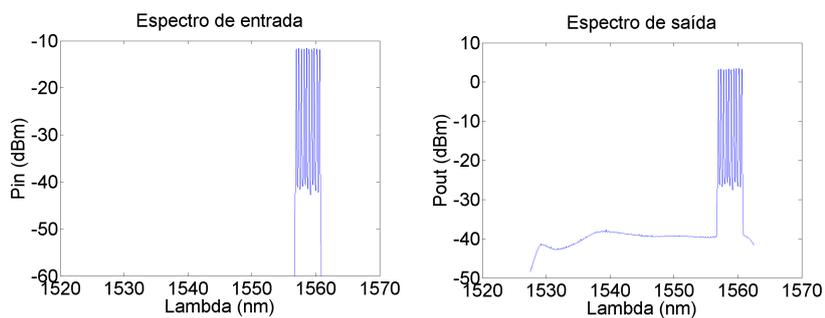


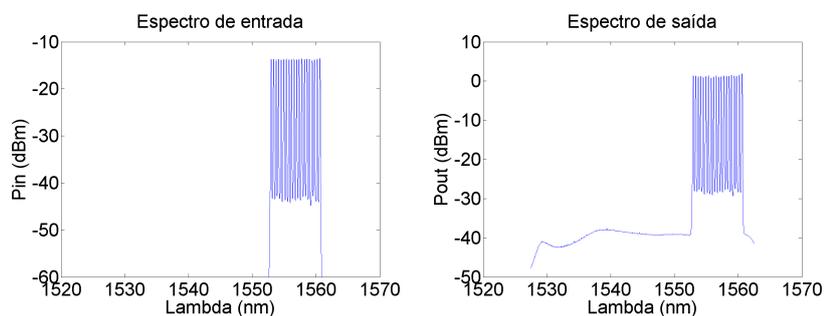
Figura 4.9: Representação do cenário de simulação com quatro amplificadores com ganhos entre 15 e 25 dB e uma potência máxima de saída de 17 dBm; um VOA com 30 dB de atenuação máxima e um ROADM com perda de 10 dB. A potência de entrada é -20 dBm/ch e a perda da fibra é 18 dB. (Fonte: elaboração própria)

Além disso, a perda na fibra é de 18 dB por trecho, considerando uma atenuação de 0,2 dB/km, o trecho possui 90 km. O VOA tem uma atenuação máxima de 30 dB e o ROADM adiciona uma perda de 10 dB ao sinal. A potência total de entrada considerada no primeiro amplificador é de -20 dBm, pois foi assumida uma potência total de entrada de -10 dBm antes do ROADM. Nestas simulações, o ROADM é considerado apenas como um dispositivo que atenua a potência do sinal, ou seja, não considera-se *crosstalk* ou outros efeitos que podem ser causados por este dispositivo.

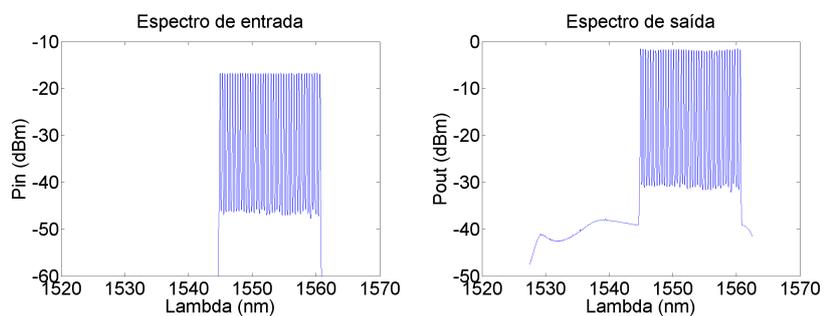
Com o intuito de comparar o desempenho das técnicas para diferentes condições de carregamento, os amplificadores foram caracterizados com 10, 20, 40 e 80 canais. Os canais são carregados a partir da frequência 192,1 THz de forma crescente, dessa forma para 10 canais é utilizada a banda entre 192,1 e 192,55 THz, para 20 canais a banda vai até 193,05 THz, já para 40 canais ela vai até 194,05 THz e para 80 até 196,05 THz. A Figura 4.10 mostra o espectro de potência na entrada e na saída do amplificador para as diferentes quantidades de canais utilizadas na caracterização.



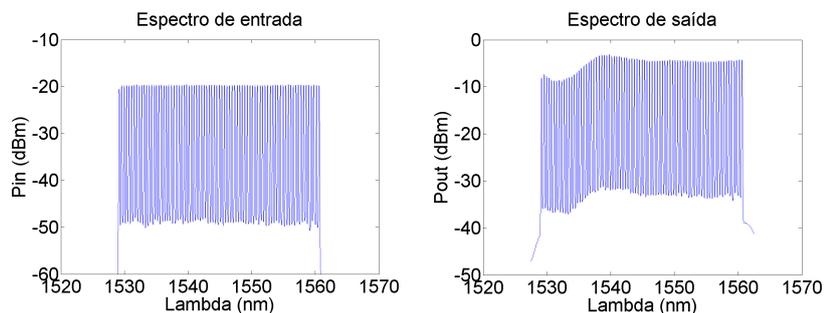
(a) 10 canais



(b) 20 canais



(c) 40 canais



(d) 80 canais

Figura 4.10: Espectro de potência na entrada e na saída do amplificador para caracterizações com (a) 10, (b) 20, (c) 40 e (d) 80 canais.

As simulações foram executadas para cada um dos carregamento citados acima. Além disso, a técnica ME utilizou um passo de 0,5 dB, pois verificou-se que com 0,1 dB a técnica demora muito para obter os resultados (mais de 24 horas) e para um passo de 1 dB a resolução não tem precisão adequada.

Todas as simulações foram executadas em um PC com CPU Intel Core i7-4500U 1,80 GHz. Nestas simulações o fator de ruído foi calculado considerando as perdas no VOA e no ROADM, que podem influenciar no ruído pela inserção de ruído balístico, como mostrado na equação

$$F_{cascata} = F_1 + \frac{F_2}{G_1 L_1} + \dots + \frac{F_N}{G_1 L_1 \dots G_{N-1} L_{N-1}} + \frac{1}{G_1 L_1 \dots G_{N-1} L_{N-1} G_N L_{VOA} L_{ROADM}}, \quad (4.1)$$

na qual apenas a perda no VOA (L_{VOA}) e no ROADM (L_{ROADM}) foram adicionados à Equação (3.5).

Nesta análise também é avaliada a influência da escolha do ponto de operação no consumo de energia da cascata. Para isso, o processo de caracterização avaliou a potência total elétrica em Watts consumida em cada ponto de operação, para que este valor seja utilizado como uma métrica de consumo de energia do amplificador. O processo de caracterização foi executado em um ambiente de temperatura controlada (em torno de 25 °C) e depois da atuação do TEC (*thermo-electric cooler*), o que significa que o amplificador está em um estado de operação estável. Devido a isso, a potência consumida pelo amplificador é proporcional à potência do laser de bombeamento, e, portanto, depende do ponto de operação do amplificador. O consumo de energia da cascata será considerado como a soma da potência de cada amplificador.

Por fim, a escalabilidade das abordagens propostas em termos de tempo e de qualidade da solução também é analisada. Para tanto, são realizadas simulações com diferentes números de amplificadores na cascata. As condições das simulações são as mesmas descritas na Figura 4.9, apenas removendo ou adicionando o módulo básico indicado na figura (conjunto de fibra e amplificador).

Análise do número de iterações do AsHB Flex

O número de iterações utilizado é um fator chave para o desempenho do AsHB Flex. Uma iteração é um percurso completo de atualização, ou seja, atualização direta e inversa da técnica AsHB Flex, como descrito na Seção 3.1. A Figura 4.11 mostra a média e o desvio padrão do tempo de execução da técnica AsHB Flex, após 30 execuções, em função do número de iterações, considerando o cenário da Figura 4.9. As barras do desvio padrão são tão pequenas que dificilmente podem ser vistas após a segunda iteração. O tempo de execução foi avaliado para o cenário com 80 canais, pois o número de canais não impacta no tempo

de execução da técnica. Como o tempo de execução aumenta de maneira logarítmica com o número de iterações, alcançar bons resultados utilizando poucas iterações é desejável (rápida convergência).

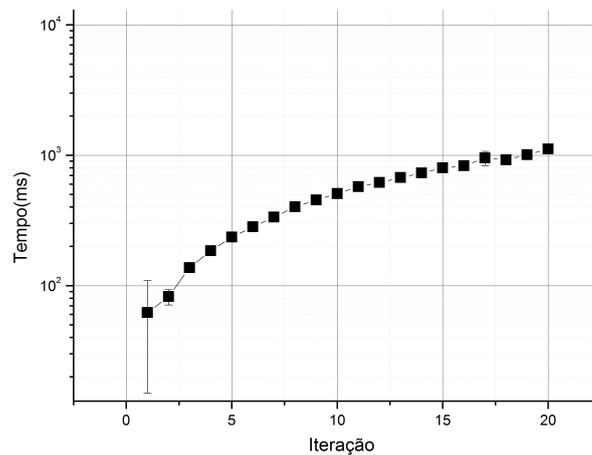


Figura 4.11: Média e desvio padrão do tempo de execução da técnica AsHB Flex, após 30 execuções, em função do número de iterações.

A Figura 4.12 mostra as curvas dos valores de figura de ruído e de planicidade de ganho obtidos pela técnica AsHB Flex em função do número de iterações para diferentes números de canais. A técnica AsHB Flex apresenta uma rápida convergência, pois atinge seu melhor valor utilizando em torno de cinco iterações, bem menos do que as 50 utilizadas na AsHB tradicional, já que a restrição da potência de saída está sendo controlada de uma forma mais fácil com o VOA. Note que o *ripple* aumenta com o aumento do número de canais, o que é uma característica do amplificador EDFA utilizado.

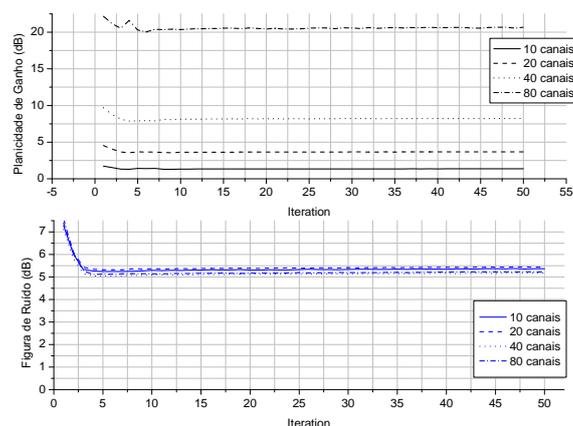


Figura 4.12: Curvas de planicidade de ganho e figura de ruído em função do número de iterações do AsHB Flex para (a) 10 (sólida), (b) 20 (traço), (c) 40 (ponto) e 80 (traço e ponto) canais.

Devido a esses resultados, todas as próximas simulações são realizadas utilizando cinco iterações para a AsHB Flex.

Análise comparativa das soluções

No problema ACOP, a figura de ruído e a planicidade de ganho (*ripple*) da cascata definem a qualidade da solução obtida. Quanto menor os valores para essas métricas, melhor será a solução. A Figura 4.13 mostra a figura de ruído e a planicidade de ganho da cascata obtidas para cada uma das técnicas: WAdGC (triângulo), AsHB Flex (pentágono), AsHB (círculo), MaxGain (estrela) e ME (quadrado). A técnica tradicional, que define os ganhos dos amplificadores de forma a compensar as perdas dos dispositivos anteriores a ele, é chamada aqui de CompPerdas, e é representada por um ponto em forma de diamante na Figura 4.13. Todas as possíveis soluções do ME são também apresentadas como uma nuvem de pontos. As cores indicam o consumo total de potência em Watts da cascata, com a graduação de cores definida pela barra de cores no canto inferior direito de cada gráfico. As Figuras de 4.13a a 4.13d apresentam os resultados para 10, 20, 40 e 80 canais, respectivamente. Note que a solução única obtida pelo ME (o quadrado) representa a solução com a menor distância d definida pela Equação (2.1).

Analisando a Figura 4.13, fica evidente que a técnica CompPerdas é a pior solução em todos os cenários. Os gráficos também mostram que a MaxGain e a AsHB Flex, ambas abordagens locais propostas neste trabalho, obtiveram melhores soluções do que a WAdGC (encontrada na literatura [1]). MaxGain é melhor do que AsHB Flex nos cenários de 10, 20 e 40 canais, apesar de que, em alguns casos, a diferença é pequena e pode ser considerada desprezível. Além disso, as soluções obtidas pelo MaxGain são próximas das melhores soluções possíveis (ME) para 10, 20 e 40 canais. No cenário com 80 canais, a MaxGain e a AsHB Flex retornaram uma solução com melhor figura de ruído possível, mas com um planicidade de ganho em torno de 0,4 dB maior do que a técnica método exaustivo (melhor solução).

A Tabela 4.6 ilustra os pontos colocados nestes argumentos, mostrando os atributos dos amplificadores retornados pelas técnicas AsHB Flex, ME, MaxGain e CompPerdas, no cenário com 80 canais. O ganho do primeiro amplificador do CompPerdas foi definido para 18,82 dB porque é o menor ganho na máscara para uma potência total de entrada de -20 dBm. O ganho correto compensaria a perda do ROADM anterior ao primeiro amplificador, neste caso 10 dB, porém, devido a esta restrição da máscara, o ganho é maior, o que beneficia a figura de ruído da cascata retornada pelo CompPerdas.

Os melhores resultados retornados pela técnica MaxGain, comparados com os das outras técnicas, indicam que, para os amplificadores utilizados nesta análise, os pontos de operação que resultam em uma baixa NF da cascata, também retornam um baixo *ripple*. Esta tendência pode não ser a mesma para outros amplificadores com características diferentes. Os bons resultados retornados pelo AsHB Flex em cenários diferentes fortalece a hipótese de que uma

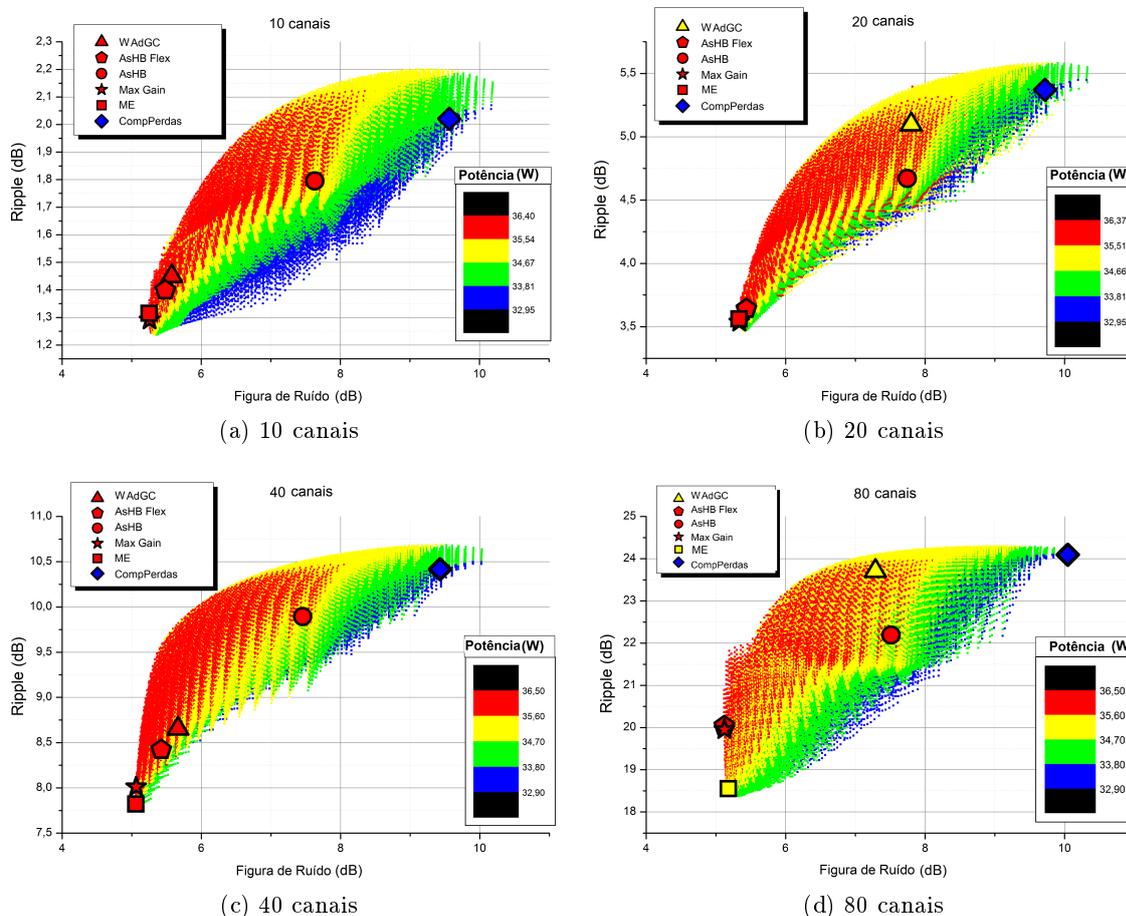


Figura 4.13: Soluções obtidas pelas técnicas ME (todas elas como uma nuvem de pontos e a solução com o menor d como um quadrado), WAdGC (triângulo), AsHB Flex (pentágono), AsHB (círculo), MaxGain (estrela) e ComPerdas (diamante) em termos de figura de ruído, *ripple* e consumo de potência (barra de cores) da cascata com quatro amplificadores, para (a) 10, (b) 20, (c) 40 e (d) 80 canais.

técnica local iterativa é melhor do que uma técnica local “egoísta” (que define o melhor ponto de operação na primeira oportunidade). O melhor desempenho do AsHB Flex em comparação com o AsHB mostra a importância da consideração do VOA na cascata, o que permite que os amplificadores funcionem em um ponto de operação com melhor desempenho se houver mais flexibilidade.

Com relação ao consumo de energia, nota-se que, em geral, as soluções com o melhor desempenho são encontradas na região com mais alto consumo. Apesar do ME mostrar que, para obter baixa NF, os amplificadores precisam operar em potências mais altas, soluções com uma NF um pouco maior e *ripple* menor podem ser obtidas em uma região de menor consumo, como na solução quadrada na Figura 4.13d.

Tabela 4.6: Atributos dos amplificadores retornados pelas técnicas ME, MaxGain, AsHB Flex e CompPerdas para 80 canais.

ME (menor d)					
$NF_{cascata} = 5,18 \text{ dB}$ $Rp_{cascata} = 4,64 \text{ dB}$					
$Potencia_{cascata} = 35,35 \text{ W}$					
	P_{in} (dBm)	Gain (dB)	NF (dB)	Rp (dB)	Potência (W)
Amplificador 1	-20	25	4,05	6,15	9,11
Amplificador 2	-13	25	3,87	6,04	9,17
Amplificador 3	-6	19	3,69	3,21	8,58
Amplificador 4	-5	18	3,71	3,15	8,49
MaxGain					
$NF_{cascata} = 5,12 \text{ dB}$ $Rp_{cascata} = 4,98 \text{ dB}$					
$Potencia_{cascata} = 36,26 \text{ W}$					
	P_{in} (dBm)	Gain (dB)	NF (dB)	Rp (dB)	Potência (W)
Amplificador 1	-20	25	4,05	6,15	9,11
Amplificador 2	-13	25	3,87	6,04	9,17
Amplificador 3	-6	23	3,7	3,97	8,23
Amplificador 4	-1	18	3,78	3,79	8,84
AsHB Flex					
$NF_{cascata} = 5,12 \text{ dB}$ $Rp_{cascata} = 5,01 \text{ dB}$					
$Potencia_{cascata} = 36,32 \text{ W}$					
	P_{in} (dBm)	Gain (dB)	NF (dB)	Rp (dB)	Potência (W)
Amplificador 1	-20	25	4,05	6,15	9,11
Amplificador 2	-13	25	3,87	6,04	9,17
Amplificador 3	-6	23,2	3,71	4,04	9,17
Amplificador 4	-0,8	18,18	3,79	3,81	8,88
CompPerdas					
$NF_{cascata} = 10,05 \text{ dB}$ $Rp_{cascata} = 6,02 \text{ dB}$					
$Potencia_{cascata} = 33,68 \text{ W}$					
	P_{in} (dBm)	Gain (dB)	NF (dB)	Rp (dB)	Potência (W)
Amplificador 1	-20	18,82	4,12	0,54	8,54
Amplificador 2	-14,13	18	4,08	0,5	8,4
Amplificador 3	-7,13	18	4,08	0,5	8,4
Amplificador 4	-1,05	18	4,08	0,5	8,4

Análise das técnicas para ACOP em cascatas com números diferentes de amplificadores

Além de retornarem boas soluções, as técnicas ACOP precisam ser rápidas e escaláveis para funcionarem satisfatoriamente em um cenário dinâmico. A Figura 4.14 mostra a comparação entre o tempo de execução médio após 30 execuções das técnicas AsHB Flex, MaxGain, WAdGC e ME, para cascatas com diferentes números de amplificadores. Como o AsHB não retornou bons resultados na análise anterior e o CompPerdas é calculado *off-line*, estas técnicas não são consideradas.

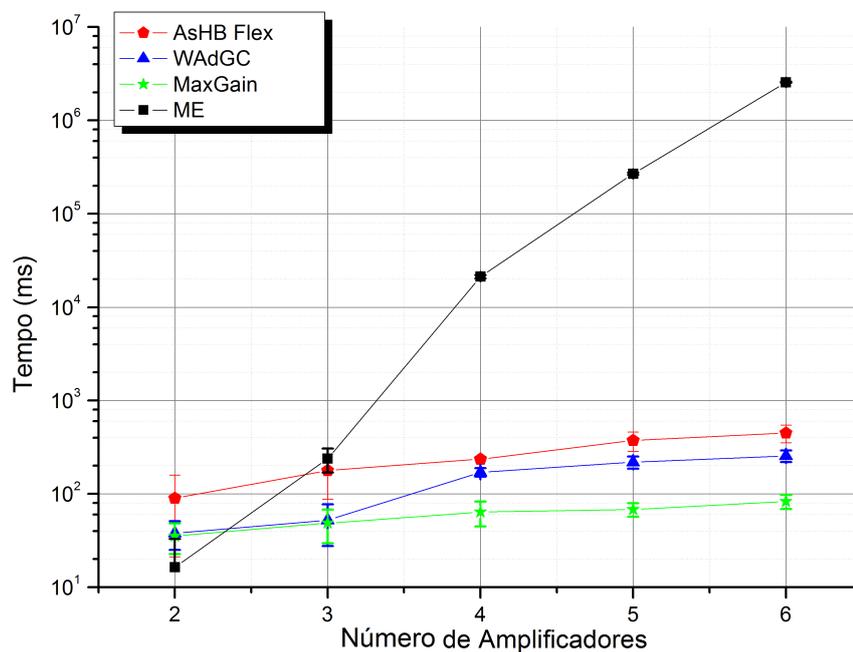


Figura 4.14: Média e desvio padrão do tempo de execução após 30 execuções das técnicas MaxGain, WAdGC, AsHB Flex e ME, em função do número de amplificadores na cascata.

É possível perceber, a partir da Figura 4.14 que, para uma cascata com dois ou três amplificadores, não há diferença significativa entre os tempos de execução das técnicas. Por outro lado, para cascatas com mais de três amplificadores, torna-se evidente a superioridade das técnicas locais em comparação com a técnica ME. Para uma cascata com dois amplificadores, o ME encontrou uma solução em 0,2 segundos, um tempo muito próximo ao das técnicas locais. Entretanto, para uma cascata com quatro amplificadores, foram necessários 20 segundos, e considerando seis amplificadores o tempo chegou a 40 minutos.

Além disso, as técnicas locais mostram uma boa escalabilidade, pois apresentam pouca dependência dos seus tempos de execução com o tamanho da cascata, variando de 0,1 segundos para uma cascata com dois amplificadores, até 0,4 segundos para seis amplificadores. Entre as técnicas, o MaxGain foi a mais rápida, pois é uma heurística simples e acha a solução

em um iteração única. A técnica AsHB Flex é a mais lenta pois necessita de cinco iterações (atualização direta e inversa) para achar a solução.

A Tabela 4.7 mostra o impacto do número de amplificadores da cascata no desempenho das técnicas locais por meio dos valores de figura de ruído e planicidade de ganho da cascata retornados pelo MaxGain, AsHB Flex, WAdGC e CompPerdas, considerando cascatas com diferentes números de amplificadores, de 4 até 10, considerando 40 canais. Observa-se que o MaxGain retorna os menores valores de NF e Rp da cascata para todos os casos, independentemente do número de amplificadores. Já o CompPerdas retorna os piores valores, o que significa que, mesmo para cascatas com maior número de amplificadores, o MaxGain mantém sua superioridade.

Tabela 4.7: Figura de ruído e o *ripple* da cascata retornado pelo MaxGain, AsHB Flex, WAdGC e CompPerdas para cascatas com números diferentes de amplificadores e considerando 40 canais.

Número de Amplificadores	<i>MaxGain</i>		<i>AsHB Flex</i>		<i>WAdGC</i>		<i>CompPerdas</i>	
	NF	Rp	NF	Rp	NF	Rp	NF	Rp
4	4,9477	8,0108	5,1148	8,292	5,814	9,3432	9,9806	10,4748
5	4,9899	8,746	5,5584	10,865	5,8678	10,5085	10,9497	13,0935
6	5,0317	9,4818	6,1732	11,9532	5,9022	11,1738	11,7415	15,7122
7	5,0731	10,2172	6,4185	13,7018	5,9446	12,0288	12,411	18,3309
8	5,1142	10,9528	6,6818	15,4176	5,9866	12,8832	12,9909	20,9496
9	5,1548	11,6883	6,909	17,0982	6,0283	13,7376	13,5024	23,5683
10	5,1951	12,423	7,0564	18,833	6,0695	14,593	13,96	26,187

4.3 Desenvolvimento de um aplicativo para SDN

No contexto das redes ópticas dinâmicas, o conceito de redes definidas por software (SDN - *Software defined networking*) vem se mostrando uma ferramenta promissora para auxiliar no gerenciamento e configuração destas redes. O principal objetivo da SDN é dividir a camada responsável por gerenciar a rede da camada responsável pela transmissão dos dados. Para tanto, SDN utiliza conceitos de virtualização de equipamentos e engenharia de software para criar um sistema de gerenciamento de rede flexível e que não se restringe a determinado equipamento ou tipo de rede, criando assim um conceito de sistema operacional na rede.

A Figura 4.15 ilustra a arquitetura básica de um plano de controle SDN que é formado pelas camadas de aplicação, controle e infraestrutura, e pelas interfaces entre estas camadas. Observa-se que a camada de controle provê uma plataforma de desenvolvimento de aplicativos, na qual cada aplicativo pode ser desenvolvido de forma independente das especificações dos dispositivos da rede, basta apenas que sigam as especificações da interface entre as camadas de aplicação e dados. Isso facilita a automação de operações complexas da rede e permite

ao usuário ter mais controle sobre a rede, o que resulta em desenvolvimento mais flexível de novos serviços e protocolos, alta utilização da rede, melhor QoS, menor consumo de energia e alta receita [61].

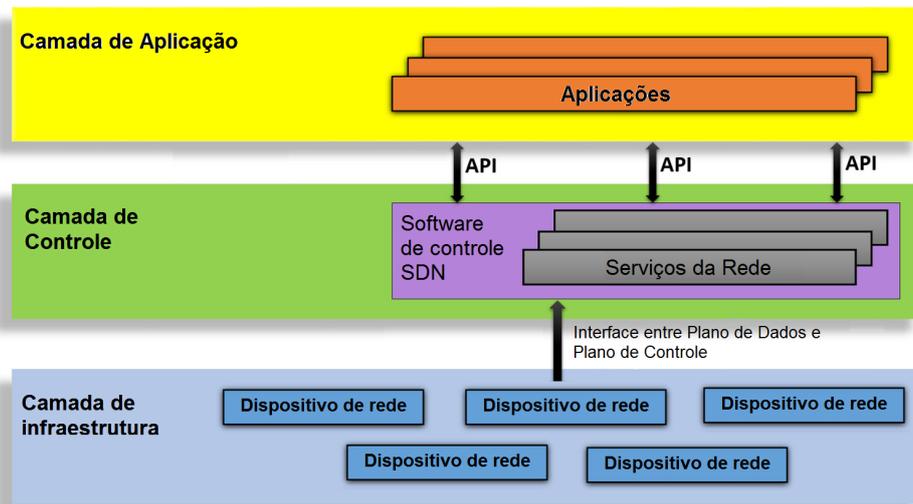


Figura 4.15: Arquitetura das redes definidas por software. (Fonte: adaptado de [8])

Diante disso, esta seção descreve os avanços quanto ao objetivo específico: *Implementar as técnicas desenvolvidas como aplicativos de rede em uma rede com controle SDN*. A rede utilizada foi a rede autônoma de teste do Centro de Pesquisa e Desenvolvimento (CPqD), que possui um controlador SDN desenvolvido pelo próprio centro. Na Subseção 4.3.1 são apresentadas algumas aplicações do conceito de SDN em redes ópticas encontradas na literatura. Na Subseção 4.3.2 são apresentados os detalhes quanto à rede autônoma do CPqD, destacando o funcionamento do controlador SDN. Na Subseção 4.3.3 é apresentado o processo de implementação da técnica MaxGain na rede autônoma. Finalmente, na Subseção 4.3.4 é apresentado o experimento realizado para a validação e verificação da implementação da MaxGain, bem como os resultados obtidos durante este experimento.

4.3.1 SDN e redes ópticas

O conceito de SDN não se restringe a um tipo específico de rede, pois a camada de controle pode controlar qualquer dispositivo que implemente as funções definidas na interface entre a camada de controle e a camada de infraestrutura (vide Figura 4.15). A aplicação de SDN em redes ópticas tem se mostrado promissora e tem sido tema de muitos trabalhos científicos [21, 22, 8].

Os principais trabalhos usam a SDN com o intuito de utilizar de forma mais eficiente os recursos da rede óptica. Neste tipo de trabalho, é evidenciado o maior benefício do uso de SDN nas redes ópticas, que é o gerenciamento mais completo dos recursos. Essa característica

torna possível a diminuição dos custos de manutenção e implantação da rede, além de um menor gasto energético atrelado a uma melhora na qualidade de transmissão [62, 63, 64].

Outros trabalhos buscam utilizar a SDN para criar um gerenciamento unificado para a rede óptica e outras tecnologias de rede. Nestes trabalhos, o foco é a integração do gerenciamento de redes como IP/MPLS e LTE (4G) com o gerenciamento da rede óptica. Neste cenário, que é bastante comum na infraestrutura de Internet, os trabalhos mostram que a utilização de SDN simplifica o trabalho do operador de rede, além de possibilitar a criação de aplicativos que possam gerenciar de forma inteligente os recursos dos diferentes tipos de rede, o que acarreta em melhor desempenho e menor custo [65, 66, 67].

Há também os trabalhos que estudam a aplicação de SDN em redes ópticas com *data centers*. Devido à enorme quantidade de dados que os servidores de grandes *data centers* necessitam transferir, utilizar as novas tecnologias de redes ópticas flexíveis e modulações avançadas permitem às transmissões ópticas o envio de centenas de Tb/s. Entretanto, essas novas tecnologias necessitam de um gerenciamento mais complexo, o que pode ser auxiliado pelo uso de SDN [68, 69, 70].

Por fim, existem os trabalhos com foco mais conceitual, que tratam da adaptação dos conceitos de SDN para a área de redes ópticas. O principal objetivo destes trabalhos é evidenciar os desafios e os prováveis benefícios no uso de SDN para o controle de redes ópticas. [8, 71, 72].

4.3.2 Rede autônoma do CPqD

A Figura 4.16 ilustra a topologia da rede autônoma de teste do CPqD. A rede é constituída por um nó central que possui um ROADM de grau quatro, e quatro nós extremos que possuem ROADMs de grau três. Cada nó é conectado através de um par de fibras com o nó adjacente, e todos se conectam ao nó central. Cada conexão entre os nós é composta por um fibra SSMF (G.652) de 100 km, ou então um fibra de 50 km com um atenuador óptico de 10 dB para que todo caminho entre ROADMs tenha uma perda total em torno de 20 dB. Entre cada nó existem dois amplificadores EDFAs que possuem ganho mínimo e máximo de 12 e 28 dB e uma potência máxima de saída de 21 dBm.

Todos os sub-sistemas da rede se comunicam com o plano de controle para proverem dados de monitoramento e para serem controlados pelo plano de controle após as ações das aplicações de rede.

Na Figura 4.16, também é possível visualizar a rede de comunicação de dados utilizada para o gerenciamento da rede óptica. Essa rede paralela utiliza um canal *Giga-bit Ethernet* no canal óptico com comprimento de onda igual a 1510 nm para prove a comunicação entre os nós ópticos e o plano de controle. Multiplexadores do canal de supervisão (SOM - *Supervisory optical channel multiplexer*) e demultiplexadores do canal de supervisão (SOD - *Supervisory optical channel demultiplexer*), que multiplexam/demultiplexam os canais da banda C com

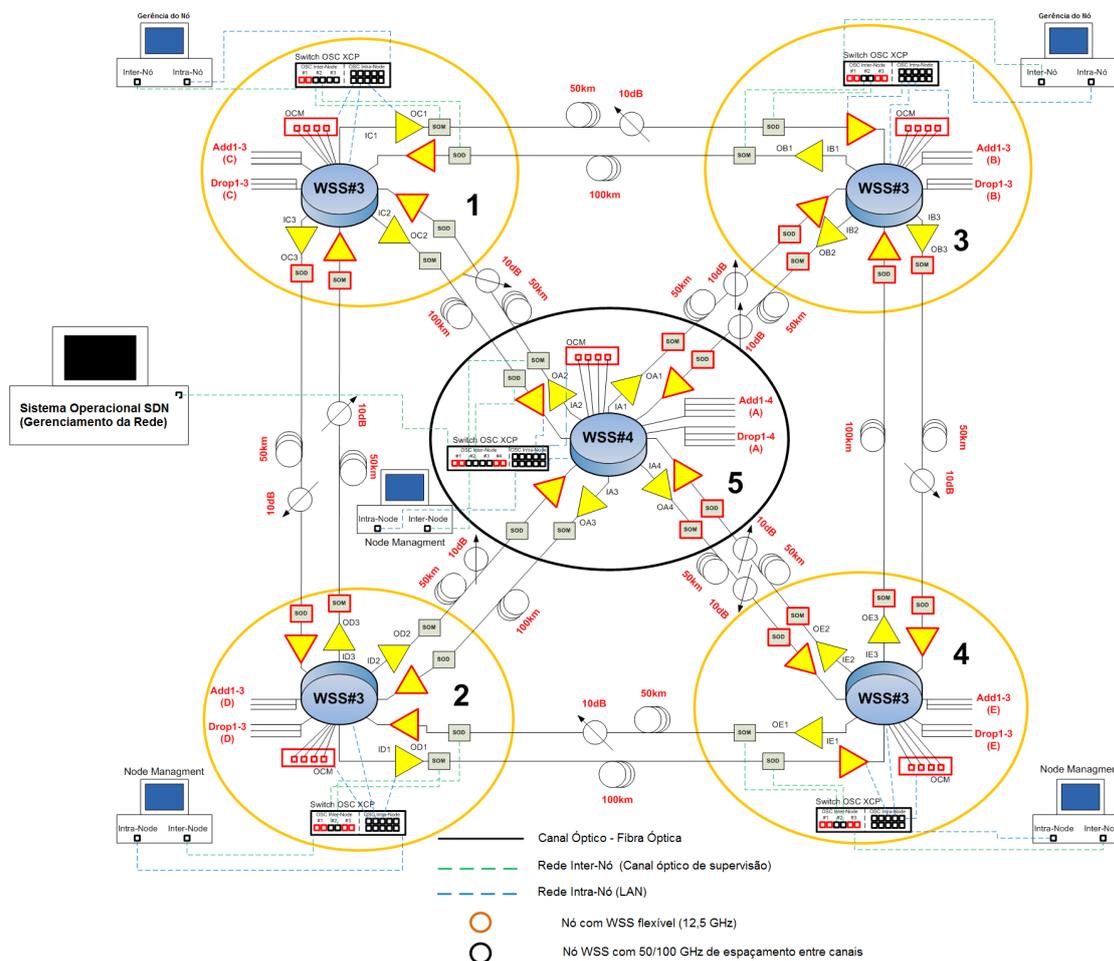


Figura 4.16: Topologia da rede autônoma do CPqD, ilustrando a conectividade óptica e também as conexões da rede de gerenciamento. (Fonte: adaptado de [9])

o canal de supervisão em 1510 nm, são utilizados para cada par de fibras, multiplexando o canal de supervisão após o primeiro amplificador óptico, e demultiplexando-o antes do segundo amplificador.

Um *switch* camada 3 (*switch* capaz de trabalhar na camada de rede) é utilizado em cada nó para conectar os dispositivos elétricos que utilizam *ethernet* de 10/100 Mbps e o canal óptico de supervisão com um transmissor de 1 Gbps. Utilizando estes *switches*, o plano de controle pode comunicar-se com cada nó óptico na rede e, conseqüentemente, com cada dispositivo óptico (ROADM, EDFA e etc), habilitando, assim, o monitoramento e atuação pelo plano de controle nos dispositivos da rede.

A organização desta rede autônoma pode ser melhor compreendida por meio da Figura 4.17, que apresenta uma foto da rede destacando seus nós e alguns de seus equipamentos.

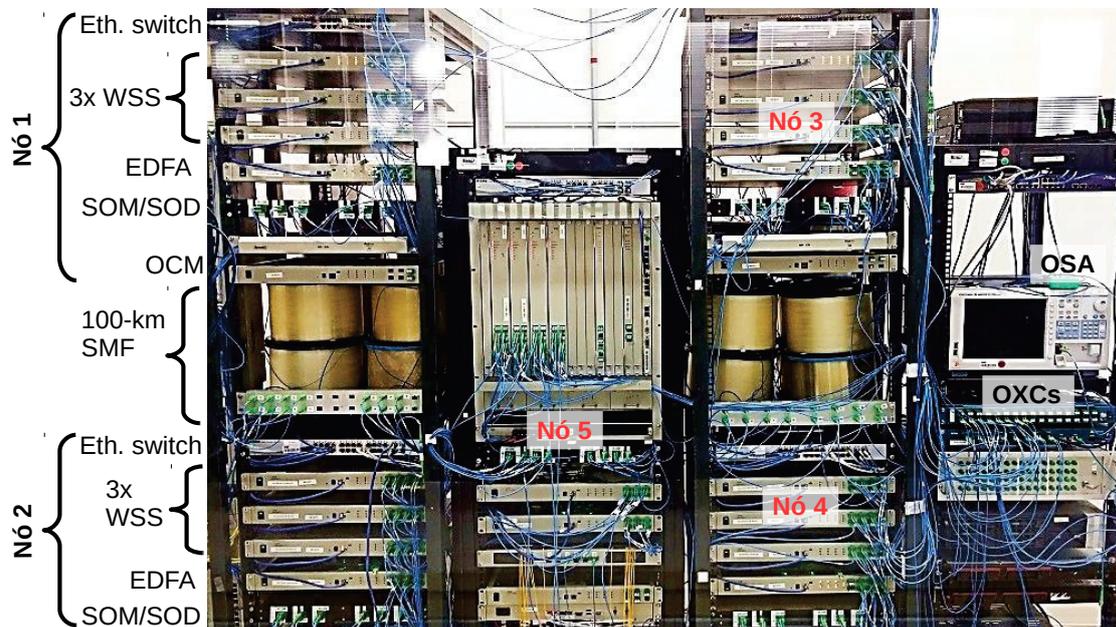


Figura 4.17: Foto da rede autônoma do CPqD, destacando os seus nós e alguns dos seus equipamentos. (Fonte: adaptado de [10])

Controlador SDN

Um elemento chave da rede autônoma é o controlador SDN que foi proposto e desenvolvido pelo próprio CPqD [73]. Este controlador utiliza uma arquitetura SDN hierárquica cujo principal diferencial é a adição de uma nova camada entre as camadas de aplicação e de controle. O controlador distribui as funções do plano de controle em duas camadas diferentes: uma camada superior com foco no melhor provisionamento de serviços de rede multi-domínio para as aplicações de negócio, e uma camada inferior que gerencia a infraestrutura da rede por meio da interação com dispositivos de domínio específico. A adição da camada intermediária permite que os aplicativos de rede possam ser desenvolvidos em nível de abstração maior, tornando o desenvolvimento mais eficiente e aplicável a diferentes infraestruturas de rede.

A Figura 4.18 mostra a arquitetura do plano de controle SDN desenvolvido pelo CPqD e utilizado no controle da rede autônoma. Os controladores de rede presentes na camada de infraestrutura são responsáveis por atuar diretamente nos equipamentos da rede e, portanto, são dependentes do domínio da rede. Além de atuar nos equipamentos, esses controladores são responsáveis por proverem à camada de aplicação uma interface com funções que abstraem as especificidades do equipamento, para que as aplicações possam funcionar independentemente do domínio da rede. O controlador *OpenFlow*, por exemplo, abstrai os detalhes de funcionamento dos equipamentos, que utilizam este padrão, para a camada superior. Apesar de ser um padrão bastante utilizado no cenários SDN e poder ser utilizado em redes com diferentes tecnologias de transmissão [74], o *OpenFlow* ainda não se firmou no cenário de transmissão

óptica, a adaptação deste protocolo para o cenário de redes ópticas é objeto de estudo em alguns trabalhos [75, 76].

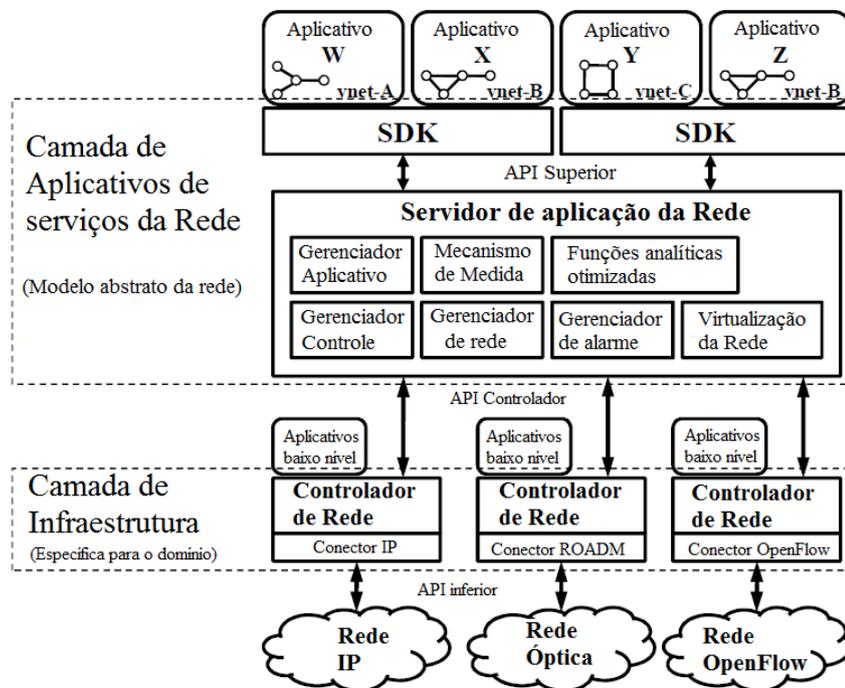


Figura 4.18: Arquitetura do plano de controle SDN desenvolvido pelo CPqD para controle da rede autônoma. (Fonte: adaptado de [9]).

O servidor de aplicação provê ao SDK (*Software Development Kit*) um conjunto de instruções baseado em um modelo abstrato da rede. Por estar na camada do meio, o servidor de aplicação é responsável pelo gerenciamento das camadas de aplicação e de infraestrutura. Além disso, esta camada é responsável por realizar a virtualização da rede, o que é de extrema importância para as aplicações, pois cada uma delas utiliza uma virtualização de parte da rede.

O SDK é responsável por criar uma sub-camada de auxílio para alguma linguagem de programação (*e.g.* C++, Java, Python), tornando o processo de desenvolvimento mais simples e eficiente. Esta sub-camada implementa mecanismos avançados para otimizar o desempenho e a escalabilidade das aplicações, tais como: armazenamento temporário de dados, agrupamento de conexões e pré-validação de requisições das aplicações.

4.3.3 Implementação do MaxGain na rede autônoma

A Figura 4.19 ilustra os módulos do controlador SDN envolvidos na implementação da técnica MaxGain como uma aplicação de rede. Percebe-se que a técnica MaxGain é implementada

tendo como base o SDK-CPP, que dá suporte a programas escritos na linguagem de programação C++ [11]. Portanto, a MaxGain foi implementada em C++ e compilada como uma biblioteca compartilhada, para então ser executada pelo servidor de aplicação.

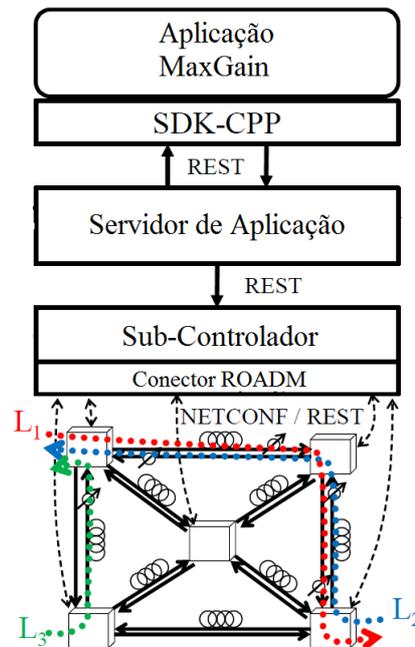


Figura 4.19: Representação gráfica dos módulos do controlador SDN envolvidos na implementação da técnica MaxGain como uma aplicação de rede. (Fonte: adaptado de [11])

O servidor de aplicação é uma aplicação Java EE 7 que é executada em um *container* WidFly 8.0.0, a mais recente versão da JavaEE *runtime* JBOSS [77].

O sub-controlador foi implementado em C++ com intuito de ser um controlador leve, de domínio específico e que pode controlar centenas de operações em vários elementos da rede. O controlador foi construído de uma forma modular para que seja simples a inclusão e remoção de funcionalidades por meio de módulos independentes. Existem quatro módulos principais: um agendador de medidas que coleta periodicamente informações dos dispositivos da rede; um mecanismo de conexão que realiza o estabelecimento de caminhos por meio de cada nó e lida com as possíveis falhas de estabelecimento; um gerenciador de topologia que gerencia os nós da rede incluindo informações de topologia; e um gerenciador de conectores que abstrai o protocolo utilizado nas interfaces dentro dos dispositivos.

Por fim, o conector ROADM funciona como um *driver* que permite que o sub-controlador tenha acesso aos elementos da rede, e assim possa alterar o comportamento e adquirir informação destes elementos.

4.3.4 Experimento para validação da técnica MaxGain em SDN

Após a implementação do MaxGain, foi conduzido um experimento com o intuito de validar a implementação realizada e verificar o correto funcionamento da técnica em um ambiente de rede real. O cenário considerado neste experimento é mostrado na Figura 4.20, na qual os círculos representam os nós da rede, os triângulos os amplificadores e as fibras ópticas estão entre eles. Os valores em vermelho na Figura 4.20 representam as perdas em cada trecho da rede que foram calculadas após um orçamento de potência feito na rede autônoma.

As máscaras dos amplificadores utilizados fornecem pontos de operações que possuem ganho entre 12 e 28 dB, potência total de entrada entre -26 e 8 dBm, potência máxima de saída igual a 21 dBm, figura de ruído entre 2,5 e 9,7 dB e *ripple* entre 3,5 e 5,9 dB.

Neste cenário o sinal na entrada do primeiro amplificador (AMP1) possui 40 canais 112 Gbps DP-QPSK igualmente espaçados (considerando a grade ITU de 50 GHz), com potência em torno de -21,5 dBm/ch, o que resulta em uma potência total de entrada de -5,5 dBm. Ao chegar no nó 3, apenas a primeira metade do espectro (20 canais) é passada para o próximo enlace.

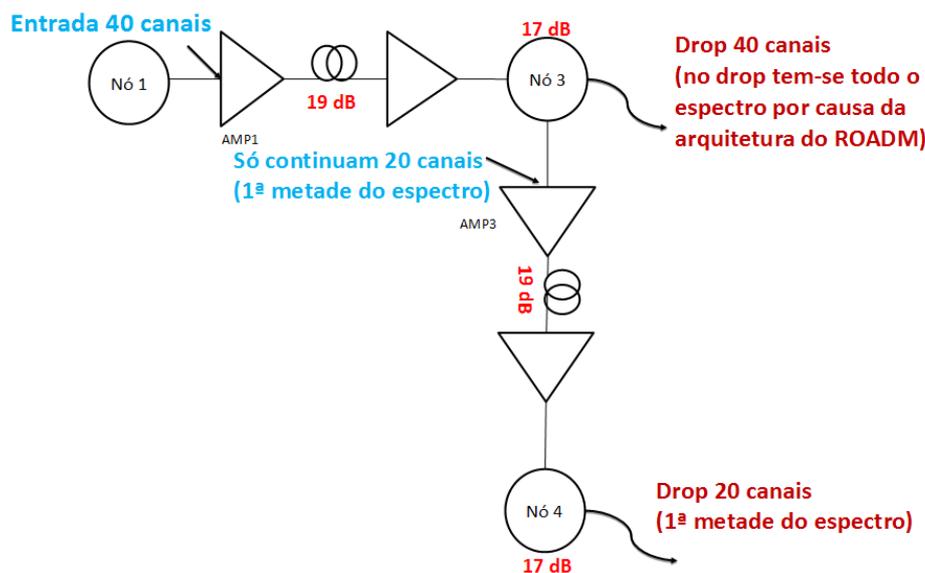


Figura 4.20: Cenário considerado na validação do MaxGain. Os nós da rede são representados pelos círculos sendo o primeiro nó o círculo superior esquerdo. Os amplificadores são representados pelos triângulos. (Fonte: elaboração própria)

Já havia sido implementada e validada pelo CPqD a técnica AdGC. Portanto, esta técnica será utilizada nos experimentos para comparação com o MaxGain. A implementação das técnicas funciona de forma que em cada enlace exista um processo diferente responsável por atualizar os pontos de operação dos amplificadores do enlace. Então, no cenário apresentado pela Figura 4.20, dois processos paralelos estarão sendo executados, um deles responsável por

atualizar o ponto de operação dos amplificadores 1 e 2, e o outro responsável por atualizar o ponto de operação dos amplificadores 3 e 4. Essa duplicidade de processos é necessária pois a MaxGain é uma técnica ACOP para enlace ponto-a-ponto, que nestes experimentos está funcionando em um cenário de rede.

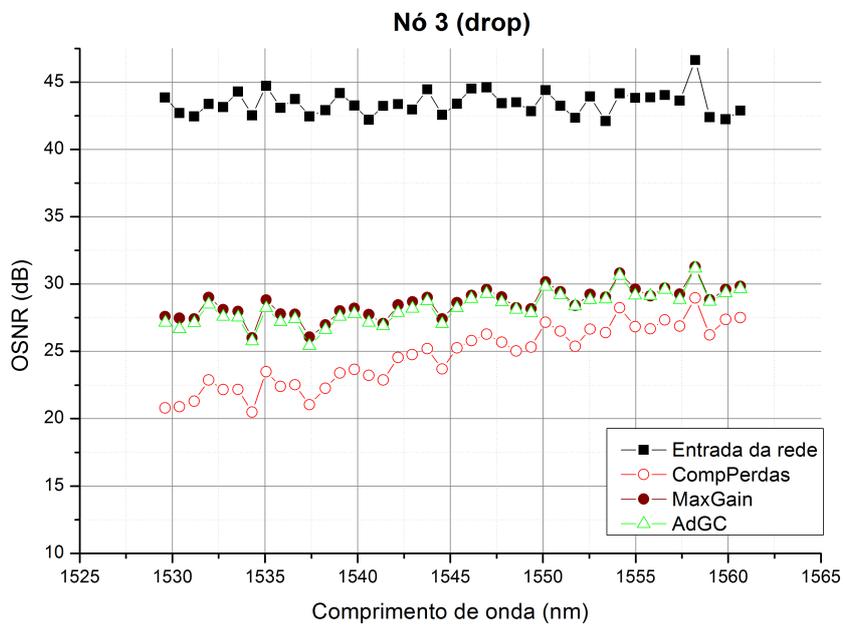
Além disso, foi realizado um experimento no qual a rede autônoma funcionou sem nenhuma técnica ACOP. Neste experimento, os ganhos foram definidos *off-line* e seguindo a lógica da técnica CompPerdas. Portanto, não há ajuste em tempo real do ponto de operação neste caso.

A Figura 4.21 apresenta os gráficos de OSNR em função do comprimento de onda no *drop* do nó 3, e no *drop* do nó 4, para as técnicas MaxGain, AdGC e CompPerdas no cenário ilustrado na Figura 4.20. Observa-se que, tanto no nó 3 quanto no nó 4, as técnicas MaxGain e AdGC foram capazes de retornar uma OSNR melhor do que a CompPerdas, sendo essa diferença maior na saída do nó 4.

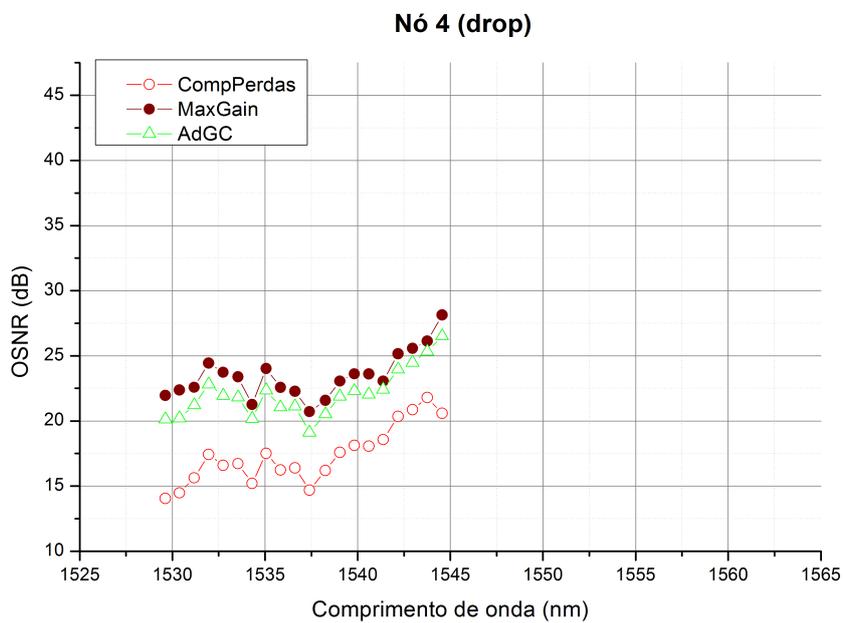
A Tabela 4.8 mostra os atributos dos amplificadores retornados pelas técnicas MaxGain, AdGC e CompPerdas considerando o cenário da Figura 4.20. Percebe-se que os ganhos retornados pelas técnicas MaxGain e AdGC são próximos, o que explica a similaridade dos resultados destas técnicas. O mesmo não acontece para a técnica CompPerdas, pois há uma diferença maior entre os ganhos desta técnica e das outras duas.

Tabela 4.8: Atributos dos amplificadores retornados pelas técnicas MaxGain, AdGC e CompPerdas considerando o cenário da Figura 4.20.

		<i>MaxGain</i>	<i>AdGC</i>	<i>CompPerdas</i>
AMP1	$P_{in}^{total}(dBm)$	-5,5	-5,4	-5,4
	$Gain(dB)$	24	23	16,5
	$P_{out}^{total}(dBm)$	18,4	17,5	11,01
AMP2	$P_{in}^{total}(dBm)$	-0,5	-1,4	-8,1
	$Gain(dB)$	11,9	12,8	18,9
	$P_{out}^{total}(dBm)$	11,4	11,3	10,7
AMP3	$P_{in}^{total}(dBm)$	-15,1	-14,8	-15,5
	$Gain(dB)$	23,8	22,8	16,4
	$P_{out}^{total}(dBm)$	8,6	8,3	0,9
AMP4	$P_{in}^{total}(dBm)$	-9,8	-10,5	-17,6
	$Gain(dB)$	12,1	13,3	18,4
	$P_{out}^{total}(dBm)$	2,3	2,7	0,7



(a)



(b)

Figura 4.21: Gráficos de OSNR por comprimento de onda no *drop* do (a) nó 3 e do (b) nó 4 para MaxGain, AdGC e ComPerdas no cenário de rede da Figura 4.20. Em (a) ainda é apresentada a OSNR na entrada do primeiro amplificador (Entrada Rede).

4.4 Análise do impacto dos efeitos não-lineares nas técnicas ACOP

Apesar dos bons resultados retornados pela MaxGain, a lógica utilizada por esta técnica (escolher o ponto de operação com o maior ganho possível) tende a aumentar as potências de saída do amplificador para a fibra, o que pode expor os canais a efeitos não-lineares, diminuindo assim a qualidade da transmissão. Como mencionado na Subseção 3.3, as melhores soluções retornadas pelas técnicas são aquelas nas quais os ganhos dos amplificadores, principalmente nos primeiros, são altos.

Diante disso, é necessário que se analise as soluções não somente pela figura de ruído e planicidade, mas por alguma outra métrica de qualidade que leve em conta os impactos dos efeitos não-lineares na qualidade do sinal. Nenhuma das técnicas ACOP apresentadas foi avaliada considerando um sistema com muitos canais utilizando formatos de modulação avançados e efeitos não-lineares simultaneamente.

Portanto, nesta seção, serão analisadas as soluções das técnicas ACOP em termos de taxa de erro de bit (BER - *Bit error rate*) considerando um cenário de simulação mais desafiador. Foram considerados 40 canais operando a uma taxa de 120 Gbps utilizando o formato de modulação 64 QAM em uma grade fixa com espaçamento de 50 GHz entre os canais. Também foi imposta uma restrição na potência de saída dos amplificadores. Esta restrição foi adicionada para que seja possível avaliar em detalhes o impacto dos efeitos não-lineares no desempenho das técnicas. Estas simulações foram executadas no *software* comercial OptiSystem®, pois o simulador desenvolvido nesta tese – e utilizado nas análises anteriores – não considera efeitos não-lineares como uma penalidade da camada física.

4.4.1 Cenário de simulação utilizado para a análise do impacto dos efeitos não-lineares nas técnicas

A Figura 4.22 mostra o sistema de comunicação óptica utilizado nas simulações, que é formado por três *spans* e quatro amplificadores ópticos em cascata. Os enlaces utilizam uma fibra monomodo padrão (SSMF - *Standard Single Mode Fiber*). Cada *span* tem um comprimento de 90 km. Os parâmetros da fibra são: coeficiente de atenuação igual a 0,2 dB/km, parâmetro de dispersão (D) igual a 16,75 ps/nm/km e coeficiente não-linear (γ) igual a $1,32 W^{-1}km^{-1}$.

Os ganhos dos amplificadores foram definidos de acordo com os resultados das técnicas para cada cenário. O amplificador utilizado aqui é o mesmo que foi utilizado na Subseção 4.2.2, e tem ganho máximo de 25 dB, ganho mínimo de 15 dB e potência total máxima de saída igual a 17 dBm. A figura de ruído de cada amplificador irá depender do ponto de operação selecionado pelas técnicas.

A fonte de dados foi modelada como uma sequência binária pseudoaleatória (PRBS -

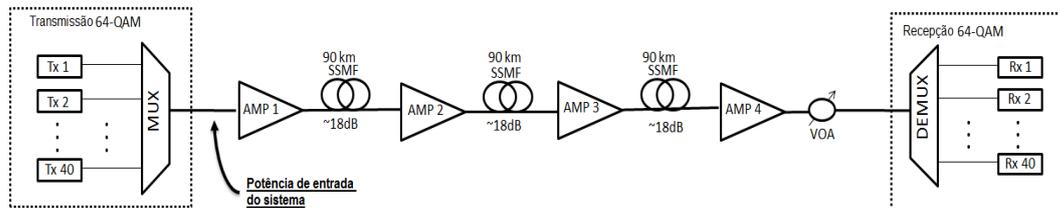


Figura 4.22: Representação da cascata de amplificadores definida para as simulações da análise do impacto dos efeitos não-lineares nas técnicas. (Fonte: elaboração própria)

Pseudorandom binary sequence) com um comprimento de 2^{15} bits. Os multiplexadores e demultiplexadores foram modelados como um filtro Gaussiano de quarta ordem com largura de banda igual a 50 GHz. O transmissor utilizado é um 64QAM com dupla polarização. A largura de linha dos lasers foi definida como zero, para que os efeitos não-lineares possam ser destacados. O sinal óptico na saída do transmissor consiste de 40 canais DP-64QAM na banda C (grade ITU-T) operando cada um em uma taxa de 120 Gbps e com espaçamento entre canais de 50 GHz.

A potência de entrada do sistema foi definida como -5 dBm total (ou -21 dBm/ch) e a OSNR de entrada igual a 30 dB. A BER do canal 193,4 THz (1550 nm) será utilizada como a BER de referência do sistema, pois este canal é um dos canais centrais do sistema e, portanto, o mais susceptível a sofrer influência dos efeitos não lineares, principalmente por auto modulação de fase (SPM) e modulação cruzada de fase (XPM).

Um VOA é utilizado no final da cascata para controlar a potência que chega ao receptor. Um receptor padrão coerente é utilizado para resgatar a informação enviada. Primeiro, a dispersão cromática é compensada, e então a demultiplexação das polarizações é feita utilizando o algoritmo de múltiplos módulos [78, 79, 80]. Finalmente, a fase da portadora é estimada utilizando o algoritmo descrito em [81]. A largura de banda do oscilador local é também definida para ser igual a zero. As características passa baixa dos componentes elétricos são modeladas como um filtro de Bessel de quinta ordem com uma largura de banda de $0,75 \cdot R_s$, na qual R_s é a taxa de símbolo.

4.4.2 *Resultados da análise do impacto dos efeitos não-lineares nas técnicas para ACOP*

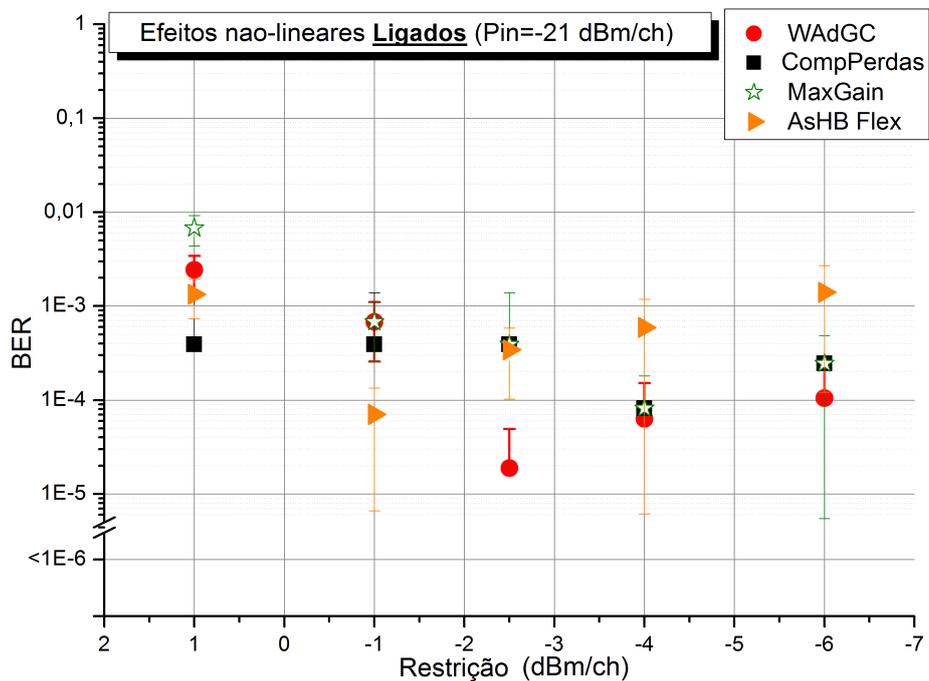
Uma estratégia comum para reduzir o impacto das não-linearidades ópticas é reduzir a potência de lançamento na fibra. Devido a isso, foi introduzida uma restrição na potência de saída do amplificador, que limita a potência total óptica máxima de saída que o amplificador pode operar. Esta restrição de potência é implementada removendo-se da máscara de potência dos amplificadores os pontos de operação que tenham potência de saída maior do que o limite permitido.

A Figura 4.23 mostra o desempenho do sistema (BER) em função da restrição de potência de saída aplicada às técnicas locais do ACOP. Considerando-se 40 canais, cada um com potência igual a 1 dBm, tem-se um sinal com potência total em torno de 17,02 dBm, portanto uma restrição de até 1 dBm/ch na saída significa que o amplificador está operando sem restrição, pois sua potência máxima de saída é 17 dBm. Portanto, se não houver restrição de potência, a potência de lançamento na fibra pode atingir altos valores, dependendo do resultado da técnica ACOP, e o sistema pode ser limitado pelas não-linearidades. Por outro lado, para valores baixos de potência máxima de saída (restrição severa), a potência do sinal pode ser pequena o suficiente para evitar as não-linearidades, porém o desempenho do sistema pode ser limitado pela baixa OSNR.

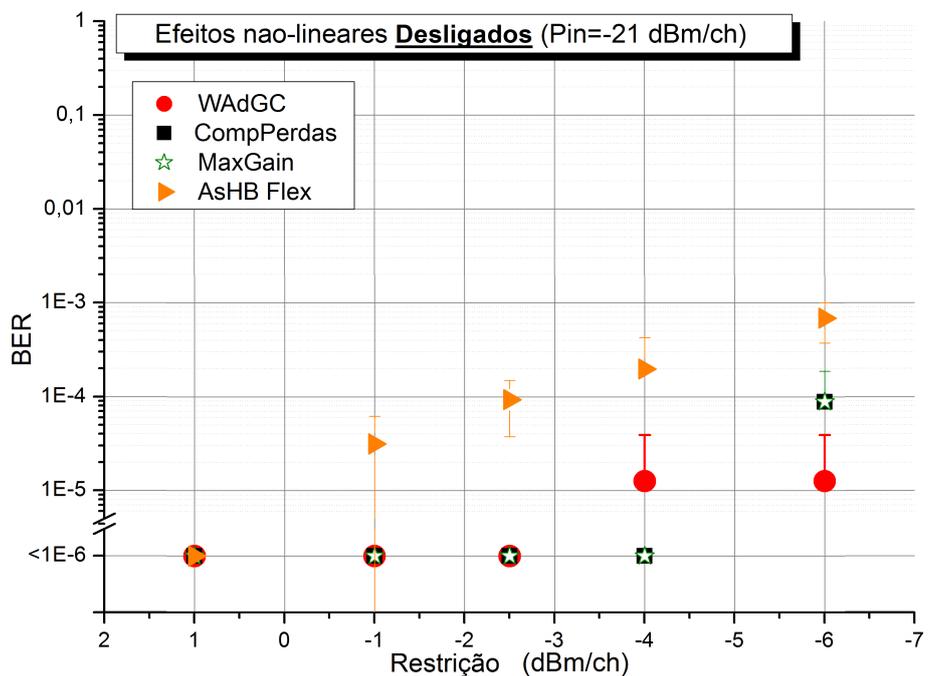
A Figura 4.23a mostra a média e o desvio padrão da BER após 10 execuções das técnicas WAdGC, CompPerdas, MaxGain e AsHB Flex, em função da restrição de potência de saída do amplificador, em um cenário no qual os efeitos não-lineares estão ativos. Percebe-se que, para o caso sem restrição, o MaxGain atingiu os piores valores de BER, mas, com o aumento da restrição, esta técnica retorna os mesmos valores da WAdGC (restrição -1 dBm/ch) e depois os mesmo valores da CompPerdas (restrição -2,5 dbm/ch em diante). A técnica WAdGC conseguiu encontrar a melhor solução quando a restrição imposta foi igual a -2,5 dBm/ch, e nos outros casos obteve resultados semelhantes às outras técnicas. Já a técnica AsHB Flex obteve a melhor solução quando a restrição foi igual a -1 dBm/ch. A técnica CompPerdas obteve seu resultado mais expressivo no caso sem restrição, no qual sua BER foi um pouco menor do que as outras técnicas.

Por outro lado, a Figura 4.23b apresenta as mesmas informações da Figura 4.23a em um cenário no qual os efeitos não-lineares não estão ativos. Portanto, o desempenho do sistema é limitado apenas pela OSNR devido à acumulação do ruído ASE. Para algumas técnicas, e em algumas restrições, não foi possível encontrar um único erro após as 10 execuções das simulações. Para superar esta limitação, seria necessário aumentar o comprimento da sequência de bits, o que aumentaria bastante o tempo de simulação. Contudo, utilizando-se os resultados da técnica AsHB Flex, com restrições a partir de -1 dBm/ch, e uma regressão linear, foi possível verificar que o valor da BER nestes casos seria em torno de 10^{-6} . Então, para a viabilidade da comparação, foi incluído no eixo da BER um valor que representa todas as soluções com BER menor do que 10^{-6} .

Comparando-se as Figuras 4.23a e 4.23b, é possível perceber que todas as técnicas são impactadas pelos efeitos não-lineares, pois há uma melhora da BER quando estes efeitos são removidos da simulação. Tal melhora fica evidente nos casos em que a restrição é menor e, portanto, a atuação dos efeitos não-lineares é maior. A técnica MaxGain, por exemplo, teve uma diminuição de mil vezes no valor da BER no caso sem restrição. É possível perceber, também, que a AsHB Flex a partir da restrição -1 dBm/ch tem seu desempenho limitado basicamente pelo ruído ASE, visto que o posicionamento dos seus pontos segue a mesma



(a)



(b)

Figura 4.23: Média e desvio padrão da BER (a) considerando e (b) não considerando os efeitos não-lineares após 10 execuções das técnicas MaxGain, WAdGC, CompPerdas e AsHB Flex, em função da restrição de potência de saída do amplificador.

tendência nos casos com e sem não-linearidades.

A Tabela 4.9 mostra os atributos dos amplificadores retornados pelas técnicas WAdGC, CompPerdas, MaxGain e AsHB Flex, considerando o cenário sem restrição. Observa-se que os primeiros amplificadores nas técnicas CompPerdas e o AsHB Flex possuem potência de saída menor do que os das técnicas WAdGC e MaxGain, o que explica o fato de na Figura 4.23a os pontos da AsHB Flex e da CompPerdas estarem abaixo das outras técnicas. Além disso, a técnica MaxGain, por escolher os maiores ganhos, tem os amplificadores com as maiores potências de saída, o que explica por que esta é a técnica mais afetada pelas não-linearidades.

Tabela 4.9: Atributos dos amplificadores retornados pelas técnicas WAdGC, CompPerdas, MaxGain e AsHB Flex considerando o cenário sem restrição de potência.

		<i>WAdGC</i>	<i>CompPerdas</i>	<i>MaxGain</i>	<i>AsHB Flex</i>
AMP1	P_{in}^{total} (dBm)	-4,98	-4,98	-4,98	-4,98
	Gain (dB)	22	18	22	15
	P_{out}^{total} (dBm)	17,02	13,02	17,02	10,02
	NF (dB)	3,73	3,77	3,73	3,81
AMP2	P_{in}^{total} (dBm)	-0,98	-4,98	-0,98	7,98
	Gain (dB)	17	18	18	23,21
	P_{out}^{total} (dBm)	16,02	13,02	17,02	15,23
	NF (dB)	3,87	3,77	3,85	3,72
AMP3	P_{in}^{total} (dBm)	-1,98	-4,98	-0,98	-2,77
	Gain (dB)	18	18	18	20,01
	P_{out}^{total} (dBm)	16,02	13,02	17,02	17,25
	NF (dB)	3,82	3,77	3,85	3,78
AMP4	P_{in}^{total} (dBm)	-1,98	-4,98	-0,98	-0,75
	Gain (dB)	18	18	18	17,77
	P_{out}^{total} (dBm)	16,02	17,02	17,02	17,02
	NF (dB)	3,82	3,77	3,85	3,86

4.5 Considerações sobre o capítulo

Os resultados apresentados nesta seção contribuíram para alcançar alguns dos objetivos específicos deste trabalho.

Com relação ao objetivo específico 1, por exemplo, mostrou-se na Seção 4.1 que é possível utilizar uma rede neural MLP para mapear a NF e *ripple* do amplificador como uma função das suas potências totais de entrada e de saída. Foi comprovado também que a MLP pode evitar a necessidade de pequenos passos para obter uma máscara de potência com uma boa resolução. Isso significa que a utilização da MLP como uma ferramenta auxiliar no processo de caracterização pode reduzir o tempo gasto para caracterizar um amplificador no estágio experimental. Utilizando-se um intervalo de ganho de 3 dB para medir os pontos de operação, os resultados apresentaram erros menores do que 0,1 dB. Então, considerando que o tempo

médio para a caracterização de um amplificador, alterando-se a potência de entrada a um passo de 1 dB, é em torno de 5 horas, a utilização da MLP possibilita o uso da caracterização em passos de 3 dB, o que reduzirá o tempo deste processo para 1 hora e 40 minutos, ou seja, um ganho real de 3 horas e 20 minutos com um erro muito baixo. Além disso, as curvas contínuas para a caracterização do amplificador podem ser usadas pelas técnicas ACOP durante o processo de adaptação.

Nas análises apresentadas na Seção 4.2 – que fazem parte do objetivo específico 3 – observou-se que a restrição na potência de saída considerada pelo AsHB torna-se um diferencial em relação à técnica encontrada na literatura (AdGC), porém é prejudicial à QoT da cascata. Entretanto, a AsHB Flex supera essa limitação sendo capaz de manter a restrição de potência e alcançar boa QoT. Percebeu-se também que, para máscaras com variados valores de canais, a técnica MaxGain retorna os melhores resultados em termos de NF e *ripple* da cascata. Por outro lado, a técnica AsHB Flex retorna resultados tão bons quanto a MaxGain em alguns cenários, e em outros se mantém ao menos tão boa quanto a técnica AdGC, mostrando que para o cenário considerado as técnicas aqui propostas superam a técnica proposta na literatura.

Apesar de retornar o conjunto com todos os possíveis resultados para o ACOP, a técnica global proposta aqui – método exaustivo – não escala bem com o número de amplificadores da cascata. Portanto esta técnica se mostra como uma opção a ser utilizada apenas em enlaces pequenos, ou como um importante *benchmark* para as outras técnicas ACOP.

Entretanto, em uma análise considerando um cenário mais completo, percebeu-se que todas as técnicas tem o seu desempenho degradado pelos efeitos não-lineares. Faz-se necessário uma maior investigação quanto a esta degradação, pois a limitação de tempo imposta pelo *software* comercial utilizado não permite a realização de uma análise mais detalhada e em cenários mais diversos. Contudo, pelos resultados apresentados na Seção 4.4 já é possível afirmar que as técnicas devem ser adaptadas para que seu desempenho não sofra uma degradação tão grande por conta dos efeitos não-lineares.

Também foi apresentada na Seção 4.3 a implementação, validação e teste da técnica MaxGain na rede autônoma do CPqD, o que é um avanço quanto ao objetivo específico 5 e mostra – de forma bastante clara – o impacto real que as técnicas ACOP podem causar no desempenho de uma rede óptica autônoma.

5 . AVALIAÇÃO DAS TÉCNICAS PARA ACOP CONSIDERANDO NÃO-LINEARIDADES E CANAIS INDEPENDENTES

A Seção 4.4 mostrou a necessidade de considerar os efeitos não-lineares na análise das técnicas ACOP. Além disso, artigos recentes na área de definição autônoma de ganho e caracterização de amplificadores apontam a necessidade de considerar os efeitos não-lineares em suas análises [34] [5]. Contudo, utilizar um simulador como o OptiSystem [®], que utiliza modelos numéricos para o cálculo deste efeitos, não é uma solução rápida nem de fácil integração com os algoritmos ACOP. Portanto, a utilização de um modelo analítico que seja capaz de calcular as não-linearidades em um tempo menor, com uma boa precisão e que possa ser implementado em conjunto com as técnicas ACOP apresenta-se como uma boa solução para a consideração dos efeitos não-lineares pelas técnicas ACOP.

Contudo, além de analisar o impacto dos efeitos não-lineares de uma forma mais rápida e integrada, também é necessário a criação de estratégias para a minimização do impacto destes efeitos no desempenho das técnicas ACOP.

Ademais, as análises realizadas no Capítulo 4 não levam em consideração as informações de espectro, e por conta disso não é possível modelar o impacto causado em cada canal do sinal pelo *ripple* do amplificador, bem como, não é possível saber quais canais sofrem mais com a inserção do ruído ASE. Por conta disso, o *ripple* nestas análises era considerado como a soma dos *ripples* de cada amplificador. Portanto, para uma análise mais realista, precisa-se considerar como as distorções causadas nos sinais pelos amplificadores, e o cascadeamento destas distorções, alteram a QoT do sistema.

Diante das necessidades descritas acima, neste capítulo o cenário utilizado nas análises das técnicas ACOP será modificado para que os canais do sinal óptico sejam alterados pelo amplificador de forma independente, e para que os efeitos não-lineares sejam considerados na análise das técnicas ACOP.

Na Seção 5.1 a modelagem do amplificador para canais independentes será detalhada e será apresentada uma adaptação na rede neural proposta na Seção 4.1 para modelar os amplificadores utilizando as informações de espectro da máscara de potência. Na Seção 5.2

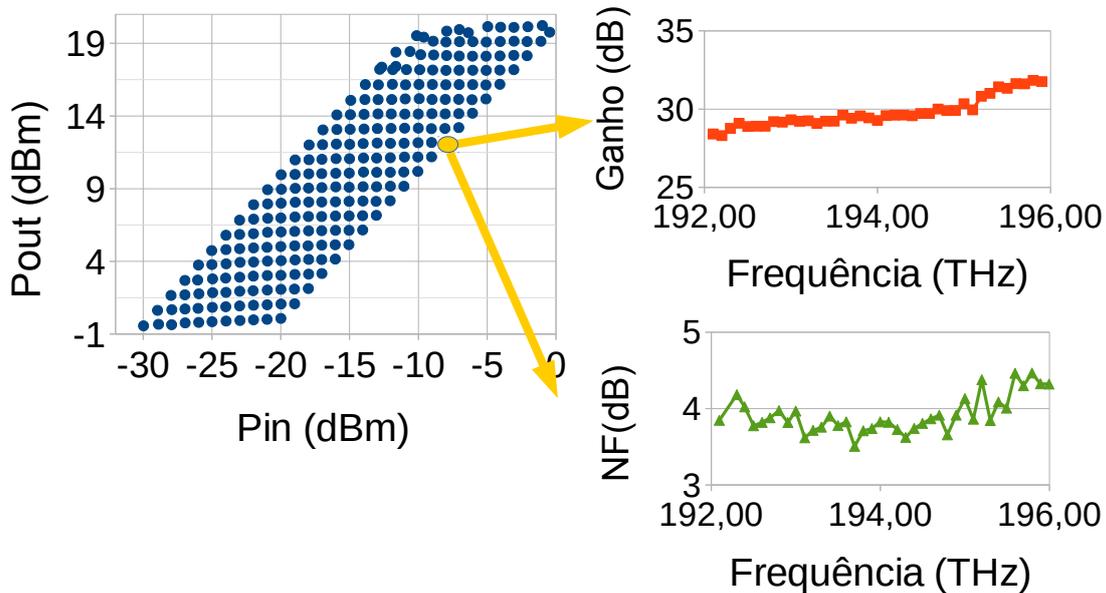


Figura 5.1: Ilustração mostrando um ponto de operação da máscara e os valores de ganho e figura de ruído (NF) ao longo do espectro de operação (Fonte: elaboração própria).

será apresentado o modelo analítico para cálculo dos efeitos não-lineares. Na Seção 5.3 será apresentada uma estratégia que considera um VOA na saída de cada amplificador e utiliza este VOA para controlar a potência de lançamento na fibra com o intuito de minimizar o impacto dos efeitos não-lineares. Por fim, na Seção 5.4 é apresentada uma técnica ACOP global que utiliza otimização multiobjetivo e é capaz de otimizar os valores dos ganhos dos amplificadores e das perdas dos VOAs simultaneamente.

5.1 Modelagem do amplificador para canais independentes

O primeiro passo para modelar o impacto do amplificador óptico em canais independentes é considerar o ganho e a figura de ruído do amplificador canal-a-canal na máscara do amplificador. O processo de caracterização descrito na Seção 2.1 é capaz de adquirir as informações de ganho e figura de ruído para cada canal caracterizado. Dessa forma, para cada ponto de operação da máscara tem-se um conjunto de dados que representam os valores de ganho e figura de ruído para cada frequência caracterizada. A Figura 5.1 ilustra esta nova estrutura considerada na máscara, destacando um ponto de operação e as informações de espectro presentes neste ponto.

Diante disso, o mapeamento definido pela RNA proposta na Seção 4.1 não é mais um modelo suficiente para definir as características do amplificador, pois tal RNA não considera as informações dos canais presentes na máscara do amplificador. Então, faz-se necessário

a utilização e/ou criação de modelos que possam levar em consideração as informações de espectro presentes na máscara, e assim conseguir retornar as características dos amplificadores para cada canal de forma independente.

5.1.1 *Estimadores encontrados na literatura*

Em [82], Fei e colaboradores propuseram um *framework* que visa criar estimadores para o ganho sofrido por cada canal considerando as informações do espectro presente na máscara de potência. Este *framework* é composto por quatro módulos, os módulos 1 e 2 tratam dos casos em que os valores de frequência do canal (módulo 1) ou potência total de entrada (módulo 2) são diferentes dos valores caracterizados, ou seja, presentes na máscara de potência. Os outros dois módulos lidam com os casos em que o sinal de entrada não está equalizado (módulo 3) e o espectro não está completo de canais (módulo 4). A implementação do módulo 3 é feita de três formas diferentes, por isso são propostos três estimadores diferentes. Contudo, os módulos 1 e 2 são os que realmente utilizam os dados da máscara de potência do amplificador, e eles seguem uma estratégia de interpolação linear para calcular as suas saídas. As equações abaixo mostram como a saída do módulo 1 é calculada,

$$s(f_k, P_{in}, G_{set}) = (1 - \alpha) \cdot m(f_i, P_{in}, G_{set}) + \alpha \cdot m(f_{i+1}, P_{in}, G_{set}), \quad (5.1)$$

$$\alpha = \frac{f_k - f_i}{f_{i+1} - f_i}, \quad (5.2)$$

na qual f_k é a frequência do canal recebido, f_i e f_{i+1} são as frequências mais próximas de f_k e que estão armazenadas na máscara de potência do amplificador, a função $m(\cdot)$ retorna o ganho do canal f_i considerando uma potência total de entrada (P_{in}) e um ganho alvo (G_{set}). O ganho retornado pela função $m(\cdot)$ é o valor contido na máscara. O cálculo do módulo 2 segue a mesma lógica descrita nas equações acima, contudo, utiliza a função $s(\cdot)$ ao invés da função $m(\cdot)$, e considera como entrada um P_{in} que não foi caracterizado.

Os estimadores presentes em [82] apresentam bons resultados para uma cascata de até 6 amplificadores. Tais resultados são validados com experimentos executados com amplificadores reais. Contudo, neste artigo apenas a potência de saída (ganho) de cada canal é estimada, e por usar uma lógica de interpolação este modelo necessita armazenar todas as informações da máscara, o que acarreta em um alto custo de armazenamento. Ademais, a cada canal a ser estimado, é necessário buscar na máscara inteira os pontos vizinhos do canal a ser caracterizado, o que acarreta em um custo computacional recorrente.

5.1.2 Adaptação da Rede Neural para Considerar Informações de Espectro

O mapeamento baseado em rede neural proposto na Seção 4.1 pode ser uma alternativa ao estimador proposto em [82]. Com a rede neural, é possível retornar mais de uma característica do canal ao mesmo tempo (*e.g.* ganho e figura de ruído), sem precisar armazenar a máscara inteira, o que conseqüentemente consome menos tempo. Estas vantagens podem ser úteis em cenários onde a capacidade de armazenamento é crítica, como por exemplo em sistemas embarcados, e também em cenários onde o tempo é crítico, como no caso de utilizar este estimador como uma função de avaliação de *fitness* em um algoritmo de otimização.

Para considerar as informações de canal armazenadas na máscara de potência do amplificador, a rede neural proposta na Seção 4.1 foi alterada para considerar novas entradas e saídas (vide Figura 5.2). As novas entradas são: a potência total de entrada do sinal (P_{in}), o ganho no qual o amplificador deve operar (G_{set}) e a frequência do canal. As novas saídas são: ganho do canal (G_{ch}) e figura de ruído do canal (NF_{ch}). A rede neural aceita todos os valores de frequência e P_{in} dentro do intervalo definido na máscara do amplificador. Em cenários com canais de entrada não equalizados, a rede neural utiliza a estratégia *Total Input Power* (TIP) com *Gain Matching* (GM), que é uma das estratégias utilizadas no módulo 3 do estimador proposto em [82]. Na estratégia TIP, a potência de saída de uma canal é estimada como:

$$P_{out}(f_i) = P_{in} g(f_i, P_{in}, G_{set}) \quad (5.3)$$

na qual $P_{in} = \sum_i P_{in}(f_i)$ e a função $g(\cdot)$ retorna o ganho estimado para um canal. Já o GM realiza uma correção em cada potência de saída de acordo com o ganho estimado pelo TIP e o ganho que deve ser configurado no amplificador (G_{set}), utilizando a equação 5.4.

$$\hat{P}_{out}(f_i) = P_{in}(f_i) \frac{G_{set}}{G_{tot}} g(f_i, P_{in}, G_{set}), \quad (5.4)$$

na qual $P_{out} = \sum_i P_{out}(f_i)$ e $G_{tot} = \frac{P_{out}}{P_{in}}$.

Para validar a implementação da rede neural, foi utilizada a máscara de potência de um amplificador EDFA de um estágio. A área de operação definida pela máscara de potência para estes amplificadores possui ganhos entre 20 e 30 dB, potências totais de entrada entre -30 e 0 dBm, figuras de ruído entre 4,47 e 5,9 dB e *ripples* entre 0,67 e 4,96 dB. Na caracterização desta máscara, foram considerados 39 canais na banda C.

O treinamento da rede neural utilizou todos os pontos da máscara do amplificador, pois o objetivo principal é estimar corretamente os valores dentro da máscara, e não extrapolar o mapeamento para valores externos à região da máscara. Os dados de treinamento foram embaralhados considerando o G_{set} e P_{in} , mas foram ordenados por frequência. Essa ordenação foi feita com o intuito de apresentar o espectro completo de um ponto de operação à rede neural. Todos os dados foram normalizados no intervalo $[0, 15 - 0, 85]$. Os dados de validação

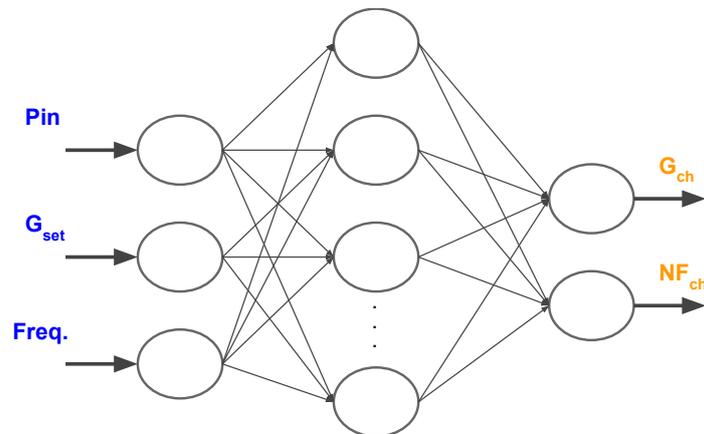


Figura 5.2: Ilustração da rede neural desenvolvida para a estimativa do ganho e da figura de ruído de uma canal, considerando os dados presentes na máscara de potência do amplificador. (Fonte: elaboração própria)

foram selecionados escolhendo-se aleatoriamente metade dos dados. A técnica utilizada no treinamento foi a *backpropagation*, com uma taxa de aprendizado de 0,3, um *momentum alpha* (termo utilizado para minimizar flutuações nos valores dos pesos) de 0,3 e a condição de parada foi 5 mil épocas de treinamento.

A Figura 5.3 mostra os erros de treinamento e validação da rede neural proposta. É possível perceber que a rede neural está funcionando corretamente e com um erro bem pequeno, pois os erros estão decrescendo ao longo das épocas e ambos atingem um erro médio quadrático em torno de $1,5e^{-3}$. Apesar da fase de treinamento convergir em torno de mil épocas, a rede neural foi treinada utilizando 5 mil épocas para que a quantidade de *outliers* fosse reduzida.

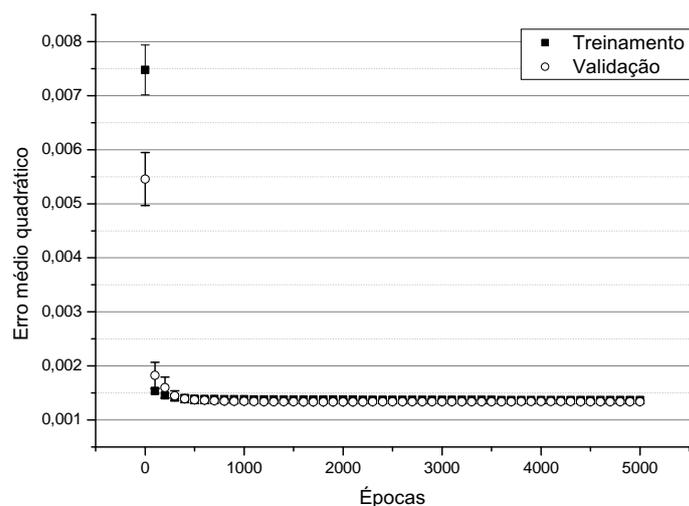


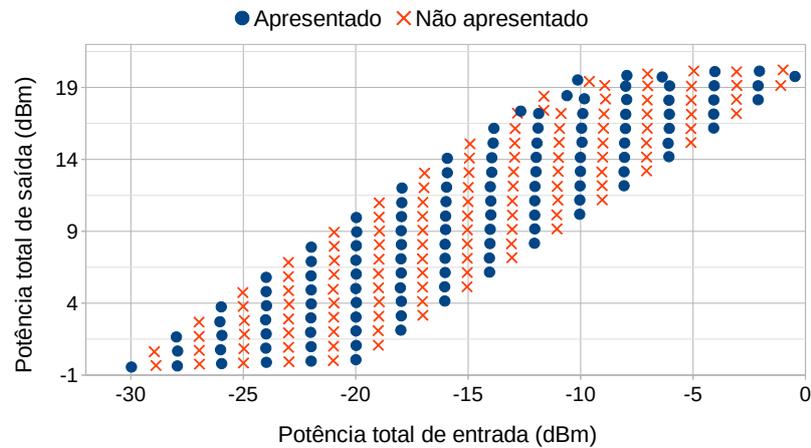
Figura 5.3: Erro médio quadrático das fases de treinamento e validação em função do número de épocas de treinamento.

Para avaliar a qualidade da rede neural proposta, os resultados obtidos pela rede serão comparados com os resultados retornados pelo estimador proposto em [82]. Como dito anteriormente, em [82] foram propostos três estimadores, entretanto apenas dois deles atingiram resultados muito bons. Como a rede neural proposta aqui utiliza a estratégia TIP com GM, para uma comparação justa, será considerado apenas o estimador chamado de TIP&GM em [82] e este estimador será chamado de Método de Interpolação (MI).

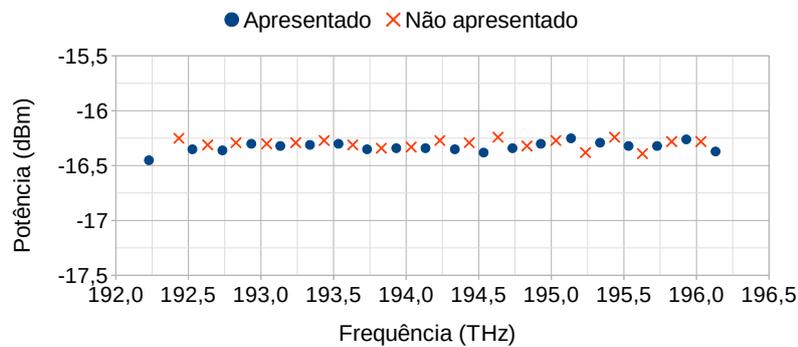
A rede neural proposta foi simulada utilizando 9 neurônios na camada escondida, este valor foi escolhido após avaliações preliminares do erro da RNA. Com essa quantidade de neurônios, a RNA possui 56 conexões entre neurônios (considerando o neurônio *bias* nas camadas de entrada e escondida), o que significa que os dados armazenados são os 56 pesos de cada conexão. Por outro lado, o MI precisa armazenar todos os pontos da máscara de potência. Cada ponto foi caracterizado considerando 39 canais e para cada canal são armazenados cinco valores: G_{set} , P_{in} , frequência, G_{ch} e NF_{ch} . A máscara utilizada nas simulações tem 231 pontos, o que significa que é necessário armazenar 45.045 ($231 \times 39 \times 5$) valores para realizar a interpolação como proposta em [82]. Portanto, a utilização da rede neural irá requisitar 804 vezes menos espaço de memória do que o MI.

Existe uma diferença significativa no tempo consumido pela rede neural e pelo MI. Após 30 execuções independentes das duas técnicas, com o intuito de retornar o G_{ch} e NF_{ch} de 39 canais, o tempo médio do MI foi 384 ms com um desvio padrão de 31,91 ms, enquanto que o tempo médio da rede neural foi de 4,73 ms com desvio padrão de 3,92 ms. Portanto, a rede neural executa a mesma tarefa, em média, 80 vezes mais rápido do que o método de interpolação.

Para avaliar a precisão da rede neural em comparação ao MI, alguns pontos da máscara de amplificação foram removidos e a rede neural foi treinada com essa máscara reduzida. Em seguida, os pontos removidos foram apresentados e o erro absoluto entre o valor estimado e o valor da máscara foram calculados. No caso do MI, a mesma máscara reduzida, utilizada para treinar a rede neural, foi utilizada como o dado de referência e os pontos removidos foram utilizados como os pontos a serem estimados. A remoção dos pontos seguiu duas estratégias: 1) remoção dos pontos com frequências alternadas e 2) remoção dos pontos com P_{in} alternados. A Figura 5.4 ilustra como estas estratégias dividiram a máscara de potência do amplificador.



(a) Potências de entrada alternadas

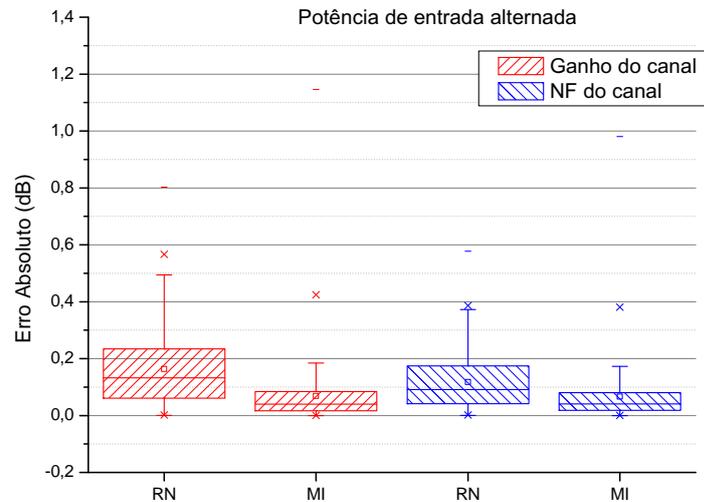


(b) Frequências alternadas

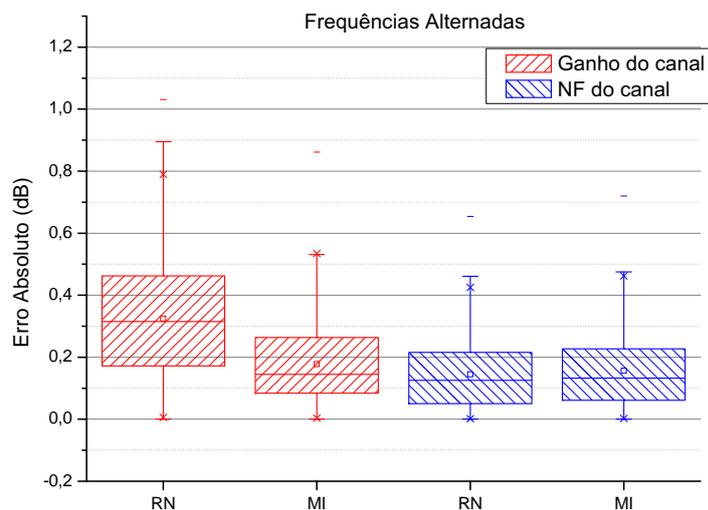
Figura 5.4: Ilustração das duas estratégias utilizadas para dividir a máscara de potência em pontos que foram ou não apresentados à rede neural e ao método de interpolação. (Fonte: elaboração própria)

Apesar de em [82] o MI não ter sido utilizado para estimar a NF_{ch} , o modelo do MI foi alterado para estimar a NF_{ch} da mesma forma que estima o G_{ch} . Então, a NF_{ch} estimada pelo MI é o resultado da interpolação entre as NFs dos canais/frequências mais próximos de um dado ponto na máscara de amplificação.

A Figura 5.5 mostra a distribuição do erro absoluto na estimativa do G_{ch} e NF_{ch} para a rede neural (RN) e para o método de interpolação (MI), considerando os pontos não apresentados com frequência alternadas e P_{in} alternados. É possível perceber que a variação do erro de estimação do G_{ch} , nas duas estratégias de divisão, é menor no MI. Por outro lado, a variação do erro de NF_{ch} é praticamente a mesma tanto para o MI quanto para a RN. Contudo, pela análise dos *box-plots*, é possível perceber que não existe diferença estatística significativa entre RN e MI no cenário considerado, e que a mediana do erro fica abaixo de 0,4 dB.



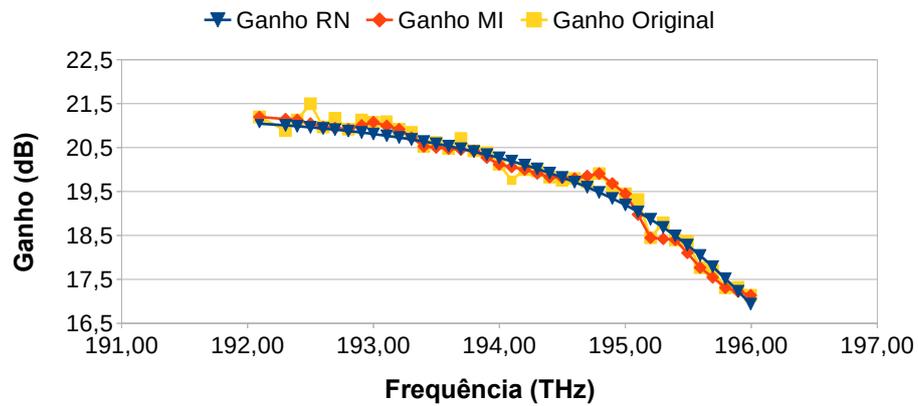
(a) Potências de entrada alternadas



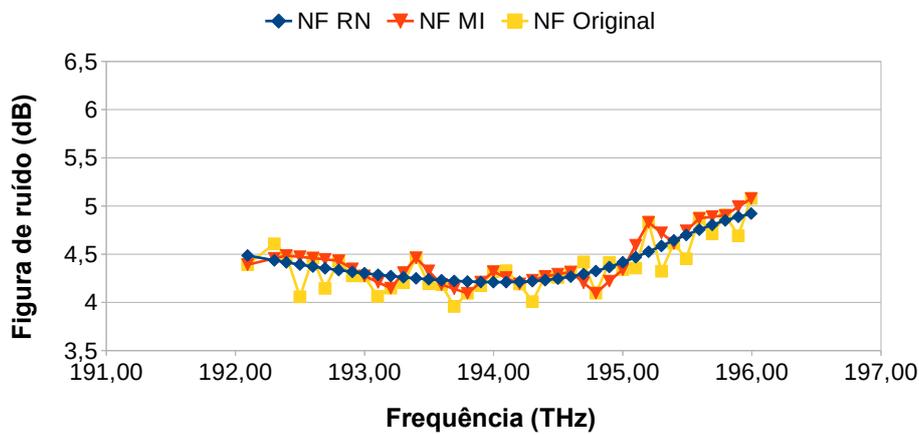
(b) Frequências alternadas

Figura 5.5: Distribuição do erro absoluto na estimativa do ganho e da NF dos canais, nos pontos não apresentados, utilizando a RN e o MI, considerando que a máscara foi dividida pelas (a) potências de entrada ou (b) frequências.

Portanto, é possível utilizar a rede neural para realizar a mesma tarefa que o MI sem nenhuma perda de precisão significativa. A Figura 5.6 compara isto ao mostrar a similaridade das curvas retornadas pelo MI e pela RN para um determinado ponto de operação da máscara. Essa figura também mostra como ambas as curvas são similares à curva retornada pelo processo de caracterização (e armazenada na máscara do amplificador). Além disso, pode-se ver como a curva retornada pela RN é mais suave, e essa suavidade pode indicar que a RN é menos afetada pelo ruído de medição.



(a) Curvas de Ganho



(b) Curvas de NF

Figura 5.6: Curvas de (a) ganho e (b) figura de ruído armazenada na máscara de potência do amplificador (quadrado), retornada pelo MI (losango) e retornada pela RN (triângulo invertido), em função da frequência do canal.

Para mostrar que este método baseado em RN pode ser aplicado para outros tipos de máscara, a mesma simulação descrita anteriormente foi executada para a máscara de potência de uma EDFA de dois estágios. A área de operação definida pela máscara de potência para este amplificador possui ganhos entre 20 e 30 dB, potências totais de entrada entre -30 e 0 dBm, figuras de ruído entre 3 e 12,81 dB e ripples entre 0,45 e 12,04 dB. Os mesmo 39 canais considerados na caracterização do EDFA de um estágio foram considerados neste EDFA de dois estágios.

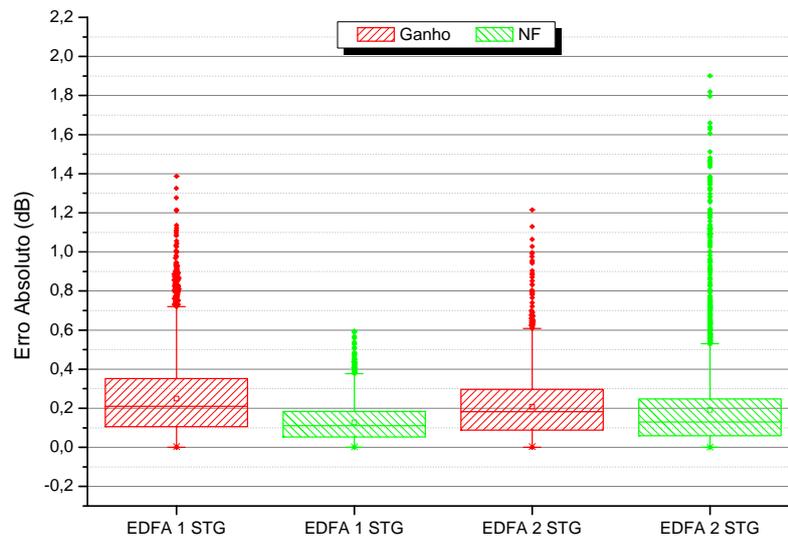


Figura 5.7: Distribuição do erro de teste (absoluto) retornado pela RN na estimação do ganho e da figura de ruído de um EDFA de um estágio (1 STG) e de um EDFA de dois estágios (2 STG).

A Figura 5.7 mostra a distribuição do erro de teste retornado pela RN na estimação do ganho e da figura de ruído do EDFA de um estágio e do EDFA de dois estágios. Percebe-se que a distribuição do erro para o EDFA de dois estágios é muito similar à distribuição do erro para o EDFA de um estágio. Como ficou claro pelos resultados anteriores, a rede neural obteve um bom desempenho com a máscara do amplificador EDFA de um estágio. Então, a similaridade dos resultados do amplificador EDFA de dois estágios mostra que o mesmo desempenho é alcançado para este outro amplificador.

5.2 Utilizando modelo analítico para cálculo de efeito não-linear

Nesta seção, será apresentada outra contribuição desta tese: a utilização de um modelo de não-linearidades em conjunto com as técnicas ACOP. Na Subseção 5.2.1 será apresentado o modelo utilizado, bem como algumas de suas características. Na Subseção 5.2.2 o cenário de simulação adotado para a integração deste modelo será descrito. Por fim, na Subseção 5.2.3 serão apresentados os resultados obtidos nas simulações.

5.2.1 Modelo analítico utilizado

Com o objetivo de simular um cenário que considera efeitos não-lineares como uma penalidade física na transmissão do sinal, foi utilizado o modelo IGN (*Incoherent Gaussian-noise Model*) [83]. O modelo IGN é uma variação mais simples do modelo de ruído gaussiano. Nesta versão

mais simples, a interferência coerente entre a penalidade não-linear gerada em diferentes *spans* é negligenciada. A principal vantagem do modelo IGN em relação a outros modelos mais precisos e sofisticados é o seu menor tempo de computação. Contudo, segundo os resultados apresentados em [83], a precisão do IGN é muito boa para a modelagem de sistemas práticos.

O modelo IGN é explicado em detalhes em [83], porém alguns pontos chaves podem ser destacados. Um deles é que este modelo assume que as não-linearidades são relativamente pequenas, ou seja, que elas são uma perturbação quando comparadas ao sinal útil. O modelo também assume que o sinal transmitido se comporta estatisticamente como um ruído gaussiano estacionário, considerando para isso que o sinal sofrerá distorções ao longo da transmissão. Isto torna a aplicação deste modelo mais indicada para sistema de transmissão sem compensação de dispersão, como o utilizado neste trabalho. Outro ponto chave é que o IGN assume que o distúrbio causado no sinal pela não-linearidade, que é definido pelo termo *non-linear interference* (NLI), se manifesta como um ruído gaussiano aditivo. Desta forma, o cálculo da potência de ASE e de NLI são realizados separadamente, e por fim podem ser somados. Estes pressupostos são tentativas de aproximação que têm sido utilizadas para simplificar a criação do modelo, conseqüentemente causam um impacto na precisão do mesmo. Contudo, em [83] o modelo IGN é validado em uma variedade de experimentos e os resultados mostram que o modelo possui uma boa precisão na previsão do desempenho de um sistema óptico.

Nesta tese, o IGN foi implementado na linguagem Java e validado com os resultados presentes no artigo em que foi proposto [83]. De uma forma sistêmica, o modelo IGN será um avaliador da cascata de amplificadores definida pelas técnicas ACOP. Portanto as técnicas ACOP não utilizarão os valores retornados pelo modelo IGN para guiar o seu processo. Dessa forma, o modelo IGN é visto pelas técnicas ACOP como um módulo que recebe como entrada e gera como saída os dados apresentados na Tabela 5.1.

5.2.2 *Cenário considerado nas simulações*

Simulações foram feitas considerando o cenário apresentado na Figura 4.22, com quatro amplificadores EDFA de um estágio (os mesmos utilizados na Seção 5.1.2). A potência de entrada no primeiro amplificador foi considerada igual a -21 dBm/ch , simulando um sinal emitido por um transmissor de -3 dBm que passa por um ROADM com perda de 18 dB antes de chegar ao primeiro amplificador.

A Tabela 5.2 apresenta os valores definidos para o modelo IGN nas simulações realizadas. Os outros valores de entrada para o modelo irão variar de acordo com a técnica utilizada. Quanto aos valores de saída, $OSNR_{ASE}[N_{ch}]$ e $OSNR_{ASE+NLI}[N_{ch}]$ são os utilizados como medida de desempenho do sistema. Como cada canal possui o seu valor de OSNR, o foco nos resultados será na mínima OSNR ($\min(OSNR)$), ou seja, a menor OSNR dentre as OSNRs de todos os canais.

Tabela 5.1: Parâmetros de entrada e valores de saída definidos pelo modelo IGN, juntamente com suas descrições.

Parâmetro	Descrição
Entradas	
B_{signal}	Largura de banda do sinal
$\Delta_{f_{ch}}$	Espaçamento entre os canais
N_{ch}	Número de canais
P_{TX}	Potência por canal do sinal de entrada
$f_{ch}[N_{ch}]$	Frequência de cada canal
$Length$	Tamanho dos <i>spans</i>
N_{spans}	Número de <i>spans</i>
$NF[N_{ch}][N_{AMP}]$	Figura de ruído de cada amplificador do enlace para cada canal
$Gain[N_{ch}][N_{AMP}]$	Ganho de cada amplificador do enlace para cada canal
Saídas	
$G_{NLI}[N_{ch}]$	Densidade espectral de potência da <i>non linear impairment</i> (NLI) em cada canal na saída do último amplificador
$SNR_{ASE}[N_{ch}]$	Densidade espectral de potência da <i>signal-to-noise ratio</i> (SNR) gerada apenas pelo ruído ASE em cada canal na saída do último amplificador
$SNR_{ASE+NLI}[N_{ch}]$	Densidade espectral de potência da SNR gerada pelo ruído ASE e NLI em cada canal na saída do último amplificador
$OSNR_{ASE}[N_{ch}]$	Densidade espectral de potência da OSNR gerada apenas pelo ruído ASE em cada canal na saída do último amplificador
$OSNR_{ASE+NLI}[N_{ch}]$	Densidade espectral de potência da OSNR gerada apenas pelo ruído ASE e NLI em cada canal na saída do último amplificador

Tabela 5.2: Parâmetros de entrada e valores de saída definidos pelo modelo IGN, juntamente com suas descrições.

Parâmetro	Descrição
Entradas	
B_{signal}	28 GHz (Nyquist)
$\Delta_{f_{ch}}$	100 GHz
N_{ch}	39
P_{TX}	-21 dBm/ch
$f_{ch}[N_{ch}]$	Frequências que os amplificadores foram caracterizados
$Length$	100 km

Nesta avaliação é utilizado o estimador baseado em rede neural proposto na Seção 5.1.2 para avaliar cada canal do sinal de forma independente. O sinal de entrada é considerado plano e tem os canais nas mesmas frequências utilizadas na caracterização do amplificador.

Além da consideração da $OSNR_{ASE}$ e $OSNR_{ASE+NLI}$, outra métrica extremamente importante nestas simulações será o *ripple* da cascata. Com a utilização do cenário com informação dos canais, será possível calcular o *ripple* de uma forma mais precisa do que era

calculado no Capítulo 4. O valor do *ripple* da cascata será a diferença de potência entre o canal com maior potência e o canal com menor potência, do sinal presente na saída do último amplificador da cascata. O sinal entra plano no primeiro amplificador da cascata e cada amplificador distorce, canal-a-canal, de acordo com o *ripple* definido na máscara de potência e estimado pela rede neural. Dessa forma, as distorções são acumuladas a cada amplificador que o sinal passar.

5.2.3 Resultados da utilização do modelo analítico com as técnicas ACOP

A Figura 5.8 apresenta os valores de OSNR de cada canal no caso em que é considerado apenas o ruído ASE, e no caso onde o ruído NLI é considerado em conjunto com o ASE, para as soluções retornadas pelas técnicas ACOP locais. Neste cenário específico, as técnicas MaxGain e AdGC retornaram as mesmas soluções, por isso existe apenas um gráfico para as duas. É possível perceber que o formato da curva da $OSNR_{ASE}$ é similar para todas as técnicas, tendo um maior valor na MaxGain ($\approx 30dB$) e um menor valor na CompPerdas ($\approx 28dB$). Além disso, o decaimento da $OSNR_{ASE}$ é mais abrupto na CompPerdas do que nas outras técnicas.

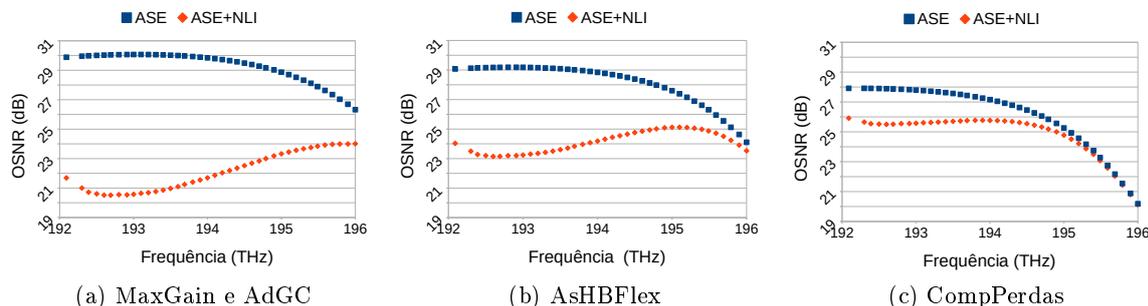


Figura 5.8: Curvas de OSNR ASE e de OSNR ASE+NLI em função da frequência, retornadas pelas técnicas locais.

Por outro lado, a curva da $OSNR_{ASE+NLI}$ possui formatos bem diferentes na CompPerdas e na MaxGain, tendo na solução do AsHB Flex um caso intermediário entre estes dois primeiros. Essa diferença mostra que a MaxGain é mais impactada pelos efeitos não-lineares do que a CompPerdas, principalmente nos seus primeiros canais, pois possuem maior potência. A AsHB Flex se mostra como uma solução intermediária que consegue atingir valores OSNR ASE próximos aos da MaxGain, porém sem ser tão impactada pelas não-linearidades.

Com a informação apresentada na Figura 5.8 é possível avaliar qual a melhor técnica dado um determinado perfil de tráfego da rede. Em um tráfego homogêneo, no qual a maioria dos canais é modulado com o mesmo formato de modulação, a OSNR limiar será semelhante para todos os canais, portanto, neste cenário, a AsHB Flex seria a melhor opção, visto que possui a menor variação entre os valores de OSNR ASE+NLI dos canais. Por outro lado, em um

cenário heterogêneo, no qual os canais são modulados com formatos de modulação distintos, o limiar de OSNR irá variar entre os canais, o que pode tornar a CompPerdas uma escolha suficiente, se a alocação de canais colocar os canais com formato de modulação mais robusto nas frequências mais altas.

Análise dos ganhos definidos

Com a intenção de avaliar a causa das diferenças de OSNR percebidas na Figura 5.8, a Figura 5.9 apresenta os gráficos de ganho por canal em cada amplificador do enlace considerando as técnicas ACOP locais. Percebe-se que a mesma relação encontrada no gráfico da OSNR é vista na definição de ganho do primeiro amplificador, ou seja, a MaxGain define os maiores ganhos, a CompPerdas os menores e a AsHB Flex um valor intermediário. Nos amplificadores dois e três, a diferença entre os valores de ganhos retornados é muito pequena, praticamente insignificante. Já no amplificador quatro, a técnica AsHB Flex define um patamar de ganho maior do que as demais.

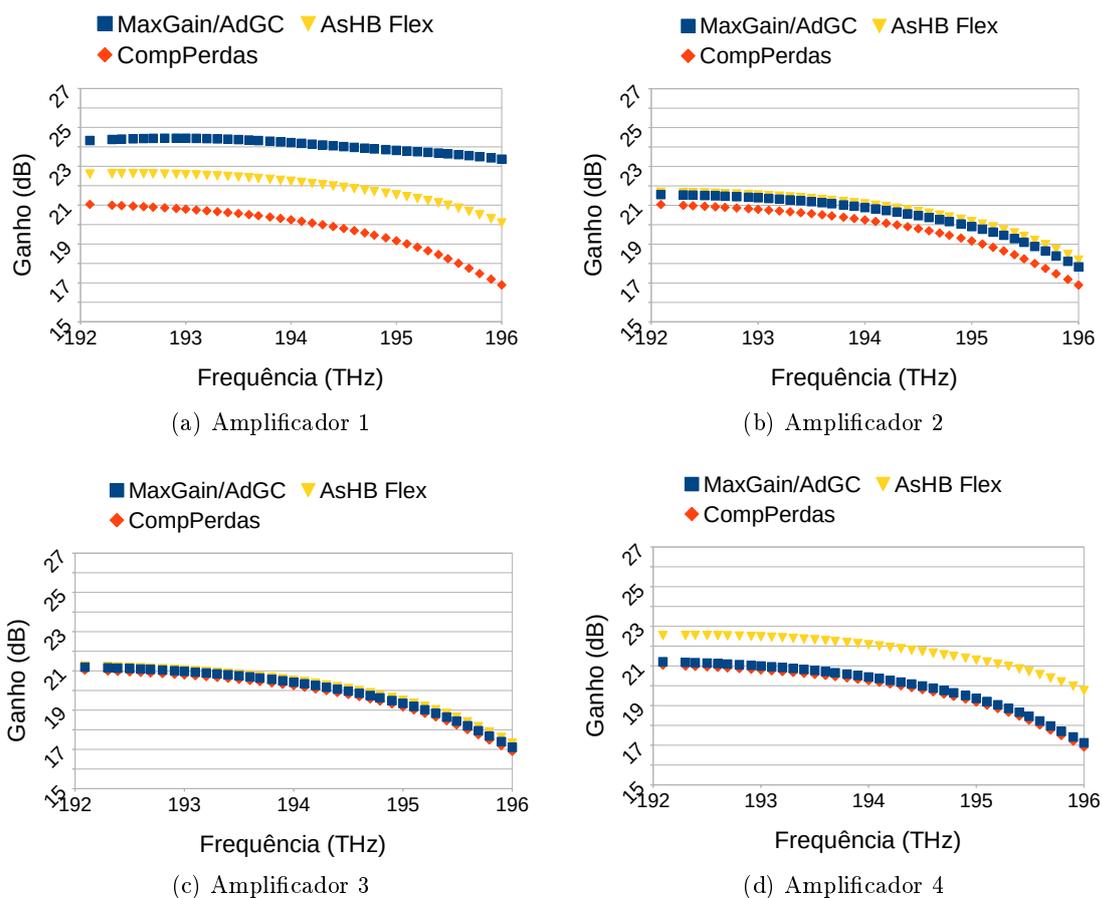


Figura 5.9: Curvas de ganho em função da frequência retornadas pelas técnicas MaxGain e AdGC (quadrado), AsHB Flex (triângulo invertido) e CompPerdas (losango).

A Figura 5.10 apresenta o gráfico do ganho agregado (somatório dos ganhos dos quatro amplificadores) de cada canal para as três técnicas consideradas. É interessante perceber que a MaxGain e a AsHB Flex definem praticamente o mesmo ganho agregado, porém distribuem esse ganho de forma diferente entre os amplificadores do enlace.

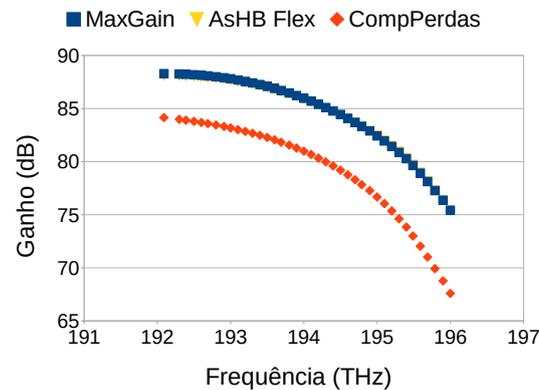
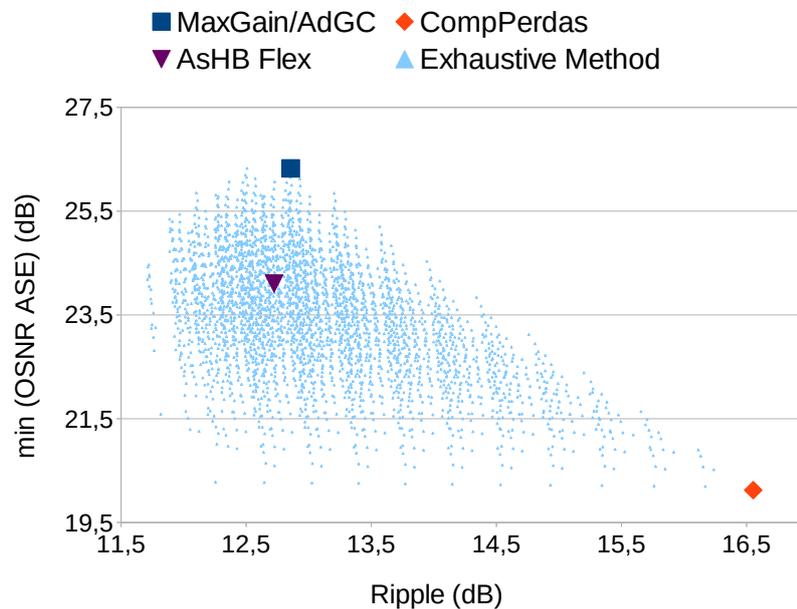


Figura 5.10: Curvas do ganho agregado em função da frequência, retornadas pelas técnicas locais.

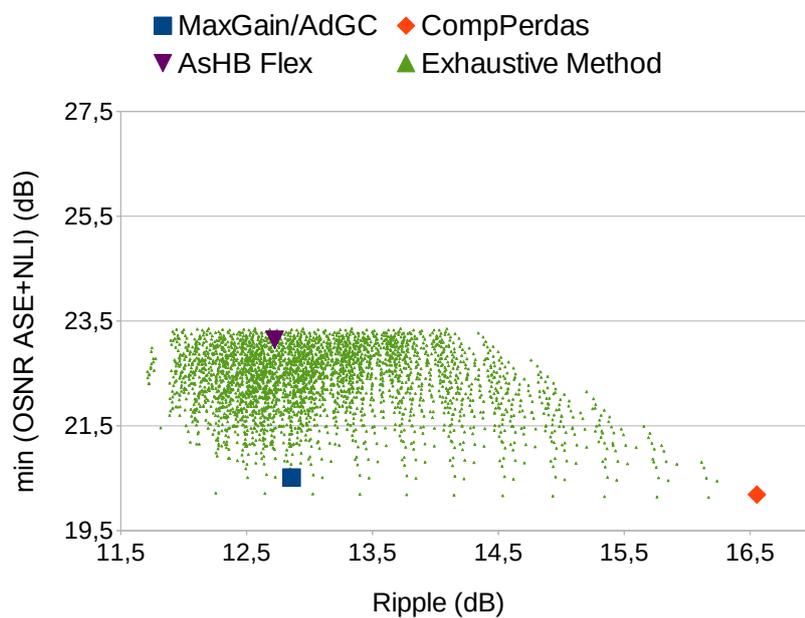
Análise do desempenho das técnicas locais

Com o intuito de avaliar a qualidade das soluções retornadas pelas soluções locais, foi executado o Método Exaustivo para avaliar todas as possíveis combinações válidas de ganhos no enlace considerado, com um passo fixo de 0,1 dB entre um ganho e outro.

A Figura 5.11 apresenta os gráficos do *ripple* da cascata em função da OSNR ASE e ASE+NLI, no qual cada pequeno triângulo é uma das possibilidades geradas pelo método exaustivo, e os outros pontos posicionam as soluções encontradas pelas técnicas locais neste espaço. Percebe-se que, ao se considerar a não-linearidade, existe um novo limite máximo na OSNR. Considerando somente ASE, é possível atingir uma OSNR em torno de 26 dB, enquanto que, considerando ASE+NLI, essa OSNR máxima passa a ser menor do que 23,5 dB. É possível perceber, também, que a CompPerdas retorna os piores valores nas duas dimensões, e para as duas OSNRs. Considerando a OSNR ASE+NLI, a AsHB Flex e a MaxGain estão bem próximas em termos de *ripple*, porém a AsHB Flex retorna uma OSNR que supera em 2,5 dB a retornada pela MaxGain. Ao se comparar as Figuras 5.11a e 5.11b, pode-se perceber como a consideração da NLI impactou no relacionamento entre a AsHB Flex e a MaxGain, pois a MaxGain passa de uma OSNR ASE maior do que a AsHB Flex para uma OSNR ASE+NLI menor. Este impacto na MaxGain é ainda mais evidente ao se identificar que ela é a técnica com a maior OSNR ASE, mas é praticamente tão ruim quanto a CompPerdas na OSNR ASE+NLI.



(a)



(b)

Figura 5.11: OSNR (a) ASE e (b) ASE+NLI do pior canal em função do *ripple* do sinal do último amplificador. Triângulos representam as soluções do método exaustivo, quadrado da técnica MaxGain, diamante da CompPerdas e triângulo invertido da AsHBFlex.

Análise da escalabilidade das técnicas locais

A Figura 5.12 apresenta os valores de *ripple* e mínima OSNR ASE+NLI das soluções retornadas pelas três técnicas locais em enlaces com número de amplificadores (spans) diferentes. Percebe-se que a tradicional técnica CompPerdas retorna os piores valores das duas métricas em todos os casos, já a AsHB Flex retorna os melhores valores de OSNR em enlaces com até 6 amplificadores. Apesar das técnicas MaxGain e AdGC retornarem os melhores valores de *ripple* na maioria dos casos, a diferença do valor retornado por estas técnicas e o retornado pela AsHB Flex é muito pequena, o que em termos práticos representa um empate entre as três técnicas quanto ao *ripple* da cascata. Diante destes resultados, é possível afirmar que a AsHB Flex é a melhor escolha para cenários com enlaces que possuem diferentes números de amplificadores, pois é capaz de retornar bons valores de OSNR e ripple que, quando não são os melhores entre as técnicas, estão muito próximos dos melhores.

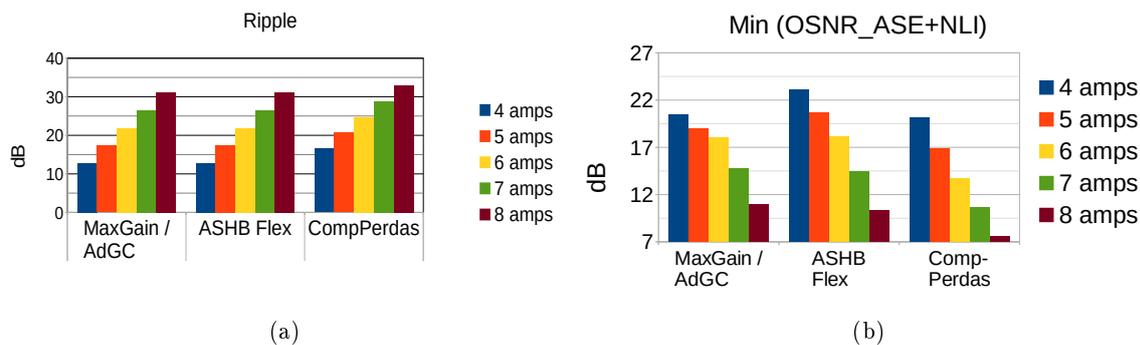


Figura 5.12: Valores de *ripple* e mínima OSNR ASE+NLI para as três técnicas locais em enlaces com diferentes números de amplificadores.

A Tabela 5.3 apresenta os mesmos valores da Figura 5.12, porém para cenários em que a potência de entrada do sistema apresentado é alterada. Percebe-se que a AsHB Flex continua sendo uma boa opção quando a potência de entrada é diminuída para -24 dBm/ch , pois a OSNR da solução retornada por esta técnica continua sendo a maior, enquanto o ripple é apenas 0,43 dB maior do que a melhor técnica neste quesito (MaxGain). Ao se aumentar a potência de entrada para -18 dBm/ch a qualidade da solução retornada pela técnica CompPerdas é superior em termos de OSNR às outras técnicas, contudo a AsHB Flex retorna o melhor valor de *ripple*, então a escolha entre CompPerdas e ASHB Flex para esta potência de entrada se dará pela preferência entre OSNR e planicidade de ganho.

Vale salientar que, para uma potência total de entrada de -18 dBm/ch , o número de pontos de operações possíveis de serem escolhidos é muito pequena, pois a potência total na entrada do primeiro amplificador fica muito próxima ao limite máximo da máscara. Essa diminuição das possibilidades de escolha torna este cenário muito ruim para técnicas adaptativas, visto que, por existirem poucas possibilidades de escolha, a escolha mais simples da

técnica CompPerdas é suficiente.

Tabela 5.3: Valores de mínima $OSNR_{ASE+NLI}$ e de *ripple* da cascata retornados pelas técnicas locais para cenários com diferentes potências de entrada. O melhor valor de cada linha está destacado em negrito.

	MaxGain	AdGC	ASHB Flex	CompPerdas
	$Min(OSNR_{ASE+NLI})(dB)$			
-24 dBm/ch	21,04	21,19	23,45	17,01
-21 dBm/ch	20,51	20,51	23,14	20,12
-18 dBm/ch	20,60	20,60	21,48	22,22
	$Ripple(dB)$			
-24 dBm/ch	10,45	10,51	10,88	17,25
-21 dBm/ch	12,86	12,86	12,72	16,55
-18 dBm/ch	15,57	15,57	15,44	16,31

A utilização do IGN torna evidente que os efeitos não-lineares são um fator de impacto no desempenho das técnicas ACOP. Portanto, é preciso que, no desenvolvimento destas técnicas, sejam criados mecanismos que minimizem este impacto.

5.3 Utilizando VOA na saída para minimizar o impacto dos efeitos não-lineares

Como visto na Figura 4.23, a restrição na potência de lançamento na fibra influencia diretamente na qualidade da transmissão, pois pode minimizar o impacto dos efeitos não-lineares. Esta restrição pode ser imposta diretamente ao amplificador e conseqüentemente às técnicas ACOP. Contudo, esta imposição diminui a quantidade de pontos de operação possíveis para uma determinada potência de entrada. Uma alternativa mais eficiente é a utilização de um VOA na saída do amplificador. Assim, as técnicas ACOP terão total liberdade na escolha do melhor ponto de operação, já que o VOA será responsável por aplicar a perda necessária para que o sinal esteja dentro da restrição de potência. A Figura 5.13 ilustra o impacto na quantidade de pontos de operação possíveis de serem escolhidos quando se considera uma restrição igual a 15 dBm, a potência de entrada igual a -6 dBm e a aplicação da restrição sendo feita diretamente pelo amplificador e pelo VOA. Neste exemplo fica evidente que a utilização do VOA beneficiará a escolha de um melhor ponto de operação, pois, neste caso, os pontos com melhor figura de ruído ficariam de fora caso a restrição estivesse sendo aplicada diretamente pelo amplificador.

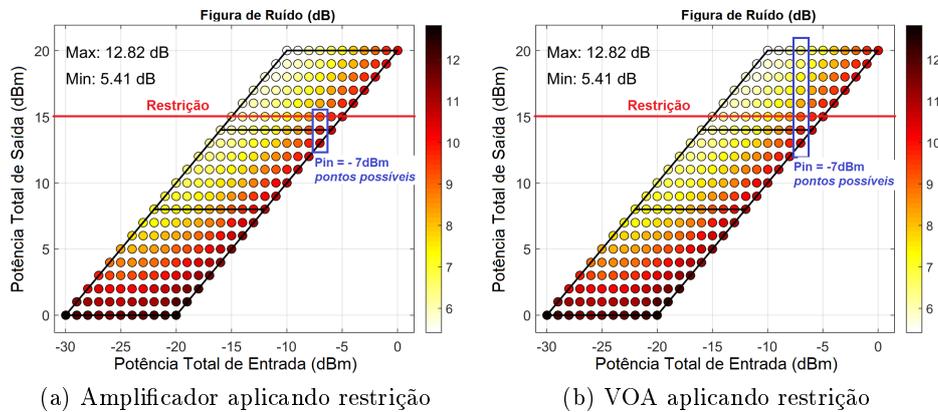


Figura 5.13: Ilustração do impacto da imposição de uma restrição de potência de lançamento na quantidade de pontos de operação possíveis de serem escolhidos, considerando a restrição igual a 15 dBm, a potência de entrada igual a -6 dBm e a aplicação da restrição sendo feita (a) diretamente pelo amplificador ou (b) pelo VOA. Esta máscara de potência é do amplificador EDFA de um estágio. (Fonte: elaboração própria)

Diante disso, o cenário utilizado anteriormente neste trabalho foi adaptado para considerar que na saída de cada amplificador existe um VOA, como mostra a Figura 5.14. Além da possibilidade de melhorar os resultados, esta adaptação está alinhada com a prática, visto que a consideração de um VOA na saída do amplificador já é utilizada em alguns amplificadores ópticos comerciais [84].

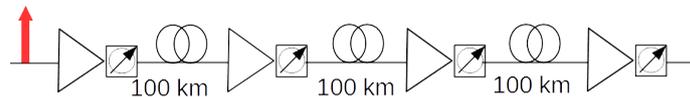


Figura 5.14: Representação da cascata de amplificadores que é utilizada nas simulações deste trabalho, considerando uma VOA na saída de cada amplificador. (Fonte: elaboração própria)

Neste novo cenário, as técnicas ACOP são responsáveis pela escolha do ponto de operação e também por definir a perda do VOA. A forma mais simples de alterar as técnicas ACOP para este novo cenário é considerando que existe uma restrição fixa na potência de lançamento e que o VOA sempre irá atuar para que a potência de lançamento na fibra esteja dentro destas restrições. Utilizar um valor limite para a potência de lançamento é uma técnica comum utilizada na prática e um valor padrão utilizado para esta restrição é 0 dBm/ch [1].

Simulações foram feitas considerando o cenário apresentado na Figura 5.14, com quatro amplificadores EDFA de um estágio (os mesmos utilizados na Seção 5.2) cuja máscara de potência é apresentada na Figura 5.15. A técnica CompPerdas não foi considerada neste cenário pois não faria sentido adicionar uma perda após o ganho do amplificador, já que o objetivo desta técnica é que o ganho do amplificador compense a perda do *span* anterior.

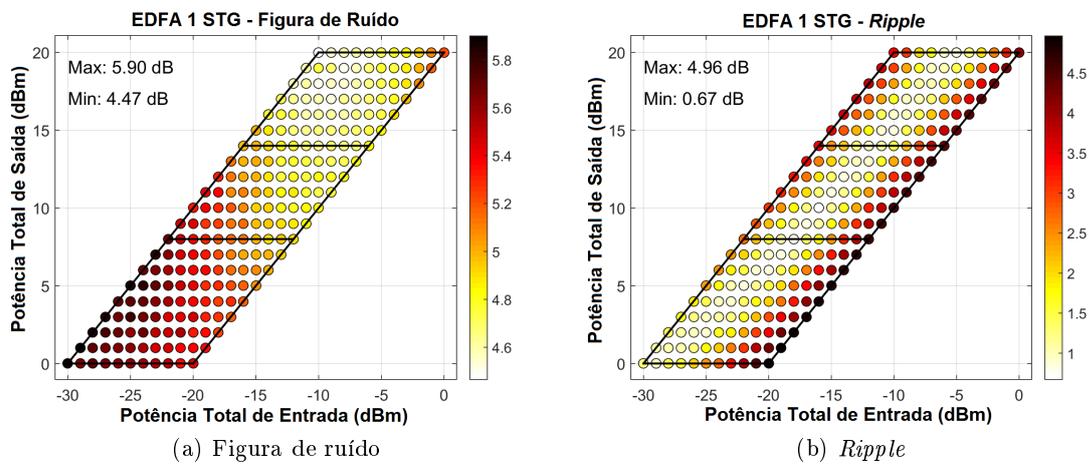


Figura 5.15: Máscara de potência do amplificador EDFA de um estágio utilizado nas simulações, destacando em cores os valores de figura de ruído e *ripple* de cada ponto de operação. (Fonte: elaboração própria)

A Figura 5.16 mostra as curvas de OSNR ASE e OSNR ASE+NLI na saída dos amplificadores, e as curvas de OSNR ASE+NLI na saída dos VOAs, em função da frequência, retornadas pelas técnicas MaxGain/AdGC e AsHB Flex. Ao se comparar a OSNR ASE+NLI e a OSNR ASE+NLI Res. (após o VOA), percebe-se na técnica MaxGain um aumento do pior valor de OSNR de 20,51 dB para 25,43 dB (quase 5 dB), enquanto que na técnica AsHB Flex esse aumento é bem mais reduzido. Por ser mais impactada pelos efeitos não-lineares, a técnica MaxGain/AdGC sofre um aumento mais significativo na sua mínima OSNR ASE+NLI em comparação à AsHB Flex, que sofre menos com tais efeitos.

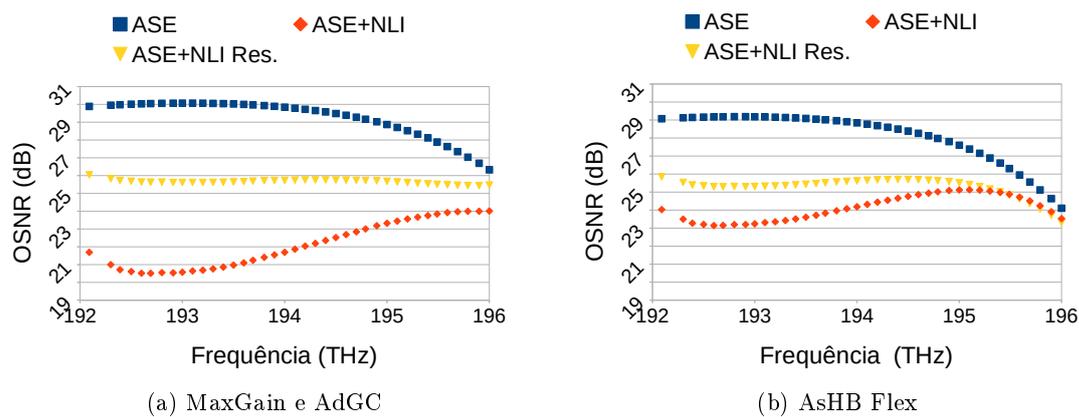


Figura 5.16: Curvas de OSNR ASE (quadrado), OSNR ASE+NLI (losango) e OSNR ASE+NLI após aplicação da restrição (triângulo invertido) em função da frequência, retornadas pelas técnicas MaxGain/AdGC e AsHB Flex.

A Figura 5.17 apresenta as curvas de ganho em função da frequência na saída do amplificador para os casos com e sem VOA, e na saída do VOA para o caso com VOA, retornadas pela técnica MaxGain (consequentemente pela AdGC). No caso “Após o VOA” os valores de ganho são o resultado da subtração do ganho na saída do amplificador (caso “Com VOA”) pela perda do VOA. É possível perceber que a utilização do VOA permite à técnica MaxGain colocar o amplificador para operar em ganhos mais altos, pois a restrição será aplicada pelo VOA. Esta escolha beneficia a OSNR e o *ripple*, pois, para o amplificador em questão, ganhos mais altos significam valores de *ripple* e figura de ruído menores. Percebe-se também que a utilização do VOA tornou a curva do ganho agregado um pouco mais plana, já que o *ripple* adicionado em cada amplificador é menor.

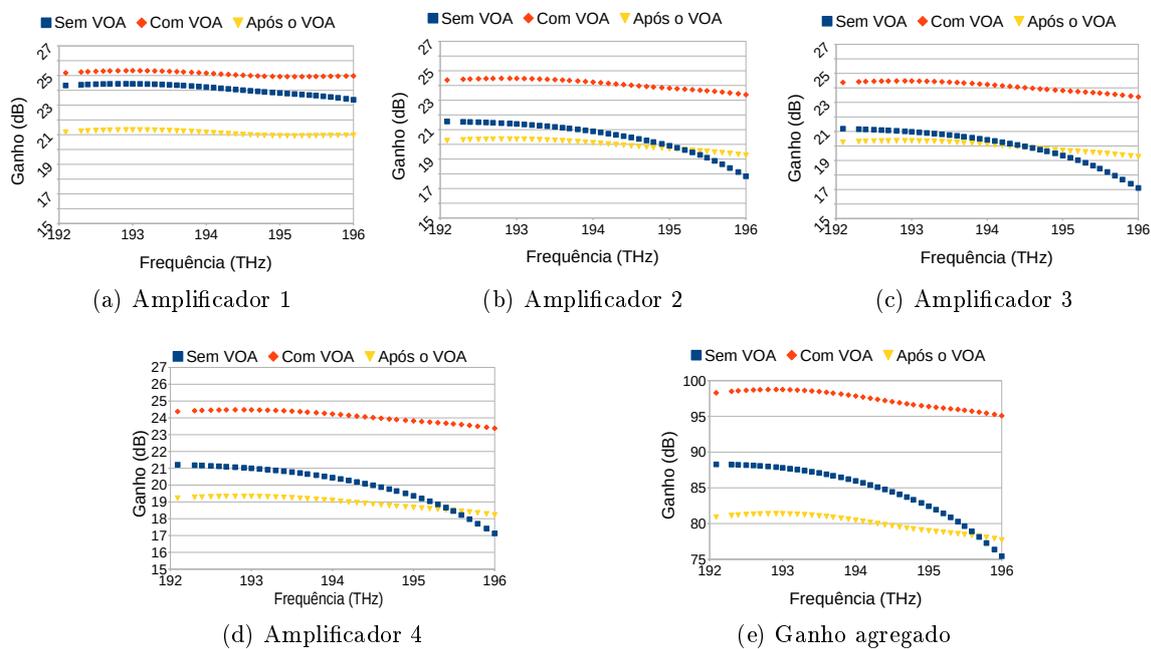


Figura 5.17: Curvas de ganho em função da frequência na saída dos amplificadores de 1 a 4 (a),(b),(c),(d), retornadas pela técnica MaxGain (e AdGC) para os casos sem VOA e com VOA. Também é apresentada a curva de ganho na saída do VOA para o caso com VOA (e).

A Figura 5.18 mostra o posicionamento das soluções retornadas pelo método exaustivo, pela MaxGain/AdGC, pela AsHB Flex e pela CompPerdas, no espaço formado pelo *ripple* e a mínima OSNR ASE (Figuras 5.18a e 5.18b), e no espaço formado pelo *ripple* e a mínima OSNR ASE+NLI (Figura 5.18c e 5.18d), considerando o caso sem VOA (sem restrição) e o caso com VOA (restrição de 0 dBm/ch). Percebe-se que, ao se considerar o VOA (e a restrição), novas soluções na região de baixo *ripple* apareceram. Isso é consequência da maior liberdade dada pelo VOA ao processo de escolha, fazendo com que soluções impossíveis sem a restrição aparecessem.

A maioria destas soluções que apareceram são soluções que utilizam pontos de operação

no segundo amplificador em diante, com uma potência total de entrada menor do que no caso sem VOA, já que o VOA na saída do amplificador anterior diminui a potência do sinal que chega nestes amplificadores. Ao analisar a máscara de potência apresentada na Figura 5.13, percebe-se que, para potências de entrada mais altas (entre -5 e 0 dBm), a quantidade de pontos de operação é bem menor do que para potências menores (ex: -10 dBm), o que comprova o aumento de possibilidades de escolha para potências de entradas menores.

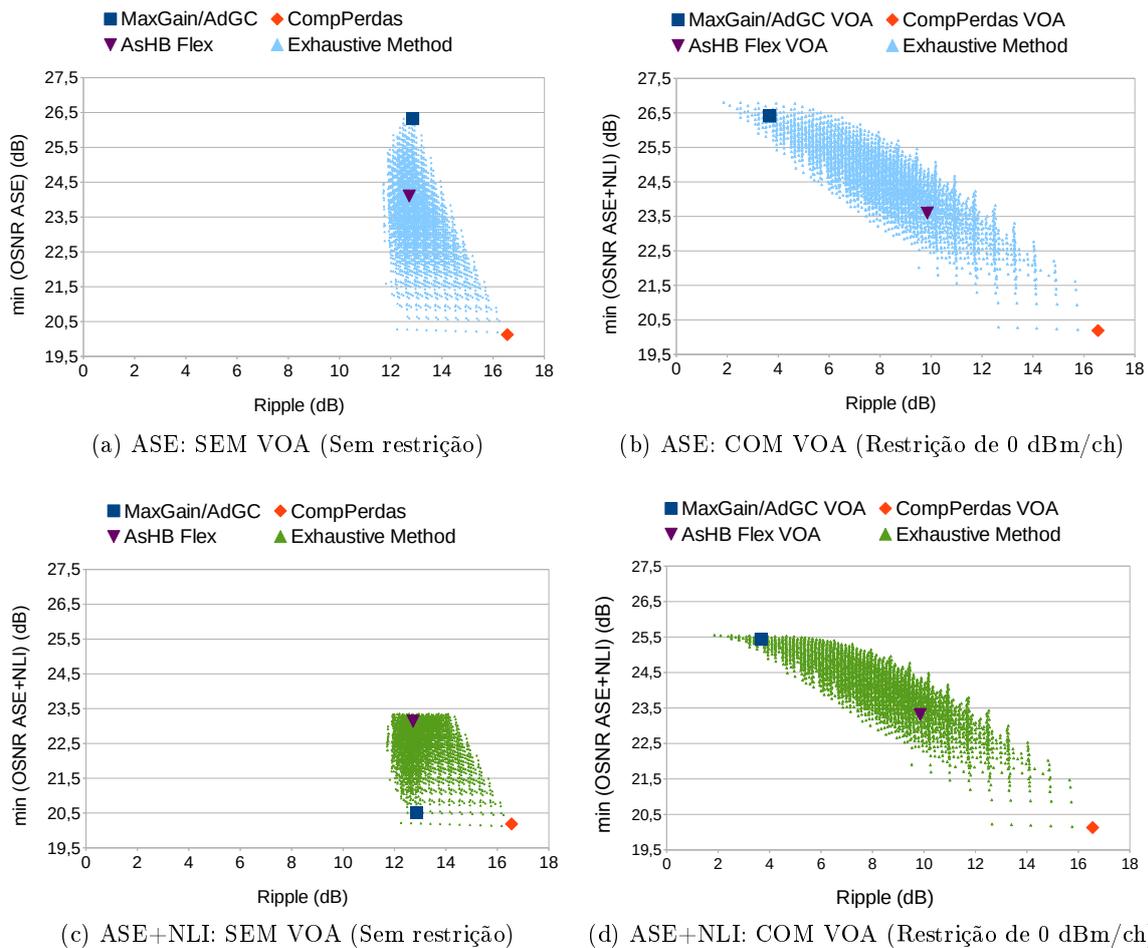


Figura 5.18: Posicionamento das soluções retornadas pelo método exaustivo (triângulos), pela MaxGain/AdGC (quadrado), pela AsHB Flex (triângulo invertido) e pela CompPerdas (losango); no espaço formado pelo ripple e a mínima (a)-(b) OSNR ASE e a (c)-(d) mínima OSNR ASE+NLI, considerando o caso (a)-(c) sem VOA/sem restrição e o caso (b)-(d) com VOA/com restrição. Para um amplificador EDFA de um estágio.

Contudo, a grande diferença ao se utilizar o VOA para o controle do impacto dos efeitos não-lineares é vista no desempenho da técnica MaxGain. No cenário anterior, sem restrição, esta técnica alcançava os melhores valores de OSNR ASE (Figura 5.18a), porém, ao se considerar os efeitos não-lineares, os valores de OSNR se tornavam os piores dentre todos os

possíveis (Figura 5.18c). No cenário com o VOA, esta técnica continua atingindo os melhores valores no cenário sem não-linearidades (Figura 5.18b) e se mantém na região de mais alta OSNR ao se considerar a OSNR ASE+NLI (Figura 5.18d). Esse comportamento da MaxGain comprova a importância da aplicação da restrição na potência de lançamento e mostra que a utilização do VOA para implementar tal restrição é extremamente eficiente.

Com o intuito de verificar o comportamento das técnicas em outro tipo de amplificador, as mesmas simulações descritas anteriormente foram realizadas considerando quatro amplificadores EDFA de dois estágios cuja máscara de potência é apresentada na Figura 5.19. A área de operação definida pela máscara de potência para estes amplificadores possui ganhos entre 20 e 30 dB, potências totais de entrada entre -30 e 0 dBm, figuras de ruído entre 3,00 e 12,81 dB e *ripples* entre 0,45 e 12,04 dB.

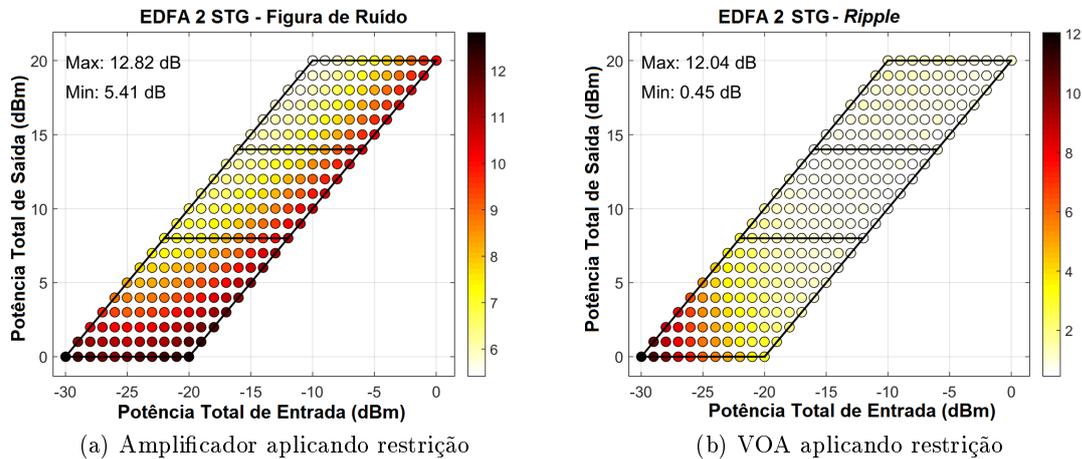


Figura 5.19: Máscara de potência do amplificador EDFA de dois estágios utilizado nas simulações, destacando em cores os valores de figura de ruído e *ripple* de cada ponto de operação. (Fonte: elaboração própria)

A Figura 5.20 mostra as mesmas informações da Figura 5.18, só que para o cenário com amplificadores EDFA de dois estágios. Percebe-se que, apesar da diferença no formato da nuvem de pontos, se comparado ao cenário com EDFA de um estágio, as modificações que acontecem nas soluções ao se considerar a restrição sendo implementada pelo VOA são similares. Mais uma vez, essa mudança é mais evidente na técnica MaxGain, que deixa de ter uma queda da região de maior OSNR para a região de menor OSNR, quando a NLI é considerada sem a restrição, para ter uma pequena queda que não a retira da região de maior OSNR, no caso em que a NLI é considerada e existe a restrição implementada pelo VOA.

Apesar do bom resultado apresentado nas Figuras 5.18 e 5.20 ao se inserir o VOA na saída, a ideia de utilizar uma restrição com um valor fixo é simplória e não garante que o sistema funciona na sua melhor configuração.

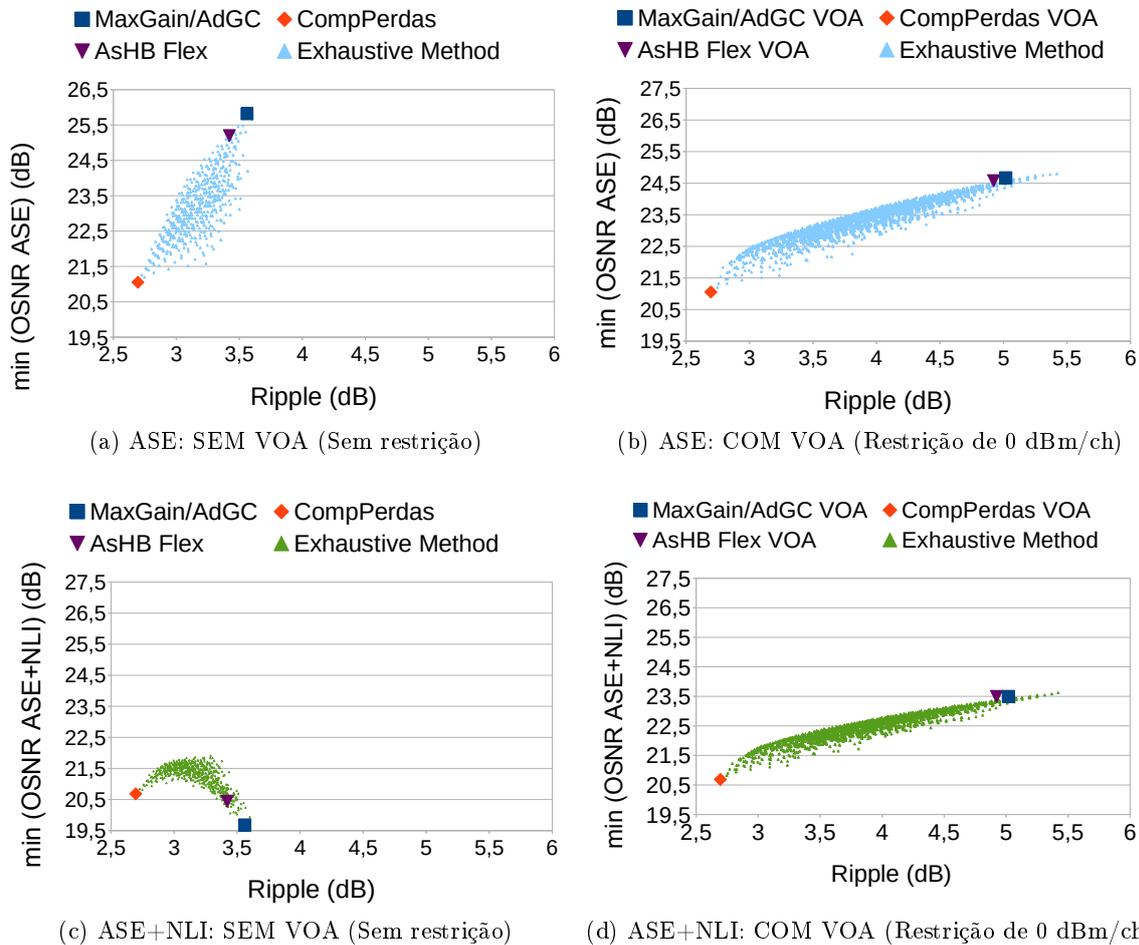


Figura 5.20: Posicionamento das soluções retornadas pelo método exaustivo (triângulos verdes), pela MaxGain/AdGC (quadrado azul), pela AsHB Flex (triângulo invertido amarelo) e pela CompPerdas (losango vermelho); no espaço formado pelo ripple e a mínima (a)-(b) OSNR ASE e a (c)-(d) mínima OSNR ASE+NLI, considerando o caso (a)-(c) sem VOA/sem restrição e o caso (b)-(d) com VOA/com restrição. Para um amplificador EDFA de dois estágios.

5.4 Utilizando otimização multiobjetivo para definição dos ganhos e perdas dos VOAs

Uma solução mais geral, e possivelmente mais eficiente do que a apresentada na seção anterior, é não utilizar uma restrição de potência de lançamento fixa, mas sim definir qual o melhor valor para esta restrição junto com a definição do ponto de operação. Dessa forma, o problema ACOP ganha mais um grau de liberdade para atingir uma melhor QoT do sistema. Entretanto, o problema também se torna mais complexo, pois, além de definir os pontos de operação dos amplificadores, também será necessário definir as melhores perdas para os VOAs. Estas

definições precisam ser feitas em conjunto, pois a melhor perda para um VOA dependerá do ponto de operação escolhido pelo amplificador que o contém. Também é necessário definir qual o objetivo destas definições, seja maximizar a OSNR, minimizar o *ripple* ou ambos.

Técnicas de otimização multiobjetivo (MOO - *Multi-Objective Optimization*) se mostram promissoras para a solução deste tipo de problema. Por serem técnicas de otimização, técnicas MOO são capazes de encontrar eficientemente bons valores para variáveis em um espaço de busca multi-dimensional. O diferencial das técnicas MOO é que a otimização é guiada por mais de um objetivo, e estes objetivos são conflitantes entre si. Portanto, no caso ACOP, no qual tem-se a maximização da OSNR e a minimização do *ripple* como objetivos conflitantes, uma técnica MOO deverá alcançar bons resultados.

Para melhor entendimento do funcionamento das técnicas MOO, na Subseção 5.4.1 são apresentados conceitos básicos sobre MOO e na Subseção 5.4.2 é apresentada a técnica MOO utilizada. Em seguida, na Subseção 5.4.3, a organização das simulações será apresentada e, por fim, na Subseção 5.4.4, serão apresentados os resultados obtidos com a utilização de uma técnica MOO para o ACOP.

5.4.1 *Conceitos básicos de MOO*

Em um problema de otimização com objetivo único, tem-se um conjunto (vetor) de variáveis de decisão $\hat{x} = \{x_1, \dots, x_n\}$ que pertence a um espaço de decisão Ω e que deverá ter seus valores definidos de forma a minimizar (maximizar) o valor de uma variável independente y , mais conhecida como função objetivo $f(\hat{x})$. Em uma otimização com objetivo único apenas uma solução é retornada, pois existe apenas um $f(\hat{x})$ ótimo.

Contudo, muitos problemas de otimização do mundo real lidam com a otimização de objetivos conflitantes, como, por exemplo, a minimização do *ripple* e a maximização da OSNR no problema ACOP. Neste contexto, o retorno do algoritmo não é uma solução mas sim um conjunto de soluções não-dominadas conhecido como frente de Pareto. Na Figura 5.21, as soluções A, B, C, D e E representam o conjunto de soluções da frente de Pareto, e fica claro que as soluções F e G não são boas escolhas quando comparadas às soluções na frente de Pareto. Contudo, percebe-se que ao se comparar as soluções entre A e E não é possível definir qual delas é a melhor. Por exemplo, a solução E possui menor *ripple* se comparada à solução A, porém a solução A possui maior OSNR. Na terminologia de Pareto [85] as soluções B, C e D dominam a solução F ou $\{B, C, D\} \preceq F$, as soluções entre A e E dominam a solução G ou $\{A, B, C, D, E\} \preceq G$, e as soluções entre A e E são incomparáveis entre si.

São necessárias métricas específicas para avaliar a qualidade das soluções retornadas por uma técnica multiobjetivo. Em uma otimização com único objetivo, a qualidade da técnica é avaliada pela simples comparação entre o valor $f(\hat{x})$ da solução retornada pela técnica e os valores $f(\hat{x})$ das soluções retornadas por outras técnicas, ou um valor $f(\hat{x})$ ideal. Já para as técnicas MOO, é preciso avaliar a qualidade da frente de Pareto em termos de convergência

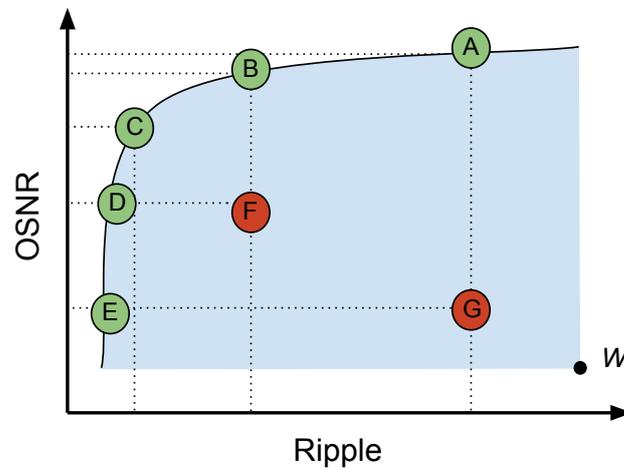


Figura 5.21: Um problema com duas funções objetivo: *ripple* e OSNR. A frente de Pareto está destacada pela linha que une os pontos entre A e E, o *datum point* W e a área definida entre este ponto e a frente de Pareto estão destacados. (Fonte: elaboração própria)

e distribuição das soluções ao longo deste conjunto. Neste trabalho é utilizada a métrica *Hypervolume* que foi proposta por Zitzler [86] em 1999. Esta métrica avalia a área formada entre um determinado ponto, chamado *datum point*, e a frente de Pareto (vide área azul na Figura 5.21). Por meio desta avaliação, tanto a convergência quanto a distribuição das soluções são consideradas. Frentes de Pareto com soluções espalhadas e que apresentaram boa convergência irão ter valores mais elevados de *Hypervolume*.

5.4.2 A técnica SMPSO

A técnica MOO escolhida para ser utilizada na solução do ACOP é a *Speed-constrained Multi-objective PSO* (SMPSO). Esta técnica foi escolhida pois apresenta um bom desempenho na otimização de variáveis reais, além de ser uma das técnicas com mais rápida convergência dentre as técnicas do estado-da-arte na área de MOO [87]. A rápida convergência permitirá que a técnica encontre boas soluções com poucas iterações (menos tempo), e isso é um fator importante para as técnicas ACOP.

A técnica SMPSO utiliza a estratégia da otimização por enxame de partículas (PSO - *Particle Swarm Optimization*), que é uma técnica de computação inteligente inspirada na movimentação de bando de pássaros em busca de alimento. Em um algoritmo PSO existe um enxame (conjunto) de partículas e cada uma delas possui uma posição ($\hat{x} = \{x_1, \dots, x_n\}$) que codifica as variáveis de decisão do problema a ser otimizado. A cada iteração do algoritmo, as posições das partículas são atualizadas de acordo com um vetor velocidade, e este vetor é definido considerando-se as melhores posições encontradas pela partícula e pelo enxame até o momento da atualização. A atualização de velocidade da partícula no PSO segue a equação

(5.5):

$$x_i(t) = x_i(t-1) + v_i(t); \quad (5.5)$$

na qual $v_i(t)$ é o fator velocidade da partícula i e é dado por:

$$v_i(t) = \omega \cdot v_i(t-1) + C_1 \cdot r_1 \cdot (x_{p_i} - x_i) + C_2 \cdot r_2 \cdot (x_{g_i} - x_i), \quad (5.6)$$

em que, x_{p_i} é a melhor solução que a partícula i já encontrou, x_{g_i} é a melhor solução (partícula líder) que o enxame inteiro já encontrou, ω é o fator de inércia da partícula e controla o compromisso entre busca local e global, r_1 e r_2 são dois números aleatórios uniformemente distribuídos entre $[0,1]$, e C_1 e C_2 são parâmetros específicos que controlam as importâncias dadas a melhor posição encontrada pela partícula e a melhor posição encontrada pelo enxame.

O SMPSO é uma adaptação do PSO para resolução de problemas multiobjetivos e o seu grande diferencial é a utilização de um método para o controle da velocidade das partículas. Durante o processo de otimização, a partícula pode ser levada para fora do espaço de busca por conta de valores muito altos de velocidade, a esse processo é dado o nome de explosão do enxame [88]. O propósito do método de controle de velocidade da partícula é evitar esta explosão. Ele é feito por meio da multiplicação da velocidade por um fator de constrição χ originalmente desenvolvido em [88] e que segue a seguinte fórmula:

$$\chi = \frac{2}{2 - \varphi - \sqrt{\varphi^2 - 4\varphi}} \quad (5.7)$$

onde

$$\varphi = \begin{cases} C_1 + C_2, & \text{se } C_1 + C_2 > 4 \\ 1, & \text{se } C_1 + C_2 \leq 4. \end{cases} \quad (5.8)$$

Além da utilização deste fator de constrição, o SMPSO também utiliza um outro mecanismo para garantir que os valores de velocidade não saiam dos limites do espaço de busca por conta de sucessivos aumentos. Considerando cada variável j em uma partícula i tal mecanismo restringe a velocidade da seguinte forma:

$$v_{i,j}(t) = \begin{cases} \text{delta}_j & \text{se } v_{i,j}(t) > \text{delta}_j \\ -\text{delta}_j & \text{se } v_{i,j}(t) \leq -\text{delta}_j \\ v_{i,j}(t) & \text{caso contrário} \end{cases} \quad (5.9)$$

onde

$$\text{delta}_j = \frac{\text{limiteSuperior}_j - \text{limiteInferior}_j}{2}, \quad (5.10)$$

e limiteSuperior_j e limiteInferior_j são os valores limites que a variável j pode assumir.

Portanto, de forma resumida, no SMPSO as velocidades das partículas são calculadas

de acordo com a equação 5.5, a velocidade resultante é multiplicada pelo fator de contração (equação (5.7)) e ao valor final é aplicada a restrição definida na Equação (5.9).

O Algoritmo 5 apresenta o pseudocódigo da técnica SMPSO. Além da contração da velocidade, esta técnica também possui outros diferenciais. Um deles é a utilização de um arquivo externo que armazena as partículas não-dominadas a cada iteração do algoritmo, para ser adicionada ao arquivo a partícula deve ser incomparável com todas as outras que já estão no arquivo. A utilização deste arquivo externo segue o mesmo princípio da técnica evolucionária NSGA-II [89]. Outro diferencial é a utilização de um operador de mutação polinomial que é aplicado em parte das partículas para simular uma turbulência no enxame e assim gerar diversidade nas soluções.

Algoritmo 5: Pseudocódigo da técnica SMPSO.

- 1 Inicialize as partículas (velocidade e posição inicial);
- 2 Crie um arquivo externo vazio;
- 3 **enquanto** *O número total de iterações não foi alcançado* **faça**
- 4 Calcule a velocidade das partículas; //Equações (5.5) - (5.10)
- 5 Atualize a posição das partículas;
- 6 Aplique uma turbulência ao enxame;
- 7 Avalie a função objetivo ($f(\hat{x})$) das partículas;
- 8 Atualize o arquivo externo com as partículas líderes;
- 9 Atualize a memória da partícula;

Saída: Arquivo externos com as partículas líderes.

Nas simulações realizadas neste trabalho foi utilizada a implementação da técnica SMPSO presente no *framework* JMetal. O JMetal é um *framework* orientado à objetos baseado na linguagem Java que disponibiliza um conjunto de meta-heurísticas para otimização multiobjetivo. Este *framework* já foi utilizado em mais de 500 trabalhos científicos e todos os seus algoritmos funcionam corretamente [90]. O tamanho da população e do arquivo externo foi definido como 100, a probabilidade de mutação é o inverso do número de variáveis e o número de iterações foi definido de acordo com a análise de convergência realizada na Subseção 5.4.4. Estes valores foram definidos pelo artigo no qual a técnica foi proposta [87].

5.4.3 Organização das simulações

A Figura 5.22 ilustra a comunicação entre a técnica SMPSO e o simulador do sistema óptico. Para cada partícula do SMPSO são enviados para o simulador os ganhos dos amplificadores e as perdas dos VOAs codificados na posição da partícula. O simulador irá estabelecer a cascata de amplificadores de acordo com os parâmetros recebidos, calcular as métricas desta cascata e enviar os valores de *ripple* e mínima OSNR ASE+NLI de volta ao SMPSO. Ou seja, o simulador do sistema óptico funciona como a função objetivo do SMPSO e irá definir os objetivos

de cada partícula da população em cada iteração do algoritmo. Neste contexto, o SMPSO terá dois objetivos: 1) minimizar o *ripple* e 2) maximizar a mínima OSNR ASE+NLI ¹.

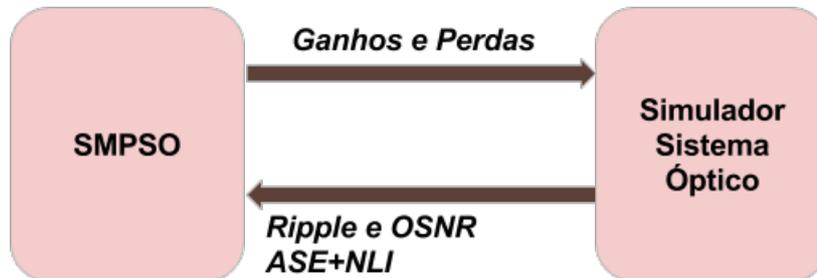


Figura 5.22: Ilustração da interação entre o SMPSO e o simulador do sistema óptico para a realização da otimização. (Fonte: elaboração própria)

A Tabela 5.4 mostra a organização das variáveis do problema na partícula do SMPSO. O tamanho da partícula será o dobro ($2N$) da quantidade de amplificadores da cascata (N). As primeiras N posições irão conter os valores dos ganhos dos amplificadores, e as posições restantes irão conter as perdas dos VOAs de cada amplificador.

Tabela 5.4: Organização das variáveis do problema em uma partícula do SMPSO. As primeiras N posições contêm os valores dos ganhos dos amplificadores e as posições restantes contêm os valores das perdas dos VOAs.

G_1	G_2	...	G_N	L_1	L_2	...	L_N
-------	-------	-----	-------	-------	-------	-----	-------

5.4.4 Resultados da utilização de MOO para ACOP

Nesta subseção serão apresentados os resultados obtidos na utilização da técnica SMPSO para definição dos ganhos dos amplificadores e as perdas dos VOAs em uma cascata de amplificadores. Os resultados obtidos foram analisados considerando-se aspectos diferentes do problema.

Análise de convergência do algoritmo

A análise de convergência do SMPSO irá definir quantas iterações são necessárias para que o algoritmo alcance um estado de convergência. Esta análise é feita por meio da avaliação do valor do *Hypervolume* ao longo das iterações do algoritmo. Como mencionado anteriormente, o *Hypervolume* necessita de um *datum point* para ser calculado, e uma forma simples de definir os valores deste ponto é escolhendo valores muito ruins dos objetivos de otimização. Para o

¹Com o intuito de simplificar a leitura, as próximas referências à mínima OSNR ASE+NLI serão feitas apenas utilizando o termo OSNR.

cenário considerado neste trabalho, a coordenada do *datum point* é $\{5, 15\}$ que, no espaço de objetivo definido na Figura 5.21, significa um *ripple* de 5 dB e uma OSNR de 15 dB.

A Figura 5.23 apresenta a média e o desvio padrão do *Hypervolume* em função do número de iterações, após 30 execuções da simulação, para cascatas com número de amplificadores entre 2 e 8. Para cascatas com seis ou mais amplificadores, a população do SMPSO foi aumentada para 200 partículas, pois percebeu-se que, com o aumento do número de amplificadores, e o conseqüente aumento da dimensionalidade do problema, são necessárias mais partículas para explorar bem o espaço de busca. Para cascatas com 2 e 3 amplificadores percebe-se que, a utilização de 250 iterações é suficiente para que o SMPSO estabilize. Já para 4 e 5 amplificadores o ideal é a utilização de 1000 iterações. Para cascatas com 6 ou mais amplificadores, além da maior população, também é necessário um maior número de iterações, sendo 2000 iterações o mínimo indicado. Portanto, no decorrer deste trabalho a quantidade de iterações e o tamanho da população utilizadas seguirá os valores descritos anteriormente, de acordo com o tamanho da cascata.

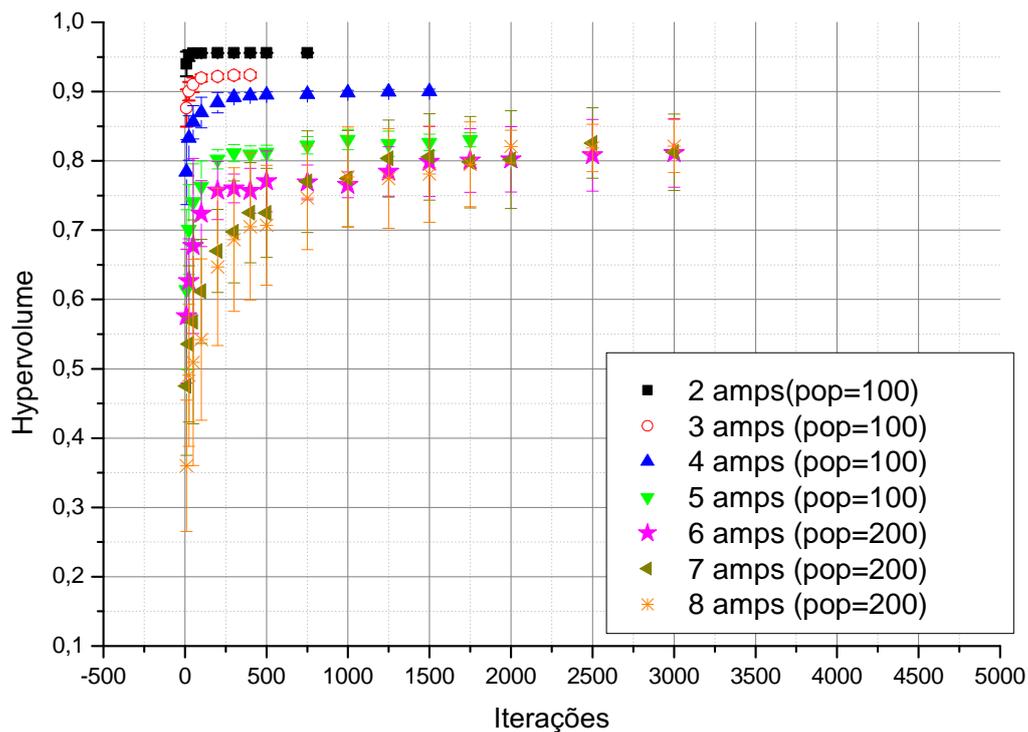


Figura 5.23: Média e desvio padrão da métrica *Hypervolume*, após 30 execuções, em função do número de iterações para cascatas com número de amplificadores entre 2 e 8. Para cascata com 6 ou mais amplificadores a população do SMPSO foi aumentada de 100 para 200 partículas.

Análise das soluções retornadas

Para avaliar a qualidade das soluções, a frente de Pareto retornada pelo SMPSO será comparada com a frente de Pareto obtida pelo Método Exaustivo. O Método Exaustivo utilizado aqui é uma adaptação do Método Exaustivo apresentado na Seção 3.2. Entretanto, além de gerar todos os possíveis valores de ganho, este método também irá gerar todos os possíveis valores de perda para os VOAs. Além disso, no final do processo, o Método Exaustivo retornará todas as possíveis combinações de ganhos e perdas, juntamente com o *ripple* e a OSNR ASE+NLI destas combinações. A frente de Pareto do Método Exaustivo é formada pelo conjunto das soluções não-dominadas dentre o universo de soluções retornadas.

Os valores de ganho dos amplificadores e perda dos VOAs devem variar de acordo com um passo fixo no Método Exaustivo, definindo assim a precisão das variáveis do problema ACOP. Quão maior a precisão das variáveis, maior o tempo gasto pelo Método Exaustivo para retornar a frente de Pareto; quão menor a precisão das variáveis, pior a qualidade da frente de Pareto retornada. O SMPSO não possui restrição de precisão, contudo, para uma comparação mais justa e precisa com o Método Exaustivo, as variáveis definidas por essa técnica serão truncadas, de acordo com uma determinada precisão, antes de serem enviadas ao simulador do sistema óptico. Além disso, esse truncamento deverá acontecer na prática, visto que os sistemas de controle automático de ganho possuem uma resolução determinada para a definição do ganho (vide Seção 4.1).

Nas simulações realizadas, o valor de ganho do amplificador varia de acordo com os ganhos máximo e mínimo definidos pela máscara, enquanto que o valor do VOA varia de 0 a 20 dB. As precisões utilizadas nas simulações foram de 1 dB (apenas valores inteiros), 0,5 dB (20; 20,5; 21...) e 0,1 dB (variação de uma casa decimal), tanto para os ganhos dos amplificadores como para as perdas dos VOAs.

A Figura 5.24 apresenta as frentes de Pareto para um enlace com dois amplificadores retornadas pelo SMPSO e pelo Método Exaustivo (EM) considerando variáveis com as precisões descritas anteriormente. É possível perceber que o SMPSO retorna a mesma frente de Pareto do EM se as variáveis forem apenas valores inteiros (1 dB). Percebe-se também que, com uma melhor precisão (0,1 dB), a frente de Pareto retornada pelo SMPSO, apesar de não ser idêntica, é praticamente igual à retornada pelo EM. Além disso, ao se comparar a frente de Pareto retornada pelo SMPSO sem restrição e a frente retornada pelo SMPSO com precisão de 0,1 dB, percebe-se que o truncamento das variáveis para se adequar à restrição não influencia significativamente a qualidade das soluções retornadas.

Para enlaces com mais de dois amplificadores, é inviável, por conta do tempo computacional, utilizar uma precisão de 0,1 dB nas variáveis do Método Exaustivo. Diante disso, simulações foram realizadas para cascatas com três e quatro amplificadores, porém apenas as resoluções de 0,5 e 1 dB, respectivamente, foram consideradas para estes enlaces maiores. A Figura 5.25 apresenta as frentes de Pareto para estes enlaces retornadas pelo SMPSO

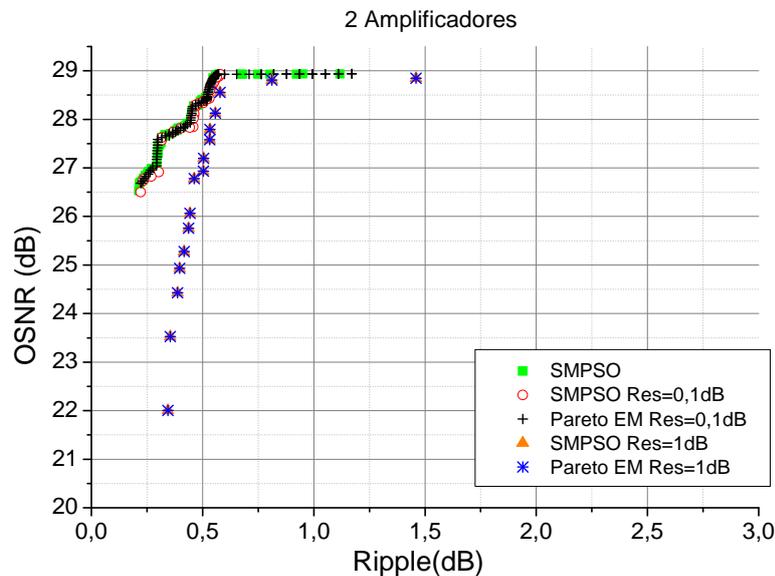
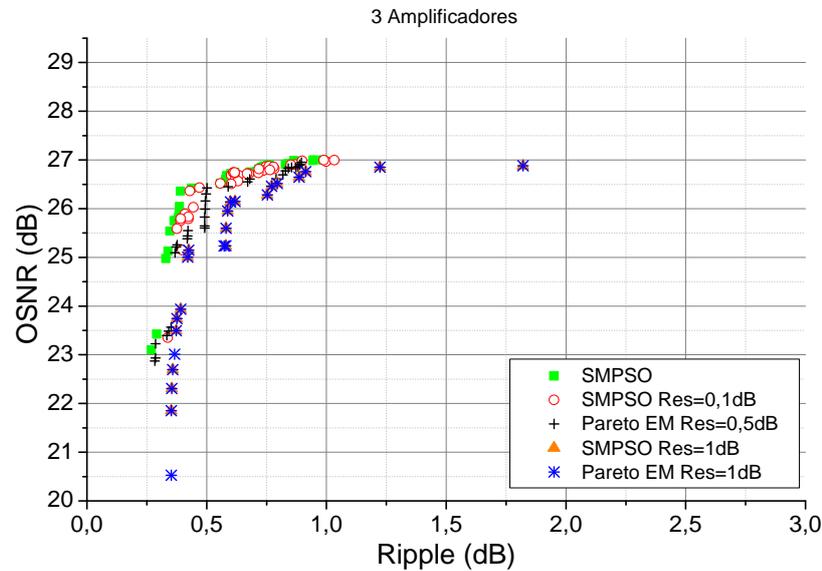


Figura 5.24: Representação das frentes de Pareto para um enlace com 2 amplificadores, retornadas pelo SMPSO e pelo método exaustivo (EM) considerando variáveis com precisão de uma casa decimal ($0,1dB$), variáveis inteiras ($1dB$) e o SMPSO sem nenhuma restrição na precisão das variáveis.

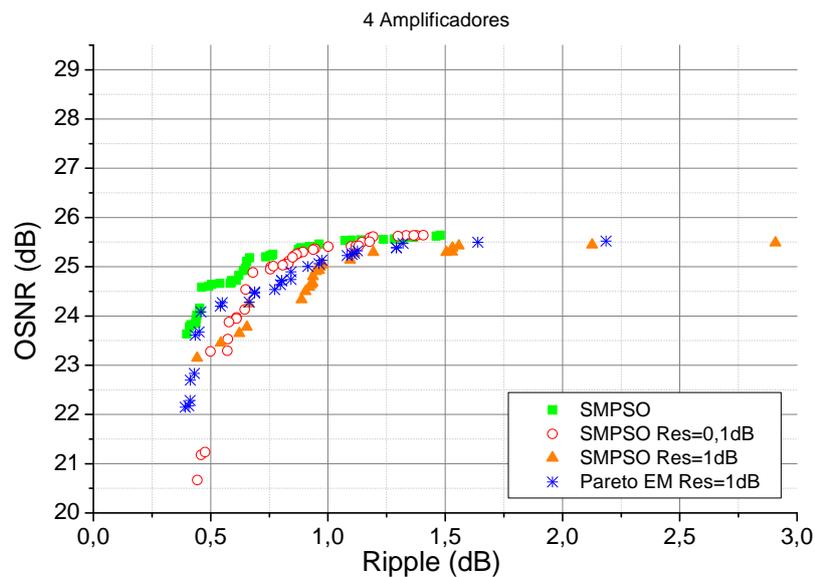
e pelo Método Exaustivo considerando variáveis com as precisões descritas anteriormente. Percebe-se que, em ambos os casos, as frentes de Pareto cobrem uma região de menor OSNR se comparadas às frentes de Pareto da Figura 5.24. Este comportamento é esperado, já que mais amplificadores são considerados no enlace e conseqüentemente mais ruído é adicionado ao sinal.

Na Figura 5.25a percebe-se que, assim como no enlace com dois amplificadores, o SMPSO retorna a mesma frente de Pareto do Método Exaustivo se a precisão considerada for 1 dB. Assim como no enlace menor, a frente de Pareto retornada pelo SMPSO sem restrição é muito próxima da frente de Pareto retornada pelo SMPSO com restrição de 0,1 dB, mostrando o pequeno impacto desta diminuição de precisão neste cenário. Apesar de não ter sido viável produzir a frente de Pareto com precisão de 0,1 dB para o Método Exaustivo, a frente de Pareto com precisão de 0,5 dB nos dá um indicativo de que aumentar a precisão do EM iria tornar a frente de Pareto mais próxima da frente de Pareto do SMPSO com melhor precisão.

Por outro lado, na Figura 5.25b é possível perceber que neste enlace maior e com a restrição de 1 dB o SMPSO não consegue retornar a mesma frente de Pareto do Método Exaustivo, como nos casos anteriores. Além disso, a frente de Pareto retornada pelo Método Exaustivo possui soluções que dominam uma grande parte da frente de Pareto do SMPSO considerando as restrições de 0,1 e 1 dB. Isto mostra que para um enlace com quatro amplificadores o SMPSO não conseguiu alcançar as melhores soluções possíveis. Esta dificuldade é conseqüência do



(a) 3 Amplificadores



(b) 4 Amplificadores

Figura 5.25: Representação das frentes de Pareto, para um enlace com (a) 3 e (b) 4 amplificadores, retornadas pelo SMPSO e pelo método exaustivo (EM) considerando variáveis com precisão de $0,5dB$, variáveis inteiras ($1dB$) e o SMPSO sem nenhuma restrição na precisão das variáveis.

aumento da dimensionalidade do problema, e portanto pode-se indutivamente afirmar que quanto maior o tamanho do enlace mais difícil será para o SMPSO encontrar uma frente de Pareto similar à do Método Exaustivo. Contudo, apesar de não serem as melhores soluções possíveis, as soluções retornadas pela técnica MOO possui bons valores de *ripple* e OSNR,

além de serem adquiridas em um tempo muito menor.

Outro aspecto relevante na Figura 5.25b é que a frente de Pareto que utiliza variáveis com precisão de 0,1 dB é um pouco pior do que a frente de Pareto que possui a máxima precisão, pois as soluções com *ripple* abaixo de 1,75 dB, na frente de Pareto menos precisa, não possuem valores de OSNR tão bons quanto na frente de Pareto com máxima precisão. Isso também é consequência do aumento da dimensionalidade do problema, que torna uma diminuição na precisão das variáveis um redutor mais severo nas possíveis soluções a serem encontradas.

A Figura 5.26 destaca as curvas de potência e OSNR ASE+NLI de três soluções em diferentes posições da frente de Pareto retornada pelo SMPSO para uma cascata de quatro amplificadores. Essa curvas ilustram, no espectro, o conflito entre minimizar o *ripple* e maximizar a OSNR. Contudo, percebe-se que a frente de Pareto se encontra em uma região na qual a diferença de *ripple* entre a solução com melhor *ripple* e a solução com pior *ripple* é muito pequena, o que torna a maximização da OSNR o objetivo mais decisivo. Na Tabela 5.5 são detalhados os valores das variáveis para cada uma das soluções destacadas na Figura 5.26.

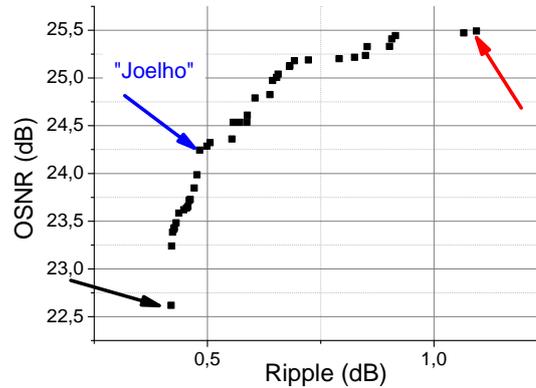
Tabela 5.5: Valores em dB dos ganhos dos amplificadores e das perdas dos VOAs definidas pelas soluções escolhidas na Figura 5.26a.

(dB)	G_1	G_2	G_3	G_4	L_1	L_2	L_3	L_4
Melhor Ripple	23,5	28,9	20,00	28,9	7,4	3,3	5,7	4,7
Melhor OSNR	25,4	26,9	23,4	25,7	6,4	6,8	2,3	6,2
"Joelho"	25,5	29,9	20,0	26,4	9,8	6,3	1,2	4,3

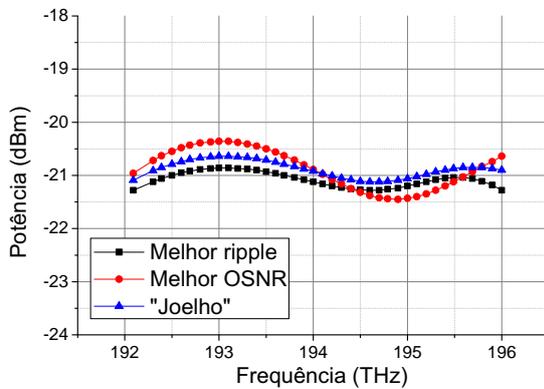
Análise do tempo computacional

Outro aspecto importante na análise desta implementação do SMPSO é o tempo computacional necessário para que a técnica retorne as soluções. Como visto na Figura 4.14, técnicas ACOP globais, como o Método Exaustivo, sofrem com o problema de escalabilidade. A utilização de MOO para a resolução do ACOP é uma solução global. Portanto, é de extrema importância avaliar se a utilização do SMPSO é eficiente computacionalmente.

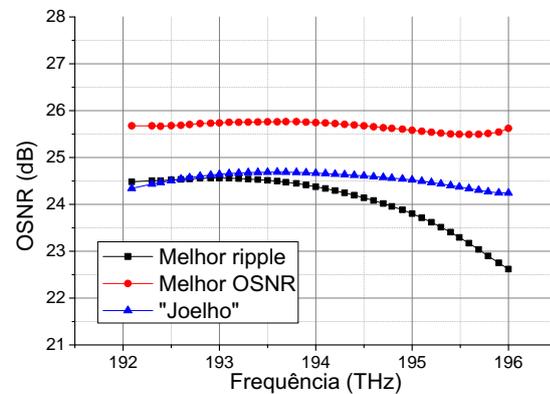
A Tabela 5.6 mostra o tempo gasto pelo Método Exaustivo e pelo SMPSO para retornar uma frente de Pareto considerando enlaces com 2, 3 e 4 amplificadores. Para o Método Exaustivo também é considerado a precisão utilizada nas variáveis. É possível notar que o tempo do SMPSO tem um crescimento linear com o aumento do número de amplificadores na cascata, o que mostra uma boa escalabilidade desta técnica. Além disso, percebe-se que o SMPSO é muito mais rápido do que o Método Exaustivo já na menor cascata (2 amplificadores), e que a diferença entre os tempos se torna ainda maior com o aumento do tamanho da cascata, chegando a ser 20 segundos contra três dias e meio em uma cascata com quatro



(a) Soluções escolhidas



(b) Curvas de potência



(c) Curvas de OSNR ASE+NLI

Figura 5.26: Representação das curvas de (b) potência e (c) OSNR de (a) três soluções em locais distintos da Frente de Pareto retornada pelo SMPSO para uma cascata com 4 amplificadores EDFA de um estágio.

amplificadores. Vale ressaltar, que o SMPSO não teve sua precisão alterada, enquanto que o Método Exaustivo teve a precisão das suas variáveis diminuída com o aumento da cascata para que fosse possível adquirir os resultados em um tempo aceitável.

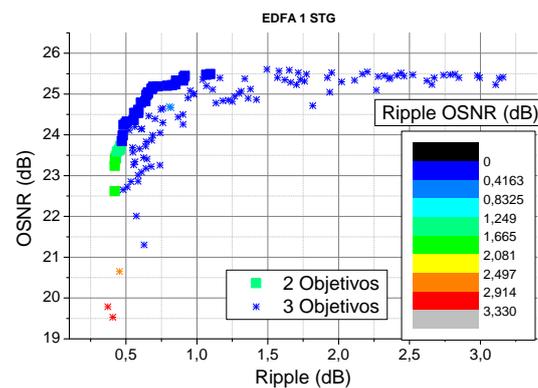
Tabela 5.6: Tempo gasto pelo Método Exaustivo e pelo SMPSO para retornar uma frente de Pareto considerando enlaces com 2, 3 e 4 amplificadores. Os valores entre parênteses representam a precisão das variáveis considerada em cada caso.

	2 AMPS	3 AMPS	4 AMPS
SMPSO	5s	15s	20s
Método Exaustivo	3,5 horas (0,1 dB)	18 horas (0,5 dB)	3,5 dias (1 dB)

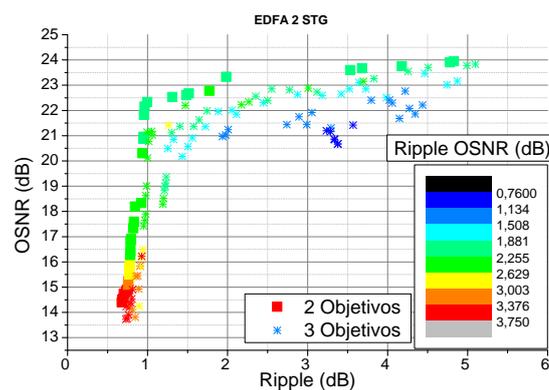
Análise da adição de um novo objetivo: minimizar o ripple de OSNR

Uma outra análise foi feita para avaliar se a adição de um novo objetivo, a minimização do *ripple* de OSNR, aumentaria a qualidade das soluções retornadas. Para tanto, além do *ripple* de potência e da OSNR ASE+NLI, o simulador do sistema óptico também retornaria o valor do *ripple* de OSNR para o SMP SO. Assim, o algoritmo MOO teria três objetivos: 1) minimizar *ripple* de potência; 2) maximizar OSNR ASE+NLI e 3) minimizar *ripple* de OSNR.

A Figura 5.27 mostra as frentes de Pareto retornadas pelo SMP SO para uma cascata de quatro amplificadores, considerando 2 e 3 objetivos e dois tipos distintos de amplificadores EDFA. Nesta figura, apesar de existirem três objetivos de otimização a frente de Pareto foi apresentada em um plano que utiliza dois destes objetivos, e o terceiro objetivo foi utilizado para definir as cores das soluções. No caso da frente de Pareto obtida pela otimização com dois objetivos, o *ripple* de OSNR de cada solução foi calculado ao final da otimização apenas para a definição das cores das soluções.



(a) EDFA 1 estágio



(b) EDFA 2 estágios

Figura 5.27: Representação das frentes de Pareto retornadas pelo SMP SO considerando 2 e 3 objetivos no processo de otimização e uma cascata com 4 amplificadores, para dois tipos de EDFAs.

É possível notar que para os dois tipos de amplificadores a frente de Pareto da otimização com dois objetivos possui soluções que dominam as soluções da frente de Pareto da otimização com três objetivos. Além disso, a grande maioria das soluções na frente de Pareto com menos objetivos possuem valores de *ripple* de OSNR que são tão bons quanto os encontrados na frente de Pareto com mais objetivos. Portanto, a adição de um novo objetivo com o intuito de minimizar o *ripple* de OSNR não é uma boa estratégia, visto que, sem considerar esta meta como um objetivo de otimização é possível conseguir bons valores. A explicação para tal comportamento se deve ao fato de que minimizar o *ripple* de OSNR não está em conflito com o objetivo de maximizar a OSNR, pois percebe-se na Figura 5.27 que os piores valores de *ripple* de OSNR estão na região de baixa OSNR e os melhores valores na região de mais alta OSNR.

Comparação da técnica utilizando MOO e da técnica com restrição fixa

Por fim, é interessante avaliar o ganho de desempenho obtido com a utilização de MOO para a solução do ACOP em comparação à solução inicial, que apenas aplicava uma restrição fixa à potência de lançamento.

A Figura 5.28 mostra a frente de Pareto retornada pelo SMP SO (ACOP MOO) para o mesmo cenário utilizado na Seção 5.3, juntamente com as soluções retornadas pelo Método Exaustivo e pelas técnicas locais que utilizaram uma restrição fixa, ou seja, esta figura coloca em um mesmo gráfico a frente de Pareto da Figura 5.26a e as soluções da Figura 5.18d. Percebe-se que utilizar MOO para a definição dos ganhos dos amplificadores e as perdas dos VOAs contribuiu para que soluções com baixíssimo *ripple* fossem encontradas nos dois tipos de amplificadores. Percebe-se também, que apesar da melhora no *ripple* a máxima OSNR alcançada pelo SMP SO é, na prática, a mesma alcançada pela técnica local MaxGain.

Como visto anteriormente, tanto na análise de convergência quanto na análise da qualidade das soluções, quanto maior a cascata de amplificadores mais difícil é para a técnica MOO encontrar as melhores soluções possíveis. Então, com o intuito de avaliar a qualidade das soluções retornadas pela técnica MOO na solução do ACOP para cascatas com tamanhos variados, foram feitas simulações para cascatas com mais de quatro amplificadores. As Tabelas 5.7 e 5.8 mostram os valores de OSNR e *ripple* das soluções retornadas pela MOO e pelas principais técnicas locais. Já que a técnica MOO não retorna uma única solução, são apresentadas três soluções desta técnica, uma das soluções possui o melhor valor de *ripple*, a outra o melhor valor de OSNR e a terceira possui a melhor/menor distância euclidiana (d_i) em relação à origem do plano cartesiano formado pelos objetivos de otimização.

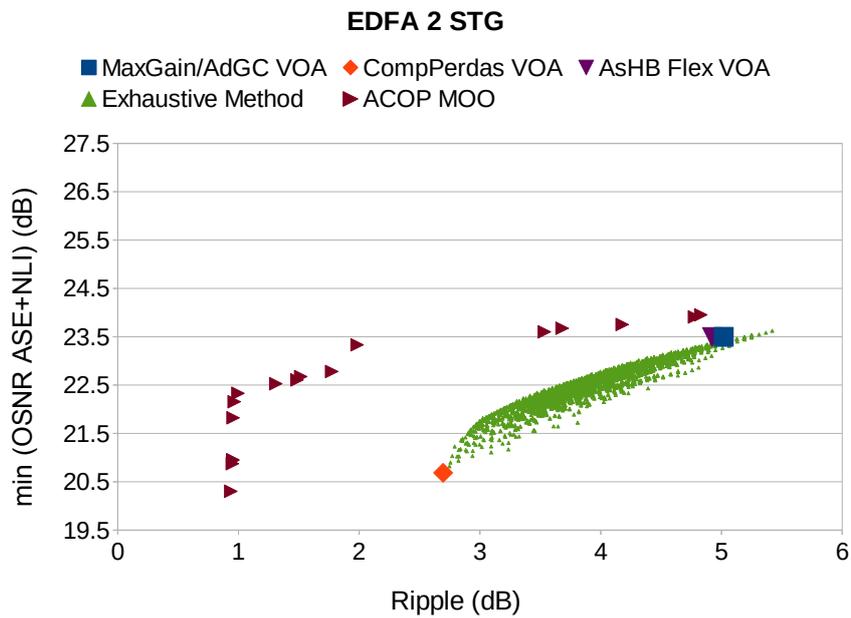
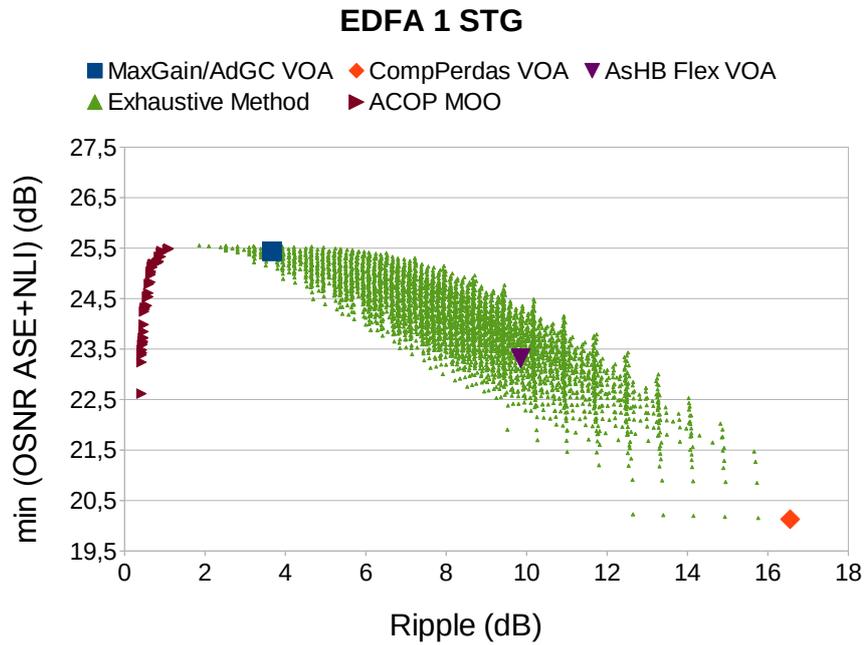


Figura 5.28: Frente de Pareto retornada pelo SMPSCO (ACOP MOO) no espao objetivo formado pelos objetivos de otimizao, em conjunto com a solues retornadas pelo metodo exaustivo (triangulos verdes), pela MaxGain/AdGC (quadrado azul), pela AsHB Flex (triangulo invertido amarelo) e pela CompPerdas (losango vermelho), para dois tipos de EDFA.

Tabela 5.7: Valores de Ripple (dB) das soluções retornadas pelas técnicas locais e por três soluções da frente de Pareto retornada pelo SMPPO. Para cada coluna, o melhor valor encontrado está destacado em negrito.

<i>Ripple (dB)</i>					
	4 AMPS	5 AMPS	6 AMPS	7 AMPS	8 AMPS
MaxGain/AdGC c/VOA	3,66	4,77	5,88	6,98	8,09
ASHB Flex c/VOA	9,85	12,51	15,01	17,60	20,02
CompPerdas c/VOA	16,55	20,66	20,66	25,12	29,52
ACOP MOO (melhor Ripple)	0,37	0,53	0,50	0,64	0,75
ACOP MOO (melhor d_i)	0,43	0,69	0,84	1,00	0,75
ACOP MOO (melhor OSNR)	1,12	3,99	5,46	2,43	1,15

Tabela 5.8: Valores de OSNR (dB) das soluções retornadas pelas técnicas locais e por três soluções da frente de Pareto retornada pelo SMPPO. Para cada coluna, o melhor valor encontrado é destacado em negrito.

<i>OSNR (dB)</i>					
	4 AMPS	5 AMPS	6 AMPS	7 AMPS	8 AMPS
MaxGain/AdGC c/VOA	25,43	24,25	23,17	22,17	21,21
ASHB Flex c/VOA	23,31	21,06	18,95	16,76	14,60
CompPerdas c/VOA	20,12	16,91	13,22	8,76	5,02
ACOP MOO (melhor OSNR)	25,64	24,49	23,41	22,84	21,05
ACOP MOO (melhor d_i)	22,38	23,13	22,65	22,09	18,07
ACOP MOO (melhor Ripple)	20,07	19,13	19,09	16,67	18,07

A Tabela 5.7 reforça o que foi visto na Figura 5.28: que a técnica MOO é superior às outras técnicas quanto ao *ripple* das soluções. Percebe-se que mesmo a solução com pior *ripple* (melhor OSNR) possui um *ripple* maior do que as soluções retornadas pelas técnicas globais com restrição fixa, em todas as cascatas.

Já a Tabela 5.8 mostra que a superioridade da solução MOO com melhor OSNR é pequena em relação à técnica MaxGain, na verdade, a pequena diferença entre as OSNR retornadas por estas técnicas mostra que na prática existe um empate entre elas nesta métrica. Entretanto, ao se considerar o valor de *ripple* a solução MOO com melhor OSNR possui um valor bem menor, o que a torna a melhor escolha para este cenário.

5.5 Considerações sobre o capítulo

Diante dos resultados apresentados neste capítulo é possível tecer algumas considerações quanto à qualidade das contribuições aqui propostas.

A primeira contribuição foi a criação de um novo estimador de características do canal para ser utilizado em conjunto com as técnicas ACOP. Este estimador recebe informações sobre o ponto de operação do amplificador (ganho alvo e potência total de entrada) e a frequência do canal desejado, então retorna qual será o ganho e a figura de ruído deste canal na saída do amplificador.

Os resultados mostraram que, adaptando a rede neural proposta na Seção 4.1, foi possível criar um estimador capaz de retornar mais de uma característica do canal de uma só vez e sem perder precisão, quando comparado com o estimador estado-da-arte encontrado na literatura [82]. Além disso, quando comparado com o estimador proposto em [82], a rede neural é 80 vezes mais rápida e requer 804 vezes menos espaço de memória. Portanto, o estimador baseado em rede neural contribui para o desafio ACOP facilitando: a utilização de técnicas de otimização iterativas (porque ele é rápido); e a implementação das técnicas ACOP em sistemas restritos como microcontroladores (porque ele consome poucos recursos de memória).

A segunda contribuição foi a integração do modelo analítico IGN com as técnicas ACOP, para que este modelo possa ser utilizado como um avaliador do impacto dos efeitos não-lineares na qualidade das soluções retornadas pelas técnicas. Por ser um modelo rápido e com boa precisão, foi possível avaliar as técnicas ACOP de uma forma mais detalhada.

As simulações com o IGN comprovaram a hipótese de que os efeitos não-lineares prejudicariam bastante a MaxGain, pois há uma forte queda na OSNR retornada por esta técnica quando a NLI é considerada. Esta queda fez com que, ao se considerar a pior OSNR dentre todos os canais, o desempenho da MaxGain fique próximo ao do CompPerdas em termos de OSNR. Entretanto, a MaxGain supera a CompPerdas em termos de ripple. Além disso, o AsHB Flex se mostrou um caso intermediário entre boa OSNR ASE e pequena queda de OSNR ASE+NLI, o que fez com que a solução retornada por esta técnica obtivesse o melhor valor de OSNR ASE+NLI dentre as técnicas, mantendo ainda um bom valor de ripple. Esse bom desempenho do AsHB Flex também foi confirmado em cenários com cascatas com diferentes: números de amplificadores, comprimentos dos spans e potências de entrada.

A terceira contribuição foi propor a utilização de um VOA na saída de cada amplificador como um método de minimizar o impacto dos efeitos não-lineares nas técnicas ACOP. A aplicação inicial desta proposta considerou que o VOA simplesmente mantém a potência de lançamento na fibra abaixo de uma determinada restrição de potência. Contudo, um método mais sofisticado utilizando otimização multiobjetivo foi proposto para que tanto os ganhos dos amplificadores quanto as perdas dos VOAs fossem definidas simultaneamente, sem que

haja uma restrição fixa para a potência de lançamento na fibra.

A simples utilização do VOA para controlar uma restrição fixa na potência de lançamento já retornou resultados muito bons, fazendo com que a técnica MaxGain retornasse altos valores de OSNR mesmo com os efeitos não-lineares sendo considerados. Além disso, ao utilizar o VOA novas soluções com baixo *ripple*, antes impossíveis de serem alcançadas, foram encontradas.

Por fim, os resultados retornados pela utilização da técnica SMPSO, para a definição dos ganhos e perdas dos amplificadores, mostraram que esta técnica de otimização multiobjetivo é capaz de encontrar as melhores soluções possíveis em cascatas com até três amplificadores, e que para cascatas com quatro ou mais amplificadores ela supera em muito o *ripple* das soluções encontradas pelas técnicas ACOP locais. Por outro lado, a técnica MaxGain se mostrou mais uma vez uma técnica que é capaz de retornar excelentes valores de OSNR, pois os valores retornados são similares aos melhores retornados pela técnica SMPSO. Contudo utilizar otimização multiobjetivo para a criação de técnicas ACOP globais se mostrou uma boa alternativa pois retorna soluções com qualidade similar às melhores soluções possíveis (frente de Pareto do Método Exaustivo) e em um tempo bem menor, para cascatas de tamanhos variados.

6 . CONCLUSÃO

Neste trabalho procurou-se contribuir para o problema de como definir autonomamente o ponto de operação de amplificadores ópticos em cascata, de forma a melhorar/manter a qualidade de transmissão de um enlace óptico. Para tanto, buscou-se desenvolver e analisar técnicas para a definição autônoma do ponto de operação de amplificadores EDFAs. Diante dos resultados obtidos, algumas considerações quanto à solução do problema mencionado podem ser feitas.

Primeiramente, pode-se afirmar que a utilização de uma rede neural artificial como um regressor não-linear é capaz de transformar as informações discretas da máscara de potência do amplificador em uma função contínua. Tal transformação possibilita um maior grau de liberdade para as técnicas ACOP, além de diminuir em até três vezes o tempo necessário para a caracterização de um amplificador, tudo isso com um erro de aproximação muito baixo. Além disso, a utilização da rede neural para realizar a regressão das informações de uma máscara com informações de espectro se mostra uma solução muito mais eficiente na utilização dos recursos computacionais quando comparada à solução encontrada na literatura.

É possível afirmar, também, que as técnicas propostas nesta Tese contribuem de forma significativa para a evolução da pesquisa nesta área. Uma das razões é que apenas duas técnicas ACOP foram encontradas nos trabalhos anteriores presentes na literatura. Outra razão é que as técnicas propostas aqui possuem características únicas e inovadoras. O AsHB, por exemplo, é uma técnica iterativa que utiliza conceitos de aprendizado de máquina para a adaptação do ponto de operação, além de ter sido a primeira proposta a considerar a restrição que mantém a potência de saída do enlace em um valor pré-definido, o que contribui para a aplicação das técnicas ACOP em um cenário de rede. O Método Exaustivo (ME) é a uma técnica ACOP global para enlace ponto-a-ponto, e é capaz de definir todo o espaço de busca do problema ACOP, podendo ser usada como *benchmark* para outras técnicas ACOP. Por fim, o MaxGain é uma heurística criada a partir do conhecimento adquirido no desenvolvimento das outras técnicas, o que a torna uma técnica simples, rápida e que retorna excelentes resultados.

Quanto ao impacto das técnicas ACOP na qualidade da transmissão, percebe-se que o ajuste correto do ponto de operação dos amplificadores em uma cascata de amplificadores contribui para o aumento da QoT do enlace. Este aumento ocorre principalmente por conta da diminuição da inserção do ruído e aumento da planicidade do ganho. Contudo, existem

diferenças entre as soluções encontradas pelas técnicas. A técnica ME, por exemplo, retorna com certeza a melhor solução, porém não possui escalabilidade, isto é, seu tempo computacional cresce rapidamente com o aumento do número de amplificadores da cascata. Entretanto, apesar das diferenças entre as técnicas ACOP, todas elas mostraram ser uma melhor solução do que o método tradicional de definir os ganhos dos amplificadores apenas para compensar as perdas do enlace.

Uma contribuição importante das análises feitas foi a avaliação do impacto dos efeitos não-lineares no desempenho das técnicas ACOP, pois em trabalhos importantes para área esta análise é sugerida como trabalho futuro [5, 34]. Comprovou-se que é preciso considerar tais efeitos para que o desempenho das técnicas ACOP não seja degradado. Diante disso, foi possível propor adaptações para as técnicas ACOP visando a diminuição do impacto das não-linearidades. A consideração de uma VOA na saída de cada amplificador se mostrou uma ótima adaptação capaz de permitir às técnicas ACOP manterem seu bom desempenho sem sofrerem degradação dos efeitos não-lineares.

Além disso, a consideração do VOA na saída dos amplificadores tornou o problema ACOP muito mais do que a simples definição dos ganhos dos amplificadores, mas também a definição das perdas dos VOAs. E neste sentido, outra contribuição inédita deste trabalho foi a utilização de uma técnica de otimização multiobjetivo para solucionar o problema ACOP. Os resultados desta contribuição mostraram que é possível ter-se uma solução global completa e eficiente para a resolução do problema ACOP, pois por meio da utilização de uma técnica multiobjetivo foi possível alcançar os melhores resultados desta Tese.

Por fim, os resultados obtidos mostraram que a aplicação das técnicas ACOP em um cenário de rede real pode ser simples e direta se um controlador SDN for utilizado, pois as técnicas ACOP são consideradas como um aplicativo de rede no contexto de SDN.

Visto que as redes ópticas têm sido desafiadas a se tornarem mais dinâmicas, pois são utilizadas como *backbone* para outras redes que possuem necessidades e tecnologias diferentes, o desenvolvimento e análise das técnicas ACOP irá permitir que os amplificadores ópticos se adaptem ao novo cenário das redes ópticas dinâmicas e heterogêneas. Por ser um dispositivo crucial para as comunicações ópticas, a correta adaptação do ponto de operação do amplificador óptico contribuirá positivamente para a QoT da rede óptica como um todo.

Portanto, pode-se dizer que este trabalho é uma contribuição importante para o cenário de comunicação de dados como um todo, já que as comunicações ópticas são o principal meio de transmissão utilizado para suprir a crescente demanda global por esse tipo de comunicação.

6.1 Limitações e Sugestões para Trabalhos Futuros

Apesar das contribuições realizadas neste Tese, algumas limitações ainda existem. Estas limitações estão relacionadas, principalmente, com a variedade de cenários que podem ser

encontrados na prática pelo problema ACOP. Nesta Tese alguns cenários foram considerados, porém uma investigação mais profunda pode ser feita considerando: enlaces com links de tamanhos diferentes, máscaras de outros tipos de amplificadores (ex: Raman, Híbrido), parâmetros de potência, e restrição de potência, variados.

Além disso, nesta Tese foram consideradas apenas as técnicas ACOP para enlace ponto-a-ponto. Visto que o objetivo final de se adaptar de forma autônoma o ponto de operação dos amplificadores é melhorar o funcionamento de uma rede óptica dinâmica, é importante analisar o desempenho das técnicas aqui propostas em alguns cenários de rede.

Diante disso algumas sugestões para trabalhos futuros decorrentes desta Tese são:

1. Criação de máscaras de potência que já considerem para cada ponto de operação o impacto sofrido pelos efeitos não-lineares, dessa forma os efeitos não-lineares se tornariam uma das variáveis de decisão no processo das técnicas ACOP;
2. Análise do desempenho das técnicas considerando diferentes tipos de sinais ópticos, ou seja, sinais com diferentes: quantidades de canais, planicidades, formas, distribuições de canais, potências;
3. Adaptação das técnicas aqui propostas para considerarem a participação dos ROADMs na solução do problema ACOP, permitindo a definição dos ganhos e a equalização dos canais de forma conjunta;
4. Análise do desempenho das técnicas em variados cenários de rede, podendo comparar as técnicas propostas com a técnica ACOP para cenário de rede encontrada na literatura;
5. Criação de novas técnicas ACOP para cenário de rede que utilizem conceitos de inteligência computacional para tratar informações de várias camadas das rede óptica em seu processo de decisão (otimização multicamada).

REFERÊNCIAS

- [1] MOURA, U. C. de et al. Edfa adaptive gain control effect analysis over an amplifier cascade in a dwdm optical system. In: IEEE. *Microwave & Optoelectronics Conference (IMOC), 2013 SBMO/IEEE MTT-S International*. 2013. p. 1–5.
- [2] MOURA, U. C. de et al. Caracterizador automatizado de máscara de potência de amplificadores ópticos para redes wdm reconfiguráveis. In: SBRT. *XXX Brazilian Symposium on Telecommunication*. Brasília, Brazil, 2012.
- [3] OLIVEIRA, J. R. F. de. *Amplificador óptico híbrido Raman/EDFA com controle automático de ganho para redes DWDM reconfiguráveis*. Tese (Doutorado) — Universidade de São Paulo, 2014.
- [4] SILVA, M. J. da. *Avaliação experimental de desempenho e consumo de potência elétrica de amplificadores EDFA e híbrido Raman/EDFA para redes ópticas reconfiguráveis*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2016.
- [5] MOURA, U. et al. Cognitive methodology for optical amplifier gain adjustment in dynamic dwdm networks. *Journal of Lightwave Technology*, IEEE, v. 34, n. 8, p. 1971–1979, 2016.
- [6] CARVALHO, H. S. et al. Agc edfa transient suppression algorithm assisted by cognitive neural network. In: IEEE. *Telecommunications Symposium (ITS), 2014 International*. 2014. p. 1–5.
- [7] OLIVEIRA, J. R. et al. Demonstration of edfa cognitive gain control via gmpls for mixed modulation formats in heterogeneous optical networks. In: IEEE/OSA. *Optical Fiber Communication Conference*. Anaheim, United States, 2013. p. OW1H–2.
- [8] BHAUMIK, P. et al. Software-defined optical networks (sdons): a survey. *Photonic Network Communications*, Springer, v. 28, n. 1, p. 4–18, 2014.
- [9] ALABARCE, M. G.; MAGALHÃES, E. C.; OLIVEIRA, J. R. F. de. *How To Operate the Rede Autônoma*. Campinas, Brazil, 2014.

- [10] GARRICH, M. et al. Pioneering hardware modeling and software design for optical infrastructure in the autonomous network project. In: IEEE. *International Conference on Optical Network Design and Modeling (ONDM)*. 2016. p. 1–6.
- [11] CARVALHO, H. et al. Sdn dual-optimization application for edfas and wss-based roadms. In: IEEE/OSA. *Optical Fiber Communication Conference*. Los Angeles, United States, 2015. p. Th3J.4.
- [12] CISCO, C. V. N. I. Global mobile data traffic forecast update, 2015–2020. *white paper*, 2016.
- [13] TANENBAUM, A. S.; WETHERALL, D. J. *Computer networks*. 5th. ed. Boston: Pearson Education, 2011. 99-105 p.
- [14] ZERVAS, G. S.; SIMEONIDOU, D. Cognitive optical networks: Need, requirements and architecture. In: *2010 12th International Conference on Transparent Optical Networks (ICTON)*. Munich, Germany: IEEE, 2010. p. 1–4.
- [15] TOMKOS, I. et al. Next generation flexible and cognitive heterogeneous optical networks. p. 225–236, 2012.
- [16] WEI, W.; WANG, C.; YU, J. Cognitive optical networks: Key drivers, enabling techniques, and adaptive bandwidth services. *Communications magazine*, IEEE, v. 50, n. 1, 2012.
- [17] MOVAHEDI, Z. et al. A survey of autonomic network architectures and evaluation criteria. *Communications Surveys & Tutorials*, IEEE, v. 14, n. 2, p. 464–490, 2012.
- [18] KHAN, F. N. et al. Non-data-aided joint bit-rate and modulation format identification for next-generation heterogeneous optical networks. *Optical Fiber Technology*, Elsevier, v. 20, n. 2, p. 68–74, 2014.
- [19] JIMÉNEZ, T. et al. A cognitive quality of transmission estimator for core optical networks. *Journal of Lightwave Technology*, IEEE, v. 31, n. 6, p. 942–951, 2013.
- [20] FERNÁNDEZ, N. et al. Survivable and impairment-aware virtual topologies for reconfigurable optical networks: A cognitive approach. In: IEEE. *2012 4th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT)*. St. Petersburg, Russia, 2012. p. 793–799.
- [21] DAS, S.; PARULKAR, G.; MCKEOWN, N. Why openflow/sdn can succeed where gmpls failed. In: IEEE/OSA. *European Conference and Exhibition on Optical Communication*. 2012. p. Tu-1.

- [22] CHOI, H. Y. et al. Demonstration of ber-adaptive wson employing flexible transmitter/receiver with an extended openflow-based control plane. *Photonics Technology Letters*, IEEE, v. 25, n. 2, p. 119–121, 2013.
- [23] DESURVIRE, E. *Erbium-doped fiber amplifiers: Device and System Developments.* : Wiley-Interscience, 2002.
- [24] ISHII, K. et al. Experimental investigation of transients in six cascaded agc edfas and their suppression using a high-speed voa. *IEICE Communications Express*, The Institute of Electronics, Information and Communication Engineers, v. 1, n. 4, p. 137–142, 2012.
- [25] KILPER, D. et al. Control process gain of erbium doped fiber amplifiers with wavelength division multiplexed signals. In: IEEE/OSA. *Optical Amplifiers and Their Applications*. 2006. p. JWB8.
- [26] YU, Q.; FAN, C. Simple dynamic model of all-optical gain-clamped erbium-doped fiber amplifiers. *Journal of lightwave technology*, IEEE, v. 17, n. 7, p. 1166, 1999.
- [27] ZIRNGIBL, M. Gain control in erbium-doped fibre amplifiers by an all-optical feedback loop. *Electronics letters*, IET, v. 27, n. 7, p. 560–561, 1991.
- [28] YUNKO, S. et al. Gain control in erbium-doped fibre amplifiers by tuning centre wavelength of a fibre bragg grating constituting resonant cavity. *Electronics Letters*, IET, v. 34, n. 10, p. 990–991, 1998.
- [29] TIAN, C.; KINOSHITA, S. Analysis and control of transient dynamics of edfa pumped by 1480-and 980-nm lasers. *Journal of lightwave technology*, IEEE, v. 21, n. 8, p. 1728, 2003.
- [30] AGRAWAL, G. P. Fiber-optic communication systems. In: _____. 4th. ed. : John Wiley and Sons, 2010. cap. 7, p. 295–300.
- [31] BARBOZA, E. A. et al. Self-adaptive erbium-doped fiber amplifiers using machine learning. In: SBMO/IEEE. *International Microwave & Optoelectronics Conference (IMOC)*. Rio de Janeiro, Brazil, 2013. p. 1–5.
- [32] CABALLERO, A. et al. Cognitive, heterogeneous and reconfigurable optical networks: The chron project. *Journal of Lightwave Technology*, IEEE, v. 32, n. 13, p. 2308–2323, 2014.
- [33] MIGUEL, I. de et al. Cognitive dynamic optical networks [invited]. *Journal of Optical Communications and Networking*, IEEE/OSA, v. 5, n. 10, p. A107–A118, 2013.

- [34] WANG, X. et al. Effects of signal power control strategies and wavelength assignment algorithms on circuit osnr in wdm networks. *Photonic Network Communications*, Springer, v. 31, n. 3, p. 404–417, 2016.
- [35] HAYEE, M.; WILLNER, A. Transmission penalties due to edfa gain transients in add-drop multiplexed wdm networks. *Photonics Technology Letters*, IEEE, v. 11, n. 7, p. 889–891, 1999.
- [36] KARASEK, M.; VALLES, J. A. Analysis of channel addition/removal response in all-optical gain-controlled cascade of erbium-doped fiber amplifiers. *Journal of lightwave technology*, IEEE, v. 16, n. 10, p. 1795–1803, 1998.
- [37] AHN, J. T.; KIM, K. H. All-optical gain-clamped erbium-doped fiber amplifier with improved noise figure and freedom from relaxation oscillation. *Photonics Technology Letters*, IEEE, v. 16, n. 1, p. 84–86, 2004.
- [38] KIM, C. et al. All-optical gain-controlled bidirectional add-drop amplifier using fiber bragg gratings. *Photonics Technology Letters*, IEEE, v. 12, n. 7, p. 894–896, 2000.
- [39] CARVALHO, H. S. et al. Agc edfa transient suppression algorithm assisted by cognitive neural network. In: IEEE. *2014 International Telecommunications Symposium (ITS)*. 2014. p. 1–5.
- [40] OLIVEIRA, J. R.; OLIVEIRA, J. C.; FERREIRA, E. C. Transient suppression of gain controlled edfas for optical reconfigurable optical networks applications. In: IEEE/OSA. *Frontiers in Optics*. Rochester, New York United States, 2008. p. FTuG3.
- [41] DESURVIRE, E. et al. Dynamic gain compensation in saturated erbium-doped fiber amplifiers. *Photonics technology letters*, IEEE, v. 3, n. 5, p. 453–455, 1991.
- [42] BIANCIOTTO, A. et al. Edfa gain transients: experimental demonstration of a low cost electronic control. *Photonics Technology Letters*, IEEE, v. 15, n. 10, p. 1351–1353, 2003.
- [43] MONNARD, R.; SRIVASTAVA, A. Optical amplifier transient suppression requirements for dynamic dwdm networks. In: IEEE/OSA. *Optical Amplifiers and Their Applications*. Otaru, Japan, 2003. p. TuA1.
- [44] DUMAS, B.; OLIVARES, R. Transient link control technique applied to optical hybrid amplifier (edfa+ dfra) cascades. *Journal of Optical Communications and Networking*, Optical Society of America, v. 4, n. 11, p. 858–864, 2012.
- [45] KASZUBOWSKA-ANANDARAJAH, A. et al. EDFA transient suppression in optical burst switching systems. In: *2012 14th International Conference on Transparent Optical Networks (ICTON)*. : IEEE, 2012. p. 1–4.

- [46] OIKAWA, Y. 0.2-dB Gain Excursion AGC-EDFA with a High Speed VOA for 100-Channel Add/Drop Equivalent Operation. In: *Optical Fiber Communication Conference*. Washington, D.C.: OSA, 2012. p. OW4D.3.
- [47] SAMUEL, A. L. Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, IBM, v. 44, n. 1.2, p. 206–226, 2000.
- [48] MAEDCHE, A.; STAAB, S. Ontology learning for the semantic web. *Intelligent Systems*, IEEE, v. 16, n. 2, p. 72–79, 2001.
- [49] HUANG, Z. et al. Credit rating analysis with support vector machines and neural networks: a market comparative study. *Decision support systems*, Elsevier, v. 37, n. 4, p. 543–558, 2004.
- [50] KONONENKO, I. Machine learning for medical diagnosis: history, state of the art and perspective. *Artificial Intelligence in medicine*, Elsevier, v. 23, n. 1, p. 89–109, 2001.
- [51] WIDROW, B.; HOFF, M. E. et al. Adaptive switching circuits. Defense Technical Information Center, 1960.
- [52] VALENÇA, M. *Fundamentos das Redes Neurais*. Recife, Brazil: Livro Rápido, 2010. 107-156 p.
- [53] KIRKPATRICK, S.; JR., D. G.; VECCHI, M. Optimization by simulated annealing. *Science*, Washington, v. 220, n. 4598, p. 671–680, 1983.
- [54] BANEY, D.; GALLION, P.; TUCKER, R. Theory and measurement techniques for the noise figure of optical amplifiers. *Optical Fiber Technology*, Elsevier, v. 6, n. 2, p. 122–154, 2000.
- [55] MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943.
- [56] ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958.
- [57] MINSKY, M.; SEYMOUR, P. Perceptrons. MIT press, 1969.
- [58] HAYKIN, S. S. *Neural networks and learning machines*. 3. ed. NJ, USA: Pearson Education Upper Saddle River, 2009.
- [59] WERBOS, P. J. Beyond regression: New tools for prediction and analysis in the behavioral sciences. *Doctoral Dissertation, Applied Mathematics, Harvard University, MA*, 1974.

- [60] HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. *Neural networks*, Elsevier, v. 2, n. 5, p. 359–366, 1989.
- [61] FOUNDATION, O. N. Software-defined networking: The new norm for networks. *ONF White Paper*, 2012.
- [62] JI, Y. et al. All optical switching networks with energy-efficient technologies from components level to network level. *Journal on Selected Areas in Communications*, IEEE, v. 32, n. 8, p. 1600–1614, 2014.
- [63] CASELLAS, R. et al. Control and management of flexi-grid optical networks with an integrated stateful path computation element and openflow controller [invited]. *Journal of Optical Communications and Networking*, IEEE/OSA, v. 5, n. 10, p. A57–A65, 2013.
- [64] LIU, L. et al. Demonstration of a dynamic transparent optical network employing flexible transmitters/receivers controlled by an OpenFlow-stateless PCE integrated control plane [Invited]. *Journal of Optical Communications and Networking*, v. 5, n. 10, p. A66–A75, 2013. ISSN 1943-0620.
- [65] BOJIC, D. et al. Advanced wireless and optical technologies for small-cell mobile backhaul with dynamic software-defined management. *Communications Magazine*, IEEE, v. 51, n. 9, p. 86–93, 2013.
- [66] DIOS, O. de et al. Coordinated computation and setup of multi-layer paths via inter-layer pce communication: Standards, interoperability and deployment. *Communications Magazine*, IEEE, v. 51, n. 12, p. 144–154, 2013.
- [67] HARAI, H. et al. Optical packet and circuit integrated networks and software defined networking extension. *Journal of Lightwave Technology*, IEEE, v. 32, n. 16, p. 2751–2759, 2014.
- [68] MALACARNE, A. et al. Multiplexing of asynchronous and independent ask and psk transmissions in sdn-controlled intra-data center network. *Journal of Lightwave Technology*, IEEE, v. 32, n. 9, p. 1794–1800, 2014.
- [69] ASENSIO, A.; VELASCO, L. Managing transfer-based datacenter connections. *Journal of Optical Communications and Networking*, IEEE/OSA, v. 6, n. 7, p. 660–669, 2014.
- [70] NGUYEN, K.-K.; CHERIET, M.; LEMIEUX, Y. Virtual slice assignment in large-scale cloud interconnects. *Internet Computing*, IEEE, v. 18, n. 4, p. 37–46, 2014.
- [71] CHANNEGOWDA, M.; NEJABATI, R.; SIMEONIDOU, D. Software-defined optical networks technology and infrastructure: Enabling software-defined optical network opera-

- tions [invited]. *Journal of Optical Communications and Networking*, IEEE/OSA, v. 5, n. 10, p. A274–A282, 2013.
- [72] GRINGERI, S.; BITAR, N.; XIA, T. J. Extending software defined network principles to include optical transport. *Communications Magazine*, IEEE, v. 51, n. 3, p. 32–40, 2013.
- [73] SIQUEIRA, M. et al. An optical sdn controller for transport network virtualization and autonomic operation. In: *Globecom Workshops (GC Wkshps)*. Atlanta, GA, USA: IEEE, 2013. p. 1198–1203.
- [74] MCKEOWN, N. et al. Openflow: enabling innovation in campus networks. *ACM SIGCOMM Computer Communication Review*, ACM, v. 38, n. 2, p. 69–74, 2008.
- [75] LIU, L. et al. Openslice: An openflow-based control plane for spectrum sliced elastic optical path networks. *Optics express*, IEEE/OSA, v. 21, n. 4, p. 4194–4204, 2013.
- [76] CVIJETIC, N. et al. Sdn and openflow for dynamic flex-grid optical access and aggregation networks. *Journal of Lightwave Technology*, IEEE, v. 32, n. 4, p. 864–870, 2014.
- [77] SPOLTI, F. C. *WildFly: New Features*. : Packt Publishing Ltd, 2014.
- [78] SAVORY, S. J. Digital coherent optical receivers: algorithms and subsystems. *Journal of Selected Topics in Quantum Electronics*, IEEE, v. 16, n. 5, p. 1164–1179, 2010.
- [79] GODARD, D. Self-recovering equalization and carrier tracking in two-dimensional data communication systems. *Transactions on Communications*, IEEE, v. 28, n. 11, p. 1867–1875, 1980.
- [80] SETHARES, W. A.; REY, G. A.; JOHNSON, C. Approaches to blind equalization of signals with multiple modulus. In: *International Conference on Acoustics, Speech, and Signal Processing*. Glasgow, UK: IEEE, 1989. p. 972–975.
- [81] PFAU, T.; HOFFMANN, S.; NOÉ, R. Hardware-efficient coherent digital receiver concept with feedforward carrier recovery for m -qam constellations. *Journal of Lightwave Technology*, IEEE, v. 27, n. 8, p. 989–999, 2009.
- [82] FEI, Y. et al. Estimating edfa output power with an efficient numerical modeling framework. In: *International Conference on Communications (ICC)*. London, UK: IEEE, 2015. p. 5222–5227.
- [83] POGGIOLINI, P. et al. The gn-model of fiber non-linear propagation and its applications. *Journal of Lightwave Technology*, IEEE, v. 32, n. 4, p. 694–721, 2014.
- [84] FINISAR. *M2300CD Fixed Gain EDFA Booster with output VOA*. 2014. Rev. A00.

- [85] COELLO, C. A. C. et al. *Evolutionary algorithms for solving multi-objective problems.* : Springer, 2007. v. 5.
- [86] ZITZLER, E. *Evolutionary algorithms for multiobjective optimization: Methods and applications.* Tese (Doutorado) — ETH Zurich, Switzerland, 1999.
- [87] NEBRO, A. J. et al. Smpso: A new pso-based metaheuristic for multi-objective optimization. In: *Symposium on Computational intelligence in multi-criteria decision-making.* Nashville, TN, USA: IEEE, 2009. p. 66–73.
- [88] CLERC, M.; KENNEDY, J. The particle swarm-explosion, stability, and convergence in a multidimensional complex space. *Transactions on Evolutionary Computation*, IEEE, v. 6, n. 1, p. 58–73, 2002.
- [89] DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *Transactions on evolutionary computation*, IEEE, v. 6, n. 2, p. 182–197, 2002.
- [90] DURILLO, J. J.; NEBRO, A. J. jmetal: A java framework for multi-objective optimization. *Advances in Engineering Software*, Elsevier, v. 42, n. 10, p. 760–771, 2011.

A . SUMÁRIO DE PUBLICAÇÕES

Publicações Decorrentes deste Trabalho

Título: Mapping EDFA Noise Figure and Gain Flatness Over the Power Mask Using Neural Networks.

Autores: Carmelo J. A. Bastos-Filho, Erick de A. Barboza, Joaquim F. Martins-Filho, Uiara C. de Moura e Juliano R. F. de Oliveira.

Local: Journal of Microwaves, Optoelectronics and Electromagnetic Applications, Vol. 12, No. SI-2, Julho 2013. (*Publicado*)

Resumo: Optical Amplifiers play an important role in optical communications. The characterization within the operational range is crucial for the proper deployment and usage of such devices. In general, one needs to measure a certain number of operation points to complete the characterization. In spite of this, there is a lot of missing data for some operational deployment cases. We show that one can use simple neural networks to execute a regression task and obtain a continuous characterization curve of Gain Flatness and Noise Figure over Amplifier Power Mask. This regression can be made using a lower number of points than usual. We obtained errors lower than 0.1 dB for Gain Flatness and Noise Figure over the entire operational range.

Título: Self-Adaptive Erbium-Doped Fiber Amplifiers Using Machine Learning.

Autores: Erick de A. Barboza, Carmelo J. A. Bastos-Filho, Joaquim F. Martins-Filho, Uiara C. de Moura e Juliano R. F. de Oliveira.

Local: SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference, Rio de Janeiro, Brazil, Agosto 4-7,2013(*Publicado*).

Resumo: This paper presents a method to autonomously adjust the operating point of amplifiers in a cascade using an approach based on machine learning. The goal is to smoothly adjust the gain of each amplifier in the cascade in order to reach predefined input and output power levels for the entire link, aiming to minimize both the noise figure and the gain flatness

of the transmission system. The proposal uses an iterative method and performs feedforward and backward error adjustments based on local information. The experimental results indicate that our proposal can optimize the performance of the link ensuring predefined input and output power levels, which is important in a network scenario. As an example, our proposal was capable to define the gain of 6 amplifiers returning a link with a noise figure equal to 30.06 dB and a gain flatness equal to 5.26 dB, while maintaining the input and output powers around 3 dBm with an error lower than 0.1 dB.

Título: Impact of Nonlinear Effects on the Performance of 120 Gb/s 64 QAM Optical System using Adaptive Control of Cascade of Amplifiers.

Autores: Erick de A. Barboza, Marcionilo J. da Silva, Leonardo D. Coelho, Joaquim F. Martins-Filho, Carmelo J. A. Bastos-Filho, Uiana C. de Moura e Juliano R. F. de Oliveira.

Local: SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference, Ipojuca, Brazil, Nov. 3-6, 2015 (*Publicado*).

Resumo: Several approaches have been proposed in order to solve the adaptive control of optical amplifier operating point problem (ACOP). These approaches aim to adjust the gain of each amplifier in a cascade of amplifiers. Some previous results show that it is possible to decrease the noise added by the amplifiers by using these strategies. However, the configurations found by these approaches may degrade the quality of the transmission due to nonlinear effect, because the amplifiers may operate with a high output power. Therefore, the goal of this work is to analyze the impact of the nonlinear effects in the solutions found by these approaches by evaluating the BER of a system that uses a very sensitive modulation in terms of OSNR (64QAM). We tested LossComp, WAdGC and AsHB approaches in a system with 40 channels, using 50GHz fixed grid and considering high and low system input powers. The results showed that for all analyzed approaches the system quality of transmission is affected by the nonlinear effects, and the effect is worse in those with higher amplifier output powers.

Título: Local and Global Approaches for the Adaptive Control of a Cascade of Amplifiers

Autores: Erick de A. Barboza, Marcionilo J. da Silva, Leonardo D. Coelho, Joaquim F. Martins-Filho, Carmelo J. A. Bastos-Filho, Uiana C. de Moura e Juliano R. F. de Oliveira.

Local: Photonic Network Communications (*Publicado*).

Resumo: In this work we present and analyze three approaches for the adaptive control of the operating point of a cascade of Erbium-doped fiber amplifiers (EDFA), aiming optical networks performance enhancement. The first approach is called Annealing Search Heuristic with Backpropagation and flexible output (*AsHB flex*) and uses machine learning concepts to update the amplifiers gains through an iterative process. The second one (*Exhaustive Method*) uses an exhaustive search to evaluate all possible solutions for the problem and obtain the optimum solution. The last one

(*MaxGain*) is a heuristic method that uses previous knowledge about the problem to obtain the solutions. The amplifier characteristics and specifications were obtained experimentally through measurements of gain, noise figure, gain ripple and power consumption on commercially available EDFAs. We performed comparisons among these approaches and others found in the literature, and the results show that the three proposals outperformed the previous ones in terms of noise figure and gain ripple. For example, in a link with 4 amplifiers the *Exhaustive Method* achieved a reduction of the cascade noise figure from 10.05 dB to 5.18 dB and a reduction of the gain ripple from 6.02 dB to 4.64 dB, when compared with the traditional approach, which defines the gain to compensate the loss of the previous link. However, the computation time of *Exhaustive Method* becomes prohibitive as the number of amplifiers in the link increases. Both *MaxGain* and *AsHB flex* obtained similar solutions, close to the optimum operation point in a reasonable time.

Título: Estimating the Spectral Gain and the Noise Figure of EDFA Using Artificial Neural Networks

Autores: Carmelo J. A. Bastos-Filho, Erick de A. Barboza, Joaquim F. Martins-Filho.

Local: International Conference on Transparent Optical Networks ICTON 2017 Girona, Spain, July 2-6, 2017 (*Publicado*).

Resumo: In this paper, we propose a new approach to estimate the gain and the noise figure of EDFAs. This is an important tool for solving the adaptive control of operating point (ACOP) problem in optical amplifiers. The proposal uses an artificial neural network to enable a quick estimation of both amplifiers features requiring a small amount of memory. Results show that the neural network estimator is 80 times faster and uses 804 times fewer data than state of the art estimator, without losing significant accuracy. These advantages will help the use of iterative optimization techniques, like computational intelligence, to tackle the ACOP problem. Besides, it can assist in the implementation of ACOP approaches in simple devices like microcontrollers.