

UNIVERSIDADE ESTADUAL PAULISTA JÚLIO DE MESQUITA FILHO
CAMPUS DE SÃO JOÃO DA BOA VISTA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

GERALDO ANTONIO DE OLIVEIRA JUNIOR

**Compensação de não linearidades em redes PON coerentes de longa
distância usando clusterização baseada em histograma**

São João da Boa Vista

2020

GERALDO ANTONIO DE OLIVEIRA JUNIOR

**Compensação de não linearidades em redes PON coerentes de longa
distância usando clusterização baseada em histograma**

Versão original

Dissertação apresentada à Universidade Estadual Paulista Júlio de Mesquita Filho - Campus de São João da Boa Vista para obtenção do título de Mestre em Engenharia Elétrica pelo Programa de Pós-graduação em Engenharia Elétrica.

Área de concentração: Comunicações ópticas

Orientador: Prof. Dr. Ivan Aritz Aldaya Garde

Coorientador: Prof. Dr. Marcelo Luis Francisco Abbade

São João da Boa Vista

2020

O48c

Oliveira Junior, Geraldo Antonio de

Compensação de não linearidades em redes PON coerentes de longa distância usando clusterização baseada em histograma / Geraldo Antonio de Oliveira Junior. -- São João da Boa Vista, 2021

52 p.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Câmpus Experimental de São João da Boa Vista, São João da Boa Vista

Orientador: Ivan Aritz Aldaya Garde

Coorientador: Marcelo Luis Francisco Abadde

1. Comunicações óticas. 2. Fibras óticas. 3. Teoria da aprendizagem computacional. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Câmpus Experimental de São João da Boa Vista. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.



ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE GERALDO ANTONIO DE OLIVEIRA JUNIOR, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DO CÂMPUS EXPERIMENTAL DE SÃO JOÃO DA BOA VISTA - CÂMPUS DE SÃO JOÃO DA BOA VISTA.

Aos 30 dias do mês de novembro do ano de 2020, às 09:00 horas, por meio de Videoconferência, realizou-se a defesa de DISSERTAÇÃO DE MESTRADO de GERALDO ANTONIO DE OLIVEIRA JUNIOR, intitulada **Compensação de não linearidades em redes PON coerentes de longa distância usando clusterização baseada em histograma..** A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. IVAN ARITZ ALDAYA GARDE (Orientador(a) - Participação Virtual) do(a) Coordenadoria de Curso de Engenharia Eletrônica e de Telecomunicações / Câmpus de São João da Boa Vista, Prof. Dr. RAFAEL ABRANTES PENCHEL (Participação Virtual) do(a) Coordenadoria de Curso de Engenharia Eletrônica e de Telecomunicações / Câmpus de São João da Boa Vista, Prof. Dr. DIEGO CESAR VALENTE E SILVA (Participação Virtual) do(a) Informática / Instituto Federal de Educação Ciência e Tecnologia de São Paulo. Após a exposição pelo mestrando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: Aprovado. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.

Prof. Dr. IVAN ARITZ ALDAYA GARDE



Dedico este trabalho acima de tudo à Deus, por guiar meus passos, acolher minhas angustias, enxugar minhas lágrimas e falar comigo através da criação.

Obrigado, Senhor...

Agradecimentos

Em primeiro lugar, Obrigado Senhor! Não teria chegado aqui sem sua presença em minha vida. Mesmo eu sendo fraco, o Senhor foi fiel.

Agradeço aqueles que Deus colocou primeiro em meu caminho: meus pais, Geraldo e Evalda, que através do seu exemplo me ensinaram a importância da educação, da luta e da justiça; aos meus padrinhos, Sebastião Camargo e Maria do Carmo, por me mostrarem o caminho da fé e me ensinarem a ouvir e acolher a vontade de Deus.

A minha esposa Susana, parceira de todas as horas, e minha filha Giana, vocês são meus grandes amores e o principal motivo desta jornada. Obrigado por compartilharem comigo as alegrias, lágrimas e frustrações nesta jornada.

À toda minha família, em especial meus irmãos, Edmar e Edinamar pela amizade, conversa e paciência. As meus cunhados, cunhadas, sobrinhas, tios e primos; pela amizade e por aceitarem minha ausência nos últimos anos. Em especial a Erika Tatiana, por nos ajudar em tantos momentos deste projeto.

Ao GAM, por partilharem conosco a comida, a bebida, as gargalhadas e até as lágrimas. Ao Grupo Maanaim de Uberlândia, meu coração estará com vocês em cada barraca montada, em cada fogueira acesa, em cada lágrima acolhida e cada sorriso compartilhado. "Que o Senhor nos abençoe e nos guarde..."

Aos professores e funcionários da UNESP, em especial aos professores Ivan Aritz Aldaya Garde e Marcelo Luís Francisco Abbade, pela orientação, apoio e paciência na execução deste trabalho.

Aos colegas da UNESP por dividirem comigo sua história, seu conhecimento e amizade.

A todos os colegas do IFSP, que me incentivaram, colaboraram e compartilharam experiências e sonhos nesta jornada.

Por fim, a todos que fizeram parte direta ou indiretamente dessa jornada, meu muito obrigado.

*“A fé e a razão constituem como que as duas asas pelas quais o espírito humano se eleva
para a contemplação da verdade.”*

(Fides et Ratio — João Paulo II — 14 de setembro de 1998)

Resumo

OLIVEIRA JUNIOR, Geraldo Antonio de. **Compensação de não linearidades em redes PON coerentes de longa distância usando clusterização baseada em histograma**2020. 52 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual Paulista (UNESP), Campus Experimental de São João da Boa Vista, São João da Boa Vista, 2020.

As mudanças recentes em nossa sociedade tem aumentado a demanda junto ao setor de telecomunicações por soluções que busquem ampliar a largura de banda e o alcance das redes de acesso. Neste contexto, as redes ópticas passivas de longo alcance (LR-PON) ao usarem processadores digitais de sinais (DSP) operando em sistemas de comunicações coerentes, conseguem aliar o ganho de mixagem e a diversidade de formatos de amplitude e fase, apresentam alto potencial de sucesso no desafio de compensar os efeitos combinados do ruído e da distorção não linear. Neste trabalho, é proposto o uso de aprendizagem de máquina aplicada a um novo algoritmo de agrupamento, denominado agrupamento baseado em histograma (HBC), que emprega a densidade de um histograma 2D para classificar constelações distorcidas de forma não linear. O algoritmo foi aplicado em uma rede LR-PON de 100 km de comprimento com divisão de 1:64 nos primeiros 80 km do enlace. Os resultados alcançados mostram uma melhor eficiência de HBC em comparação aos algoritmos utilizados de *Benchmark*, Máxima Verossimilhança e *K-means*. Quando levado em conta o fator Q, HBC é 0,57 dB melhor que Máxima Verossimilhança e 0,21 dB melhor que *K-means*. Quando olhamos para BER, HBC alcança um valor de 2×10^{-3} , sendo 2,5 dB e 1,25 dB maior que Máxima Verossimilhança e *K-means* respectivamente.

Palavras-chaves: Comunicações Ópticas. Redes Ópticas Passivas. Processamento Digital de Sinais. Aprendizagem de máquina. Clustering. *K-means*. Histograma. DSP. PON. LR-PON.

Abstract

OLIVEIRA JUNIOR, Geraldo Antonio de. **Compensation of non-linearities in coherent long reach PON using histogram-based clustering**. 2020. 52 p.
Dissertation (Master of Electric Engineering) – São Paulo State University (UNESP),
Campus of São João da Boa Vista, São João da Boa Vista, 2020.

Recent changes in our society have increased demand from the Telecommunications sector for solutions that seek to increase the bandwidth and reach of access network. In this context, Long Reach Passive Optical Network (LR-PON) when using digital signal processor (DSP) operating in coherent communications system are able to combine the mixing gain and the diversity of amplitude and phase formats, have high potential success in the challenge of compensating for the combined effects of noise and non-linear distortion. This work proposes the use of machine learning applied to a new clustering algorithm, called histogram-based clustering (HBC), which uses the sensitivity of a 2D histogram to classify constellations distorted in a non-linear way. The algorithm is applied in a LR-PON network of 100 km with 1:64 split in the first 80 km of the span. The results show a better efficiency of HBC when compared to the algorithms used for Benchmark, Maximum Likelihood and K-means. When taking into account the Q factor, HBC is 0.57 dB better than Maximum Likelihood and 0.21 dB better than K-means. When looking at BER, HBC reaches a value of 2×10^{-3} , with 2.5 dB and 1.25 dB greater than Maximum Likelihood and K-means respectively.

Keywords: Optical Communications. Passive Optical Networks. Digital Signal Processing. Machine Learning. Clustering. K-means. Maximum Likelihood. Histogram. DSP. PON. LR-PON.

Lista de figuras

Figura 1 – Capacidade média das redes de acesso de banda-larga (CISCO, 2020).	16
Figura 2 – Diagrama de blocos de um sistema de comunicações coerente digital. DAC: conversor analógico-digital, DP-MZM: modulador duplo paralelo Mach-Zehnder. LD: diodo laser. SSMF: fibra monomodo padrão. LD_{LO} : diodo laser do oscilador local. PD: fotodetector. Fonte: Feito pelo autor baseado em modelo de (KIKUCHI, 2010).	19
Figura 3 – Diagrama de fluxo do algoritmo de clusterização proposto. (a) Símbolos 16-QAM distorcidos na entrada do algoritmo. (b) Histograma 2D cal- culado. (c) Limites ótimos sobrepostos no histograma 2D. (d) Limites para cada agrupamento no topo da constelação distorcida recebida. (e) Constelação classificada. Fonte: (ALDAYA <i>et al.</i> , 2020).	33
Figura 4 – Diagrama de blocos do sistema simulado LR-PON coerente. S/P: con- versão serial-paralelo. DAC: conversor digital-analógico. DL: diodo laser. DP-MZM: modulador duplo paralelo Mach-Zehnder. EDFA: amplifica- dor de fibra dopada com érbio. VOA: atenuador óptico variável. SSMF: fibra monomodo padrão. DPT: Rastreador de polarização dinâmica. LPF: filtro passa-baixa. ADC: conversor analógico-digital. Fonte: (AL- DAYA <i>et al.</i> , 2020).	34
Figura 5 – Sistema WDM-LR-PON utilizado no cenário.	37
Figura 6 – Constelações obtidas para o canal central de um sistema WDM LR-PON com potências de transmissão de (a) 1 mW e (b) 3 mW. As figuras mostram constelações considerando unicamente SPM e SPM, XPM e FWM.	38
Figura 7 – Desempenho do HBC em função da potência óptica transmitida (a) BER e (b) fator Q. Como referência o desempenho de máxima verosimilhança e <i>k-means</i> são incluídos. Fonte: (ALDAYA <i>et al.</i> , 2020).	39
Figura 8 – Constelações obtidas para diferentes potências de entrada e classificadas usando máxima verosimilhança, <i>k-means</i> e HBC. Fonte: (ALDAYA <i>et</i> <i>al.</i> , 2020)	41

Figura 9 – Análise das regiões de decisão para uma potência de transmissão de 10mW. (a) Histograma da constelação recebida. (b) Máxima verossimilhança. (c) *K-means*. (d) HBC. Em (b-d) as constelações foram sobrepostas às regiões de decisão, e na parte inferior um retângulo detalhando a constelação inferior esquerda, conforme mostrado na Figura (a). Fonte: (ALDAYA *et al.*, 2020). 42

Figura 10 – BER em termos de tamanho de bloco processado, juntamente com a eficiência de HBC para uma potência de transmissão de 7 mW, ponto em que HBC alcança seu desempenho ótimo. Para fins de comparação, o BER usando a Máxima Verossimilhança também é mostrado. Fonte: (ALDAYA *et al.*, 2020). 43

Lista de quadros

Quadro 1 – Comparativo entre sistemas coerentes e de detecção direta.	20
Quadro 2 – Comparativo entre as técnicas de Aprendizagem de máquinas.	25
Quadro 3 – Parâmetros utilizados na simulação da rede LR-PON.	36

Lista de tabelas

Tabela 1 – BER e fator Q ótimos para os diferentes esquemas de classificação. . .	40
---	----

Lista de abreviaturas e siglas

ANN	Redes neurais artificiais
ASE	Ruído de emissão espontânea amplificada
BER	Taxa de erro de bits
CD	Dispersão cromática
DAC	Conversor analógico-digital
DBP	Retro-propagação digital
DBSCAN	Clusterização Espacial Baseada em Densidade de Aplicações com Ruído
DP-MZM	Modulador Mach-Zehnder duplo-paralelo
DPT	Rastreador de polarização dinâmica
DSP	Processador digital de sinais
EDFA	Amplificador fibra dopada a érbio
EM	Maximização de expectativa
FLOPS	Operações de ponto flutuante por segundo
FWM	Mistura de quatro ondas
HBC	Clusterização baseada em histograma
IoT	Internet das coisas
IP	Protocolo de Internet
ISI	Interferência inter-simbólica
IVSTF	Função de transferência inversa da série de Volterra
KNN	K-ésimo vizinho mais próximo
LD	Diodo laser
LPF	Filtro passa-baixa

LR-PON	Redes ópticas passivas de longa distância
MMA	algoritmo de módulo múltiplo
OFDM	Multiplexação por divisão de frequências ortogonais
OLT	Terminal de enlace óptico
ONU	Unidade de rede óptica
O&M	Operação e manutenção
OPC	Conjugação de fase óptica
PCTW	Par de ondas gêmeas de fases conjugadas
PON	Rede óptica passiva
PMD	Dispersão por modo de polarização
QAM	Modulação de amplitude em quadratura
QPSK	Modulação por deslocamento de fase em quadratura
SNR	Relação sinal-ruído
S/P	Conversor série-paralelo
SPM	Automodulação de fase
SSMF	Fibra monomodo padrão
SVM	Máquina de vetores de suporte
VOA	Atenuador óptico variável
WDM	Multiplexação por divisão em comprimento de onda
XPM	Modulação de fase cruzada

Sumário

1	Introdução	16
1.1	<i>Redes ópticas passivas</i>	17
1.2	<i>Redes ópticas passivas de longa distância</i>	17
1.3	<i>Sistemas ópticos coerentes</i>	18
1.3.1	Efeitos não lineares em sistemas coerentes	21
1.3.2	Mitigação de efeitos não lineares em sistemas coerentes digitais . .	23
1.4	<i>Aprendizagem de máquinas para compensação de não linearidades . .</i>	25
1.4.1	Aprendizagem supervisionada	25
1.4.2	Aprendizagem não supervisionada	27
1.5	<i>Contribuição</i>	30
1.6	<i>Organização do documento</i>	30
2	Clusterização baseada em histograma	32
3	Arranjo de simulação e métricas de avaliação	34
4	Resultados	37
4.1	<i>Análise do cenário</i>	37
4.2	<i>Análise do desempenho</i>	38
4.3	<i>Análise do tamanho do bloco e complexidade computacional</i>	43
4.4	<i>Discussão</i>	46
5	Conclusão	47
	Referências	48

1 Introdução

Segundo o último relatório da Cisco, espera-se que até 2023 o número de usuários de Internet chegue aos 5,3 bilhões de pessoas, cerca de 66% da população mundial, e o número de dispositivos conectados à Internet será três vezes este número (CISCO, 2020). Metade das conexões globais corresponderá a dispositivos do tipo máquina a máquina (*M2M*), sendo a categoria de carros conectados a que mais cresce dentro do cenário dos dispositivos da Internet das Coisas (IoT, do inglês *Internet of Things*). Mesmo que estas aplicações se baseiem na maioria dos casos em transmissão sem fio, em algum momento elas irão requerer uma infraestrutura fixa que dê suporte a esse aumento. Além disso, a popularização de aplicações multimídia, como transmissão de vídeo de alta qualidade, está incrementando os requerimentos da taxa de transmissão dos usuários domésticos. A Figura 1 mostra que a evolução da capacidade média global da banda larga continua a crescer e mais que dobrará de 2018 a 2023, de 45,9 Mbps para 110,4 Mbps (CISCO, 2020). Simultaneamente, a capacidade média das conexões de dispositivos móveis será três vezes maior em 2023, sendo que nas redes 5G este valor chegará a 13 vezes a velocidade média das conexões (CISCO, 2020).




Figura 1 – Capacidade média das redes de acesso de banda-larga (CISCO, 2020).

Diante deste cenário as redes ópticas se apresentam como o único meio de transmissão capaz de atingir os requisitos de banda necessários para atender este crescimento, incentivando as operadoras de telecomunicações a buscar formas de melhorar o desempenho de suas redes e oferecer conexões de qualidade a usuários cada vez mais distantes (AGRAWAL, 2014).

1.1 Redes ópticas passivas

Entre as principais soluções para atingir os crescentes requerimentos de capacidade, as redes ópticas passivas (PONs, do inglês *passive optical networks*) têm sido amplamente empregadas. Uma rede PON é formada por um terminal de enlace óptico (OLT, do inglês *optical link terminal*) e várias unidades de redes ópticas (ONU, do inglês *optical network units*) interconectadas por uma rede de distribuição composta unicamente por elementos passivos, i.e. fibra e divisores/multiplexadores (NESSET, 2017). Devido à simplicidade da rede de acesso, as PON apresentam uma melhor confiabilidade perante os sistemas baseados em redes de distribuição ativa e maior facilidade de implementação, operação e manutenção (O&M) (KIM, 2003)(HSU *et al.*, 2010). Estas características resultam em um menor custo de instalação e manutenção, fazendo com que as PON tenham emergido como uma alternativa cada vez mais estendida para satisfazer os requerimentos de capacidade no acesso (HSU *et al.*, 2010; CHEN; HE; CHEN, 2014; LAVERY *et al.*, 2010; LAVERY *et al.*, 2013). Porém, ao não fazer uso de amplificadores ópticos, as perdas de transmissão da fibra e dos divisores, junto ao ruído do fotodetector do receptor, tendem a limitar o comprimento do enlace e a largura de banda do sistema, em especial quando a dispersão é compensada por técnicas de pré-distorção (LIU; EFFENBERGER, 2015). Assim, as PON apresentam alcances típicos entre 20 km e 30 km (TOWNSEND *et al.*, 2007; LAVERY *et al.*, 2013).

1.2 Redes ópticas passivas de longa distância

A fim de reduzir ainda mais o custo por usuário, uma opção interessante é a concentração dos recursos das OLTs, de forma a aumentar a quantidade de clientes por enlace. Porém uma maior concentração resulta naturalmente em um comprimento de

enlace maior. Para ampliar o alcance das PON, de modo a promover a redução de custos e uma melhor utilização de recursos da rede, duas abordagens podem ser consideradas. Por um lado, pode-se adotar o uso de nós ativos para compensar as perdas da fibra e dos nós de divisão (HSU *et al.*, 2010)(CHEN; HE; CHEN, 2014). Todavia, este método torna a arquitetura da rede de distribuição mais complexa, dificultando a manutenção e reduzindo a confiabilidade. Por outro lado, a evolução tecnológica dos processadores de sinais digitais (DSPs, do inglês *digital signal processors*) permitiram a implementação de receptores coerentes mais eficientes e econômicos. Assim, a adoção de receptores coerentes permite estender o alcance do enlace, pois apresentam uma melhor sensibilidade que os sistemas baseados em detecção direta, além de poder usar formatos de modulação vetorial.

Nesse contexto as PONs de longa distância (LR-PON, do inglês *long-reach PON*) baseadas em receptores coerentes vem atraindo uma atenção crescente. Ao utilizar DSPs para compensar eficientemente os impedimentos lineares, o uso desta tecnologia em enlaces LR-PONs tem se mostrado promissor para alcançar distâncias de até 100 km sem a necessidade de amplificação (ALDAYA *et al.*, 2020; HSU *et al.*, 2010; CHEN; HE; CHEN, 2014). A melhoria deste alcance é um fator que amplia as possibilidades das LR-PON, possibilitando o uso delas como redes *back-haul* em sistemas celulares 5G e conexão entre *datacenters* distribuídos (MATA *et al.*, 2018). Além da melhoria na sensibilidade, a recepção coerente permite a utilização de formatos de modulação que exploram simultaneamente a diversidade de amplitude e de fase, incrementando significativamente a capacidade dos sistemas (KIKUCHI, 2016). Porém, para atingir este aumento no produto capacidade-comprimento de enlace, os impedimentos devem ser efetivamente compensados, o que requer um conhecimento detalhado dos diferentes impedimentos e como estes impactam os sinais modulados.

1.3 Sistemas ópticos coerentes

Os sistemas ópticos coerentes se baseiam em misturar o sinal recebido com um sinal de referência a fim de obter um ganho de mistura (KIKUCHI, 2010). Estes sistemas foram inicialmente estudados durante a década de 1980, porém estas primeiras implementações apresentavam dois desafios técnicos: as flutuações de polarização e o ruído de fase dos lasers usados no transmissor e receptor (AGRAWAL, 2016). Com o desenvolvimento de amplificadores de fibra dopada no início dos anos 1990, já na quarta geração de sistemas de

comunicação óptica, os sistemas ópticos coerentes perderam interesse. Estes amplificadores permitiram incrementar o comprimento dos enlaces e o uso de multiplexação por divisão em comprimento de onda (WDM, do inglês *wavelength division multiplexing*) para aumentar a taxa de transmissão (KIKUCHI, 2016). Assim, os sistemas baseados em modulação de intensidade, combinados com enlaces *multi-span*, satisfizeram as necessidades de capacidade até o início dos anos 2000. A partir da primeira década deste milênio, os sistemas com taxas de 100 Gbps por comprimento de onda fizeram com que a sincronização virasse uma séria limitante. Uma solução a este problema é aumentar a duração do símbolo, isto é, incrementar o número de bits por símbolo. Infelizmente, a modulação de intensidade não permite um aumento do número de níveis sem causar uma sensibilidade excessiva ao ruído aditivo. Desta forma, para aumentar o número de bits por símbolo sem sacrificar a sensibilidade ao ruído, outras dimensões do sinal devem ser exploradas, por exemplo a fase. Por este motivo, os sistemas coerentes voltaram a receber uma crescente atenção a partir do ano de 2008, como forma de melhorar a eficiência espectral de sistemas WDM. Porém, diferente dos sistemas coerentes propostos na década de 1980, os novos sistemas coerentes fazem uso de DSPs para compensar o efeito do ruído de fase dos lasers. Por fazer uso de processamento digital, estes sistemas são denominados sistemas coerentes digitais (AGRAWAL, 2014).

Diferente da detecção direta anteriormente utilizada, os sistemas coerentes digitais utilizam tanto a amplitude como a fase do sinal para transmitir a informação. O esquema geral é mostrado na Figura 2.




Figura 2 – Diagrama de blocos de um sistema de comunicações coerente digital. DAC: conversor analógico-digital, DP-MZM: modulador duplo paralelo Mach-Zehnder. LD: diodo laser. SSMF: fibra monomodo padrão. LD_{LO} : diodo laser do oscilador local. PD: fotodetector. Fonte: Feito pelo autor baseado em modelo de (KIKUCHI, 2010).

Nestes sistemas, a sequência de bits é processada por um DSP para criar dois sinais digitais que, após conversão ao domínio analógico, alimentam um modulador Mach-Zehnder (MZM, do inglês *Mach-Zehnder modulator*) duplo-paralelo que modula as componentes em fase e quadratura do sinal de saída de um laser monomodo de onda contínua. O sinal modulado é então amplificado e transmitido pela rede de distribuição. No receptor, o sinal é misturado com o segundo laser de onda contínua em uma rede híbrida de 90°. Este laser tem por função servir de referência de fase da portadora na recepção do sinal transmitido. É importante notar que os lasers do transmissor e receptor são independentes. Isto é, mesmo operando em frequências próximas, suas fases estão descorrelacionadas. Por isso, a detecção não pode ser considerada homodina, pois esta presume correlação de fase. Neste caso, a detecção é denominada como intradina (KIKUCHI, 2016). O Quadro 1 compara diferentes características dos sistemas coerentes digitais e detecção direta.

Quadro 1 – Comparativo entre sistemas coerentes e de detecção direta.

	Sistemas coerentes	IM/DD
Parâmetros de modulação	Amplitude e fase	Intensidade
Método de detecção	Intradina	Detecção direta
Sensibilidade a fase da portadora	Sim	Não
Sensibilidade polarização	Sim	Não

Fonte: (KIKUCHI, 2016)

O fato de os sistemas coerentes utilizarem formatos de modulação e esquemas de detecção diferentes faz com que os impedimentos que afetam o sinal transmitido possam ter efeitos diferentes dos que ocorrem em sistemas com detecção direta. Além disso, a possibilidade de recuperar tanto a amplitude como a fase do sinal, permite uma compensação mais eficiente do que quando a informação de fase não pode ser recuperada. Desta forma, diferentes impedimentos lineares induzidos pela fibra, como a dispersão cromática (CD, do inglês *chromatic dispersion*) e a dispersão por modo de polarização (PMD, do inglês *polarization mode dispersion*), assim como o ruído de fase linear causado pelos lasers e as flutuações do estado de polarização, podem ser compensados mediante o uso de DSP. A qualidade do sinal está então limitada pela combinação dos efeitos não lineares e o ruído aditivo. No caso particular de LR-PON em que não se tem amplificadores no enlace, o ruído aditivo é causado pelos fotodetectores.

1.3.1 Efeitos não lineares em sistemas coerentes

Em sistemas com detecção direta, tanto o espalhamento não linear, i.e. Brillouin e Raman, como o efeito eletro-óptico *Kerr* possuem potencial para limitar o desempenho de sistemas, dependendo da potência óptica lançada na fibra (AGRAWAL, 2014). Em sistemas coerentes, ao contrário, o efeito *Kerr* é comumente identificado como a distorção não linear dominante (KIKUCHI, 2016). Este efeito resulta em automodulação de fase (SPM, do inglês *self-phase modulation*), modulação de fase cruzada (XPM, do inglês *cross-phase modulation*) e mistura de quatro ondas (FWM, do inglês *four-wave mixing*) que desempenham um papel importante no âmbito dos sistemas coerentes, pois convertem flutuações de intensidade em flutuações de fase (AGRAWAL, 2000). Este efeito ocorre devido a variação do índice de refração local em presença de um campo óptico intenso e pode ocorrer, por exemplo, quando um ou vários sinais a diferentes comprimentos de onda se propagam simultaneamente dentro de uma fibra, pois a pequena área modal das fibras SSMF, resulta em uma alta intensidade (AGRAWAL, 2000). O efeito *Kerr* é quantificado por meio da susceptibilidade elétrica de terceira ordem $\chi^{(3)}$ o que por sua parte causa diferentes distorções no sinal.

O efeito de SPM refere-se ao deslocamento de fase autoinduzido que um campo óptico sofre durante a propagação em um meio não linear. Desta forma, o deslocamento de fase resultante em um segmento de comprimento L , assumindo que a potência do sinal permanece constante, é dado por:

$$\phi = (n + n_2 I) k_0 L, \quad (1)$$

em que $k_0 = \omega/c = 2\pi/\lambda$, ω é a frequência angular, λ é o comprimento de onda e I é a intensidade do sinal que se propaga pelo meio. n representa o índice de refração linear de fase e n_2 o coeficiente não linear. É claro que o deslocamento de fase não linear resultante de SPM é (AGRAWAL, 2000):

$$\phi_{NL} = n_2 k_0 L I, \quad (2)$$

o qual pode ser alternativamente expresso em termos da potência transmitida conforme:

$$\phi_{NL} = \gamma L P, \quad (3)$$

em que $\gamma = n_2 k / A_{eff}$. A Equação 3 ainda considera que a potência permanece constante e, portanto, é válida para segmentos muito curtos de fibra. Para considerar segmentos maiores

em que a atenuação da fibra é significativa, L deve ser substituído pelo comprimento efetivo da fibra:

$$L_{eff} = \frac{1 - \exp(-\alpha L)}{\alpha}, \quad (4)$$

sendo α o coeficiente de atenuação da fibra. É importante notar que o deslocamento não linear depende da potência óptica instantânea. Na ausência de CD, o deslocamento de fase não linear segue adiabaticamente a forma do pulso. Quando o meio apresenta CD, esta provoca interferência inter-simbólica fazendo com que símbolos adjacentes interajam não linearmente. Esta interação entre diferentes símbolos resulta em um efeito aparentemente estocástico que se denomina ruído de fase não linear.

Já o efeito causado pela XPM se apresenta quando vários sinais, multiplexados em comprimento de onda, são transmitidos simultaneamente por um meio não linear e a fase de um dos sinais é modificada pela intensidade do outro sinal. Assim, o deslocamento de fase induzido é dado por (AGRAWAL, 2000):

$$\phi_{NL1} = 2\gamma L_{eff} P_2, \quad (5)$$

sendo ϕ_{NL1} o deslocamento de fase induzido num dos sinais pelo outro sinal com potência P_2 . Pode-se observar que as expressões que descrevem a SPM e a XPM são similares. A única diferença é o fator 2 que deve ser incluído para considerar a degenerescência do processo XPM.

Como citado acima, o fenômeno conhecido como FWM também é causado pelo efeito *Kerr*. No caso não degenerado, quatro ondas interatuam para transferir energia entre si. A fim de verificar o princípio de conservação de energia, as frequências destes sinais devem estar relacionadas por $\omega_4 = \omega_1 \pm \omega_2 \pm \omega_3$, sendo ω_i a frequência do sinal i -ésimo. Esta expressão pode ser modificada para o caso parcialmente degenerado ($\omega_3 = 2\omega_1 \pm \omega_2$) e para o caso completamente degenerado ($\omega_2 = 3\omega_1$) (AGRAWAL, 2014). Porém somente o caso completamente degenerado e parcialmente degenerado tem interesse prático como mecanismos de distorção não linear em sistemas práticos. Por outro lado, além de verificar o princípio de conservação de energia, a eficiência do processo de FWM depende do casamento de fase entre as diferentes componentes que interagem. Em sistemas coerentes, em que a rede de distribuição geralmente não inclui fibra compensadora de dispersão, assume-se que FWM não é tão eficiente como em sistemas baseados em detecção direta (BOYD, 2019).

O peso relativo de SPM, XPM e FWM na transmissão do sinal, assim como a resultante distorção da constelação dependerá de diferentes parâmetros do sistema. Evidentemente, em sistemas de um único canal, SPM será o único mecanismo de distorção não linear da fibra e provocará na constelação uma rotação de fase não linear, adquirindo uma forma espiral característica. Além disso, o SPM, mesmo sendo determinístico, interage com a dispersão cromática, resultando em um efeito que parece estocástico e que geralmente se denomina ruído de fase não linear, ou efeito Gordon-Mollenauer (GORDON; MOLLENAUER, 1990). Em sistemas multicanal, por outro lado, XPM e FWM também estarão presentes, sendo o primeiro, geralmente o efeito dominante (AGRAWAL, 2000). Isto ocasionará além de uma distorção de forma espiral, também uma dispersão de pontos maior (SEMRAU; KILLEY; BAYVEL, 2018).

1.3.2 Mitigação de efeitos não lineares em sistemas coerentes digitais

Conforme mencionado anteriormente, junto com o ruído aditivo do receptor, o efeito Kerr é o fator limitante em sistemas coerentes. Como o efeito Kerr é determinístico, ele pode ser a priori mitigado. Neste cenário, múltiplas técnicas têm sido propostas para mitigar a distorção não linear e estender ao máximo o alcance do enlace ou a margem de potência disponível (TORRES-ZUGAIDE *et al.*, 2017). Estas técnicas podem ser classificadas, dependendo da sua implementação, no domínio óptico ou elétrico.

As técnicas no domínio óptico caracterizam-se por utilizar mecanismos ópticos que não requeiram eletrônica ou, ao menos, não eletrônica de alta frequência. Em (ROS *et al.*, 2014), o autor avalia experimentalmente uma técnica para mitigação do efeito *Kerr*, usando conjugação de fase óptica na metade do enlace de um link de dispersão compensada com distância de 800 km e formato de modulação de amplitude em quadratura (QAM, do inglês *quadrature amplitude modulation*) com 5 canais WDM de 28 GBauds e multiplexados em polarização. Em (DU; MORSHED; LOWERY, 2012) demonstrou-se experimentalmente a compensação de não linearidades em supercanais multi-portadora usando conjugação de fase óptica (OPC, do inglês *optical phase conjugation*). Já em (LIU *et al.*, 2013), se propõe um método para realizar o cancelamento da distorção não linear, por meio da transmissão simultânea de um par de ondas gêmeas conjugadas em fase (PCTW, do inglês *phase conjugated twin waves*), detectando e sobrepondo-as em um receptor coerentemente. Estas

técnicas de modo geral carecem de flexibilidade e são de difícil implementação fora do laboratório. Técnicas eletrônicas: As técnicas de compensação elétricas são implementadas no DSP após a digitalização dos sinais fotografados. Os algoritmos utilizados, por sua vez, podem ser divididos em inversão de modelo e aqueles baseados em aprendizagem de máquinas.

As técnicas eletrônicas baseadas em inversão de modelo baseiam-se em obter um modelo mais ou menos preciso do canal não linear e achar o sistema inverso deste modelo. Entre as diferentes técnicas de inversão de modelo, a mais simples é a conhecida como modelo *Wiener-Hammerstein*, a qual consiste em um elemento não linear estático combinado com dois elementos lineares dinâmicos. Em (MILLAR *et al.*, 2010), o autor investiga o desempenho de um equalizador de *Wiener-Hammerstein* na compensação de não linearidades entre canais de sistemas PDM-QPSK e PDM-16QAM para distâncias de 7.780 km e 1.600 km, respectivamente. Em (MHATLI *et al.*, 2015) propõe-se a utilização de outro equalizador *Wiener-Hammerstein* para sistemas metropolitanos, enquanto que em (TORRES-ZUGAIDE *et al.*, 2017; TORRES-ZUGAIDE *et al.*, 2016) aplica-se esta técnica em redes de acesso. O modelo de *Wiener-Hammerstein* é simples mas não é capaz de compensar eficientemente a distorção não linear, principalmente em sistemas *multi-span* em que a distorção não linear acontece em diferentes pontos do enlace. Neste contexto, equalizadores baseados em retro-propagação digital (DBP, do inglês *digital back-propagation*) e na função de transferência inversa da série Volterra (IVSTF, do inglês *Inverse Volterra Series Transfer Function*) foram desenvolvidos. Em (PAKALA; SCHMAUSS, 2015) os autores usam DBP para mitigar as não linearidades em sistemas coerentes com modulação QAM, ao passo que em (GIACOU MIDIS *et al.*, 2014) é proposto o uso de um equalizador não linear reconfigurável baseado na IVSTF para sinais de dupla polarização e multiplexação óptica por divisão de frequência ortogonal (OFDM, do inglês *orthogonal frequency division multiplexing*). Infelizmente, os equalizadores baseados em DBP ou IVSTF sofrem de um custo computacional proibitivo, impossibilitando a sua aplicação em sistemas em tempo real.

A fim de atingir simultaneamente um bom desempenho e um custo computacional aceitável, as técnicas eletrônicas baseadas em aprendizagem de máquinas têm sido propostas e estudadas recentemente. Devido a importância de tais técnicas para o posicionamento deste trabalho, dedicaremos uma subseção a este assunto.

1.4 Aprendizagem de máquinas para compensação de não linearidades

Aprendizagem de máquinas é o termo empregado para definir a detecção automatizada de padrões significativos, realizados por um sistema automatizado em uma determinada coletânea de dados (SHALEV-SHWARTZ; BEN-DAVID, 2014). A aprendizagem de máquinas pode ser dividida em dois tipos, a aprendizagem supervisionada e a não supervisionada, dependendo se a técnica utilizada necessita ou não de uma sequência de dados para treinar e otimizar os parâmetros. No Quadro 2 é apresentada de forma resumida esta categorização e os algoritmos mais comuns para cada categoria, mostrando de forma sucinta as características de alguns deles.

Quadro 2 – Comparativo entre as técnicas de Aprendizagem de máquinas.

Aprendizagem de máquinas		
Supervisionada		Não Supervisionada
Classificação	Regressão	
ANN	ANN	<i>K-means</i>
KNN	Regressão polinomial	DBSCAN
SVM	SVR	Maximização da expectativa

1.4.1 Aprendizagem supervisionada

Nestes algoritmos, temos um conjunto de treinamento que contém uma sequência de entradas e seus valores de saída correspondentes, conforme fornecido por um supervisor (ALPAYDIN, 2016). No caso de redes ópticas, é enviada uma sequência de treinamento, de maneira que o receptor conheça os valores ideais associados aos dados recebidos. Todavia, mesmo tendo um bom desempenho na compensação de impedimentos não lineares, a necessidade de envio desta sequência acaba por reduzir a taxa de transferência efetiva, limitando a capacidade destes algoritmos para se adaptar em redes reconfiguráveis. As técnicas de aprendizagem supervisionada, por sua vez, podem se dividir em técnicas baseadas em classificação e regressão.

Os algoritmos de classificação caracterizam-se por associar um rótulo de saída a cada elemento de entrada, gerando um domínio de saída discreto. Assim cada elemento

de entrada é associado a uma classe de saída determinada (ALPAYDIN, 2016). Esta classificação pode ser implementada utilizando diferentes alternativas:

- Redes neurais artificiais (ANN, do inglês *artificial neural networks*): Esta técnica emula as interações do cérebro humano, sendo composta por uma rede com unidades de processamento simples, chamadas neurônios (ou nós) e as múltiplas conexões entre estes são chamadas de sinapses. Cada sinapse tem uma direção e um peso, e o peso define o efeito do neurônio anterior sobre o neurônio posterior (ALPAYDIN, 2016).
- K-ésimo vizinho mais próximo (KNN, do inglês *k nearest neighbour*): Nesta técnica um novo elemento é associado à classe correspondente e à classe majoritária dos k vizinhos mais próximos (ALPAYDIN, 2016). Esta técnica tem sido avaliada em sistemas metropolitanos (PÉREZ; TORRES, 2019; WANG *et al.*, 2016) e também em sistemas LR-PON (PAULA *et al.*, 2020).
- Máquina de vetores de suporte (SVM, do inglês *support vector machine*): O princípio da SVM, também conhecida como *kernel machine*, é aplicado em um conjunto de instâncias cujas amostras pertencem a duas classes. A SVM constrói um hiperplano e busca maximizar a separação entre as classes através da criação de duas regiões, o qual é denominado hiperplano de separação ótima. As amostras desconhecidas (não classificadas) são então mapeadas para esse mesmo espaço, e atribuídas a uma das classes (ALPAYDIN, 2009; SHALEV-SHWARTZ; BEN-DAVID, 2014). As SVMs têm sido aplicadas na compensação de não linearidade, por exemplo em (GIACOUMIDIS *et al.*, 2016c).

Ao contrário da classificação, os algoritmos de regressão caracterizam-se por um domínio de saída contínuo. Desta forma, mediante regressão, visa-se inverter o efeito do canal recuperando o sinal antes de sofrer a distorção não linear. O modelo baseia-se na dependência entre a entrada e a saída de dados para prever os valores de saída de uma nova amostra. Na regressão, esta precisão depende de quão perto as previsões do modelo estão dos valores de saída observados nos dados de treinamento, levando-se em conta que os dados de treinamento refletem suficientemente bem as características da segunda amostra (ALPAYDIN, 2016). Assim como na classificação, diferentes técnicas podem ser adotadas para implementar a regressão:

- ANN: já explicada na subseção anterior, as ANNs podem ser configuradas tanto para classificação como para regressão. As ANNs tem sido extensamente propostas para compensação de não linearidades mediante regressão em diferentes cenários e com diferentes formatos de modulação. Por exemplo, um *perceptron* multi-camada é utilizado em (KUNCHEVA, 2014) para um sistema com modulação de portadora única, enquanto que em (JARAJREH *et al.*, 2014) e em (GIACOUMIDIS *et al.*, 2019) tem sido proposta uma rede completamente conectada para sistemas multiportadora.
- Regressão polinomial: quando um conjunto de dados se apresenta de forma não linear, faz-se necessário encontrar uma função que se adéque aos dados. Assim, é possível ajustar os graus de complexidade da função de forma a encontrar a função que melhor se adéque aos dados recebidos. Na regressão polinomial, o parâmetro de complexidade é a ordem do polinômio ajustado, o qual precisa ser otimizado para não ser demais complexo nem demais simples, possibilitando assim o erro de generalização (SHALEV-SHWARTZ; BEN-DAVID, 2014) (ALPAYDIN, 2009).
- Regressão por vetores de suporte (SVR, do inglês *support vector regression*): Este método aplica a técnica de SVM para a regressão, porém, ao contrário da separação realizada na classificação, aqui é construída uma função não linear como soma dos diferentes vetores de suporte. Na SVR é usada uma abordagem que busca definir margens moderadas aceitáveis, de forma a obter uma função que ajusta os valores de treinamento a uma função não linear que se adéque à maioria dos pontos. Desta forma, a constelação após o tratamento é mais próxima à constelação ideal e a taxa de erro é reduzida (BISHOP, 2006) (ALPAYDIN, 2009). Em (GIACOUMIDIS *et al.*, 2016b) os autores apresentam um novo método de equalização de não linearidades implementando SVR baseado em DSP, com multiplexação 16-QAM e modulação CO-OFDM, e o comparam experimentalmente com DBP em um enlace de 2.000 km.

1.4.2 Aprendizagem não supervisionada

Se na aprendizagem supervisionada, os parâmetros do sinal são obtidos por meio de um mapeamento da entrada para uma saída cujos valores corretos são fornecidos por um supervisor; na aprendizagem não supervisionada, não existe tal supervisor e temos apenas os dados de saída. Assim, a aprendizagem não supervisionada procura a estrutura

mais adequada para os dados que apresentam padrões subjacentes (ALPAYDIN, 2009). Ainda que existam alguns trabalhos relatando algoritmos de regressão não supervisionados, i.e. (GIACOMIDIS *et al.*, 2016a), a maioria destes algoritmos implementam classificação. É importante esclarecer que muitas vezes os algoritmos de classificação não supervisionada são denominados de *clusterização*, pois procuram agrupamento de pontos (*cluster*) sem nenhum conhecimento prévio. Entre os métodos de clusterização mais estudados, podemos encontrar os seguintes:

- *K-means*: Este algoritmo realiza a clusterização minimizando a distância dos pontos a k centroides, baseando-se exclusivamente na distância entre os pontos e trabalhando de forma iterativa. Em uma primeira etapa, é atribuído a cada amostra o centroide mais próximo. Na segunda etapa, a localização dos centroides dos agrupamentos é recalculada de acordo com novas atribuições. O procedimento termina quando a convergência é alcançada e não há alteração do valor da função de custo entre iterações sucessivas (BOADA; BORKOWSKI; MONROY, 2015). Entre os trabalhos que utilizam *K-means* para compensar as não linearidades podemos mencionar: (PAKALA; SCHMAUSS, 2015) e (ZHANG *et al.*, 2017).
- Agrupamento espacial baseado em densidade de aplicações com ruído (DBSCAN, do inglês *Density-based spatial clustering of applications with noise*): Como o próprio nome indica, este é um método baseado em densidade que agrupa o conjunto de dados com base na vizinhança de um conjunto de amostras. O DBSCAN necessita de apenas dois parâmetros: o raio mínimo para os agrupamentos (ξ) e o número mínimo de pontos necessários para formar um agrupamento (K_{min}). O algoritmo verifica se, para cada amostra do conjunto de dados, as condições definidas pelo algoritmo são atendidas, e se é possível iniciar um novo agrupamento ou expandir um existente (BOADA; BORKOWSKI; MONROY, 2015). Este algoritmo tem sido utilizado para compensar não linearidades em sistemas de comunicação ópticas em (LIN *et al.*, 2019).
- Maximização de expectativa (EM, do inglês *expectation maximization*): Este algoritmo visa extrair os parâmetros de um modelo de mistura gaussiana, ou seja, uma soma de distribuições normais multivariadas ponderadas, pelo ajuste dos dados de entrada. Este processo requer achar os parâmetros das diferentes distribuições: médias (μ_k), matrizes de covariância (Σ_k) e coeficientes de mistura (π_k). EM resulta

em regiões de decisão que se adaptam bem à distribuição de pontos, mas devido ao grande número de parâmetros de otimização, requer técnicas avançadas para sua inicialização, como por exemplo *K-means*. Posteriormente, as etapas de expectativa (E) e maximização (M) são iteradas até que a convergência seja alcançada. Primeiro, na etapa E, as probabilidades para cada amostra pertencente a cada agrupamento, também chamadas de responsabilidades, são calculadas. Na etapa M, o conjunto de parâmetros que definem o modelo é recalculado usando os novos valores de responsabilidades. A iteração termina quando a função de custo não muda entre iterações sucessivas (BOADA; BORKOWSKI; MONROY, 2015). Em (ZIBAR *et al.*, 2012), EM é avaliada como técnica de clusterização para compensar o ruído de fase não linear.

Conforme apresentado, diversas técnicas foram propostas para mitigar os efeitos não lineares causados pela transmissão por fibra. As técnicas ópticas carecem de flexibilidade ao mesmo tempo que necessitam de um projeto mais cuidadoso da rede óptica (ROS *et al.*, 2014). As técnicas de compensação eletrônica utilizando DBP (IP; KAHN, 2008) (MILLAR *et al.*, 2010) e equalização não linear baseada em IVSTF (GIACOU MIDIS *et al.*, 2014) demandam um elevadíssimo custo computacional que resulta em consumo energético e latência proibitivos. Diante destes desafios, a aprendizagem de máquinas se destaca como uma ferramenta importante, utilizada por vários grupos para tratar os sinais afetados pelos impedimentos não lineares (ZIBAR *et al.*, 2015) (GIACOU MIDIS *et al.*, 2019) (KHAN; LU; LAU, 2017) (MATA *et al.*, 2018). As abordagens supervisionadas propostas, utilizando ANN (AHMAD; KUMAR, 2016), (CHEN; TAO; ZHAO, 2006) e (JARA JREH *et al.*, 2014) SVM (NGUYEN *et al.*, 2016) (WANG *et al.*, 2015) (GIACOU MIDIS *et al.*, 2014), apresentaram um bom desempenho, mas devido ao fato de serem supervisionadas têm uma redução na taxa transmissão efetiva derivada da necessidade da transmissão de uma sequência de treinamento (particularmente em redes dinâmicas). Em outra vertente, o aprendizado não supervisionado baseado em clusterização dispensa o envio de sequências de treinamento, na medida que o algoritmo aprende com o próprio conjunto de dados. Dentre os algoritmos de clusterização, o mais popular é o *K-means* (ZHANG *et al.*, 2017) (LI *et al.*, 2013) (BOADA; BORKOWSKI; MONROY, 2015) e (PAKALA; SCHMAUSS, 2015). Giacomindis propôs o uso de clusterização baseada na propagação de afinidade (AP) (GIACOU MIDIS *et al.*, 2018) para tratar constelações de formato arbitrário; e DBSCAN

para melhorar o desempenho de sistemas afetados pela distorção não linear e pelo ruído aditivo (GIACOUMIDIS; LIN; BARRY, 2019). O efeito do ruído aditivo também foi tratado com sucesso a partir do uso de classificação baseada na EM (ZIBAR *et al.*, 2012). Todavia estes algoritmos sofrem com limitações derivadas de suas próprias características. Devido ao fato de suas regiões de decisão serem limitadas por fronteiras retas, o *K-means* não é apropriado para tratar de constelações fortemente afetadas por SPM. Por sua vez, o DBSCAN depende da definição de parâmetros ξ e K_{min} , respectivamente o raio da área e o número mínimo de pontos desta área (ALDAYA *et al.*, 2020).

1.5 Contribuição

Neste trabalho é proposto e analisado um novo algoritmo baseado em densidade, denominado clusterização baseada em histograma (HBC, do inglês *histogram-based clustering*) (ALDAYA *et al.*, 2020), que mitiga parcialmente o efeito do ruído de fase não linear causado pela SPM. De forma particular, foi estudada a utilização deste algoritmo em redes LR-PON com um único comprimento de onda e com comprimento de 80 km+20 km, formato de modulação 16-QAM e taxa de transmissão de 56 Gbps. Os resultados numéricos mostram que o algoritmo proposto é capaz de compensar o ruído de fase não linear mais eficientemente que o *K-means*, devido ao fato de conseguir calcular regiões de decisão com fronteiras curvas, que são melhor adaptadas à distribuição dos símbolos afetados por ruído de fase não linear. Além disso, também é analisada a complexidade computacional do algoritmo HBC, que devido ao fato de ser não iterativo, apresenta uma complexidade determinística.

1.6 Organização do documento

O presente documento contém cinco capítulos, sendo que este primeiro capítulo foi dedicado a justificar o problema de pesquisa e a introduzir as diferentes soluções encontradas na literatura e suas respectivas limitações. O restante do trabalho encontra-se organizado da seguinte forma:

1. No Capítulo 2 é descrito detalhadamente o algoritmo proposto, incluindo um diagrama de fluxo com as diferentes etapas e um exemplo de uso simplificado;

2. No Capítulo 3 descreve-se a configuração da simulação da rede LR-PON utilizada para avaliar o algoritmo;
3. No Capítulo 4 são apresentados os resultados numéricos, que incluem a análise de desempenho para diferentes níveis de potência e a comparação com *K-means*, que é usado como *benchmark*. Neste capítulo também se estuda o tamanho de bloco requerido e a complexidade computacional do algoritmo proposto;
4. Finalmente, no Capítulo 5 apresentam-se as principais conclusões e os possíveis trabalhos futuros.

2 Clusterização baseada em histograma

Após observar as distribuições dos símbolos em constelações de sistemas profundamente afetados por ruído de fase não linear, foi percebido que esta densidade de pontos podia ser utilizada para identificar as regiões de alta densidade, que correspondem às diferentes classes. Com base nesta ideia, desenvolveu-se um algoritmo que foi denominado agrupamento baseado em histograma (HBC, do inglês *Histogram-based clustering*). Ele caracteriza-se por ser um algoritmo de agrupamento não iterativo, baseado em densidade e com custo computacional determinístico. O HBC analisa a densidade dos pontos em um histograma 2D de forma a atribuir uma classe ao agrupamento nas áreas de alta densidade de pontos. Em comparação com outros algoritmos de clusterização o algoritmo proposto apresenta algumas vantagens. Podemos citar, por exemplo, o algoritmo *K-means*, que não leva em consideração as informações de densidade ou o algoritmo EM que requer uma inicialização complexa e uma otimização iterativa; ou ainda os algoritmos de densidade como o DBSCAN, que precisa da configuração de parâmetros adicionais (ξ e K_{min}).

O diagrama de fluxo do algoritmo é apresentado na Figura 3. Esse diagrama é baseado em um exemplo em que foram empregados 10.000 símbolos 16-QAM, obtidos a partir da aplicação de uma rotação de fase não linear dependente da amplitude ($\Delta\phi[n] = 3A^2[n]$, sendo $A[n]$ a amplitude do símbolo). Posteriormente foi adicionado ruído aditivo complexo a fim de fixar uma relação sinal-ruído (SNR, do inglês *signal-to-noise ratio*) de 20 dB. Vale destacar que este modelo, por ser simplificado e para fins de demonstração, não representa com precisão o sistema, pois não considera a interferência inter-simbólica (ISI) (ALDAYA *et al.*, 2020). A partir da constelação recebida (Figura 3a), o histograma dos símbolos é calculado (neste caso 40 segmentos foram utilizados em cada uma das direções, fase e quadratura), resultando no gráfico de contorno apresentado na Figura 3b. Neste gráfico, as 16 agrupações de alta densidade podem ser claramente identificadas. Além das áreas de alta densidade, o diagrama de contorno permite obter curvas de contorno correspondentes a diferentes níveis de densidade. Na Figura 3c, podemos ver que a linha de contorno de menor valor, que resulta em 16 ilhas isoladas, confina os pontos que representam cada uma das classes (Figura 3d). As bordas destas ilhas, que determinam os diferentes agrupamentos, estão sobrepostas no histograma, mostrando que nas regiões de constelação com distorção mais forte, aqueles na periferia, os limites dos diferentes




Figura 3 – Diagrama de fluxo do algoritmo de clusterização proposto. (a) Símbolos 16-QAM distorcidos na entrada do algoritmo. (b) Histograma 2D calculado. (c) Limites ótimos sobrepostos no histograma 2D. (d) Limites para cada agrupamento no topo da constelação distorcida recebida. (e) Constelação classificada. Fonte: (ALDAYA *et al.*, 2020).

agrupamentos estão mais próximos. Cada agrupamento é então identificado pelos pontos que formaram seu limite. Pode-se identificar os limites dos diferentes agrupamentos no topo da constelação recebida, em que é possível visualizar que os limites dos agrupamentos obtidos abrangem a maioria dos pontos de seus respectivos agrupamentos. Na Figura 3(e), depois que os pontos limite de cada agrupamento são encontrados, a distância de cada símbolo recebido até eles é calculada e a classe do ponto limite com a menor distância é atribuída ao símbolo. De forma simplificada, o algoritmo tem a seguinte sequência:

1. Cálculo do histograma 2D dos componentes em fase e quadratura dos N_s símbolos recebidos;
2. Determinação da linha de contorno mais baixa no histograma que resulte no número de agrupamentos a serem identificados;
3. Atribuição de um identificador ID de classe aos valores do limite para cada agrupamento;
4. Determinação do ponto de limite mais próximo e associação, para cada símbolo recebido, ao seu ID de classe.

3 Arranjo de simulação e métricas de avaliação

Na Figura 4 é apresentado o diagrama de blocos da rede LR-PON utilizada para avaliar o desempenho do algoritmo HBC. Nestas simulações, as tarefas de modulação e demodulação foram implementadas em MATLAB. A conversão do domínio elétrico para o óptico, assim como a transmissão e recepção do sinal por meio da rede de distribuição passiva foram simulados no *VPITransmissionMaker*. Este entorno de co-simulação foi adotado porque permite explorar simultaneamente a flexibilidade de MATLAB para processar digitalmente os sinais e fazer uso dos modelos consolidados para dispositivos ópticos e fotônicos que *VPITransmissionMaker* fornece.

No lado do transmissor, um diodo laser (LD_1) de onda continua com potência de transmissão de 1 mW e operando a 1.550 nm foi modulado usando um MZM duplo paralelo (DP-MZM, do inglês *dual-parallel Mach-Zehnder modulator*) alimentado pelas componentes em fase e quadratura do sinal modulante. Estas componentes correspondem a um sinal complexo passa-baixa 16-QAM de 56 Gbps, filtrado por um filtro Bessel de quarta ordem com uma largura de banda de 10,5 GHz e convertido ao domínio analógico por conversores analógico-digitais (DAC, do inglês *digital-to-analog converters*). Para emular o domínio analógico, uma taxa de amostragem de $8,96 \times 10^{11} \text{ s}^{-1}$ foi utilizada. O sinal óptico modulado foi amplificado por um amplificador de fibra dopada a érbio (EDFA, do inglês *erbium-doped fiber amplifier*), e de forma a controlar a potência de transmissão entre 2 e 12 mW foi usado um atenuador óptico variável (VOA, do inglês *variable optical attenuator*). Como a potência de saída do EDFA foi fixada, o ruído de emissão espontânea amplificada (ASE, do inglês *amplified spontaneous emission*) adicionado pelo amplificador




Figura 4 – Diagrama de blocos do sistema simulado LR-PON coerente. S/P: conversão serial-paralelo. DAC: conversor digital-analógico. DL: diodo laser. DP-MZM: modulador duplo paralelo Mach-Zehnder. EDFA: amplificador de fibra dopada com érbio. VOA: atenuador óptico variável. SSMF: fibra monomodo padrão. DPT: Rastreador de polarização dinâmica. LPF: filtro passa-baixa. ADC: conversor analógico-digital. Fonte: (ALDAYA *et al.*, 2020).

permaneceu constante. Além disso, dado o ganho relativamente baixo do amplificador, a potência do ruído ASE que chega na saída do receptor é insignificante em comparação com a potência do ruído do receptor (ALDAYA *et al.*, 2020).

A rede de distribuição simulada foi composta de um primeiro enlace de fibra monomodo padrão (SSMF, do inglês *standard single-mode fiber*) com 80 km de comprimento, um divisor de 1 para 64 (1:64) que foi emulado por um atenuador de 18 dB e um segundo segmento SSMF com 20 km de extensão. A propagação do sinal por ambos os enlaces de fibra foi simulada a partir da solução da equação não linear de *Schrödinger* pelo método de Fourier de passo dividido (SSFM, do inglês *Split-Step Fourier Method*) com discretização espacial adaptativa.

No receptor, o primeiro passo foi reduzir as flutuações do estado de polarização mediante um rastreador de polarização dinâmico (DPT, do inglês *dynamical polarization tracker*). Uma vez fixado o estado de polarização para coincidir com aquele do oscilador local, o sinal é combinado em uma rede híbrida de 90° alimentada com um segundo diodo laser de onda contínua com potência de 1 mW (LD_2) e comprimento de onda de operação de 1.550 nm. Os sinais combinados são então foto-detectados e filtrados por filtros passa-baixas (LPFs, do inglês *low-pass filters*) antes de serem diferencialmente amplificados. A conversão digital para analógica (ADC, do inglês *digital-to-analog conversion*) foi emulada reduzindo a frequência de amostragem do sinal para quatro amostras por símbolo.

O primeiro passo no DSP foi a compensação de CD no domínio da frequência. Posteriormente, a sincronização do sinal foi realizada pelo método de maximização de correlação cruzada usando uma sequência de sincronização alternada de 64 símbolos. A fim de reduzir a sobrecarga, essa sequência de sincronização também foi empregada para a correção de amplitude e sincronização de fase inicial. Após a mitigação da CD, sincronização e normalização, o sinal passou por um segundo processo de redução da resolução temporal para obter uma única amostra por símbolo. A correção do ruído de fase foi realizada por busca cega de fase operando em blocos de 32 símbolos. Nestas simulações, não foi considerada a PMD pois, ao contrário da CD, ela não interage significativamente com a distorção não linear e poderia ser compensada satisfatoriamente em modulações de envelope variável usando, por exemplo, algoritmo de módulo múltiplo (MMA, do inglês *multi-modulus algorithm*). As constelações distorcidas foram então processadas usando o algoritmo HBC proposto. Para fins de comparação, também são apresentados os resultados considerando a máxima verossimilhança, bem como *k-means*, que são consideradas *benchmarks* para

detecção linear e clusterizada, respectivamente. O Quadro 3 lista os parâmetros mais importantes da simulação.

Quadro 3 – Parâmetros utilizados na simulação da rede LR-PON.

Parâmetros do Sistema			
Largura do laser	0,5 MHz	Comprimento da fibra (L_1, L_2)	80km, 20 km
Potência do laser	1 mW	Atenuação da fibra	0,2 dB
Perda de inserção MZM	6 dB	CD da fibra	16 ps/nm/km
Ganho do amplificador	20 dB	PMD da fibra	3,16 ps/ $\sqrt{km}$
Figura de ruído do amplificador	4 dB	Coefficiente não-linear	$1,3 \cdot W^{-1} \cdot km^{-1}$
Atenuador	20dB	Area efetiva da fibra	80 μm^2
Densidade do ruído térmico PD	10 pA / $\sqrt{Hz}$	Largura de banda do filtro elétrico	10,5 GHz
Responsividade PD	1 W/A	Ordem do filtro de recepção elétrica	4
Parâmetros do Sinal			
Formato de modulação	16-QAM	Número de símbolos de sincronização	64
Filtro elétrico TX	Bessel de 4ª ordem	Taxa de transmissão de bits	56 Gbps
Parâmetros de Simulação			
Numero de símbolos simulados	16.384	Taxa de amostragem	$8,96 \times 10^{11} s^{-1}$

Fonte: (ALDAYA *et al.*, 2020)

Como métrica de qualidade de sinal foi adotada a taxa de erro de bits (BER, do inglês *bit error ratio*), que, considerando a falta de gaussianidade da distribuição dos pontos da constelação, foi estimada por contagem de erros e também foi calculado o fator Q equivalente (AGRAWAL, 2014), derivado da BER de acordo com:

$$Q = \sqrt{2} \operatorname{erfc}^{-1}(2BER), \quad (6)$$

em que erfc^{-1} representa a função de erro complementar inversa dada por:

$$\operatorname{erfc}(x) = \frac{2}{\sqrt{\pi}} \int_x^\infty e^{-t^2} dt. \quad (7)$$

Por outro lado, o desempenho da técnica de compensação de não linearidades foi avaliada em função da melhora da BER assim como o incremento no fator Q, que é uma métrica amplamente adotada pela comunidade.

4 Resultados

4.1 Análise do cenário

Nesta seção serão discutidos de forma breve os sistemas LR-PON de múltiplo comprimento de onda em que a distribuição aos diferentes usuários é realizada por demultiplexação de comprimento de onda. Para analisar o desempenho do sistema WDM LR-PON, foi utilizado um arranjo similar ao apresentado na Figura 5 mas considerando cinco transmissores operando em torno a 1.550 nm com uma separação frequencial de 50 GHz. Por outro lado, o atenuador que emula o divisor é eliminado pois, nos sistemas WDM não temos perdas de divisão. Finalmente, cada receptor é precedido de um filtro para selecionar o canal desejado.




Figura 5 – Sistema WDM-LR-PON utilizado no cenário.

A Figura 6 mostra as constelações obtidas para o canal central do sistema WDM, que a princípio é o canal mais afetado pela distorção não linear intercanal, i.e. XPM e FWM, considerando potências de transmissão de (a) 1 mW e (b) 3 mW. Em ambos os casos, são apresentadas as constelações considerando unicamente SPM e SPM, XPM e FWM simultaneamente. O primeiro ponto a observar é que os efeitos não lineares são muito mais aparentes para uma potência de transmissão de 3 mW. Neste caso, pode-se observar o efeito de XPM e FWM, resultando em um espalhamento maior que quando é considerado unicamente SPM.




Figura 6 – Constelações obtidas para o canal central de um sistema WDM LR-PON com potências de transmissão de (a) 1 mW e (b) 3 mW. As figuras mostram constelações considerando unicamente SPM e SPM, XPM e FWM.

De toda forma, observando as constelações, está claro que a SNR da constelação é alta inclusive para potência de transmissão de 1 mW, fazendo que os diferentes símbolos estejam suficientemente separados. Este cenário é relativamente favorável para técnicas de clusterização clássicas, como *K-means*, e não requerem algoritmos mais sofisticados para classificar corretamente os símbolos. Por outro lado, como pode ser visto na seção seguinte, as constelações obtidas para um sistema LR-PON em que o sinal é distribuído por *broadcast*, as grandes perdas de divisão fazem com que a potência recebida seja muito menor, resultando em SNRs baixas e que os agrupamentos associados a cada ponto da constelação se sobreponham. Este é um caso extremadamente desafiador para clusterização pois, as regiões de decisão devem ser estabelecidas de forma mais precisa. Em resumo, podemos concluir que a classificação em LR-PON de um único canal é mais complicada e, por tanto, representa um problema em que algoritmos de clusterização mais sofisticados, como o HBC, são requeridos.

4.2 Análise do desempenho

Tal e como mencionado no capítulo anterior, o desempenho do algoritmo será quantificado por meio da BER e do fator Q efetivo. Nas Figuras 7a e b, são apresentadas estas figuras de mérito em função da potência óptica lançada na fibra, a qual foi variada desde 2 até 12 mW.




Figura 7 – Desempenho do HBC em função da potência óptica transmitida (a) BER e (b) fator Q. Como referência o desempenho de máxima verossimilhança e *k-means* são incluídos. Fonte: (ALDAYA *et al.*, 2020).

Além das BERs e dos fatores Q obtidos usando o algoritmo proposto, estão representados também os valores obtidos tanto para máxima verossimilhança como para *K-means*, que serão usados como referência. Observando estas figuras, para baixos níveis de potência, i.e. menores que 3 mW, o desempenho das três técnicas consideradas é muito parecido, apresentando uma melhora à medida que a potência de transmissão é aumentada. Assim, a BER diminui e o fator Q aumenta (retângulo em verde). Este comportamento é esperado pois nestes níveis de potência o ruído aditivo dos fotodetectores é dominante. Para níveis altos de potência, os efeitos não lineares são dominantes e um aumento de potência resulta contraproducente. O nível ótimo de potência para os diferentes algoritmos depende do peso relativo do ruído aditivo e da distorção não linear. Assim, a potência ótima dependerá da capacidade de cada algoritmo para compensar esta última. Em particular, observa-se que a potência ótima de transmissão quando se utiliza máxima verossimilhança é de 5 mW, de 6 mW quando é utilizada *K-means* e de 7 mW no caso de HBC. Este deslocamento da potência ótima indica que o algoritmo proposto é capaz de mitigar o efeito da distorção não linear de forma mais eficiente que *K-means*. Também é possível observar que em regiões de média e alta potência, i.e. entre 6 mW e 10 mW, *K-means* e HBC conseguiram mitigar parcialmente a distorção não linear. Este resultado pode ser melhor apreciado na Tabela 1, em que são apresentados os valores ótimos de BER e de fator Q obtidos quando a potência transmitida é ótima.

	BER ótimo	Fator Q ótimo
Máxima verossimilhança	$1,1 \times 10^{-3}$	9,67 dB
K-means	$0,8 \times 10^{-3}$	10,05 dB
HBC	$0,6 \times 10^{-3}$	10,25 dB

Tabela 1 – BER e fator Q ótimos para os diferentes esquemas de classificação.

Ao considerar um nível de potência fixo no regime não linear, por exemplo 10 mW (polígono roxo da Figura 7b), é possível perceber que o HBC apresenta melhor desempenho que a máxima verossimilhança e que o *K-means*, incrementando em 1,22 dB e em 0,51 dB o fator Q efetivo, respetivamente. O melhor desempenho de HBC pode ser entendido ao se analisar as constelações após a classificação realizada pelos algoritmos (Figura 8) considerando diferentes níveis de potência. No retângulo em verde, temos as constelações classificadas por (a) máxima verossimilhança, (b) *K-means* e (c) HBC para uma potência de transmissão de 2 mW. No retângulo em laranja são apresentadas as constelações para as potências ótimas dos diferentes algoritmos, Figura 8(d) máxima verossimilhança (e) *K-means* e (f) HBC. Por fim, no retângulo roxo temos as constelações classificadas por máxima verossimilhança *K-means* e HBC são mostradas nas Figuras-8g-i respectivamente, todas elas considerando uma potência de transmissão de 10 mW.

Ao se analisar a dispersão dos pontos para diferentes níveis de potência (3 mW, 5 mW e 10 mW) na classificação por máxima verossimilhança (Figuras 8 a, d e g), percebe-se que a máxima verossimilhança resulta em regiões de decisão corretas para baixas potências. Porém, conforme a potência de lançamento é elevada e a SPM distorce a constelação de maneira mais acentuada, as regiões de decisão já não são ótimas e a BER aumenta. É possível notar uma rotação não linear da constelação, uma vez que os símbolos internos giram no sentido horário enquanto os símbolos externos giravam no sentido anti-horário. Este efeito pode ser explicado notando que, mesmo se o efeito *Kerr* girar todos os símbolos no sentido anti-horário, a compensação do ruído de fase linear inverte a rotação média, fazendo com que os pontos com menor rotação (aqueles de menor potência) sejam rotacionados na direção contrária. Outro ponto a ser observado é que mesmo o nível de ruído sendo teoricamente o mesmo para os três níveis de potência, a potência do ruído em baixos níveis de potência parece maior do que nos níveis de potência moderada. Isso se deve ao fato de que, em sistemas coerentes a potência do ruído aditivo é

virtualmente independente da potência recebida, enquanto a potência do sinal aumenta conforme aumentamos a potência transmitida.

Quando se analisa as constelações classificadas para baixos níveis de potência, é possível observar que as classificações obtidas usando os três métodos, i.e. máxima verossimilhança, *K-means* e HBC, são essencialmente idênticas, sendo confirmadas pelos valores muito próximos de BER e fator Q, conforme visto na Figura 7. Ao aumentar a potência, e consequentemente a SNR, a SPM causa a rotação não linear dos símbolos e do ruído de fase não linear, conforme mencionado acima. Se continuamos aumentando a potência transmitida, a SPM distorce ainda mais a distribuição dos pontos, resultando em regiões de alta densidade de pontos mais complicadas. De fato, é possível perceber que no regime de baixa potência em que a distorção não linear não é significativa, a máxima




Figura 8 – Constelações obtidas para diferentes potências de entrada e classificadas usando máxima verossimilhança, *k-means* e HBC. Fonte: (ALDAYA *et al.*, 2020)

verossimilhança é o esquema de detecção ideal (LATHI, 1998). Porém, para níveis de potência mais elevados os algoritmos de clusterização analisados, i.e. *K-means* e HBC, passaram a compensar melhor a SPM.




Figura 9 – Análise das regiões de decisão para uma potência de transmissão de 10mW. (a) Histograma da constelação recebida. (b) Máxima verossimilhança. (c) *K-means*. (d) HBC. Em (b-d) as constelações foram sobrepostas às regiões de decisão, e na parte inferior um retângulo detalhando a constelação inferior esquerda, conforme mostrado na Figura (a). Fonte: (ALDAYA *et al.*, 2020).

Na Figura 9 são apresentadas de forma mais detalhadas as regiões de decisão de cada algoritmo. Esta figura foi obtida a partir dos dados recebidos para uma potência de transmissão de 10 mW, de forma a remarcar a diferença entre os algoritmos. Na Figura 9(a), mostramos o histograma da constelação recebida e chamamos a atenção para a forma como a distorção afeta principalmente os símbolos externos. No retângulo branco na Figura 9(a) podemos ver dois agrupamentos que tiveram seus símbolos afetados de forma mais severa pela SPM, sendo necessário uma forma mais aprimorada na classificação. Na Figura 9(b), temos a constelação dos dados recebidos sobrepostos nas regiões de decisão de máxima verossimilhança, e pode-se perceber que a grade retangular classificou vários símbolos em regiões de decisão duvidosa tanto no centro quanto na periferia, demonstrando não ser esta a classificação ideal para a distribuição de símbolos; fato que pode ser comprovado quando se amplia a figura. Na Figura 9(c), é possível perceber que o uso de *K-means* leva a regiões de decisão mais sofisticadas mesmo que ainda com contornos retilíneos, o que resulta em uma melhor classificação das constelações dos símbolos do centro da constelação (sobre baixa potência). Porém, para símbolos na periferia ainda resulta em classificações deficientes, como pode se ver na ampliação da figura. Por fim, na Figura 9(d) temos as

regiões de decisão para HBC. À primeira vista as regiões de decisão para HBC e K-means se assemelham, visto que em símbolos de baixa potência os limites ainda são linhas retas ortogonais. Isso se deve ao fato de que nessa região a SPM causa apenas uma pequena rotação, não afetando significativamente a distribuição dos símbolos. Já para os símbolos de maior potência, os limites calculados por HBC não são retas e sim curvas, conforme pode ser visualizado na ampliação, comprovando que a linha curva atende melhor ao limite do agrupamento esperado.

4.3 Análise do tamanho do bloco e complexidade computacional

Como mencionado no início, o HBC pode ser considerado como um algoritmo de clusterização baseado em densidade não iterativo. O fato de ser não iterativo ganha importância ao implicar um tempo de processamento fixo. Este tempo, porém, depende do número de símbolos requerido para construir o histograma de forma suficientemente precisa para estimar a distribuição dos pontos, requisito este que pode ser avaliado na




Figura 10 – BER em termos de tamanho de bloco processado, juntamente com a eficiência de HBC para uma potência de transmissão de 7 mW, ponto em que HBC alcança seu desempenho ótimo. Para fins de comparação, o BER usando a Máxima Verossimilhança também é mostrado. Fonte: (ALDAYA *et al.*, 2020).

Figura 10. Como pode ser visto na figura, para valores de bloco pequenos, a BER apresenta um comportamento irregular. Conforme o tamanho do bloco aumenta a BER diminui, alcançado um valor estável para tamanhos de bloco maiores que 13.000. Como pode ser visto na figura, existe uma dificuldade na avaliação de desempenho para blocos pequenos, devido principalmente à alta variância da natureza estocástica do método, e que de acordo com o aumento do tamanho dos blocos a variância da BER diminuiu. Com o objetivo de alcançar um equilíbrio entre precisão e tempo de processamento, os dados mostrados na figura foram obtidos pela média dos resultados para um número variável de execuções, 100 para blocos de 1.000 símbolos e 5 para blocos de 16.000 símbolos. Foi possível perceber que ao aplicar HBC para tamanhos de blocos curtos em determinados conjuntos de dados, o algoritmo não convergiu para uma classificação razoável. Para quantificar este efeito, para cada tamanho de bloco foi quantificado o número de execuções que falharam a fim de calcular a eficiência, determinada pela porcentagem de execuções que levaram a uma classificação aceitável. Interpretando os resultados da Figura 10, devemos usar blocos de ao menos 2.250 para que a aplicação da HBC seja eficiente. Assim, para aplicações que exigem baixa latência, é possível o uso do tamanho mínimo de 2.250 que mesmo resultando em uma BER algo maior, assegura uma eficiência alta. Para aplicações em que a latência não é tão crítica, por outro lado, um número maior de símbolos pode ser empregado para reduzir a BER.

Quando se trabalha com algoritmos, um ponto importante a ser avaliado é a complexidade computacional. No caso do HBC, pode-se dividir o algoritmo em duas etapas principais. O primeiro estágio consiste na construção do histograma 2D e na determinação dos pontos de alta densidade. No segundo estágio, cada ponto é associado a um determinado agrupamento. Para evitar a dependência da plataforma de *software/hardware* utilizada, foi calculado o número de operações em ponto flutuantes requeridas.

No primeiro estágio, entre as diferentes opções para construir o histograma, uma das soluções possíveis é encontrar os índices dos agrupamentos para cada símbolo, e então atualizar o valor do agrupamento correspondente. Se assumirmos que tenhamos N_b agrupamentos e que o máximo e o mínimo do histograma são M e m , os índices correspondentes ao k -ésimo símbolo complexo $s[k] = s_i[k] + js_q[k]$ são:

$$ind_i[k] = \frac{N_b + 1}{M - m} \cdot (s_i[k] - m) \quad \text{e} \quad ind_q[k] = \frac{N_b + 1}{M - m} \cdot (s_q[k] - m). \quad (8)$$

Uma vez que os índices foram encontrados, a contagem do compartimento indicado por ind_i e ind_q , n_{count}^{k-1} é atualizada. Consequentemente:

$$n_{count}^k(ind_i, ind_q) = n_{count}^{k-1}(ind_i, ind_q) + 1. \quad (9)$$

Em vista disso é possível notar que, no primeiro estágio o processamento de cada símbolo exige cinco operações de ponto flutuante, sendo duas para calcular ind_i , duas para calcular ind_q e outra para atualizar a contagem de posições. Dessa forma, para construir o histograma de um bloco de símbolos N_{sym} , o número total de operações é $5N_{sym}$ e, por consequência sua complexidade é $\mathcal{O}(N_{sym})$. A descoberta dos pontos de alta densidade requer a classificação dos valores de todos os agrupamentos, ou seja, a classificação dos pontos N_b^2 . Sabe-se que algoritmos de classificação, como árvore binária ou baseados em blocos, apresentam uma complexidade de $\mathcal{O}(N_b^2 \log N_b^2)$. Desta forma a complexidade irá depender do número de símbolos e do número de classes requeridos. Em nosso caso, empregamos 16,000 símbolos e 40 agrupamentos e, como consequência, o processo de construção do histograma foi o termo dominante na avaliação do primeiro estágio.

No segundo estágio, a complexidade consiste em encontrar o ponto de alta densidade mais próximo ao símbolo a classificar. É importante notar que esse número depende da quantidade de pontos de alta densidade e que varia de acordo com a forma dos agrupamentos. Em particular, quanto mais ruidosos são os agrupamentos, maiores são as áreas de alta densidade relativa e o número de pontos com alta densidade. Se assumirmos um número de pontos de alta densidade N_{hd} , para cada símbolo, precisamos calcular as N_{hd} distâncias (estritamente, é possível calcular o quadrado da distância):

$$D_m = d^2[k] = (s_i[k] - u_i[m])^2 + (s_q[k] - u_q[m])^2, \quad (10)$$

em que $u[m] = (u_i[m] + j.u_q[m]) \in S_{hd}$. O cálculo de cada distância D_m exige cinco operações de ponto flutuante, pois precisamos calcular 2 subtrações, 2 multiplicações e 1 adição. Isso leva a complexidade do segundo estágio a ser $\mathcal{O}(N_s \cdot N_{hd})$, que é maior que em *K-means*, em que o número de distâncias a serem calculadas corresponde ao número de agrupamento. No entanto, deve-se notar que essa comparação considera apenas o cálculo da distância e não o número de operações para encontrar os centroides. A complexidade do HBC também é maior que a da rotação não linear simples, que é tão pequena quanto duas operações com valor real. (ALDAYA *et al.*, 2020)

4.4 Discussão

Foram utilizadas simulações para analisar um sistema LR-PON coerente monocanal, em que o sinal transmitido sofre distorção causada pela SPM e pelo ruído aditivo do fotodetector. Foi possível observar nas constelações da Figura 9c-k que, ao se aplicar o algoritmo HBC proposto, as regiões de decisão obtidas adaptam-se melhor à rotação em espiral das constelações distorcidas. As perdas por divisão somadas às perdas características das fibras, no entanto, adicionaram ruído as constelações, o que fez com que as bordas dos agrupamentos tornassem-se difusas. Este fato, porém, não ocorre com sistemas WDM, pois como este sistema não usa divisores, uma potência maior é recebida no receptor, o que gera uma consequente redução do impacto do ruído. Na configuração WDM, a potência óptica teria de ser aumentada bem acima do ideal, para que a XPM e a FWM causassem uma distorção que se comparasse à perda de múltiplos divisores. Por outro lado, ao se considerar a operação em dupla polarização, será necessário adequar o algoritmo para que leve em conta as duas polarizações de forma simultânea, levando logicamente a um aumento do custo computacional.

O principal objetivo do algoritmo proposto sempre foi compensar a distorção em sistemas LR-PON monocanal, sem exigir um alto custo computacional e uma sequência de treinamento, de forma a alcançar um bom equilíbrio entre desempenho e complexidade. É possível considerar que este objetivo foi alcançado ao avaliar que mesmo com o aumento da complexidade com relação a *K-means*, o algoritmo compensa de forma mais eficiente o efeito de SPM. Além disso, mesmo tendo uma tolerância um pouco menor à distorção não linear do que outros algoritmos mais sofisticados (por exemplo, 2,5 dB de HBC vs. 3 dB de EM (ZIBAR *et al.*, 2012)), o fato de não ser iterativo e não requerer uma inicialização complexa compensam estes fatores.

5 Conclusão

Neste trabalho foi proposto e analisado um novo algoritmo de clusterização baseado em densidade denominado HBC. Este algoritmo foi utilizado para compensar o SPM causado pelo efeito Kerr, assim como o resultante ruído de fase não linear, em sistemas LR-PON coerentes com formatos de modulação 16-QAM e comprimento de enlances de até 100 km e razão de divisão de 1 para 64. Os resultados obtidos na simulação realizada no MATLAB e no *VPITransmissionMaker* comprovam que o HBC obteve uma melhoria do fator Q com relação à máxima verossimilhança e ao *K-means* de 0,53 dB e 0,23 dB, respectivamente. Também são apresentados resultados de simulação que mostram que o HBC pode operar com eficiência em blocos de tamanho superiores a 2.500 símbolos e com ótimo desempenho em blocos de 12.000 símbolos.

Como proposta para trabalhos futuros, visualizamos o uso do algoritmo para sistemas com dupla polarização e a sugestão da análise de impacto que o aumento da complexidade originada no aumento da dimensionalidade irá agregar. Outro ponto a ser trabalhado refere-se aos filtros utilizados. Em nossas simulações foram empregados filtros de Bessel de quarta ordem, que simulam a limitação da largura de banda dos componentes eletrônicos do transmissor e da resposta do fotodetector e removem parte do ruído. Acreditamos que ao usar filtros mais sofisticados e que melhoram a SNR, i.e. *Nyquist*, seja possível alcançar ganhos de desempenho na classificação dos símbolos em seus respectivos agrupamentos. Outra linha a explorar é a possibilidade de aplicar este algoritmo a outro tipo de redes em que o ruído de fase seja o impedimento dominante, como por exemplo interconectores ópticos com taxas de até 400 Gbps.

Referências

- AGRAWAL, G. *Sistemas de comunicação por fibra óptica*. [S.l.]: Elsevier Brasil, 2014. v. 4. Citado 5 vezes nas páginas 17, 19, 21, 22 e 36.
- AGRAWAL, G. P. Nonlinear fiber optics. In: *Nonlinear Science at the Dawn of the 21st Century*. [S.l.]: Springer, 2000. p. 195–211. Citado 3 vezes nas páginas 21, 22 e 23.
- AGRAWAL, G. P. Optical communication: its history and recent progress. In: *Optics in Our Time*. [S.l.]: Springer, Cham, 2016. p. 177–199. Citado na página 18.
- AHMAD, S. T.; KUMAR, K. P. Radial basis function neural network nonlinear equalizer for 16-QAM coherent optical OFDM. *IEEE Photonics Technology Letters*, v. 28, n. 22, p. 2507–2510, 2016. Citado na página 29.
- ALDAYA, I.; GIACOUMIDIS, E.; OLIVEIRA, G. de; WEI, J.; PITA, J. L.; MARCONI, J. D.; FAGOTTO, E. A. M.; BARRY, L.; ABBADE, M. L. F. Histogram based clustering for nonlinear compensation in long reach coherent passive optical networks. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 10, n. 1, p. 152, 2020. Citado 14 vezes nas páginas 9, 10, 18, 30, 32, 33, 34, 35, 36, 39, 41, 42, 43 e 45.
- ALPAYDIN, E. *Introduction to machine learning*. [S.l.]: MIT press, 2009. Citado 3 vezes nas páginas 26, 27 e 28.
- ALPAYDIN, E. *Machine learning: the new AI*. [S.l.]: MIT press, 2016. Citado 2 vezes nas páginas 25 e 26.
- BISHOP, C. M. *Pattern recognition and machine learning*. [S.l.]: springer, 2006. Citado na página 27.
- BOADA, R.; BORKOWSKI, R.; MONROY, I. T. Clustering algorithms for Stokes space modulation format recognition. *Optics express*, Optical Society of America, v. 23, n. 12, p. 15521–15531, 2015. Citado 2 vezes nas páginas 28 e 29.
- BOYD, R. W. *Nonlinear optics*. [S.l.]: Academic press, 2019. Citado na página 22.
- CHEN, E.; TAO, R.; ZHAO, X. Channel equalization for OFDM system based on the BP neural network. In: IEEE. *8th International Conference on Signal Processing*. [S.l.], 2006. v. 3. Citado na página 29.
- CHEN, M.; HE, J.; CHEN, L. Real-time optical OFDM long-reach PON system over 100 km SSMF using a directly modulated DFB laser. *Journal of Optical Communications and Networking*, Optical Society of America, v. 6, n. 1, p. 18–25, 2014. Citado 2 vezes nas páginas 17 e 18.
- CISCO, S. *Cisco Annual Internet Report (2018–2023) White Paper*. [S.l.], 2020. Disponível em: <https://www.cisco.com/c/en/us/solutions/collateral/executive-perspectives/annual-internet-report/white-paper-c11-741490.html>. Citado 2 vezes nas páginas 9 e 16.
- DU, L. B.; MORSHED, M. M.; LOWERY, A. J. Fiber nonlinearity compensation for ofdm super-channels using optical phase conjugation. *Optics Express*, Optical Society of America, v. 20, n. 18, p. 19921–19927, 2012. Citado na página 23.

GIACOUMIDIS, E.; ALDAYA, I.; JARAJREH, M. A.; TSOKANOS, A.; LE, S. T.; FARJADY, F.; JAOUËN, Y.; ELLIS, A. D.; DORAN, N. J. Volterra-based reconfigurable nonlinear equalizer for coherent OFDM. *IEEE Photonics Technology Letters*, v. 26, n. 14, p. 1383–1386, 2014. Citado 2 vezes nas páginas 24 e 29.

GIACOUMIDIS, E.; ALDAYA, I.; WEI, J.; SANCHEZ, C.; MRABET, H.; BARRY, L. P. Affinity propagation clustering for blind nonlinearity compensation in coherent optical OFDM. In: OPTICAL SOCIETY OF AMERICA. *CLEO: Science and Innovations*. [S.l.], 2018. p. STh1C–5. Citado na página 29.

GIACOUMIDIS, E.; LIN, Y.; BARRY, L. P. Fibre nonlinear compensation using machine learning clustering. In: *Proceedings of the 56th ICREIT conference, London, UK*. [S.l.: s.n.], 2019. p. 18–19. Citado na página 30.

GIACOUMIDIS, E.; LIN, Y.; WEI, J.; ALDAYA, I.; TSOKANOS, A.; BARRY, L. Harnessing machine learning for fiber-induced nonlinearity mitigation in long-haul coherent optical OFDM. *Future Internet*, Multidisciplinary Digital Publishing Institute, v. 11, n. 1, p. 2, 2019. Citado 2 vezes nas páginas 27 e 29.

GIACOUMIDIS, E.; MHATLI, S.; LE, S. T.; ALDAYA, I.; MCCARTHY, M. E.; ELLIS, A. D.; EGGLETON, B. J. Nonlinear blind equalization for 16-qam coherent optical ofdm using support vector machines. In: VDE. *ECOC 2016; 42nd European Conference on Optical Communication*. [S.l.], 2016. p. 1–3. Citado na página 28.

GIACOUMIDIS, E.; MHATLI, S.; NGUYEN, T.; LE, S. T.; ALDAYA, I.; MCCARTHY, M. E.; ELLIS, A. D.; EGGLETON, B. J. Comparison of dsp-based nonlinear equalizers for intra-channel nonlinearity compensation in coherent optical ofdm. *Optics letters*, Optical Society of America, v. 41, n. 11, p. 2509–2512, 2016. Citado na página 27.

GIACOUMIDIS, E.; MHATLI, S.; NGUYEN, T.; LE, S.; ALDAYA, I.; MCCARTHY, M.; EGGLETON, B. Kerr-induced nonlinearity reduction in coherent optical OFDM by low complexity support vector machine regression-based equalization. In: IEEE. *Optical Fiber Communications Conference and Exhibition (OFC)*. [S.l.], 2016. p. 1–3. Citado na página 26.

GORDON, J. P.; MOLLENAUER, L. F. Phase noise in photonic communications systems using linear amplifiers. *Optics Letters*, Optical Society of America, v. 15, n. 23, p. 1351–1353, 1990. Citado na página 23.

HSU, D.-Z.; WEI, C.-C.; CHEN, H.-Y.; CHEN, J.; YUANG, M. C.; LIN, S.-H.; LI, W.-Y. 21 Gb/s after 100 km OFDM long-reach PON transmission using a cost-effective electro-absorption modulator. *Optics Express*, Optical Society of America, v. 18, n. 26, p. 27758–27763, 2010. Citado 2 vezes nas páginas 17 e 18.

IP, E.; KAHN, J. M. Compensation of dispersion and nonlinear impairments using digital backpropagation. *Journal of Lightwave Technology*, IEEE, v. 26, n. 20, p. 3416–3425, 2008. Citado na página 29.

JARAJREH, M. A.; GIACOUMIDIS, E.; ALDAYA, I.; LE, S. T.; TSOKANOS, A.; GHASSEMLOOY, Z.; DORAN, N. J. Artificial neural network nonlinear equalizer for coherent optical OFDM. *IEEE Photonics Technology Letters*, v. 27, n. 4, p. 387–390, 2014. Citado 2 vezes nas páginas 27 e 29.

KHAN, F. N.; LU, C.; LAU, A. P. T. Machine learning methods for optical communication systems. In: *Signal Processing in Photonic Communications*. [S.l.]: Optical Society of America, 2017. p. SpW2F–3. Citado na página 29.

KIKUCHI, K. Coherent optical communications: Historical perspectives and future directions. In: *High Spectral Density Optical Communication Technologies*. [S.l.]: Springer, 2010. p. 11–49. Citado 3 vezes nas páginas 9, 18 e 19.

KIKUCHI, K. Fundamentals of coherent optical fiber communications. *Journal of Lightwave Technology*, IEEE, v. 34, n. 1, p. 157–179, 2016. Citado 4 vezes nas páginas 18, 19, 20 e 21.

KIM, K. S. On the evolution of PON-based FTTH solutions. *Information sciences*, Elsevier, v. 149, n. 1–3, p. 21–30, 2003. Citado na página 17.

KUNCHEVA, L. I. *Combining pattern classifiers: methods and algorithms*. [S.l.]: John Wiley & Sons, 2014. Citado na página 27.

LATHI, B. P. *Modern Digital and Analog Communication Systems*. [S.l.]: Oxford University Press, Inc., 1998. Citado na página 42.

LAVERY, D.; IONESCU, M.; MAKOVEJS, S.; TORRENGO, E.; SAVORY, S. J. A long-reach ultra-dense 10 Gbit/s WDM-PON using a digital coherent receiver. *Optics Express*, Optical Society of America, v. 18, n. 25, p. 25855–25860, 2010. Citado na página 17.

LAVERY, D.; MAHER, R.; MILLAR, D. S.; THOMSEN, B. C.; BAYVEL, P.; SAVORY, S. J. Digital coherent receivers for long-reach optical access networks. *Journal of Lightwave Technology*, IEEE, v. 31, n. 4, p. 609–620, 2013. Citado na página 17.

LI, M.; YU, S.; YANG, J.; CHEN, Z.; HAN, Y.; GU, W. Nonparameter nonlinear phase noise mitigation by using M-ary support vector machine for coherent optical systems. *IEEE Photonics Journal*, v. 5, n. 6, p. 7800312–7800312, 2013. Citado na página 29.

LIN, Y.; GIACOU MIDIS, E.; O’DUILL, S.; BARRY, L. P. DBSCAN-based clustering for nonlinearity induced penalty reduction in wavelength conversion systems. *IEEE Photonics Technology Letters*, IEEE, v. 31, n. 21, p. 1709–1712, 2019. Citado na página 28.

LIU, X.; CHRAPLYVY, A.; WINZER, P.; TKACH, R.; CHANDRASEKHAR, S. Phase-conjugated twin waves for communication beyond the kerr nonlinearity limit. *Nature Photonics*, Nature Publishing Group, v. 7, n. 7, p. 560–568, 2013. Citado na página 23.

LIU, X.; EFFENBERGER, F. ONU-dependent dispersion pre-compensation at OLT for high-speed wide-coverage PON. In: IEEE. *IEEE Global Communications Conference (GLOBECOM)*. [S.l.], 2015. p. 1–5. Citado na página 17.

MATA, J.; MIGUEL, I. D.; DURAN, R. J.; MERAYO, N.; SINGH, S. K.; JUKAN, A.; CHAMANIA, M. Artificial intelligence (ai) methods in optical networks: A comprehensive survey. *Optical switching and networking*, Elsevier, v. 28, p. 43–57, 2018. Citado 2 vezes nas páginas 18 e 29.

MHATLI, S.; NSIRI, B.; JARAJREH, M. A.; CHANNOUFI, M.; ATTIA, R. Analysis of Wiener Hammerstein equalizer for optical OFDM modem. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Photonics, Devices, and Systems VI*. [S.l.], 2015. v. 9450, p. 94500X. Citado na página 24.

MILLAR, D. S.; MAKOVEJS, S.; BEHRENS, C.; HELLERBRAND, S.; KILLEY, R. I.; BAYVEL, P.; SAVORY, S. J. Mitigation of fiber nonlinearity using a digital coherent receiver. *IEEE Journal of Selected Topics in Quantum Electronics*, v. 16, n. 5, p. 1217–1226, 2010. Citado 2 vezes nas páginas 24 e 29.

NESSET, D. PON roadmap. *IEEE/OSA Journal of Optical Communications and Networking*, IEEE, v. 9, n. 1, p. A71–A76, 2017. Citado na página 17.

NGUYEN, T.; MHATLI, S.; GIACOU MIDIS, E.; COMPERNOLLE, L. V.; WUILPART, M.; MÉGRET, P. Fiber nonlinearity equalizer based on support vector classification for coherent optical OFDM. *IEEE Photonics Journal*, v. 8, n. 2, p. 1–9, 2016. Citado na página 29.

PAKALA, L.; SCHMAUSS, B. Non-linear mitigation using carrier phase estimation and k-means clustering. In: VDE. *Photonic Networks; 16. ITG Symposium*. [S.l.], 2015. p. 1–5. Citado 3 vezes nas páginas 24, 28 e 29.

PAULA, R. de; BORGES, L. N.; ABBADE, M. L. F.; ALDAYA, I. Mitigation of nonlinear phase noise in coherent 16-QAM long-reach PONs by K-nearest neighbors-based classification. In: *Accepted for publication in the Brazilian Congress of Telecommunications and Signal Processing (SBRT)*. [S.l.: s.n.], 2020. p. 1–4. Citado na página 26.

PÉREZ, A. E.; TORRES, J. J. G. KNN, k-means and fuzzy c-means for 16-QAM demodulation in coherent optical systems. In: IEEE. *Colombian Conference on Communications and Computing (COLCOM)*. [S.l.], 2019. p. 1–4. Citado na página 26.

ROS, F. D.; SACKKEY, I.; ELSCHNER, R.; RICHTER, T.; MEUER, C.; NÖLLE, M.; JAZAYERIFAR, M.; PETERMANN, K.; PEUCHERET, C.; SCHUBERT, C. Kerr nonlinearity compensation in a 5×28 -GBd PDM 16-QAM WDM system using fiber-based optical phase conjugation. In: IEEE. *The European Conference on Optical Communication (ECOC)*. [S.l.], 2014. p. 1–3. Citado 2 vezes nas páginas 23 e 29.

SEMRAU, D.; KILLEY, R. I.; BAYVEL, P. The Gaussian noise model in the presence of inter-channel stimulated raman scattering. *Journal of Lightwave Technology*, v. 36, n. 14, p. 3046–3055, 2018. Citado na página 23.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. *Understanding machine learning: From theory to algorithms*. [S.l.]: Cambridge university press, 2014. Citado 3 vezes nas páginas 25, 26 e 27.

TORRES-ZUGAIDE, J.; ALDAYA, I.; CAMPUZANO, G.; CASTANON, G. Hammerstein-based equalizer for nonlinear compensation in coherent OFDM long-reach PONs. In: IEEE. *18th International Conference on Transparent Optical Networks (ICTON)*. [S.l.], 2016. p. 1–3. Citado na página 24.

TORRES-ZUGAIDE, J.; ALDAYA, I.; CAMPUZANO, G.; GIACOU MIDIS, E.; BEAS, J.; CASTAÑÓN, G. Range extension in coherent OFDM passive optical networks using an inverse Hammerstein nonlinear equalizer. *Journal of Optical Communications and*

Networking, Optical Society of America, v. 9, n. 7, p. 577–584, 2017. Citado 2 vezes nas páginas 23 e 24.

TOWNSEND, P.; TALLI, G.; CHOW, C. W.; MACHALE, E.; ANTONY, C.; DAVEY, R.; RIDDER, T. D.; QIU, X.-Z.; OSSIEUR, P.; KRIMMEL, H. *et al.* Long reach passive optical networks. In: IEEE. *Lasers and Electro-Optics Society Annual Meeting Conference Proceedings*. [S.l.], 2007. p. 868–869. Citado na página 17.

WANG, D.; ZHANG, M.; FU, M.; CAI, Z.; LI, Z.; HAN, H.; CUI, Y.; LUO, B. Nonlinearity mitigation using a machine learning detector based on k -nearest neighbors. *IEEE Photonics Technology Letters*, IEEE, v. 28, n. 19, p. 2102–2105, 2016. Citado na página 26.

WANG, D.; ZHANG, M.; LI, Z.; CUI, Y.; LIU, J.; YANG, Y.; WANG, H. Nonlinear decision boundary created by a machine learning-based classifier to mitigate nonlinear phase noise. In: IEEE. *European Conference on Optical Communication (ECOC)*. [S.l.], 2015. p. 1–3. Citado na página 29.

ZHANG, J.; CHEN, W.; GAO, M.; SHEN, G. K-means-clustering-based fiber nonlinearity equalization techniques for 64-QAM coherent optical communication system. *Optics Express*, Optical Society of America, v. 25, n. 22, p. 27570–27580, 2017. Citado 2 vezes nas páginas 28 e 29.

ZIBAR, D.; PIELS, M.; JONES, R.; SCHÄEFFER, C. G. Machine learning techniques in optical communication. *Journal of Lightwave Technology*, IEEE, v. 34, n. 6, p. 1442–1452, 2015. Citado na página 29.

ZIBAR, D.; WINTHER, O.; FRANCESCHI, N.; BORKOWSKI, R.; CABALLERO, A.; ARLUNNO, V.; SCHMIDT, M. N.; GONZALES, N. G.; MAO, B.; YE, Y. Nonlinear impairment compensation using expectation maximization for dispersion managed and unmanaged PDM 16-QAM transmission. *Optics Express*, Optical Society of America, v. 20, n. 26, p. B181–B196, 2012. Citado 3 vezes nas páginas 29, 30 e 46.