

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
E INFORMÁTICA INDUSTRIAL

RAFAELA SCHROEDER

**CODIFICAÇÃO ANALÓGICA CONJUNTA FONTE-CANAL
COM CONJUNTOS NÃO-GAUSSIANOS DE AMOSTRAS
DE SENSORES**

DISSERTAÇÃO

CURITIBA

2019

RAFAELA SCHROEDER

**CODIFICAÇÃO ANALÓGICA CONJUNTA FONTE-CANAL
COM CONJUNTOS NÃO-GAUSSIANOS DE AMOSTRAS
DE SENSORES**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de “Mestre em Engenharia Elétrica” – Área de Concentração: Telecomunicações e Redes.

Orientador: Prof. Dr. Glauber Gomes de Oliveira Brante

CURITIBA
2019

Dados Internacionais de Catalogação na Publicação

Schroeder, Rafaela

Codificação analógica conjunta fonte-canal com conjuntos não-gaussianos de amostras de sensores [recurso eletrônico] / Rafaela Schroeder.-- 2019.

1 arquivo texto (45 f.) : PDF ; 755 KB.

Modo de acesso: World Wide Web.

Texto em português com resumo em inglês.

Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. Área de Concentração: Telecomunicações e Redes, Curitiba, 2019.

Bibliografia: f. 43-45.

1. Engenharia elétrica - Dissertações. 2. Códigos corretores de erros (Teoria da informação). 3. Processos gaussianos. 4. Teoria da codificação. 5. Sistemas de comunicação sem fio. 6. Sistemas eletrônicos analógicos. 7. Redes de sensores sem fio. 8. Processamento de sinais - Técnicas digitais. 9. Comunicação máquina a máquina. 10. Internet das coisas. 11. Métodos de simulação. 12. Sistemas de telecomunicação. I. Brante, Glauber Gomes de Oliveira, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD: Ed. 23 -- 621.3

TERMO DE APROVAÇÃO DE DISSERTAÇÃO Nº 830

A Dissertação de Mestrado intitulada “**Codificação Analógica Conjunta Fonte-Canal com Conjuntos Não-Gaussianos de Amostras de Sensores**” defendida em sessão pública pelo(a) candidato(a) **Rafaela Schroeder**, no dia **15 de julho de 2019**, foi julgada para a obtenção do título de Mestre em Ciências, área de concentração **Telecomunicações e Redes**, e aprovada em sua forma final, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial.

BANCA EXAMINADORA:

Prof(a). Dr(a). Glauber Gomes de Oliveira Brante - Presidente – (UTFPR)

Prof(a). Dr(a). André Augusto Mariano - (UFPR)

Prof(a). Dr(a). Guilherme Luiz Moritz- (UTFPR)

A via original deste documento encontra-se arquivada na Secretaria do Programa, contendo a assinatura da Coordenação após a entrega da versão corrigida do trabalho.

Curitiba, 15 de julho de 2019.

Para aqueles que me apoiaram em todas circunstâncias e são a minha maior inspiração. Dedico a vocês, pai e mãe.

AGRADECIMENTOS

Primeiramente, agradeço ao meu orientador, Glauber Brante, por todo apoio prestado no período no qual foi meu orientador. Obrigada pelas inúmeras sugestões, discussões e pela paciência para ouvir meus questionamentos e incertezas.

Agradeço aos meus pais, Volnir e Rosângela, por todo suporte que vocês me propiciaram e por serem o meu exemplo de força e perseverança.

Agradeço aos meus colegas do Laboratório de Sistemas de Comunicação Sem Fio (LABSC) pelas discussões, sugestões diversas e pelo café compartilhado.

Por fim, mas igualmente importante, agradeço aos meus amigos por me apoiarem e ouvirem os longos desabaços sobre os desafios da vida acadêmica.

O que sabemos é uma gota, o que ignoramos é um oceano. *Isaac
Newton*

RESUMO

SCHROEDER, Rafaela. Codificação Analógica Conjunta Fonte-Canal com Conjuntos Não-Gaussianos de Amostras de Sensores. 46 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2019.

Esse trabalho propõe a codificação analógica conjunta fonte-canal como uma opção para comunicações do tipo-máquina que exigem comunicação com baixo atraso. A codificação analógica se baseia em mapear os símbolos gerados pela fonte de informação em uma curva. A curva de mapeamento pode ser definida como mapeamentos geométricos ou por meio de otimizações numéricas, denotadas por codificação paramétrica e não-paramétrica, respectivamente. Neste trabalho, foram implementados os dois tipos de codificação para conjuntos de amostras não-Gaussianos coletados por sensores. Tendo em vista que o esquema paramétrico é ótimo apenas para fonte Gaussiana, foi utilizada a transformação de Box-Cox para melhorar o desempenho. Por sua vez, o esquema não-paramétrico se adapta com mais facilidade a diferentes conjuntos de amostras, porém, tem uma implementação mais complexa. Por meio dos resultados numéricos, comprovou-se que o esquema não-paramétrico tem o melhor desempenho, em geral. Além disso, pode-se observar que a transformação de Box-Cox é uma técnicas simples que melhora a performance do esquema paramétrico. Aliás, para determinados valores de relação sinal-ruído do canal o desempenho do paramétrico é similar, o que justifica a sua escolha devido à menor complexidade.

Palavras-chave: Codificação Analógica Conjunta Fonte-Canal. Comunicações do Tipo-Máquina. Amostras Não-Gaussianas.

ABSTRACT

SCHROEDER, Rafaela. Analog Joint Source-Channel Coding with Non-Gaussian Sets of Sensor Samples. 46 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2019.

This work proposes an analog joint source-channel coding scheme as an alternative for machine-type communications that require low communications delay. The analog coding scheme is based on mapping the symbols generated by an information source into a curve. The mapping curve can be defined by geometric mappings or by numerical optimizations, denoted by parametric and non-parametric coding, respectively. In this work, we have implemented these two types of coding for the non-Gaussians sets of samples collected by sensors. Considering that the parametric scheme is optimal for Gaussian sources only, the Box-Cox transformation has been used to improve the performance. On the other hand, the non-parametric scheme can easily adapt to different sample sets, at the cost of more complex implementation. The numerical results show that the non-parametric scheme achieves better performance, in general. Also, we can observe that Box-Cox transformation is a simple technique that improves significantly the performance of the parametric scheme. Moreover, for certain values of the channel signal-to-noise ratio, the performance of the parametric scheme is similar, which justifies its choice due to the lower complexity.

Keywords: Analog Joint Source-Channel Coding. Machine-Type Communications. Non-Gaussians Samples.

LISTA DE FIGURAS

Figura 1	– Diagrama em blocos do sistema digital.	19
Figura 2	– Diagrama em blocos que resume o esquema de codificação analógica conjunta fonte-canal.	22
Figura 3	– Exemplo de codificação de um par de amostras $\mathbf{x} = (1.3, 1.3)$ mapeado na curva da espiral de Arquimedes, em um único símbolo de canal $M_{\Delta}(\mathbf{x})$	26
Figura 4	– Diagrama em blocos do passo-a-passo da codificação paramétrica	28
Figura 5	– Exemplo de quantização vetorial.	31
Figura 6	– Diagrama em blocos que resume o funcionamento do PCCOVQ.	33
Figura 7	– Mapeamentos obtidos com o algoritmo PCCOVQ para o conjunto de temperaturas adotado neste trabalho.	35
Figura 8	– Histograma dos conjuntos de dados adotados, disponíveis em (UCI Machine Learning Repository, 2018).	36
Figura 9	– Histograma dos conjuntos de dados transformados por Box-Cox, disponíveis em (UCI Machine Learning Repository, 2018).	37
Figura 10	– SDR versus CSNR para o conjunto de temperaturas.	39
Figura 11	– SDR versus CSNR para o conjunto de umidades relativas.	40

LISTA DE TABELAS

Tabela 1	–	Informações sobre os conjuntos de amostras.	36
Tabela 2	–	Probabilidade de significância (P_S), antes e depois da transformação de Box-Cox.	38
Tabela 3	–	Optimização do parâmetro α	38
Tabela 4	–	Otimização do parâmetro Δ	38

LISTA DE SIGLAS

IoT	Internet das Coisas, do inglês <i>Internet of Things</i>
MTC	Comunicação do tipo máquina, do inglês <i>Machine-Type Communications</i>
URLLC	Comunicação Ultra-Confíavel e de Baixa Latência, do inglês <i>Ultra-reliable and low latency communication</i>
JSCC	Codificação Conjunta Fonte-Canal, do inglês <i>Joint Source-Channel Coding</i>
AWGN	Ruído branco Gaussiano aditivo, do inglês <i>additive white Gaussian noise</i>
SDR	Relação Sinal-Distorção, do inglês <i>Signal-to-Distortion Ratio</i>
PCCOVQ	Quantização Vetorial Otimizada para Canal com Restrição de Potência, do inglês <i>Power Constrained Channel Optimized Vector Quantization</i>
OPTA	Limite Ótimo Teoricamente Atingível, do inglês <i>Optimal Performance Theoretically Attainable</i>
PDF	Função densidade de probabilidade, do inglês <i>probability density function</i>
CSNR	Relação Sinal-Ruído do Canal, do inglês <i>Channel Signal-to-Noise Ratio</i>
LDPC	Códigos de verificação de paridade de baixa densidade, do inglês <i>Low-Density Parity-Check</i>
BICM	do inglês <i>Bit Interleaved Coded Modulation</i>
MMSE	Mínimo Erro Médio Quadrático, do inglês <i>Minimum Mean Square Error</i>
ML	Máxima Verossimilhança, do inglês <i>Maximum Likelihood</i>
MSE	Erro Médio Quadrático, do inglês <i>Mean Squared Error</i>
CSI	Informação de estado de canal do inglês <i>Channel State Information</i>
FSMN	do inglês <i>feature scaling and mean normalization</i>
DQ	Quantização distribuída, do inglês <i>Distributed Quantizer</i>
VQ	Quantização vetorial, do inglês <i>Vector Quantization</i>
COVQ	Quantização Vetorial Otimizada para Canal, do inglês <i>Channel Optimized Vector Quantizer</i>
PAM	Modulação por Amplitude de Pulso, do inglês <i>pulse amplitude modulation</i>
LBG	<i>Linde-Buzo-Gray</i>
USV	Veículos de Superfície Não-Tripulados do inglês <i>Unmanned Surface Vehicles</i>
KS	Kolmogorov-Smirnov
SVM	Máquina de vetores de suporte, do inglês <i>Support Vector Machine</i>

LISTA DE SÍMBOLOS

N	Dimensão da fonte
K	Dimensão do canal
\mathbf{x}	Vetor de amostras da fonte
$\sigma_{\mathbf{x}}^2$	Potência média da fonte
y	Sinal recebido
h	Coefficiente de desvanecimento do canal
σ_h^2	Potência média do desvanecimento
$\sigma_{\mathbf{w}}^2$	Potência média do ruído Gaussiano branco
C	Capacidade do cana
$p(h)$	função densidade de probabilidade do canal
R	Função taxa de distorção
M_{Δ}	Função de mapeamento
Δ	Distância entre os braços da espiral
θ	Mapeamento do vetor ↷
γ	fator de normalização da potência de transmissão
μ	Parâmetro do Box-Cox
$\bar{\mathbf{x}}(\mu)$	Média do vetor $\mathbf{x}(\mu)$
c_i	Vetor de reconstrução
i	Índice do vetor de reconstrução
Q	Número de regiões de quantização
Ω_i	Regiões de quantização
\mathbf{p}	Conjunto de Partições
s	Símbolo de canal
u_i	Símbolo modulado por PAM
Δ_p	Distância entre dois símbolos vizinhos
\mathbf{a}	Conjunto de dicionários
h_k	Desvanecimento h uniformemente discretizado
$f_x(\mathbf{x})$	pdf de \mathbf{x}
$\mathcal{D}_i(\mathbf{x})$	distorção de \mathbf{x}
$p_h(k)$	probabilidade de obter o desvanecimento discreto h_k
$p(j i, k)$	probabilidade de receber o índice j dado que i foi transmitido pelo canal com desvanecimento h_k
P_S	Probabilidade de Significância

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS	17
1.1.1	Objetivo Geral	17
1.1.2	Objetivos Específicos	18
1.2	ESTRUTURA DO DOCUMENTO	18
2	MODELAGEM DOS SISTEMAS DIGITAL E ANALÓGICO	19
2.1	O SISTEMA DIGITAL	19
2.2	ESQUEMA GENÉRICO DA CODIFICAÇÃO ANALÓGICA	21
3	CODIFICAÇÃO PARAMÉTRICA	24
3.1	CODIFICAÇÃO 2:1	24
3.2	TRANSFORMAÇÃO DE BOX-COX	27
4	CODIFICAÇÃO NÃO-PARAMÉTRICA	29
4.1	CONCEITOS GERAIS SOBRE QUANTIZAÇÃO VETORIAL	30
4.2	O ALGORITMO PCCOVQ	32
5	RESULTADOS E DISCUSSÕES	36
6	CONCLUSÃO E TRABALHOS FUTUROS	42
	REFERÊNCIAS	44

1 INTRODUÇÃO

O conceito de internet das coisas (IoT, do inglês *Internet of Things*) fundamenta-se na ideia de conexão entre numerosos dispositivos ou objetos por meio da internet. As comunicações do tipo máquina (MTC, do inglês *Machine-Type Communications*) são uma ferramenta importante para IoT, pois, são utilizadas para implementar as aplicações (CHEN et al., 2017). Sendo assim, os avanços na área de IoT levaram a uma crescente demanda por MTC e a necessidade de otimização desses sistemas. Atrelado a esse fato, está a próxima geração de comunicação móvel (5G). A expectativa é o que o 5G consiga atender aos requisitos dos sistemas MTC e, além disso, superar as gerações anteriores em termos de taxa de dados e capacidade (NOURI et al., 2017).

Os sistemas MTC tem diferentes requisitos de taxa de transmissão e latência que dependem do tipo de aplicações implementadas. Por exemplo, para aplicações de IoT maciça, como o monitoramento agrícola e as casas inteligentes, existe um grande número de dispositivos conectados, o que implica em atualizações frequentes para a nuvem com baixo custo. No caso de um casa inteligente, os moradores utilizam os dispositivos para controlar a entrada e saída da casa, controlar o sistema de ar condicionado, entre outros. Sendo assim, aplicações desse tipo requerem baixo custo de implementação para o usuário e baixo consumo de energia.

Por outro lado, para aplicações críticas relacionadas ao monitoramento de saúde remoto, controle da indústria e redes veiculares, é essencial assegurar que os dados coletados sejam transmitidos sem perdas. Para isso, a conectividade deve ser garantida para quase 100% do tempo, a fim de evitar que ocorram graves consequência aos usuário final, como a perda de estabilidade da planta de uma indústria (AKPAKWU et al., 2017; SHARIATMADARI et al., 2015; POPOVSKI, 2014). Portanto, para aplicações críticas, tendo em vista que essas são utilizadas em sistemas precisam garantir a estabilidade, os requisitos da comunicação são baixa latência e alta confiabilidade (URLLC, do inglês *Ultra-Reliable and Low Latency Communication*). Considera-se a latência como a latência de comunicação, em termos de quantidade de símbolos. Enquanto que comunicação ultra-confiável é um termo que denota a disponibilidade do *link* de comunicação na maior quantidade de tempo possível, ou ainda, quase 100 % do tempo (POPOVSKI, 2014).

A URLLC é essencial para a implantação da indústria 4.0, ou seja, para transformar sistemas de fabricação por meio de sistemas cyber-físicos, os quais são resultado da união de subsistemas físicos e redes de computadores, e serviços da

IoT (ZHOU et al., 2015). Por esse motivo, é interessante avaliar as possibilidades de melhoria de comunicação entre os sensores e atuadores utilizados nessas atividades. Tradicionalmente, um sistema MTC utiliza um sistema digital, o qual se baseia na codificação da fonte e canal em duas etapas (SHANNON, 1948). No sistema digital, primeiramente, a fonte de informação é codificada para um par fixo de taxa/distorção. Em seguida, é feita a codificação de canal com longos blocos de redundância para aproximar o desempenho da capacidade de Shannon.

Para comunicações de baixa latência, o esquema tradicional de codificação não é uma opção vantajosa tendo em vista os atrasos resultantes dos longos blocos de redundância necessários para melhorar o desempenho. Ao invés disso, é recomendável utilizar técnicas de transmissão de pacotes curtos (SHARIATMADARI et al., 2015).

Nesse contexto, uma opção interessante é a codificação analógica conjunta fonte-canal (JSCC, do inglês *Joint Source-Channel Coding*). A codificação analógica fundamenta-se em codificar cada símbolo em uma curva de mapeamento e transmitir através do canal sem fio. Assim, a codificação da fonte e do canal é feita em apenas uma etapa, símbolo a símbolo, o que resulta em atraso reduzido (RAMSTAD, 2002). Além disso, o sistema digital é projetado para um par específico de distorção do canal. Caso o sinal sofra uma queda brusca de desempenho e os limites do sistema sejam ultrapassados, é preciso fazer uma remodelagem completa do sistema digital. Para o esquema analógico, a solução é mais simples pois os parâmetros de codificação podem ser ajustados com facilidade para assegurar a eficiência do desempenho.

A teoria fundamental do JSCC foi proposta por (SHANNON, 1948; KOTEL'NIKOV, 1959). O objetivo é codificar os símbolos da fonte de dimensão N em símbolos de canal de dimensão K , dessa forma podem ser implementados esquemas $N : K$. Uma das vantagens do esquema analógico é que podem ser implementados esquemas de compressão ($N > K$), como por exemplo, 2:1, 3:1 e 4:1 (FLOOR; RAMSTAD, 2006) e expansão da dimensão dos símbolos fonte ($N < K$) (RAMSTAD, 2002; LU; GARCIA-FRIAS, 2015) que resultam em compressão e expansão de largura de banda, respectivamente. Para esquemas de compressão, o benefício é que pode-se obter um aumento no número de usuários simultâneos no canal físico, enquanto que a expansão de largura de banda permite melhorar a qualidade do sinal para canais ruidosos (RAMSTAD, 2002).

Com base nos mapeamentos geométricos de Shannon-Kotel'Nikov (SHANNON, 1948; KOTEL'NIKOV, 1959), foi desenvolvida a codificação paramétrica. Nesse esquema,

a ideia consiste em codificar os símbolos utilizando mapeamentos paramétricos. A vantagem da codificação paramétrica consiste na facilidade de implementação, pois as equações utilizadas são relativamente simples. Na literatura, adotando um esquema de compressão 2:1, uma possibilidade é utilizar a curva da espiral de Arquimedes como mapeamento (FLOOR; RAMSTAD, 2006; HEKLAND et al., 2009; SUÁREZ-CASAL et al., 2016; FRESNEDO et al., 2013; BRANTE et al., 2011).

Para o canal sem fio o desempenho do esquema paramétrico sofre o efeito de fatores indesejados, como o desvanecimento e a perda de percurso. Além disso, os mapeamentos propostos por Shannon-Kotel’Nikov são ótimos apenas para canal AWGN (do inglês *additive white Gaussian noise*). Esses fatores somados levam a uma limitação de desempenho. Uma opção é utilizar a codificação não-paramétrica que determina a curva de mapeamento ótima por meio de otimizações numéricas. Essa técnica faz uso de algoritmos de quantizações vetoriais para obter o mapeamento que minimiza a relação sinal-distorção (SDR, do inglês *Signal-to-Distortion Ratio*). Um desses algoritmos é o PCCOVQ (do inglês *Power Constrained Channel Optimized Vector Quantization*). Por meio do PCCOVQ, a distância em relação ao limite ótimo teoricamente atingível (OPTA, do inglês *Optimal Performance Theoretically Attainable*) é reduzida significativamente (HODGSON et al., 2016; SALEH et al., 2012). Contudo, a desvantagem desse esquema resulta da complexidade de implementação, visto que são feitas otimizações de vários parâmetros para melhorar o desempenho, enquanto que o esquema paramétrico utiliza equações relativamente simples na codificação.

Por definição, os mapeamentos analógicos são ótimos quando a função de densidade de probabilidade (PDF, do inglês *Probability Density Function*) da fonte e do canal são iguais (BERGER; TUFTS, 1967), como ocorre quando adota-se fonte Gaussiana. Na literatura majoritariamente considerou-se fonte Gaussiana e canal AWGN tendo em vista que nesse contexto o desempenho é próximo do limite teórico (HEKLAND et al., 2005). Contudo, em um cenário realista de MTC, os sensores coletam dados que não tem obrigatoriamente uma PDF definida. Por consequência, a PDF da fonte torna-se incompatível com a do canal e ocorre um declínio no desempenho.

Neste trabalho, adotou-se dois conjuntos de amostras coletadas por sensores, respectivamente, temperatura e umidade, disponíveis em (UCI Machine Learning Repository, 2018). Esses conjuntos não tem uma PDF específica, além do que, existem lacunas consideráveis entre os valores consecutivos. Essa característica dos conjuntos de dados adotados justifica a investigação de técnicas que permitam minimizar o impacto da

incompatibilidade entre fonte e canal.

Para o esquema paramétrico, foi aplicada uma técnica para tentar aproximar a PDF dos conjuntos de uma Gaussiana e, em sequência, foi feita a normalização dos dados. Optou-se por implementar a transformação de Box-Cox, o qual consiste em transformações de potência que permitem aproximar uma PDF empírica de uma PDF definida. Além disso, considerando que o transmissor e o receptor tem conhecimento das médias dos conjuntos, foi aplicada a *feature scaling and mean normalization* para que os conjuntos transformados tenham média zero. Por meio dessas técnicas simples, houve uma melhora considerável na PDF dos dados, o que resultou em uma melhora no desempenho da codificação apramétrica.

Por outro lado, o algoritmo PCCOVQ utilizado no esquema não-paramétrico se adapta com facilidade a diferentes fontes de informação. Por isso, para esse esquema são necessários apenas pequenos ajustes nos parâmetros iniciais do algoritmo e não foi preciso utilizar a transformação de Box-Cox.

Este trabalho aborda a análise de desempenho da codificação analógica conjunta fonte-canal no contexto das comunicação do tipo máquina. Para isso, utilizou-se os esquemas paramétrico e não-paramétrico e foram desenvolvidas técnicas para se adaptar aos conjuntos de dados não-Gaussianos que foram utilizados. Os resultados numéricos mostram que a codificação não-paramétrica tem o desempenho mais próximo do limite teórico. Além disso, pode-se observar que a transformação e Box-Cox melhorou significativamente o desempenho da codificação paramétrica, sendo que foi possível alcançar um desempenho próximo do esquema não-paramétrico, o qual tem uma implementação complexa devido a grande quantidade de otimizações que são feitas.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Esta dissertação tem como objetivo avaliar o desempenho dos esquemas de codificação analógica paramétrico e não-paramétrico, para conjuntos de amostras reais coletadas que não tem distribuição Gaussiana, no contexto das comunicações críticas, para as quais é necessário assegurar baixa-latência e comunicação seja ultra-confiável.

1.1.2 Objetivos Específicos

- Analisar técnicas que podem ser implementadas para comunicações ultra-confiáveis e de baixa latência (URLLC);
- Avaliar o desempenho da codificação paramétrica, implementada por meio da curva da espiral de Arquimedes, em termos de SDR e relação sinal-ruído do canal (CSNR, do inglês *Channel Signal-to-Noise Ratio*);
- Analisar a eficiência da Transformação de Box-Cox e *feature scaling and mean normalization* utilizadas na codificação paramétrica;
- Examinar o desempenho da codificação não-paramétrica, implementada com o algoritmo PCCOVQ, em termos de SDR e CSNR;
- Determinar a distância numérica entre o OPTA e a codificação paramétrica e não-paramétrica, respectivamente.

1.2 ESTRUTURA DO DOCUMENTO

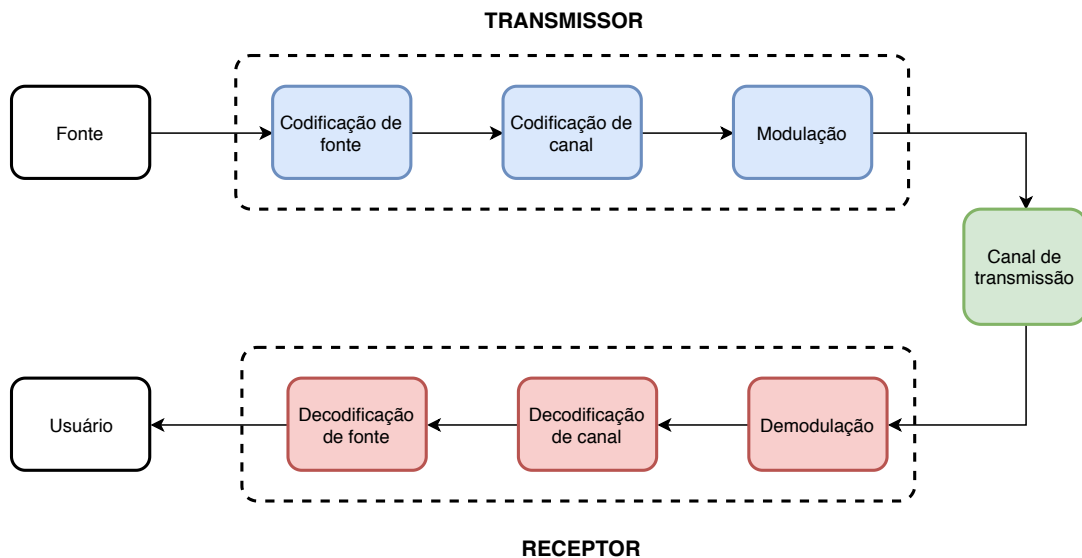
Este documento está organizado da seguinte forma: No capítulo 2 é feita uma descrição detalhada do modelo do sistema de comunicação implementado. Inicialmente, é feita uma descrição genérica do esquema analógico e são detalhadas as métricas utilizadas para avaliar o desempenho do sistema. Além disso, é feita a descrição matemática do OPTA, que também é usado para analisar a eficiência dos métodos propostos. No capítulo 3 é abordada a codificação analógica paramétrica para o esquema de compressão 2 : 1. Para esse esquema, são descritas as técnicas utilizadas para melhorar o desempenho, a transformação de Box-Cox e a técnica *feature scaling and mean normalization*. No capítulo 4, é feita descrição da codificação não-paramétrica. Tendo em vista a complexidade do tema, optou-se por descrever passo-a-passo o funcionamento do algoritmo PCCOVQ utilizado para determinar os mapeamentos ótimos para os conjuntos de dados. No capítulo 5, primeiramente é ilustrado o comportamento estatístico dos conjuntos de amostras adotados. Em seguida, são demonstrados os desempenhos da codificação paramétrica com e sem a transformação de Box-Cox, a codificação não-paramétrica e o OPTA e é feita a discussão sobre os resultados obtidos. Por fim, o capítulo 6 faz as conclusões gerais sobre a dissertação e indica possibilidades de trabalhos futuros sobre o assunto.

2 MODELAGEM DOS SISTEMAS DIGITAL E ANALÓGICO

2.1 O SISTEMA DIGITAL

O sistema digital é a opção mais utilizada para comunicações da IoT. Todavia, para URLLC, o uso desse sistema pode ser inoportuno para suprir os requisitos desse tipo de aplicação, que são confiabilidade e baixa latência. O modelo digital opera em blocos definidos que são projetados para pares fixos de distorção do sinal, conforme ilustra a Figura 1.

Figura 1 – Diagrama em blocos do sistema digital.



Fonte: Adaptado de (HAYKIN; MOHER, 2011).

A primeira etapa consiste na codificação da fonte que visa representar de forma eficiente os dados da fonte de informação. Portanto, a ideia é projetar um codificador de fonte para minimizar redundâncias do sinal original sem comprometer a mensagem recebida pelo usuário final (HAYKIN; MOHER, 2011).

Uma das técnicas mais usadas na codificação de fonte é a codificação de Huffman. Considerando que existe conhecimento estatístico sobre o sinal, esse método consiste em codificar os dados do sinal original em um dicionário já conhecido que determina a palavra código para cada símbolo com base na probabilidade de ocorrência. O algoritmo de Huffman se baseia em duas observações: os símbolos com maior probabilidade de ocorrência são os que tem as palavras código menores e os dois símbolos com menor probabilidade de ocorrência tem o mesmo tamanho de palavra-código. Dessa forma,

é feita a compressão dos dados e obtém-se uma redução significativa na quantidade de redundâncias do sinal de informação original (SAYOOD, 2006). A desvantagem da codificação de Huffman é a obrigatoriedade de conhecimento do comportamento probabilístico da fonte de informação. *A priori* essa informação não é conhecida para todos os tipos de fonte, o que acaba limitando a eficiência da compressão de Huffman. Para esses casos, sugere-se optar por outro método de codificação de fonte conhecido como Lempel-Ziv (HAYKIN; MOHER, 2011).

Depois da codificação da fonte, é feita a codificação de canal por meio de códigos corretores de erros. Os códigos corretores de erros fornecem a capacidade de detectar ou corrigir os erros de bit introduzidos pelo canal (GOLDSMITH, 2005). Entre as possibilidades de códigos que podem ser usados, destaca-se a codificação convolucional e a codificação em blocos. Além disso, existem opções mais modernas que incluem LDPC (do inglês *Low-Density Parity-Check*) e Turbo. A ideia por trás dos códigos corretores de erros é, essencialmente, transformar k bits de informação em $n > k$ bits codificados por meio de blocos de redundâncias. Dessa forma, obtém-se uma correlação entre os bits codificados e pode-se minimizar os erros de transmissão. Depois disso, o sinal é modulado e transmitido através do canal sem fio. No receptor, são feitos os procedimentos inversos: demodulação, decodificação de canal e decodificação de fonte, respectivamente.

O sistema digital implementa a codificação da fonte e canal em duas etapas com base em um dos teoremas desenvolvidos por (SHANNON, 1949), o qual prova que para canais AWGN com uma fonte de informação discreta e sem memória, pode-se obter um desempenho ótimo implementando a codificação de fonte e canal em duas etapas. Todavia, os códigos corretores de erros foram projetados majoritariamente para o canal AWGN. No canal sem fio, a influência de fatores inerentes ao meio, como o desvanecimento e da perda de percurso degrada significativamente o sinal transmitido. Para minimizar esse problema, são utilizados blocos de redundância na codificação de canal. Tendo em vista que o receptor tem que esperar a transmissão do sinal terminar para realizar os procedimentos para estimar o sinal, ao utilizar sequências de redundância o tempo de espera aumenta significativamente o que resulta em atraso na comunicação.

Por esse motivo, para aplicações URLLC torna-se interessante investigar técnicas que possibilitem atender ao requisito de baixa latência exigido para aplicações críticas. Neste trabalho, considera-se a latência de comunicação, ou seja, em termos de símbolos transmitidos. Sendo assim, a codificação analógica conjunta fonte-canal caracteriza-se por codificar símbolo a símbolo em uma curva de mapeamento, o que reduz drasticamente o

problema do atraso na comunicação. Além disso, foi comprovado em (FRESNEDO et al., 2011) que a codificação analógica tem melhor desempenho em termos de SDR em relação ao sistema digital implementado com a técnica de modulação codificada por intercalação de bit BICM (do inglês *Bit Interleaved Coded Modulation*). Portanto, tendo em vista as vantagens da codificação analógica em relação ao sistema digital, optou-se por aplicá-la neste trabalho.

2.2 ESQUEMA GENÉRICO DA CODIFICAÇÃO ANALÓGICA

A codificação analógica fundamenta-se em codificar símbolos discretos no tempo e contínuos na amplitude utilizando uma curva de mapeamento. Adota-se usualmente uma fonte sem memória, sendo assim, o vetor fonte $\mathbf{x} \in \mathbb{R}^{1 \times N}$ com potência média $\sigma_{\mathbf{x}}^2$, é codificado em $\mathcal{C}(\mathbf{x}) \in \mathbb{R}^{1 \times K}$ usando curvas de mapeamentos paramétricas ou não-paramétricas. O vetor codificado é transmitido através do canal sem fio. No receptor, o sinal recebido é denotado por

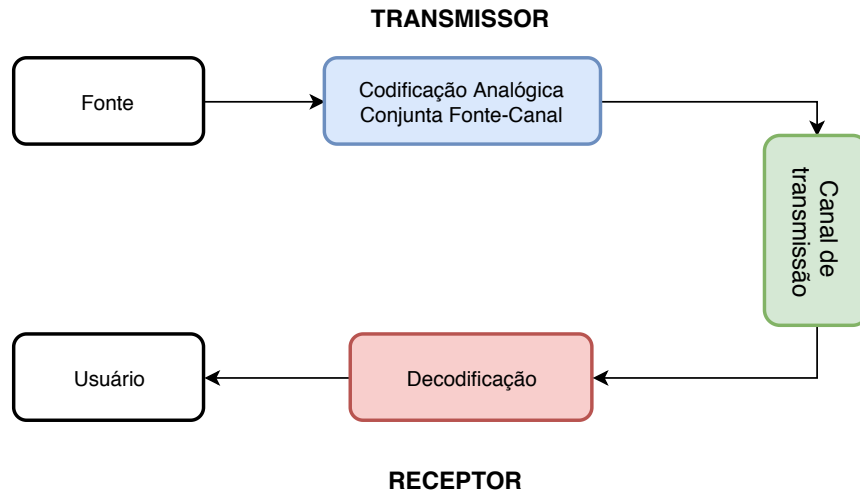
$$\mathbf{y} = \mathcal{C}(\mathbf{x}) \cdot h + \mathbf{w}, \quad (1)$$

onde h denota o coeficiente de desvanecimento do canal, o qual é modelado neste trabalho pela distribuição de Rayleigh e w é o ruído Gaussiano branco.

Para decodificar o sinal recebido, pode ser utilizado o decodificador por mínimo erro médio quadrático (MMSE, do inglês *Minimum Mean Square Error*) ou o decodificador por máxima verossimilhança (ML, do inglês *Maximum Likelihood*). O decodificador MMSE é mais robusto e complexo de ser implementado, pois, estima os símbolos que podem ou não pertencer a curva de mapeamento. Sendo assim, a estimativa dos símbolos será o valor esperado de uma função de densidade de probabilidade, que contém informações sobre a fonte (BRANTE et al., 2011). Como a probabilidade condicional é descontínua e não-linear, visto que os símbolos estimados podem não pertencer a curva paramétrica, só é possível obter \hat{X}_{MMSE} numericamente.

Como alternativa, pode-se utilizar o decodificador ML. Esse, por sua vez, consiste em realizar o mapeamento inverso para estimar os símbolos e pode ser facilmente implementado, pois a decodificação é feita com base nos símbolos que pertencem a curva paramétrica. Neste trabalho, optou-se pelo decodificador ML devido a sua fácil implementação e desempenho eficiente (FRESNEDO et al., 2013). O diagrama em blocos da Figura 2 resume o esquema de codificação analógico. Ao comparar com a Figura 1, nota-se que os três blocos referentes a codificação de canal, codificação de fonte

Figura 2 – Diagrama em blocos que resume o esquema de codificação analógica conjunta fonte-canal.



Fonte: Adaptado de (HASSANIN, 2018).

e modulação são substituídos por apenas um na codificação analógica.

Para avaliar a qualidade da transmissão é usual utilizar como métrica o Erro Quadrático Médio (MSE, do inglês *Mean Squared Error*). O MSE determina a distância Euclidiana entre o símbolo original \mathbf{x} e a estimativa feita pelo receptor $\hat{\mathbf{x}}$, denotado por

$$\text{MSE} = \frac{\|\mathbf{x} - \hat{\mathbf{x}}\|^2}{N}, \quad (2)$$

com base no MSE, pode-se determinar a SDR, do inglês *Signal-to-Distortion Ratio*) como

$$\text{SDR} = 10 \log_{10} \left(\frac{\sigma_{\mathbf{x}}^2}{\text{MSE}} \right). \quad (3)$$

Além disso, considerando a potência média do desvanecimento σ_h^2 e do ruído Gaussiano branco σ_w^2 , obtém-se CSNR denotada por

$$\text{CSNR} = 10 \log_{10} \left(\frac{\sigma_h^2}{\sigma_w^2} \right). \quad (4)$$

Outra forma de determinar se o desempenho do sistema foi eficiente é comparar com o OPTA, o qual é um limite teórico derivado dos conceitos teóricos desenvolvidos por Shannon (SHANNON, 1948) sobre capacidade do canal C e função de taxa de distorção R de uma fonte com base em um critério de fidelidade. A capacidade do canal definida por

$$C = K \int_h \log_2 \left(1 + \frac{h^2}{\sigma_w^2} \right) p(h) dh, \quad (5)$$

onde $p(h)$ é a PDF do canal, tal que a integral representa o cálculo para todas as realizações de h . Assim, C representa a taxa máxima de transmissão que não compromete a confiabilidade da transmissão. Enquanto que a função taxa de distorção R

$$R = N \log_2 \left(\frac{\sigma_x^2}{\text{MSE}} \right), \quad (6)$$

pode ser entendida como a quantidade de capacidade do canal necessária para reproduzir uma sequência de amostras fonte com determinada distorção (BERGER; TUFTS, 1967).

Matematicamente, o OPTA é obtido pela igualdade entre a capacidade do canal C (5) e a função taxa de distorção R (6). Após uma troca logarítmica, o OPTA é definido por

$$N \log_{10} \left(\frac{\sigma_x^2}{\text{MSE}} \right) = K \int_h 10 \log_{10} \left(1 + \frac{h^2}{\sigma_w^2} \right) p(h) dh. \quad (7)$$

Na codificação analógica, existe a possibilidade de implementar esquemas compressão ou expansão de largura de banda. A compressão de largura de banda obteve desempenho eficiente para diferentes esquemas ($N > K$), como em (FLOOR; RAMSTAD, 2006; FRESNEDO et al., 2013). Neste trabalho, optou-se pelo esquema de compressão 2:1. Sendo assim, o Capítulo 3 e 4 descrevem, respectivamente, a codificação paramétrica e não-paramétrica para o esquema de compressão 2:1.

3 CODIFICAÇÃO PARAMÉTRICA

No esquema paramétrico, adota-se uma fonte sem memória de amplitude contínua e discreta no tempo, que codifica os símbolos em uma curva de mapeamento e transmite os símbolos-fonte através do canal sem fio com desvanecimento Rayleigh. Além disso, assume-se informação de estado do canal no receptor (CSI). Na codificação analógica, de forma geral, podem ser implementados esquemas de expansão e compressão de largura de banda.

Para a codificação paramétrica, os esquemas de expansão de largura de banda implementados na literatura tiveram um desempenho distante do OPTA (HEKLAND et al., 2009). Considerando o esquema 1:2, a codificação fundamenta-se em transformar um símbolo fonte em dois símbolos de canal. Contudo, o efeito do ruído na transmissão pode levar a decodificação do símbolo em ramos opostos da curva de mapeamento utilizada, essa distorção é denominada distorção de limiar e é um dos fatores que limita a eficiência dos esquemas de expansão. Além disso, podem ocorrer outros erros de distorção causados pelo ruído. Esses efeitos somados limitam o desempenho dos esquemas de expansão.

A compressão de largura de banda foi implementados em diversos trabalhos na literatura. A vantagem dos esquemas compressão é que dessa forma pode-se usar a largura de banda de forma mais eficiente, o que é interessante para o cenário URLLC. Em termos de desempenho, o esquema 2:1 obteve resultados próximos do limite teórico (HEKLAND et al., 2009; FRESNEDO et al., 2013; BRANTE et al., 2013) e, além disso, teve um desempenho superior ao sistema digital (FRESNEDO et al., 2011), por esses motivos, adotou-se esse esquema para a codificação paramétrica. Contudo, além do 2:1 pode-se implementar outras ordens de compressão, 3:1, 4:1 e 3:2, como em (FLOOR; RAMSTAD, 2006), apesar do desempenho obtido ser mais distante do limite teórico.

3.1 CODIFICAÇÃO 2:1

Para o esquema de compressão 2:1, dois símbolos fonte são codificados em um símbolo de canal. Na literatura, utilizou-se como mapeamento a curva da espiral de Arquimedes, os mapeamentos de Shannon e a curva de Hilbert para o esquema 2:1 (RAMSTAD, 2002). Porém, a espiral de Arquimedes é o mapeamento mais recorrente pois tem o melhor desempenho, sendo que para o canal AWGN obteve-se desempenho próximo do OPTA (HEKLAND et al., 2005; FRESNEDO et al., 2013), além de já ter

sido utilizada para canais sem fio e alcançar desempenho eficiente (BRANTE et al., 2011; FRESNEDO et al., 2011)

Para o esquema de compressão, a codificação consiste em aplicar a função de mapeamento M_Δ e a função T_α que é utilizada para aumentar a flexibilidade do sistema (FRESNEDO et al., 2011; BRANTE et al., 2013).

Considerando o par de amostras-fonte $\mathbf{x} = (x_1, x_2)$, a codificação é feita nos braços positivos e negativos da espiral de Arquimedes, os quais correspondem aos ângulos denotados por (HEKLAND et al., 2009)

$$\hat{\theta}_1 = \arg \min_{\theta \geq 0} \left\{ \left(x_1 - \frac{\Delta}{\pi} \theta \sin \theta \right)^2 + \left(x_2 - \frac{\Delta}{\pi} \theta \cos \theta \right)^2 \right\}, \quad (8)$$

$$\hat{\theta}_2 = \arg \min_{\theta < 0} \left\{ \left(x_1 + \frac{\Delta}{\pi} \theta \sin \theta \right)^2 + \left(x_2 - \frac{\Delta}{\pi} \theta \cos \theta \right)^2 \right\}, \quad (9)$$

onde Δ é a distância entre os braços da espiral e $\theta \in \mathbb{R}$ é o ângulo que corresponde ao caminho entre o ponto original e o ponto mapeado na espiral. Em seguida, para obter a menor distância entre o ponto original e o mapeado é aplicada a função de mapeamento definida como

$$M_\Delta(\mathbf{x}) = \min(\hat{\theta}_1, \hat{\theta}_2). \quad (10)$$

A Figura 3 ilustra o exemplo de codificação de um par de amostras. Adotou-se o par $\mathbf{x} = (1.3, 1.3)$, representado pelo símbolo \circ . Os ângulos positivo e negativo θ_1 e θ_2 são mostrados na figura. Como o ângulo θ_2 está mais próximo do ponto original, o símbolo mapeado é $M_\Delta(\mathbf{x}) = \theta_2$. Dessa forma, dois símbolos-fonte representados por coordenadas no plano cartesiano são mapeadas em um único ângulo da espiral de Arquimedes, denotado por $M_\Delta(\mathbf{x})$.

A última etapa do codificador consiste em aplicar a função inversível T_α dada por


$$T_\alpha(M_\Delta(\mathbf{x})) = \text{sign}(M_\Delta(\mathbf{x})) \cdot |M_\Delta(\mathbf{x})|^\alpha, \quad (11)$$

onde α pode ser otimizado com Δ , o que melhora a taxa de distorção do sinal SDR no receptor (BRANTE et al., 2013; HU et al., 2011).

Por fim, antes de transmitir é aplicado o parâmetro γ para normalizar a energia dos símbolos de canal. Então, o símbolo transmitido através do canal é dado por

$$\mathcal{C}(\mathbf{x}) = \frac{T_\alpha(M_\Delta(\mathbf{x}))}{\gamma}. \quad (12)$$

Figura 3 – Exemplo de codificação de um par de amostras $\mathbf{x} = (1.3, 1.3)$ mapeado na curva da espiral de Arquimedes, em um único símbolo de canal $M_{\Delta}(\mathbf{x})$.



Fonte: Autoria própria.

No receptor, o símbolo recebido y é renormalizado por meio do fator $\frac{1}{\gamma}$. Em seguida, aplica-se a inversa da função $T_{\alpha}^{-1}(\cdot)$, de modo que

$$\tilde{y} = \text{sign}\left(\frac{y \cdot \gamma}{h}\right) \cdot \left|\frac{y \cdot \gamma}{h}\right|^{\frac{1}{\alpha}}. \quad (13)$$

Por fim, utiliza-se o decodificador por máxima verossimilhança para fazer a estimativa do símbolo recebido. Esse decodificador consiste no mapeamento inverso de \tilde{y} , conforme

$$\hat{\mathbf{x}}_{\text{ML}} = M_{\Delta}^{-1}(\tilde{y}). \quad (14)$$

Os mapeamentos geométricos de Shannon-Kotel’Nikov foram desenvolvidos para atingir um desempenho ótimo considerando duas circunstâncias: canal AWGN e compatibilidade entre a PDF da fonte e do canal. No entanto, sob a perspectiva da comunicação do tipo máquina, é recorrente que os dados coletados por sensores não tenham uma PDF definida. Como a PDF do canal usualmente é modelada para uma PDF Gaussiana, isso resulta em uma incompatibilidade entre as duas PDFs. Esse fato, somado ao uso do canal sem fio, causa um declínio no desempenho do esquema proposto. Contudo, pode-se implementar uma técnica conhecida como transformação de Box-Cox

para tentar aproximar a PDF empírica de uma PDF Gaussiana, conforme é descrito na seção 3.2.

3.2 TRANSFORMAÇÃO DE BOX-COX

Para conjuntos de amostras não-Gaussianos, o esquema paramétrico necessita de técnicas complementares para garantir a eficiência do desempenho. A ideia da codificação paramétrica é ser um método simples e com bom desempenho, para manter esse modelo buscou-se uma técnica que também seja fácil de ser implementada: a transformação de Box-Cox.

A transformação de Box-Cox trata-se de transformações de potência que visam aproximar uma PDF genérica de uma PDF definida, como a Gaussiana (OSBORNE, 2010). Para o vetor de símbolos fonte \mathbf{x} utilizado na codificação 2:1, a transformação de Box-Cox é dada por

$$\mathbf{x}(\mu) = \begin{cases} \ln(\mathbf{x}), & \mu = 0 \\ \frac{\mathbf{x}^\mu - 1}{\mu}, & \mu \neq 0 \end{cases} \quad (15)$$

onde $-5 \leq \mu \leq 5$ é o parâmetro que maximizar a função de log-verossimilhança. No MATLAB, utiliza-se a função `fminsearch` para determinar o valor de μ por meio de otimizações numéricas.

Considera-se que o transmissor e o receptor tem conhecimento sobre a média dos conjuntos adotados e que a informação sobre o valor de μ é repassada para o receptor. Sendo assim, para garantir que os conjuntos de dados transformados tenham média zero, foi aplicada a técnica FSMN (*feature scaling and mean normalization*)¹ a qual é uma técnica derivada de *machine learning* desenvolvida para aproximar a média dos conjuntos de dados de zero. Sendo assim, a FSMN é definida como

$$\tilde{\mathbf{x}} = \frac{\mathbf{x}(\mu) - \bar{\mathbf{x}}(\mu)}{\max\{\mathbf{x}(\mu)\} - \min\{\mathbf{x}(\mu)\}}, \quad (16)$$

sendo que $\bar{\mathbf{x}}(\mu)$ denota a média do vetor $\mathbf{x}(\mu)$.

No receptor, aplica-se a função inversa da transformação de Box-Cox depois da decodificação, conforme

$$\tilde{\mathbf{x}}_{\text{ML}} = \hat{\mathbf{x}}_{\text{ML}} \cdot \left(\max\{\mathbf{x}(\mu)\} - \min\{\mathbf{x}(\mu)\} \right) + \bar{\mathbf{x}}(\mu), \quad (17)$$

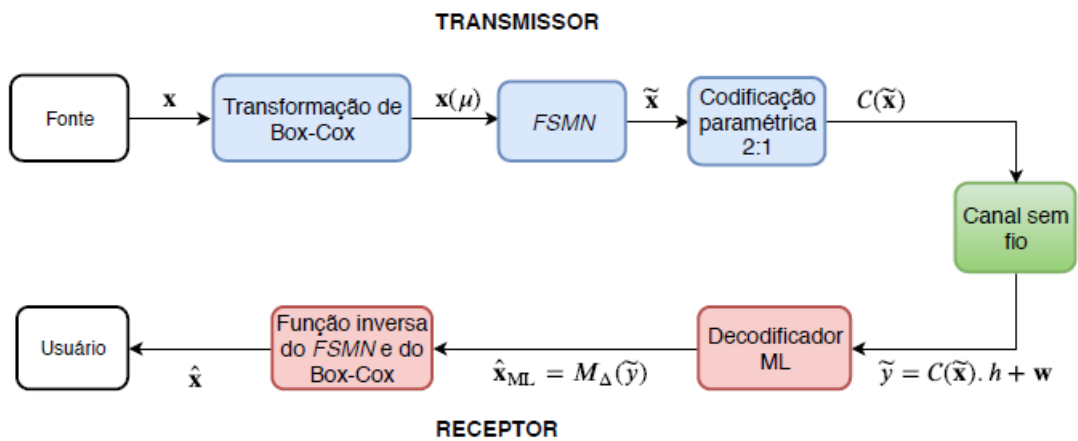
¹Para mais informações sobre *feature scaling and mean normalization*, sugere-se a leitura do ilustrativo tutorial disponível em <https://kharshit.github.io/blog/2018/03/23/scaling-vs-normalization>.

Finalmente, obtém-se o símbolo estimado

$$\hat{\mathbf{x}} = (\tilde{\mathbf{x}}_{\text{ML}} \cdot \mu + 1)^{\frac{1}{\mu}}. \quad (18)$$

Sendo assim, o digrama em blocos da Figura 4 mostra o passo-a-passo do esquema analógico paramétrico implementado neste trabalho com a transformação de Box-Cox e a FSMN.

Figura 4 – Diagrama em blocos do passo-a-passo da codificação paramétrica



Fonte: Autoria própria.

4 CODIFICAÇÃO NÃO-PARAMÉTRICA

No esquema analógico, a codificação paramétrica é uma opção fácil do ponto de vista de implementação, contudo, com desempenho limitado para canais com desvanecimento. Para esse contexto, é interessante avaliar um método mais robusto, o mapeamento não-paramétrico. A principal diferença em relação ao esquema paramétrico consiste na utilização de funções complexas para mapear os símbolos, ao invés de utilizar funções de curvas paramétricas que são apenas uma aproximação para o mapeamento.

A codificação não-paramétrica tem como objetivo determinar a curva de mapeamento ótima que minimiza a distorção do sinal. Para isso, podem ser usados vários algoritmos de otimização.

Para o contexto de uma rede de sensores sem fio com limitação de energia dos nós sensores pode ser usada a quantização distribuída (DQ, do inglês *Distributed Quantizer*) para diferentes modelos de canais (KIM et al., 2011). Outro caminho possível é utilizar a quantização vetorial (VQ, do inglês *Vector Quantization*), tendo em vista que foram obtidos bons resultados para codificação de imagens e áudio (VAISHAMPAYAN; FARVARDIN, 1992). Para canais com bastante ruído, uma opção vantajosa é empregar a quantização vetorial otimizada para canal (COVQ, do inglês *Channel Optimized Vector Quantizer*), que consiste em otimizações numéricas que determinam os pares ótimos de codificador e decodificador.

Ainda sobre os algoritmos de otimização, no extenso trabalho de Fuldseth (FULDSETH, 1997) é implementado o algoritmo de quantização vetorial otimizado para canais com restrição de potência (PCCVOQ, do inglês *Power Constrained Channel Optimized Vector Quantization*). A ideia geral é baseada nos algoritmos VQ e COVQ, porém, com foco principal para canais com restrição de potência de transmissão. O algoritmo PCCOVQ proposto por Fuldseth, inicialmente, foi implementado para o canal AWGN, sendo que o canal Rayleigh foi analisado posteriormente por (SALEH et al., 2012; HODGSON et al., 2016, 2017). Para o canal sem fio, os mapeamentos são otimizados para cada valor de ganho de desvanecimento, considerando conhecimento do canal apenas no receptor. Foi comprovado em (SALEH et al., 2012) que a codificação não-paramétrica com a utilização do PCCOVQ tem desempenho mais próximo do OPTA do que o esquema paramétrico. Por esse motivo, adotou-se o PCCOVQ como algoritmo de otimização da codificação não-paramétrica.

Para o esquema de compressão 2 : 1, a codificação não-paramétrica consiste, resumidamente, em mapear o par de símbolos fonte $x = (x_1, x_2)$ em um vetor de reconstrução c_i que tem o menor erro de distorção. Em seguida, cada índice i do é modulado por amplitude de pulso (PAM, do inglês *pulse amplitude modulation*) e transmitido através do canal sem fio. No receptor, é necessário apenas estimar o índice i .

A vantagem do esquema não-paramétrico é que podem ser otimizados uma ampla gama de parâmetros para minimizar a SDR, como será mostrado em detalhes na seção 4.2. Enquanto que no esquema paramétrico, podem ser otimizados apenas dois parâmetros no esquema 2 : 1. Isso garante ao esquema não-paramétrico maior robustez de desempenho, todavia, o aumento no número de otimizações eleva o grau de complexidade do algoritmo (HODGSON et al., 2016).

Para facilitar a compreensão do assunto, primeiramente é feita uma introdução sobre os conceitos de quantização vetorial na seção 4.1. Em seguida, é descrita a codificação analógica não-paramétrica no esquema 2:1 implementada com o algoritmo PCCOVQ na seção 4.2.


4.1 CONCEITOS GERAIS SOBRE QUANTIZAÇÃO VETORIAL

No projeto de um sistema de comunicação é necessário utilizar técnicas para diminuir a quantidade de dados a ser transmitida. A quantização permite representar um grande conjunto de valores com um conjunto menor. Na quantização, o codificador divide os símbolos gerados pela fonte em um determinado intervalo ou região de quantização Ω , o qual é representado por uma palavra-código.

Quando os intervalos de quantização tem tamanho fixo, denomina-se quantização escalar uniforme. Essa é a técnica mais fácil de ser implementada e é usada frequentemente na conversão do sinal analógico/digital. Todavia, para minimizar a distorção média é interessante que os intervalos de quantização não sejam fixos, que é o caso da quantização escalar não-uniforme. Na quantização não-uniforme, os intervalos de quantização são menores para os símbolos com maior probabilidade de ocorrência e maiores para os símbolos com menor probabilidade de ocorrência. Dessa forma, pode-se aproximar com mais precisão o intervalo adequado para os símbolos que mais aparecem e minimizar os erros de quantização (SAYOOD, 2006).

Uma proposta mais sofisticada é a quantização vetorial, a qual tem uma distorção

Figura 5 – Exemplo de quantização vetorial.



Fonte: Adaptado de (HODGSON, 2017).

mais baixa do que a quantização escalar uniforme e não-uniforme considerando a mesma taxa de transmissão. Como o próprio nome diz, a quantização vetorial consiste em determinar a região de quantização para o vetor fonte \mathbf{x} e atribuir um vetor de reconstrução \mathbf{c}_i para cada símbolo. Sendo assim, a ideia é determinar o índice i do vetor de reconstrução que minimiza a distorção. Para ilustrar essa ideia, a Figura 5 mostra um exemplo de quantização vetorial. Adotou-se quatro pares de amostras \mathbf{x} que variam no intervalo $-2,5$ até $2,5$. Sendo assim, as duas dimensões de \mathbf{x} , respectivamente, x_1 e x_2 , são codificadas em um vetor de quantização \mathbf{c}_i . Para isso, primeiro, determina-se a qual partição Ω_i o par \mathbf{x} pertence. Em seguida, são determinados os vetores de reconstrução, denotados por $\mathbf{c}_i \in \{\mathbf{c}_0, \mathbf{c}_1, \mathbf{c}_2, \mathbf{c}_3\}$, que por sua vez pertencem a $\Omega_i \in \{\Omega_0, \Omega_1, \Omega_2, \Omega_3\}$.

O algoritmo otimizado de Linde-Buzo-Gray (LBG) é usado com frequência na quantização vetorial. Esse consiste, essencialmente, em determinar a partição a qual as amostras pertencem e obter o dicionário, o qual inclui os valores quantizados das amostras. Esse processo de otimização é feito até que atingir um critério de parada pré-definido. O algoritmo LBG foi projetado adotando conhecimento da PDF da fonte e a partir disso, eram feitas as otimizações para determinar os dicionários. Contudo, para facilitar a implementação, pode-se utilizar uma sequência de treinamento e otimizar os parâmetros com base nesse (HODGSON, 2017). O algoritmo PCCOVQ implementado neste trabalho é uma aplicação do algoritmo LBG desenvolvida para canais com restrição

de potência (FULDSETH, 1997), conforme trata a seção 4.2.

4.2 O ALGORITMO PCCOVQ

Na codificação não-paramétrica utilizou-se o algoritmo PCCOVQ, o qual é baseado no algoritmo LBG. A principal diferença entre eles resulta da restrição de potência considerada pelo PCCOVQ. A ideia fundamental do PCCOVQ é determinar a quantização vetorial que minimiza a distorção, considerando que existe uma restrição de potência. Por esse motivo, o algoritmo adota o fator λ , que é o multiplicador de Lagrange utilizado para restrição de potência. Sendo assim, o desafio de implementação do PCCOVQ é conciliar a otimização dos parâmetros com a restrição de potência imposta, visto que a otimização numérica considerando apenas a distorção de quantização implica em potência infinita (HODGSON, 2017).

O PCCOVQ mapeia o vetor fonte \mathbf{x} de $N = 2$ dimensões em Q regiões de quantização Ω_i , obtendo uma partição $\mathbf{p} = \{\Omega_0, \Omega_1, \dots, \Omega_{Q-1}\}$. Em sequência, o codificador seleciona o símbolo de canal dado por $s = \Delta_p \cdot u_i$, onde u_i é o sinal modulado PAM e Δ_p é a distância entre dois símbolos vizinhos. Depois disso, o símbolo é transmitido através do canal sem fio. Considerou-se que o transmissor tem apenas uma partição p , pois não tem conhecimento sobre o estado de informação. No receptor, primeiro é feita a estimativa por máxima verossimilhança, $\hat{s} = \frac{y}{h}$. Em sequência, considerando que o receptor tem CSI perfeita o que resulta em um conjunto de dicionários \mathbf{a} otimizados para cada valor uniformemente discretizado de h , denotado por h_k . O receptor compara os valores dos *codebooks* com a estimativa \hat{s} por meio do cálculo do MSE, e, a partir disso, estima o índice i do vetor de reconstrução $\mathbf{c}_{k,i}$. A Figura 6 resume o funcionamento do PCCOVQ.

O processo de otimização do PCCOVQ consiste em determinar os parâmetros \mathbf{p} , \mathbf{a} e Δ que minimizam a distorção da fonte, restringindo a potência P , conforme

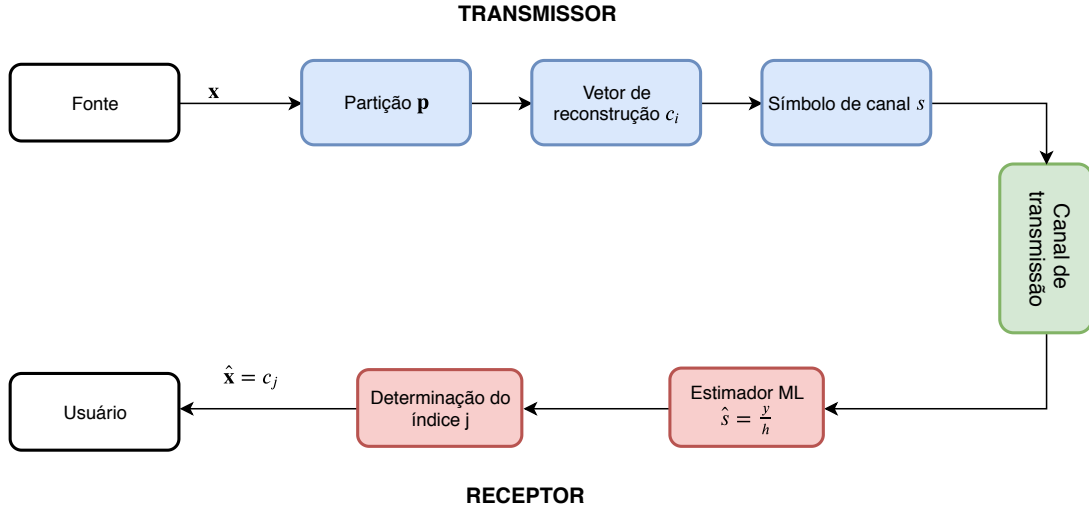
$$\min_{\mathbf{p}, \mathbf{a}, \Delta_p} D(\mathbf{p}, \mathbf{a}, \Delta_p) + \lambda P, \quad (19)$$

onde $D(\mathbf{p}, \mathbf{a}, \Delta_p)$ é a distorção da fonte, definida como

$$D(\mathbf{p}, \mathbf{a}, \Delta_p) = \sum_{i=0}^{Q-1} \int_{\Omega_i} \mathcal{D}_i(\mathbf{x}) f_x(\mathbf{x}) d\mathbf{x}, \quad (20)$$

onde $f_x(\mathbf{x})$ é a PDF de \mathbf{x} . Como foi adotada uma sequência de treinamento, o cálculo da integral da PDF é simplificado para a quantidade de amostras da sequência de treinamento

Figura 6 – Diagrama em blocos que resume o funcionamento do PCCOVQ.



Fonte: Autoria própria.

alocadas para a partição Ω_i . O termo $\mathcal{D}_i(\mathbf{x})$ denota a distorção associada à partição i , conforme

$$\mathcal{D}_i(\mathbf{x}) = \frac{1}{N} \sum_{j=0}^{Q-1} \sum_{k=0}^{H-1} p_h(k) p(j|i, k) \|\mathbf{x} - \mathbf{c}_{k,j}\|^2, \quad (21)$$

sendo $p_h(k)$ a probabilidade de se obter o desvanecimento discreto h_k e $p(j|i, k)$ define a a probabilidade de receber o índice j dado que i foi transmitido (HODGSON, 2017).

O algoritmo LBG considera uma sequência de treinamento e atribui cada elemento para o padrão representativo mais próximo. Depois disso, o padrão representativo é atualizado por meio do cálculo do centroide. Assim, quando o processo estiver concluído, teremos grupos de vetores agrupados em torno de cada um dos pontos de saída (SAYOOD, 2006). No processo de otimização, o LBG mantém dois parâmetros fixos e otimiza o terceiro, ou seja, primeiro otimiza-se o parâmetro \mathbf{p} , enquanto Δ_p e \mathbf{a} são fixos, e assim por diante. O processo de otimização é resumido a seguir com base em (SAYOOD, 2006; HODGSON et al., 2016). Informações mais detalhadas sobre o PCCOVQ podem ser vistas em (HODGSON, 2017; SALEH et al., 2012).

1. Inicialização do algoritmo para valores fixos de Δ_p , λ e uma sequência de treinamento;
2. Otimização da partição \mathbf{p} : o objetivo é determinar a partição \mathbf{p} que minimiza a função custo de distorção $\mathcal{G}_i(\mathbf{x})$. Para isso, é feito a soma entre a distorção associada

a partição (21) e a restrição de potência, definida como $\lambda \frac{\Delta_p^2}{K} \|u_i\|^2$, conforme

$$\mathcal{G}_i(\mathbf{x}) = \mathcal{D}_i(\mathbf{x}) + \lambda \frac{\Delta_p^2}{K} \|u_i\|^2, \quad (22)$$

3. Otimização do conjunto de dicionários do receptor \mathbf{a} : fundamentando-se em (SALEH et al., 2012), o dicionário ótimo é dado por

$$\mathbf{c}_{k,j} = \frac{\sum_{i=0}^{Q-1} p(j|i, k) \int_{\Omega_i} \mathbf{x} f_x(\mathbf{x}) d\mathbf{x}}{\sum_{i=0}^{Q-1} p(j|i, k) \int_{\Omega_i} f_x(\mathbf{x}) d\mathbf{x}}, j \in \mathbf{i}. \quad (23)$$


sendo que o uso da sequência de treinamento facilita o cálculo, pois o termo $\int_{\Omega_i} \mathbf{x} f_x(\mathbf{x}) d\mathbf{x}$ pode ser substituído pela soma dos valores da sequência inicial utilizada;

4. Otimização do parâmetro Δ_p : nessa etapa, utiliza-se a função `fminsearch` do *software* MATLAB para realizar as iterações não lineares e sem restrições necessárias para a otimização;
5. Cálculo da distorção $D(\mathbf{p}, \mathbf{a}, \Delta_p)$: Caso a distorção entre duas iterações consecutivas seja menor que um limite pré-definido, a otimização é finalizada. Caso contrário, o algoritmo deve continuar otimizando os parâmetros.


A vantagem do PCCOVQ é que pode-se determinar os mapeamentos ótimos para vários valores de desvanecimento h devido ao grande número de otimizações. A Figura 7 ilustra os mapeamentos obtidos para dois valores diferentes de desvanecimento e $\text{CSNR} = 30$ dB. Para determinar os mapeamentos ótimos, foram utilizados os *codebooks* do receptor. No algoritmo PCCOVQ, inicialmente, utiliza-se a sequência de treinamento com o formato de rampa. Sendo assim, o mapeamento inicial começa com o formato de rampa, e conforme o aumento de iterações, a curva se modifica para se adaptar ao desvanecimento do canal. Nota-se que a curva de mapeamento para desvanecimento profundo na Figura 6(d) é a que mais difere do formato inicial, pois, para essa condição de canal pode-se utilizar um mapeamento mais complexo porque o canal tem menos ruído, o que implica em menor quantidade de erros de estimação no decodificador. Dessa forma, garante-se um desempenho eficiente.

Finalmente, após a descrição dos dois métodos analógicos utilizados neste trabalho, o Capítulo 5 descreve detalhes estatísticos sobre os conjuntos de dados adotados neste trabalho, além disso, são ilustrados os resultados numéricos obtidos para os esquemas


Figura 7 – Mapeamentos obtidos com o algoritmo PCCOVQ para o conjunto de temperaturas adotado neste trabalho.




(a) $h = 0.01$



(b) $h = 0.05$



(c) $h = 1.4$



(d) $h = 3.0$.

Fonte: Autoria própria.

de codificação analógica implementados e são feitas discussões sobre os prós e contras dos dois esquemas.


5 RESULTADOS E DISCUSSÕES

Neste trabalho foram adotados dois conjuntos de amostras coletadas por sensores, respectivamente, temperatura e umidade, disponíveis em (UCI Machine Learning Repository, 2018). Os dados foram coletados por quatro veículos de superfície não-tripulados (USV, do inglês *Unmanned Surface Vehicles*) na cidade de Atenas, Grécia, em 2018. O conjunto de temperaturas tem 1310 amostras em uma faixa de valores de 20°C até 42°C, enquanto que conjunto de umidades relativas tem 812 amostras em uma faixa de valores de 25% até 45%. A Tabela 1 resume as informações sobre os conjuntos de temperatura e umidade e a Figura 8 mostra os histogramas.

Tabela 1 – Informações sobre os conjuntos de amostras.

Informações Gerais	Temperatura (°C)	Umidade (%)
Número de amostras	1310	812
Valor mínimo	20	25
Valor máximo	42	45
Média	32,70	38,33
Variância	27,94	11,09

Figura 8 – Histograma dos conjuntos de dados adotados, disponíveis em (UCI Machine Learning Repository, 2018).



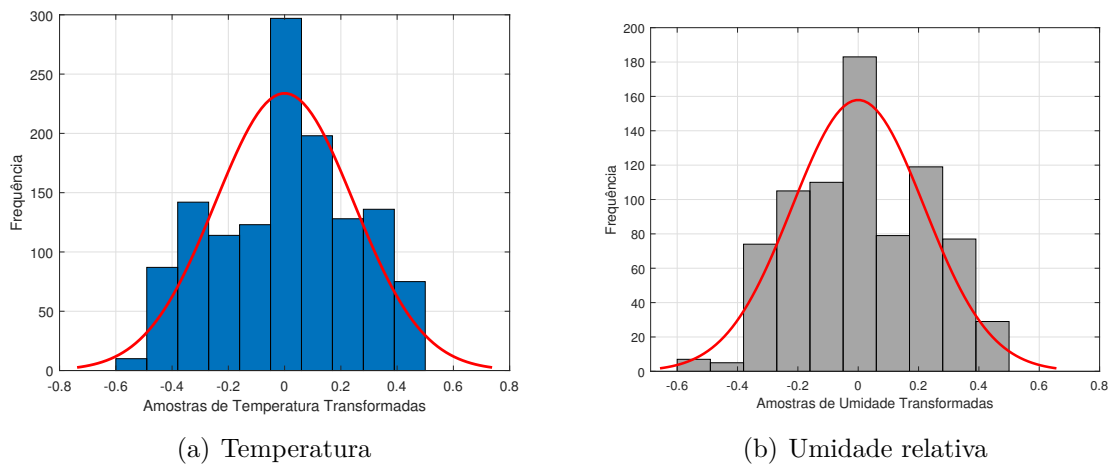
Fonte: Autoria própria.

Como foi dito no Capítulo 3, o esquema paramétrico tem desempenho ótimo quando a PDF da fonte e do canal são compatíveis. Como neste trabalho adotou-se conjuntos de amostras que não tem uma PDF definida, conforme foi ilustrado nos histogramas da Figura 8, foi utilizada a transformação de Box-Cox para tentar aproximar

a PDF dos conjuntos de amostras de uma Gaussiana. Além disso, foi utilizada uma técnica de normalização de dados denominada *feature scaling and mean normalization* para obter média zero.

A Figura 9 mostra os histogramas dos conjuntos de dados após a transformação de Box-Cox em comparação com uma PDF Gaussiana. Nota-se que existe uma distância considerável em relação a curva Gaussiana, contudo, obteve-se uma melhora considerável se compararmos com os histogramas dos conjuntos originais da Figura 8.

Figura 9 – Histograma dos conjuntos de dados transformados por Box-Cox, disponíveis em (UCI Machine Learning Repository, 2018).



Fonte: Autoria própria.

Para avaliar numericamente a eficiência da transformação de Box-Cox para os conjuntos de dados aplicou-se o teste de normalidade de Kolmogorov-Smirnov (KS) (Massey Jr., 1951). O teste KS avalia a normalidade de uma distribuição amostral por meio de uma probabilidade de significância P_S . Então, para afirmar que o conjunto de amostras tem função de probabilidade de distribuição Gaussiana, é necessário que P_S seja superior a um determinado limite de significância, usualmente adotado como $P_S > 0,05$. A Tabela 2 mostra os valores do teste KS por meio da probabilidade de significância P_S para os conjuntos de amostras originais e os conjuntos transformados por meio do Box-Cox.

Com base na probabilidade de significância P_s e no nível de significância adotado, o teste KS demonstrou que a transformação de Box-Cox não conseguiu obter distribuições Gaussianas. Acredita-se que as diferenças significativas entre os valores das amostras, ilustrados pelos histogramas da Figura 8, podem ser o fator que limitou a eficiência da transformação de Box-Cox. Contudo, essas são características inerentes dos conjuntos de dados e dificilmente podem ser contornados. Além disso, nota-se que o valor de P_S

depois da transformação de Box-Cox é significativamente maior que o P_S para os conjuntos originais que resulta em uma melhora em termos de SDR.

Além da transformação de Box-Cox, os parâmetros da codificação paramétrica Δ e α foram otimizados para melhorar a SDR. A otimização foi feita para os dois conjuntos, temperatura e umidade, levando em conta a CSNR, conforme pode ser visto nas Tabelas 3 e 4.

Tabela 2 – Probabilidade de significância (P_S), antes e depois da transformação de Box-Cox.

Conjunto	Amostras Originais	Amostras Transformadas
Temperatura	$8,5296 \cdot 10^{-7}$	$2,5334 \cdot 10^{-5}$
Umidade	$1,7067 \cdot 10^{-4}$	0,0014

Tabela 3 – Otimização do parâmetro α .

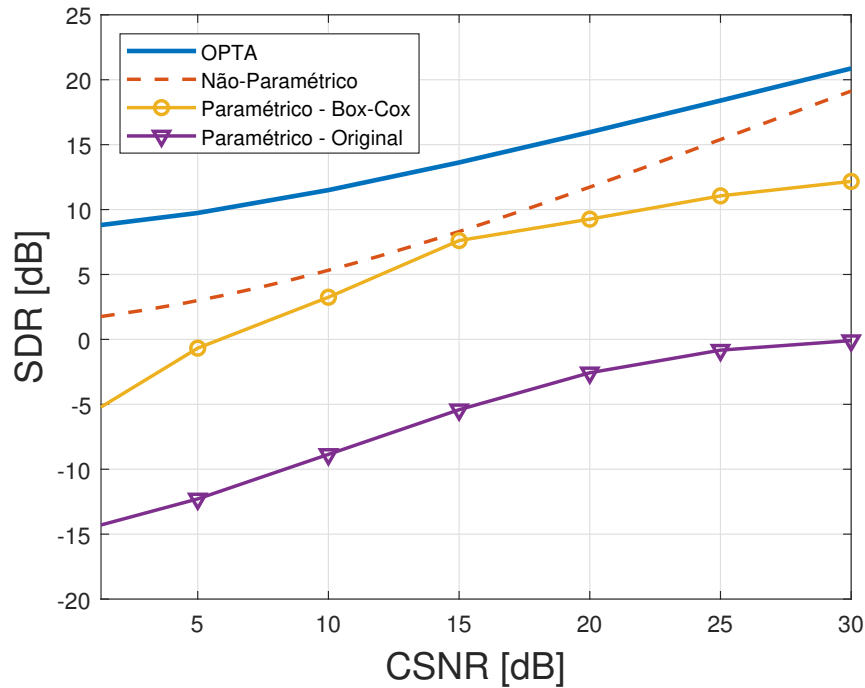
CSNR [dB]	0	5	10	15	20	25	30
Temp. Original	20,3	16,9	16,3	16,0	16,9	19,7	18,0
Temp. Box-Cox	1,0	1,5	1,5	1,5	2,0	2,0	2,0
Umid. Original	15	19,7	18,7	19,9	20,6	22,2	23,8
Umid. Box-Cox	1,0	1,5	1,5	1,5	2,0	2,0	2,0

Tabela 4 – Otimização do parâmetro Δ .

CSNR [dB]	0	5	10	15	20	25	30
Temp. Original	34	34	34	36	37	37	37
Temp. Box-Cox	3,9	3,25	3,0	2,0	2,0	2,0	2,0
Umid. Original	37	37	40	42	43	43	43
Umid. Box-Cox	3,9	3,25	3,0	2,0	2,0	2,0	2,0

Em relação ao esquema não-paramétrico, o algoritmo PCCOVQ utilizado na codificação não-paramétrica utiliza uma sequência de treinamento no formato de uma rampa. Dessa forma, os símbolos gerados pela fonte são quantizados nos vetores mais próximos da rampa. No caso da fonte Gaussiana, a variância da fonte é unitária, por isso, é usual iniciar a rampa centralizada em valores baixos, como -2 até 2 , para garantir que a quantização seja feita com distorção mínima. Contudo, como foram utilizados conjuntos de amostras que não tem variância unitária, foi preciso ajustar a rampa com base na média dos valores dos conjuntos. Devido as severas otimizações numéricas dos parâmetros utilizados, esse foi o único ajuste necessário, pois algoritmo PCCOVQ consegue se adaptar com facilidade a diferentes fontes. implementação.

Figura 10 – SDR versus CSNR para o conjunto de temperaturas.



Fonte: Autoria própria.

A Figura 10 mostra o desempenho dos esquemas propostos para o conjunto de amostras de temperatura em termos de SDR e CSNR. Considerou-se o esquema paramétrico sem e com a transformação de Box-Cox, denotado respectivamente por 'Box-Cox' e 'Original', o esquema não-paramétrico e o limite teórico (OPTA). Nota-se que o esquema não-paramétrico alcançou o melhor desempenho, sendo que para baixa CSNR a diferença para o OPTA é de apenas 7 dB e conforme a CSNR aumenta, a diferença para o limite teórico diminui gradativamente.

A otimização dos parâmetros α e Δ sem a aplicação da transformação do Box-Cox teve um desempenho bastante inferior aos demais esquemas. Notadamente, a transformação de Box-Cox melhorou o desempenho da codificação paramétrica, pois, a distância entre a curva do esquema paramétrico com e sem a transformação chega a 12 dB para CSNR = 30 dB. Além disso, ao comparar a curva do 'Box-Cox' com o esquema não-paramétrico para CSNR = 15 dB, nota-se que os desempenhos são bastante próximos, o que permite afirmar que é uma técnica válida a ser usada.

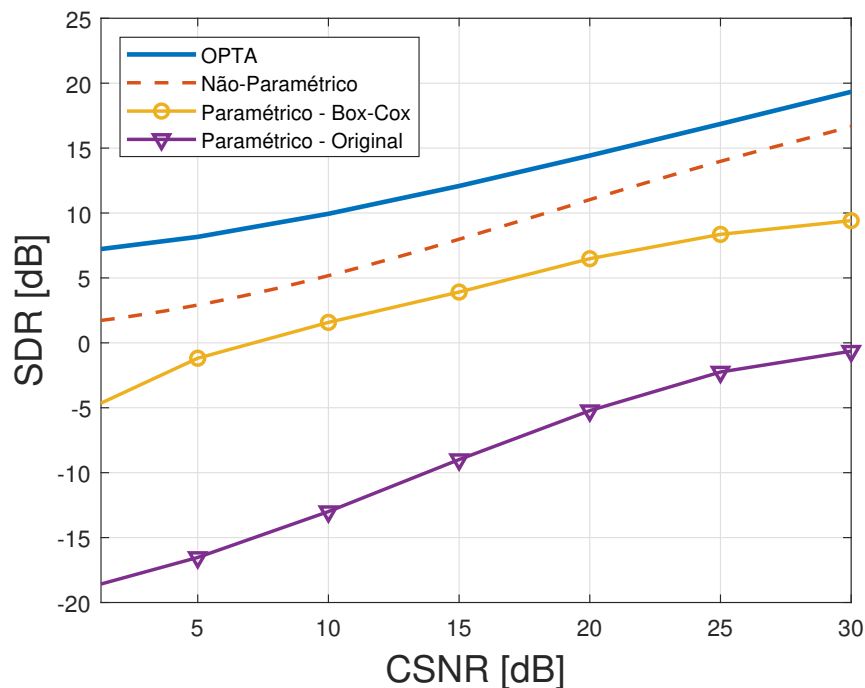
Apesar das técnicas utilizadas, a PDF dos dados transformados ainda tem diferenças relevantes em relação a uma Gaussiana. Por consequência, persiste a incompatibilidade entre a PDF do conjunto de dados e a PDF do canal, que é modelada

para uma Gaussiana. Para alta CSNR, essa característica é evidenciada pois o canal é menos ruidoso, o que resultou em uma estagnação no desempenho da codificação paramétrica para essa condição.

Ainda que existam pontos a serem melhorados, como a estagnação para alta CSNR, a codificação paramétrica com o uso da transformação de Box-Cox apresentou um resultado eficiente em relação ao limite teórico. Além disso, com uma implementação mais simples foi possível obter um desempenho próximo do não-paramétrico para determinado valor de CSNR.

Por fim, a Figura 11 mostra os resultados dos esquemas paramétrico e não paramétrico em termos SDR e CSNR para o conjunto de amostras de umidade, para o qual pode-se desenvolver conclusões similares. Assim como no caso anterior, o melhor desempenho foi do esquema não-paramétrico e a transformação de Box-Cox melhorou significativamente o desempenho do esquema paramétrico.

Figura 11 – SDR versus CSNR para o conjunto de umidades relativas.



Fonte: Autoria própria.

Um ponto importante da análise resulta da comparação entre as Figuras 10 e 11. A SDR depende da variância da fonte, conforme (3), sendo assim, o desempenho é melhor quando a variância do conjunto for menor ou próxima zero. Para o conjunto de umidades, a variância é $\sigma_x^2 = 11,09$, enquanto que a variância do conjunto de temperaturas é $\sigma_x^2 =$

27,94. Por esse motivo, a curva do 'Box-Cox' sofre menos estagnação em alta CSNR para o conjunto de unidades.

6 CONCLUSÃO E TRABALHOS FUTUROS

Nesta dissertação foram propostos os esquemas de codificação analógica paramétrico e não-paramétrico para conjuntos de dados não-Gaussianos. Essa técnica se justifica para o cenário de comunicações críticas, para as quais é necessário atender aos requisitos de baixa latência e comunicação ultra confiável. O sistema digital, tradicionalmente utilizado para MTC, utiliza longas sequências de redundância na codificação de canal para melhorar o desempenho do sistema. Isso implica em um atraso na comunicação, visto que o receptor precisa esperar a transmissão do sinal de informação e das sequências inseridas. O esquema analógico implementa a codificação da fonte e do canal em apenas uma etapa e transmite símbolo a símbolo, de forma que o atraso torna-se mínimo. O mapeamento das amostras geradas pela fonte de informação, pode ser definido por equações matemáticas que definem as curvas ou obtido por otimizações numéricas, respectivamente, paramétrico e não-paramétrico. Optou-se por implementar os dois esquemas para dois conjuntos de amostras não-Gaussianos coletadas por sensores, a fim de aproximar-se de um sistema MTC real. Como o esquema paramétrico tem desempenho ótimo quando a PDF da fonte é Gaussiana, foi utilizada a transformação de Box-Cox para tentar aproximar a PDF dos conjuntos de dados de uma Gaussiana, enquanto que o esquema não-paramétrico se adapta com facilidade a fontes não-Gaussianas devido ao grande número de otimizações utilizadas no algoritmo PCCOVQ.

Os resultados numéricos mostram que o melhor desempenho para os dois conjuntos de dados é o do esquema não paramétrico. Todavia, a transformação de Box-Cox aprimorou o desempenho da codificação paramétrica e foi possível obter resultados próximos ao do esquema não-paramétrico para o conjunto de amostras de temperaturas.

Assim, pode-se concluir que ambos esquemas podem ser utilizados para comunicações do tipo máquina. Os dois métodos implementados diferem em termos de complexidade de implementação. A codificação paramétrica é uma técnica simples que resulta em um desempenho satisfatório. Nessa, são utilizadas funções que definem as curvas, especificamente no esquema 2:1, utilizou-se a espiral de Arquimedes para mapear os símbolos. Todavia, como os mapeamentos geométricos foram projetados para o canal AWGN e fonte Gaussiana, o desempenho precisa ser otimizado para as demais circunstâncias. Por outro lado, o esquema não-paramétrico é mais robusto e fornece um desempenho superior ao paramétrico, mas as severas otimizações numéricas implicam em um aumento da complexidade de implementação.

Em trabalhos futuros, um caminho interessante seria aplicar uma das técnicas *machine learning* para a codificação analógica. Dentro do tema *machine learning*, os algoritmos supervisionados utilizam um par de entrada e saída definidos na sessão de treinamento como base para adequar as variáveis e prever resultados futuros. As técnicas de regressão utilizadas em algoritmos supervisionados tem fácil implementação, pois, consistem em determinar o melhor ajuste para os dados com base em equações matemáticas. Para aplicações envolvendo sensoriamento, a regressão logística e a SVM (Máquina de vetores de suporte, do inglês *Support Vector Machine*) são opções aconselháveis de algoritmos supervisionados, sendo que a regressão logística é a alternativa mais adequada para requisitos de precisão rigorosos (LI et al., 2017). Além disso, para algoritmos não-supervisionados, uma alternativa seria aplicar a técnica *Optimal Mass Transport* para transformar os conjuntos de dados empíricos. Essa técnica utiliza a distância de divergência entre duas distribuições para determinar a transformação de dados necessária para aproximar a PDF empírica da PDF de referência (COURTY et al., 2016).

Para complementar a análise numérica da eficiência da transformação do Box-Cox poderia ser utilizados outros testes de normalidade, como o teste de Kullback-Leibler, o qual determina a distância entre duas PDFs. Dessa forma, poderia ser feita uma discussão mais detalhada em relação aos efeitos da transformação de Box-Cox no conjunto de dados. Além disso, uma comparação dos testes de normalidade em termos de confiabilidade seria uma opção para avaliar a técnica mais adequada para o cenário adotado.

Uma análise mais detalhada dos conjuntos de dados utilizados neste trabalho mostrou que a autocorrelação entre os dados é elevada. Essa característica leva a investigação sobre a equação do OPTA. Na literatura, o esquema analógico foi implementado para fontes correlacionadas considerando o canal AWGN (SUÁREZ-CASAL et al., 2016), assim, o OPTA foi definido considerando esses fatores. Sendo assim, outra proposta a ser estudada no futuro é explorar a autocorrelação dos conjuntos e utilizar a equação do OPTA para fonte correlacionada e canal sem fio.

REFERÊNCIAS

- AKPAKWU, G. A.; SILVA, B. J.; HANCKE, G. P.; ABU-MAHFOUZ, A. M. A survey on 5g networks for the internet of things: Communication technologies and challenges. **IEEE Access**, IEEE, v. 6, p. 3619–3647, 2017.
- BERGER, T.; TUFTS, D. Optimum pulse amplitude modulation–i: Transmitter-receiver design and bounds from information theory. **IEEE Transactions on Information Theory**, IEEE, v. 13, n. 2, p. 196–208, 1967.
- BRANTE, G.; SOUZA, R. D.; GARCIA-FRIAS, J. Spatial diversity using analog joint source channel coding in wireless channels. **IEEE Trans. Commun.**, v. 61, n. 1, p. 301–311, Jan. 2013.
- BRANTE, G. G. de O.; SOUZA, R. D.; GARCIA-FRIAS, J. Analog joint source-channel coding in rayleigh fading channels. In: **IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. 2011. p. 3148–3151.
- CHEN, Y.-J.; WANG, Z.-Q.; WANG, L.-C. Impact of aggregation factor on delay performance in group-based machine type communications. In: **IEEE. 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)**. 2017. p. 1–6.
- COURTY, N.; FLAMARY, R.; TUIA, D.; RAKOTOMAMONJY, A. Optimal transport for domain adaptation. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 39, n. 9, p. 1853–1865, 2016.
- FLOOR, P. A.; RAMSTAD, T. A. Dimension reducing mappings in joint source-channel coding. In: **Proc. NORSIG**. 2006.
- FRESNEDO, O.; VAZQUEZ-ARAUJO, F. J.; CASTEDO, L.; GARCIA-FRIAS, J. Low-complexity near-optimal decoding for analog joint source channel coding using space-filling curves. **IEEE Communications Letters**, IEEE, v. 17, n. 4, p. 745–748, 2013.
- FRESNEDO, O.; VAZQUEZ-ARAUJO, F. J.; GARCIA-FRIAS, J.; GONZALEZ-LOPEZ, M.; CASTEDO, L. Comparison between analog joint source-channel coded and digital BICM systems. In: **IEEE International Conference on Communications (ICC)**. 2011. p. 1–5.
- FULDSETH, A. Robust subband video compression for noisy channels with multilevel signaling. **NTNU**, 1997.
- GOLDSMITH, A. **Wireless communications**. Cambridge university press, 2005.
- HASSANIN, M. K. **Analog joint source channel coding for multi terminal and non-linear channels**. 2018. Tese (Doutorado) — University of Delaware, 2018.
- HAYKIN, S.; MOHER, M. **Sistemas de Comunicação**. Bookman Editora, 2011.

HEKLAND, F.; FLOOR, P. A.; RAMSTAD, T. A. Shannon-Kotelnikov mappings in joint source-channel coding. **IEEE Trans. Commun.**, IEEE, v. 57, n. 1, p. 94–105, 2009.

HEKLAND, F.; GEIR, E.; RAMSTAD, T. A. et al. Using 2:1 shannon mapping for joint source-channel coding. In: IEEE. **Proc.** 2005. p. 223–232.

HODGSON, E.; BRANTE, G.; SOUZA, R.; GARCIA-FRIAS, J. Non-parametric analog joint source channel coding for amplify-and-forward two-hop networks. In: IEEE. **IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. 2017. p. 3674–3678.

HODGSON, E. A. **Compensando a perda de eficiência espectral da transferência sem fio de energia por rádio frequência com codificação analógica conjunta fonte-canal**. 2017.

HODGSON, E. A.; BRANTE, G.; SOUZA, R. D.; GARCÍA-FRÍAS, J.; REBELATTO, J. L. Compensating spectral efficiency loss of wireless RF energy transfer with analog joint source channel coding compression. **IEEE Sensors Journal**, IEEE, v. 16, n. 16, p. 6458–6469, 2016.

HU, Y.; GARCIA-FRIAS, J.; LAMARCA, M. Analog joint source-channel coding using non-linear curves and MMSE decoding. **IEEE Trans. Commun.**, v. 59, n. 11, p. 3016–3026, Nov. 2011.

KIM, A. N.; FLOOR, P. A.; RAMSTAD, T. A.; BALASINGHAM, I. Delay-free joint source-channel coding for gaussian network of multiple sensors. In: **IEEE International Conference on Communications (ICC)**. 2011. p. 1–6.

KOTEL'NIKOV, V. A. **The theory of optimum noise immunity**. McGraw-Hill, 1959.

LI, R.; ZHAO, Z.; ZHOU, X.; DING, G.; CHEN, Y.; WANG, Z.; ZHANG, H. Intelligent 5g: When cellular networks meet artificial intelligence. **IEEE Wireless Communications**, IEEE, v. 24, n. 5, p. 175–183, 2017.

LU, B.; GARCIA-FRIAS, J. Analog joint source-channel coding for transmission of correlated senders over separated noisy channels. In: **49th Annual Conference on Information Sciences and Systems (CISS)**. 2015. p. 1–5.

Massey Jr., F. J. The Kolmogorov-Smirnov test for goodness of fit. **Journal of the American Statistical Association**, v. 46, n. 253, p. 68–78, 1951.

NOURI, P.; ALVES, H.; SOUZA, R. D.; LATVA-AHO, M. Ultra-reliable short message cooperative relaying protocols under Nakagami- m fading. In: **Int. Symp. on Wireless Commun. Systems (ISWCS)**. 2017. p. 287–292.

OSBORNE, J. W. Improving your data transformations: Applying the box-cox transformation. **Practical Assessment, Research & Evaluation**, Citeseer, v. 15, n. 12, p. 1–9, 2010.

POPOVSKI, P. Ultra-reliable communication in 5g wireless systems. In: IEEE. **1st International Conference on 5G for Ubiquitous Connectivity**. 2014. p. 146–151.

- RAMSTAD, T. A. Shannon mappings for robust communication. **Telelektronikk, TELEDIREKTORATET**, v. 98, n. 1, p. 114–128, 2002.
- SALEH, A. A.; ALAJAJI, F.; CHAN, W.-Y. Power-constrained bandwidth-reduction source-channel mappings for fading channels. In: **26th Biennial Symposium on Communications (QBSC)**. 2012. p. 85–90.
- SAYOOD, K. **Introduction to Data Compression**. 3rd. ed. Morgan Kaufmann, 2006.
- SHANNON, C. E. A mathematical theory of communication. **Bell Syst. Tech. J.**, ACM, v. 27, p. 379–423; 623–656, 1948.
- SHANNON, C. E. Communication in presence of noise. In: **Proc. IRE**. 1949. v. 37, p. 10–21.
- SHARIATMADARI, H.; RATASUK, R.; IRAJI, S.; LAYA, A.; TALEB, T.; JÄNTTI, R.; GHOSH, A. Machine-type communications: current status and future perspectives toward 5g systems. **IEEE Communications Magazine**, IEEE, v. 53, n. 9, p. 10–17, 2015.
- SUÁREZ-CASAL, P.; FRESNEDO, Ó.; CASTEDO, L.; GARCÍA-FRÍAS, J. Parametric analog mappings for correlated Gaussian sources over AWGN channels. In: **IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. 2016. p. 3761–3765.
- UCI Machine Learning Repository. **GNFUV Unmanned Surface Vehicles Sensor Data Data Set**. March 2018. Disponível em: <<https://archive.ics.uci.edu/ml/datasets/GNFUV+Unmanned+Surface+Vehicles+Sensor+Data>>.
- VAISHAMPAYAN, V. A.; FARVARDIN, N. Joint design of block source codes and modulation signal sets. **IEEE Transactions on Information Theory**, IEEE, v. 38, n. 4, p. 1230–1248, 1992.
- ZHOU, K.; LIU, T.; ZHOU, L. Industry 4.0: Towards future industrial opportunities and challenges. In: **12th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)**. 2015. p. 2147–2152.