

Análise Comparativa de Métodos de Aprendizado de Máquina para Equalização

Luan Lopes Fontes, Romis Attux
l239682@dac.unicamp.br, attux@dca.fee.unicamp.br

Departamento de Engenharia de Computação e Automação (DCA)
Faculdade de Engenharia Elétrica e de Computação (FEEC)
Universidade Estadual de Campinas (Unicamp)
Campinas, SP, Brasil

Resumo – Em sistemas de comunicação digital, os efeitos do meio de transmissão são fatores limitantes para o desempenho atingível. Uma estratégia para mitigar tais efeitos é lançar mão de um filtro que recebe o nome de equalizador. Embora a teoria clássica de equalização seja construída sobre estruturas lineares, filtros não-lineares têm recebido crescente atenção nas últimas décadas tanto pela necessidade de expandir os sistemas de comunicação quanto pela maior disponibilidade de hardware de alto desempenho. Neste trabalho, buscaremos realizar uma análise comparativa abrangendo estruturas lineares e não-lineares de equalização no contexto de um leque diversificado de modelos de canal.

Palavras-chave – Aprendizado de máquina, equalização de canais.

1. Introdução

A equalização não-linear de canais de comunicação baseada em algoritmos de aprendizado de máquina [1] é um assunto de grande interesse devido ao crescimento exponencial na demanda por taxas de transmissão e robustez que caracteriza os sistemas de comunicação modernos [2].

A área de aprendizado de máquina tem experimentado, ao longo da última década, um enorme desenvolvimento, o que se deve ao crescimento explosivo na produção de dados, ao maior acesso a hardware paralelo e aos aportes teóricos trazidos pelos estudos na área de *deep learning*. Nesse contexto, deve-se analisar qual pode ser o real impacto dessa "revolução" nas tarefas de processamento de sinais ligadas à comunicação. O problema de equalização, por sua generalidade [1] e importância histórica, é uma opção natural e importante, e abordá-lo é a tarefa central deste projeto.

Neste trabalho, faremos uma análise comparativa envolvendo equalizadores lineares e não-lineares no contexto de modelos lineares e não-lineares de canal. Na seção 2, faremos uma breve apresentação do problema a ser resolvido; na seção 3, discutimos os testes e resultados, e, na seção 4, expomos nossas conclusões.

2. Comunicação e Equalização

Um sistema de comunicação digital (SCD) é, essencialmente, composto por um transmissor, um canal, e um receptor. As informações a serem transmitidas são codificadas em um alfabeto, isto é, um conjunto finito de símbolos. Neste trabalho, considera-se um modelo discreto equivalente em banda base do SCD, o qual facilita a análise sem perda de generalidade [3].

O sinal gerado $s(k)$ é um processo estocástico com amostras discretas, independentes e identicamente distribuídas (i.i.d.) pertencentes a um alfabeto finito. O tipo de modulação empregada no SCD é o que define o alfabeto - por exemplo, uma modulação 2-PAM (ou 2-PSK, em banda base) dá origem ao alfabeto $\{-1, +1\}$, que é o empregado neste trabalho.

2.1. Modelo de Canal

Ao passar por um canal, o sinal transmitido sofre distorções, o que ocasiona perda de informação. A modelagem de um canal, isto é, sua representação matemática, leva em conta, via de regra, a interferência intersimbólica (IIS), o ruído e eventuais distorções não-lineares [1].

No intuito de reverter os efeitos introduzidos pelo canal de comunicação, favorecendo a recuperação do sinal original, utiliza-se um filtro denominado equalizador. A Fig. 1 é um esquema simplificado de SCD com equalização:

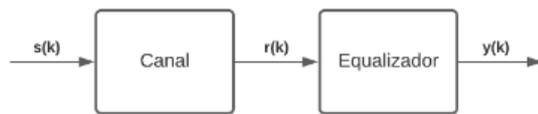


Figura 1 – Esquema Simplificado de SCD

A recuperação da informação transmitida pelo equalizador pode ocorrer de dois modos: estimação de sequência ou símbolo a símbolo. Na estimação de sequência, um conjunto de amostras recebidas é usado para se obter, através do critério de máxima verossimilhança, o sinal original [4]. Este tipo de equalizador pode ser implementado por meio do algoritmo de Viterbi [5].

Por outro lado, a metodologia de estimação de símbolo a símbolo usa um número fixo de amostras recebidas para estimar um único símbolo a cada período de amostragem. Equalizadores que utilizam essa técnica permitem que seus parâmetros sejam ajustados ao longo do tempo para se adequarem a variações no canal, merecendo o epíteto de *adaptativos*. O equalizador de memória finita símbolo a símbolo ótimo é dado pelo critério de Máxima Probabilidade A Posteriori (MAP - Máximo A Posteriori), e é chamado de equalizador bayesiano.

Os parâmetros dos equalizadores adaptativos são determinados através de algoritmos de treinamento, de modo a atender um certo critério de desempenho. Nesse contexto, o treinamento pode ser supervisionado ou não-supervisionado. No treinamento supervisionado, um *senal de treinamento* ou *senal piloto* é enviado periodicamente durante a transmissão das informações. O receptor possui uma cópia desse sinal piloto, que é utilizada para adaptar os parâmetros do equalizador durante o período de treinamento - desse modo, durante esse período, não existe transmissão efetiva de informação.

O treinamento *não-supervisionado*, também conhecido como *cego*, é caracterizado pela não existência de um sinal piloto, sendo a adaptação do equalizador feita com base exclusivamente no sinal recebido e em estatísticas do sinal transmitido [3]. Neste trabalho, enfocaremos o problema supervisionado apenas.

Os equalizadores adaptativos podem ser implementados por meio de filtros i.e. estruturas lineares ou não-lineares. Existe uma vasta bibliografia sobre a aplicação de filtros lineares na equalização de canais, com destaque para os filtros FIR (do inglês *Finite Impulse Response*). Este modelo é atraente pela sua baixa complexidade computacional e seu amplo arcabouço matemático, edificado sobre a teoria de sistemas lineares.

Por outro lado, os recentes avanços tecnológicos têm viabilizado e incentivado a utilização e estudo de estruturas não-lineares e, assim, computacionalmente mais complexas, como os filtros polinomiais [1] e as redes neurais artificiais [2,3], sendo essas o alvo de estudo neste trabalho. Dessa forma, aplicaremos tanto filtros lineares quanto não-lineares, de modo a explicitar a diferença de desempenho entre os dois métodos e os casos em que cada um é mais adequado.

3. Resultados

Considerou-se um modelo de canal com IIS e ruído. A SNR (*Signal-to-Noise Ratio*), que mede nível de ruído do canal, variou de 6 a 20 dB. As simulações contaram com 100.000 amostras e foram realizadas para o canal $H_1(z) = 1 + 0,6z^{-1}$, bem como para uma extensão não-linear do mesmo, da forma $x_p(k) = x(k) + 0,3x^3(k)$.

Foram utilizados um filtro linear com resposta ao impulso finita e uma rede neural do tipo perceptron de múltiplas camadas (MLP, do inglês *multilayer perceptron*). Em todos os testes, o equalizador bayesiano foi implementado como uma referência de desempenho.

As amostras geradas foram divididas em conjuntos de treinamento e teste, na proporção 80%-20%. O filtro linear foi treinado num esquema de regressão logística com entropia cruzada, e a MLP com esse mesmo critério e com o critério de erro quadrático médio.

3.1 - Canais Lineares

Primeiramente, consideramos o canal $H_1(z) = 1 + 0,6z^{-1}$ com dois atrasos de equalização: $d = 0$ e $d = 2$. Consideramos um equalizador com duas entradas em todos os casos.

Para o caso de atraso nulo, a distribuição dos dados, $x(k) \times x(k-1)$, ocorre segundo o que mostra a Fig. 2.

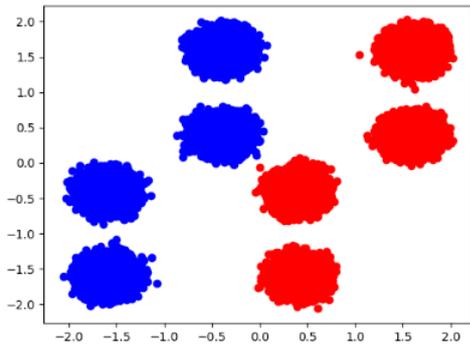


Figura 2 – Distribuição dos Dados para Atraso Nulo (Azul – Classe -1 / Vermelho – Classe +1)

Percebe-se que as classes são, em essência, linearmente separáveis. Por esse motivo, espera-se que o equalizador linear tenha bom desempenho, apenas ligeiramente inferior ao de equalizadores não-lineares. Na Fig. 3, as curvas de BER do equalizador linear, de duas implementações de uma MLP e do equalizador de Bayes mostram isso.

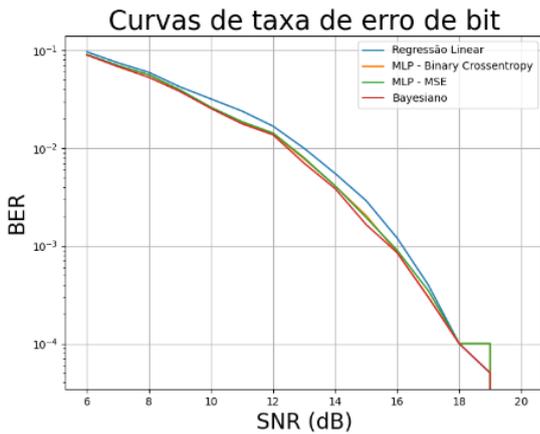


Figura 3 – Curvas de Taxa de Erro de Bit (BER) – Atraso Nulo

Por outro lado, quando o atraso é igual a dois, os estados não são linearmente separáveis, como mostra a Fig. 4.

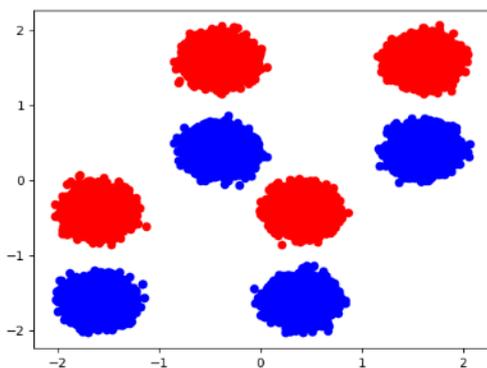


Figura 4 - Distribuição dos Dados para Atraso Dois (Azul – Classe -1 / Vermelho – Classe +1)

Nesse caso, a estrutura linear não será capaz de separar os estados, o que leva às curvas de BER da Fig. 5.

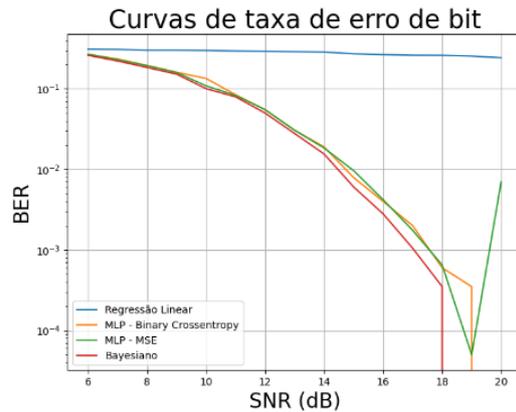


Figura 5 – Curvas de Taxa de Erro de Bit (BER) – Atraso Dois

Para as SNRs mais altas, na Fig. 3 e, especialmente, na Fig. 5, nota-se uma distorção que é causada, provavelmente, pela dificuldade de estimar a probabilidade de erro ou por algum problema de convergência da rede numa simulação.

3.2 - Canal Não-Linear

Por fim, consideramos um canal não-linear simples. Será considerada a saída do canal linear com função de transferência $H_1(z)$, $y_1(k)$, e um termo relativo a seu cubo, levando à seguinte expressão para a saída:

$$y(k) = y_1(k) + 0,3 y_1^3(k) \quad (1)$$

A distribuição dos dados para esse canal e atraso igual a dois é mostrado na Fig. 6.

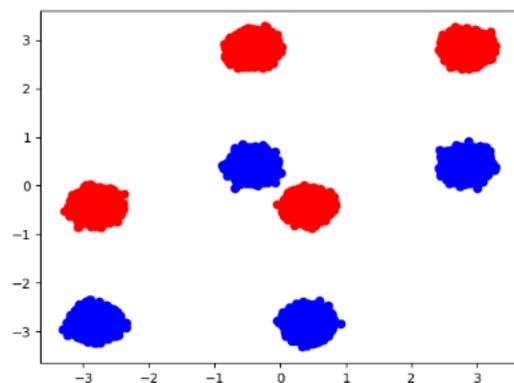


Figura 6 - Distribuição dos Dados para Atraso Dois (Azul – Classe -1 / Vermelho – Classe +1) – Canal Não-Linear

Neste caso, a distorção não-linear não é particularmente marcante, o que leva a curvas de BER similares às mostradas na Fig. 5. É isso que nos mostra a Fig. 7.

4 – Conclusões

Neste trabalho, que contempla parte dos resultados obtidos numa iniciação científica financiada pela FAPESP (proc. 2021/01684-7), fez-se uma análise comparativa inicial de estruturas lineares e não-lineares de equalização. Os resultados obtidos foram condizentes com as expectativas associadas a equalizadores lineares e não-lineares para cada espécie de canal. O resultado do equalizador de Bayes serviu sempre como referência.

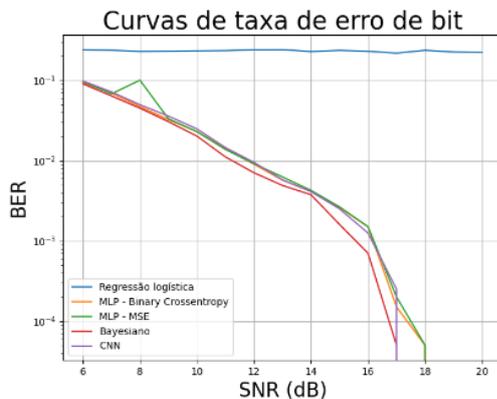


Figura 7 – Curvas de Taxa de Erro de Bit (BER) – Atraso Dois – Canal Não-Linear

Agradecimentos

Os autores agradecem à FAPESP (proc. 2021/01684-7) e ao CNPq (proc. 308811/2019-4) o apoio financeiro.

Referências

- [1] J. M. T. Romano, R. R. F. Attux, C. C. Cavalcante, R. Suyama, *Unsupervised Signal Processing: Channel Equalization and Source Separation*, CRC Press, 2010.
- [2] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, MIT Press, 2016.
- [3] S. Haykin, *Adaptive Filter Theory*, Prentice Hall, 1996.
- [4] G. Forney, “Maximum-Likelihood Sequence Estimation of Digital Sequences in the Presence of Intersymbol Interference”, *IEEE Transactions on Information Theory*, Vol. 18, No. 3, pp. 363 – 378, 1972.
- [5] G. Forney, “The Viterbi Algorithm”, *Proceedings of the IEEE*, Vol. 61, No. 3, pp. 268 – 278, 1973.