

# Modelos de aprendizado profundo para classificação de modulações de sinais de comunicação *wireless*

Natália Galvão Silva<sup>1</sup> e Marcelo da Silva Pinho<sup>1</sup>

<sup>1</sup> Instituto Tecnológico de Aeronáutica, São José dos Campos, São Paulo.

**Resumo** – A identificação do tipo e do esquema de modulação de sinais de comunicação é um problema desafiador para várias aplicações, sobretudo em Defesa. Em cenários de combate com grande número de emissores e diversos efeitos advindos da propagação de canal, monitorar, identificar e negar emissores inimigas, bem como assegurar as comunicações das forças amigas, são atividades cruciais para o sucesso no Teatro de Operações. Nesse sentido, este trabalho investiga a viabilidade de utilização de algoritmos de Aprendizado Profundo para a classificação automática de modulações de sinais de comunicação *wireless*. São propostas arquiteturas de rede neural convolucional unidimensional, residual e recorrente para classificação de 8 tipos de modulação digital e 3 tipos de modulação analógica do *dataset* RadioML2016.10a, modulações estas características de sistemas de comunicação *wireless*.

**Palavras-Chave** – Comunicação *wireless*, modulações, aprendizado profundo.

## I. INTRODUÇÃO

Com o aumento do número de tipos de emissores e fontes de interferência, têm se tornado cada vez mais desafiadoras as tarefas de detecção e identificação de assinaturas modernas de sinais de comunicação *wireless* [1]. Sinais de comunicação, apesar de serem projetados de maneira estruturada e de modo a facilitar a recuperação da informação, passam por drásticos efeitos devido à natureza dinâmica de propagação pelo canal [2,3]. Dentre eles, citam-se as condições variáveis de desvanecimento, multipercurso, acréscimo de ruído, *offsets* de frequência e atrasos de tempo, os quais tornam a inferência precisa do esquema de modulação uma tarefa árdua computacionalmente [3].

Abordagens clássicas de reconhecimento de modulações envolvem métodos baseados em máxima verossimilhança e extratores de características. Embora os métodos baseados em verossimilhança gerem estimativas ótimas, eles são computacionalmente custosos e complexos. Além disso, eles dependem de limiares utilizados como critérios de decisão e não são robustos a erros de modelagem, como por exemplo, diferenças de estimativas de coeficiente de canal e de compensações de *offset* de tempo [3]. Os métodos baseados em extração de características, em contrapartida, são mais simples, porém não garantem solução ótima e demandam conhecimento de características que permitam distinguir entre o sinal de interesse e os demais. Por conta disso, são altamente dependentes das características utilizadas (amplitude instantânea, fase instantânea, frequência instantânea, momentos, transformada de Fourier, dentre outras) e de critérios de categorização [1].

Esses métodos mencionados são, portanto, *model-driven* e não são aplicáveis em situações nas quais o nível de ruído e as características de canal não podem ser determinados com alta confiabilidade. É por isso que, em cenários reais em que

a intensidade do ruído e as condições do canal mudam dinamicamente, a utilização deles fica comprometida [4].

Como alternativa, métodos baseados em aprendizado profundo que aprendem diretamente com os sinais recebidos (*data-driven*) têm sido cada vez mais utilizados para a classificação automática de modulações [1]. Como vantagem dessa abordagem, está a capacidade dos métodos de aprendizado profundo de sintetizar padrões de grandes volumes de dados, mesmo frente a dados corrompidos com ruído e com alta variabilidade [4].

Vale destacar ainda que, em aplicações que não se detêm conhecimento prévio acerca do sinal transmitido, o uso da classificação automática de modulação aparece como uma etapa crucial entre a detecção e a demodulação do sinal [1].

Esse é o caso de aplicações em Defesa. Em Guerra Eletrônica, o monitoramento do espectro de rádio é decisivo para a pronta identificação de transmissões inimigas e para a coleta de produtos de Inteligência. Em consonância, a garantia da integridade das informações presentes nos *links* de comunicação amigas, detecção de anomalias na rede e localização de interferências é parte da garantia da consciência situacional e da confiabilidade das informações transmitidas [3,5].

Esse tema é de grande relevância, porque os sistemas de comunicação fornecem um papel vital para as estratégias militares modernas. São eles que garantem a transmissão de informações críticas do campo de batalha para todos os níveis de comando, permitindo decisões e ações oportunas e eficazes, muitas vezes decisivas para os desdobramentos e movimentação das forças amigas [5].

Alinhado com o tema, o presente estudo utilizará o *dataset* de sinais de modulações digitais e analógicas de comunicações, RadioML2016.10a, para análise exploratória acerca do uso de modelos de aprendizado profundo para a classificação automática de modulações de sistemas de comunicação *wireless* não cooperativas.

## II. FUNDAMENTAÇÃO TEÓRICA

### A. Classificação automática de modulações

As tarefas de reconhecimento de modulação são usadas tanto para detecção, quanto para demodulação de sinais. Isso porque o sinal recebido pode ser processado sem grandes erros somente quando o receptor demodula o sinal corretamente. Entretanto, com o rápido desenvolvimento das técnicas de comunicação *wireless* e mais requisitos de desempenho, o número de métodos de modulação e o número de parâmetros usados nos sistemas de comunicação têm aumentado rapidamente, tornando reconhecer os métodos de modulação acuradamente um problema [1].

Por conta disso, reconhecimento automático de modulações baseado em redes neurais profundas vem sendo utilizado em conjunto com técnicas de processamento de

sinais. Seja em aplicações com vídeo, seja em aplicações com voz, seja em aplicações com imagem [1].

A literatura mostra que abordagens envolvendo redes neurais com 3 ou 4 camadas convolucionais unidimensionais [6] ou bidimensionais [3] apresentam bom desempenho na tarefa de classificação de modulações digitais wireless. Redes com camadas convolucionais com diferentes porcentagens de dropout também vêm sendo exploradas [8].

Modelos de aprendizado de redes neurais com camadas residuais [10, 14], bem como modelos de rede recorrente do tipo Long Short Term Memory (LSTM) [1], também podem ser encontrados na literatura. Entretanto, são os modelos híbridos que vêm sendo mais utilizados como, por exemplo, do tipo rede neural convolucional com uma camada final do tipo LSTM [10, 14].

### III. METODOLOGIA

#### A. Dataset RadioML2016.10a

Neste trabalho, utilizou-se o conjunto de dados clássico RadioML2016.10a. Trata-se de um *dataset benchmark*, proposto por [2], construído utilizando a *toolkit* GNU Radio, e criado para incentivar o desenvolvimento de modelos de classificação automática de modulação. O GNU Radio é uma ferramenta de desenvolvimento de código aberto para simulação de processamento de sinais e geração de sinais de RF, quando utilizado em conjunto com Rádio Definido por Software (RDS). Ele é amplamente empregado na área acadêmica por dar suporte à pesquisa em comunicações *wireless* e a sistemas de rádio reais [7].

Os sinais desse *dataset* são formados por 128 amostras das componentes em fase (I) e em quadratura (Q) de sinais em banda base com 11 tipos diferentes de modulação (8 digitais e 3 analógicas) contaminadas com ruído aditivo gaussiano branco, considerando relações sinal-ruído (SNR) igualmente distribuídas entre (-20, 18) dB. Como *labels* disponibilizados, têm-se o tipo de modulação e a SNR de cada um dos exemplos. As modulações elencadas correspondem a esquemas de codificação utilizados comercialmente, gerados com modelo de canal dinâmico *wireless* da GNU [2]. O *dataset* pode ser encontrado em [9]. Na Fig 1, é possível verificar graficamente exemplos das amostras de sinais I e Q de cada uma das classes de modulação do conjunto de dados para sinais com SNR = 18 dB.

Destaca-se que os dados desse *dataset* foram gerados sinteticamente de maneira idêntica a sistemas reais: com modulação, *pulse shaping*, dados da portadora e demodulação. Um sinal de voz contínuo com tempos intermediários silenciosos foi utilizado como informação transmitida pelas transmissões com modulações analógicas ao passo que trechos de Shakespeare em ASCII com processamento para garantir símbolos e *bits* equiprováveis foram utilizados para as transmissões com modulações digitais [8].

Vários efeitos de canal presentes em sistemas reais de comunicação *wireless* foram incorporados aos exemplos [2]. Dentre eles, citam-se: sinal com tempos de chegada aleatórios

por conta de tráfego assíncrono e *scheduling* de protocolos de comunicação; taxa de erro de símbolo randômica por conta da amostragem de *clocks*; fase aleatória da portadora e erros de frequência devido aos *clocks*, osciladores e *delays* de fase de componentes analógicos dos *front-ends*; interferência e desvanecimento de multipercursos; desvios Doppler devido ao movimento de emissores e receptores; e ruído térmico gaussiano, ruído impulsivo e interferência de canal adjacente [2]. Outros parâmetros descritores do *dataset* são apresentados na Tabela I.

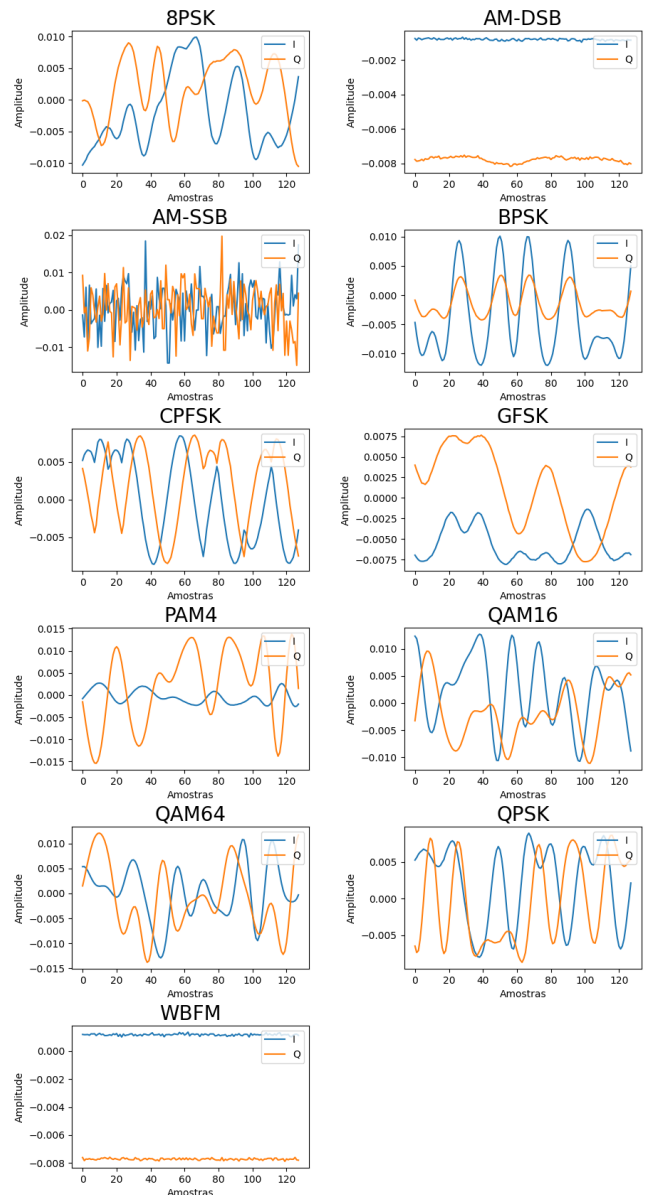


Fig. 1. Exemplos de amostras das modulações do *dataset*.

#### B. Modelos de classificação

Alinhado com o que se tem verificado nos estudos de classificação automática de modulações para o *dataset* em questão, optou-se por avaliar neste trabalho três modelos de classificação: um do tipo rede neural convolucional unidimensional, referenciado neste trabalho como CONV 1D;

um do tipo recorrente *Long Short Term Memory*, referenciado como LSTM; e um do tipo rede neural residual, referenciado como RES.

máximo, 70 épocas. Os resultados dos modelos treinados são analisados na Seção IV.

TABELA I. DATASET RADIOML2016.10A [8].

Tipos de Modulação	Digitais: BPSK, QPSK, 8PSK, 16QAM, 64QAM, BFSK, CPFSK e PAM4
	Analógicas: WBFM, AM-SSB, AM-DSB
SNR (dB)	-20:2:18 dB
Taxa de amostragem	10 <sup>6</sup> amostras/segundo
Exemplo	128 x 2
Número de exemplos	220 000
Amostras por símbolo	8

A arquitetura escolhida para o modelo de CONV1D é a utilizada em [6]. Um diagrama simplificado pode ser observado na Fig 2.




Fig 2. Arquitetura de rede neural convolucional unidimensional implementada.

A arquitetura utilizada para o modelo de LSTM foi um modelo com três camadas LSTM bidirecionais. Essa arquitetura foi inspirada em [1] e no bom desempenho que redes bidirecionais têm demonstrado para classificação de sequências temporais. Para a aplicação pretendida por este trabalho, o sinal *wireless* não é conhecido de antemão e o objetivo é realizar uma Inteligência dos sinais já capturados, assim a utilização de uma LSTM bidirecional faz sentido. Um diagrama simplificado pode ser observado na Fig 3.

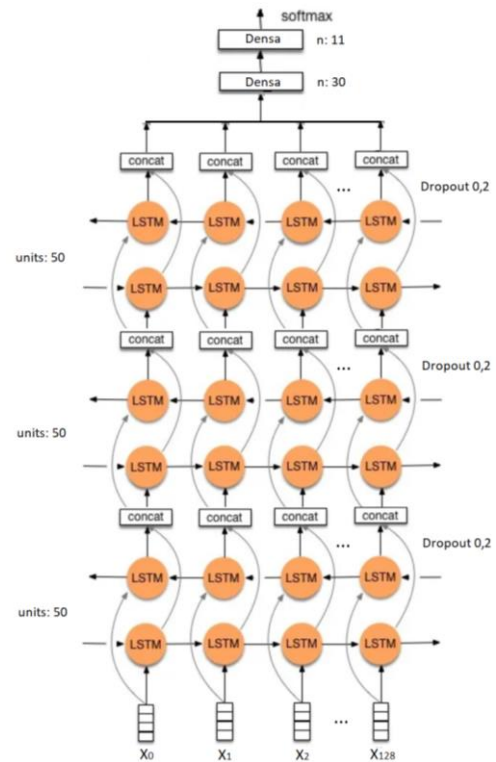


Fig 3. Arquitetura de rede neural LSTM bidirecional implementada.

A arquitetura utilizada, por sua vez, para o modelo residual é inspirada no modelo de rede neural convolucional residual apresentada em [11]. Em [11], um modelo com mais camadas convolucionais do que as utilizadas neste trabalho é empregado para classificação de modulações de intervalo de repetição de pulso de radares. Um diagrama simplificado do modelo implementado neste trabalho pode ser observado na Fig 4.




Fig 4. Arquitetura de rede neural residual implementada.

IV. RESULTADOS E DISCUSSÕES

A. Modelos de classificação

Os modelos convolucional unidimensional, recorrente LSTM e rede neural residual descritos foram treinados e as performances no treinamento podem ser verificadas nos gráficos da função custo no decorrer das épocas que constam nas Fig 5, 6 e 7.

Nesses três gráficos, é possível verificar que, com o passar das épocas, a *loss* no conjunto de treinamento permanece em queda. Contudo, a partir de determinado momento, as *losses* dos modelos no conjunto de validação começam a subir. Isso indica que as redes começaram a apresentar *overfitting* dos dados de treinamento. Com as configurações padrões e o *early stopping* do Keras, são

salvos os modelos com menor função custo no conjunto de validação.




Fig 5. Treinamento do modelo recorrente LSTM.




Fig 6. Treinamento do modelo inicial da convolucional unidimensional.




Fig 7. Treinamento do modelo de rede neural residual.

A acurácia dos modelos treinados CONV1D, LSTM e RES nos exemplos do conjunto de teste pode ser verificada na Fig 8. Na Fig 8, a acurácia dos modelos é mostrada em função da relação sinal ruído do exemplo de teste. Quanto menor a SNR, maior é a potência de ruído presente na amostra e, portanto, mais difícil se torna a classificação do

tipo de modulação. Acurácias maiores de classificação são obtidas para exemplos com SNR maior ou igual a 0 dB.

Verifica-se também que, dentre os três modelos, o modelo de rede neural residual apresentou melhor acurácia global de 0,594; seguido pelo modelo convolucional unidimensional com acurácia global de 0,572; e pelo modelo de rede neural LSTM bidirecional de 0,565.




Fig 8. Acurácia dos modelos em função da SNR dos dados.

Para melhor avaliar o desempenho dos três modelos, foram obtidas as matrizes de confusão com as predições para cada uma das classes de modulação. Foram construídas as matrizes de confusão para todas as amostras e também para apenas aquelas com  $SNR \geq 0$  dB. Elas podem ser vistas nas Fig 9, 10 e 11.

A partir das matrizes de confusão com todos os exemplos de teste, tem-se que,

- A classe AM-SSB é a modulação que apresenta maior acurácia de classificação para os três modelos implementados. Contudo, uma parcela dos exemplos das outras classes são preditos erroneamente como de modulação AM-SSB;
- As amostras das classes WBFM e AM-DSB se confundem, apresentando vários exemplos com classificação trocada. Isso pode ter relação com o fato de que as três classes analógicas representam um mesmo sinal de voz transmitido com poucas amostras. Como o sinal de voz da informação possui atrasos e tempos silenciosos entre palavras variantes no tempo, isso pode ter gerado maior proximidade entre as amostras das classes WBFM e AM-DSB; e
- A maior parte dos exemplos da classe QAM16 são classificados erroneamente como pertencentes à classe QAM64 nos modelos CONV1D e LSTM. O modelo RES é o único que classifica corretamente a maioria dos exemplos da classe QAM16. Essa dificuldade de classificá-lo corretamente pode estar relacionada com a sobreposição de pontos dessas duas constelações.

Considerando apenas os exemplos com SNR maior ou igual a 0 dB, tem-se que os modelos CONV1D e LSTM apresentaram elevada acurácia na predição das classes; exceto para a classe WBFM, que é classificada na maior parte



dos exemplos como AM-DSB, e QAM16, que é classificada na maior parte dos exemplos como QAM64. O modelo RES, por sua vez, tem maior capacidade de discriminação entre QAM16 e QAM64 e, apesar de trocar algumas classificações entre WBFM e AM-DSB, acerta a classe na maior parte dos exemplos de teste.

V. CONCLUSÃO

Com este trabalho exploratório, foi possível avaliar a capacidade de utilização de técnicas de aprendizado profundo para classificação automática de modulações de sinais de comunicação *wireless*.

Foram analisados com êxito modelos de rede neural convolucional unidimensional, LSTM e residual para a predição de modulações de sinais de comunicação *wireless* do *dataset* RadioML2016.10a.




Fig 9a. Matriz de confusão da classificação do modelo CONV1D com todos os exemplos de teste.

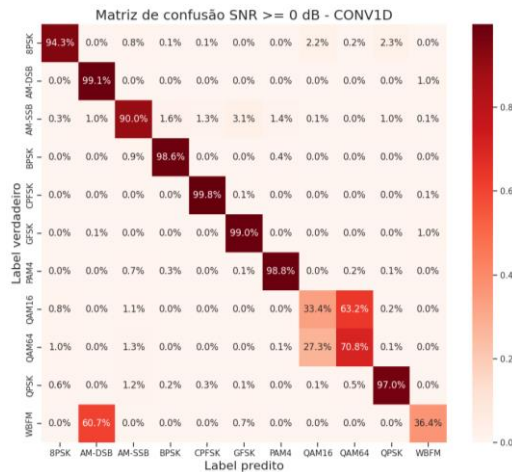


Fig 9b. Matriz de confusão da classificação do modelo CONV1D com apenas os exemplos de teste com SNR ≥ 0 dB.



Fig 10a. Matriz de confusão da classificação do modelo LSTM com todos os exemplos de teste.




Fig 10b. Matriz de confusão da classificação do modelo LSTM com apenas os exemplos com SNR ≥ 0 dB.




Fig 11a. Matriz de confusão da classificação do modelo RESIDUAL com todos os exemplos de teste.




Fig 11b. Matriz de confusão da classificação do modelo RESIDUAL com apenas os exemplos com  $SNR \geq 0$  dB.

### REFERÊNCIAS

- [1] Ke, Ziqi, and Haris Vikalo. "Real-time radio technology and modulation classification via an LSTM auto-encoder." *IEEE Transactions on Wireless Communications* 21.1 (2021): 370-382.
- [2] O'Shea, Timothy J., and Nathan West. "Radio machine learning dataset generation with GNU radio." *Proceedings of the GNU Radio Conference*. Vol. 1. No. 1. 2016.
- [3] Tekbiyik, Kürşat, et al. "Robust and fast automatic modulation classification with CNN under multipath fading channels." *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*. IEEE, 2020.
- [4] Bai, Haihai, et al. "A symmetric adaptive visibility graph classification method of orthogonal signals for automatic modulation classification." *IET Communications* (2023).
- [5] Schleher, D. Curtis. *Electronic warfare in the information age*. Artech House, Inc., 1999.
- [6] Kamassury, Kysnney & Silva, Vinícius & Silva, Danilo. (2019). "Classificação Automática de Modulações usando Redes Convolucionais 1D." *2019 Simpósio Brasileiro de Telecomunicações*. 10.14209/sbrt.2019.1570557421.
- [7] GNU radio, the free and open software radio ecosystem. Endereço eletrônico: <https://www.gnuradio.org/about/>. Acesso em 15 de julho de 2023.
- [8] O'Shea, Timothy J., Johnathan Corgan, and T. Charles Clancy. "Convolutional radio modulation recognition networks." *Engineering Applications of Neural Networks: 17th International Conference, EANN 2016, Aberdeen, UK, September 2-5, 2016, Proceedings* 17. Springer International Publishing, 2016.
- [9] RF Datasets for Machine Learning. DeepSig, Inc. Endereço eletrônico: <https://www.deepsig.ai/datasets>. Acesso em 15 de julho de 2023.
- [10] Liu, Xiaoyu, Diyu Yang, and Aly El Gamal. "Deep neural network architectures for modulation classification." *2017 51st Asilomar Conference on Signals, Systems, and Computers*. IEEE, 2017.
- [11] Han, Jin-Woo, and Cheong Hee Park. "A unified method for deinterleaving and PRI modulation recognition of radar pulses based on deep neural networks." *IEEE Access* 9 (2021): 89360-89375.