

**NELSON DE SOUZA AMORIM
FERNANDO MANUEL ARAÚJO MOREIRA
CARLOS CÉLIO SOUSA DA CRUZ
UBIRAEALSON DE LIMA RUELA
PAULA RENATHA NUNES DA SILVA
JOSÉ ROBERTO BRANCO RAMOS FILHO
VICENTE MOREIRA RODRIGUES
THIAGO AUGUSTO DE SOUSA MOREIRA
GILSON FERNANDES BRAGA JUNIOR
ESTEFANY COUTO MILÉO
(ORGANIZADORES)**

ANAIS DO XIV SIMPÓSIO BRASILEIRO DE ENGENHARIA FÍSICA



Atena
Editora

Ano 2020

**NELSON DE SOUZA AMORIM
FERNANDO MANUEL ARAÚJO MOREIRA
CARLOS CÉLIO SOUSA DA CRUZ
UBIRAEALSON DE LIMA RUELA
PAULA RENATHA NUNES DA SILVA
JOSÉ ROBERTO BRANCO RAMOS FILHO
VICENTE MOREIRA RODRIGUES
THIAGO AUGUSTO DE SOUSA MOREIRA
GILSON FERNANDES BRAGA JUNIOR
ESTEFANY COUTO MILÉO
(ORGANIZADORES)**

ANAIS DO XIV SIMPÓSIO BRASILEIRO DE ENGENHARIA FÍSICA



Atena
Editora

Ano 2020

2020 by Atena Editora

Copyright © Atena Editora

Copyright do Texto © 2020 Os autores

Copyright da Edição © 2020 Atena Editora

Editora Chefe: Profª Drª Antonella Carvalho de Oliveira

Diagramação: Geraldo Alves

Edição de Arte: Lorena Prestes

Revisão: Os Autores



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição *Creative Commons*. Atribuição 4.0 Internacional (CC BY 4.0).

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores. Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Conselho Editorial

Ciências Humanas e Sociais Aplicadas

Profª Drª Adriana Demite Stephani – Universidade Federal do Tocantins

Prof. Dr. Álvaro Augusto de Borba Barreto – Universidade Federal de Pelotas

Prof. Dr. Alexandre Jose Schumacher – Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso

Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná

Prof. Dr. Antonio Gasparetto Júnior – Instituto Federal do Sudeste de Minas Gerais

Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília

Prof. Dr. Carlos Antonio de Souza Moraes – Universidade Federal Fluminense

Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa

Profª Drª Cristina Gaio – Universidade de Lisboa

Profª Drª Denise Rocha – Universidade Federal do Ceará

Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia

Prof. Dr. Edvaldo Antunes de Farias – Universidade Estácio de Sá

Prof. Dr. Eloi Martins Senhora – Universidade Federal de Roraima

Prof. Dr. Fabiano Tadeu Grazioli – Universidade Regional Integrada do Alto Uruguai e das Missões

Prof. Dr. Gilmei Fleck – Universidade Estadual do Oeste do Paraná

Profª Drª Ivone Goulart Lopes – Istituto Internazionale delle Figlie di Maria Ausiliatrice

Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense

Profª Drª Keyla Christina Almeida Portela – Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso

Profª Drª Lina Maria Gonçalves – Universidade Federal do Tocantins

Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte

Prof. Dr. Marcelo Pereira da Silva – Universidade Federal do Maranhão

Profª Drª Miranilde Oliveira Neves – Instituto de Educação, Ciência e Tecnologia do Pará

Profª Drª Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa

Profª Drª Rita de Cássia da Silva Oliveira – Universidade Estadual de Ponta Grossa

Profª Drª Sandra Regina Gardacho Pietrobon – Universidade Estadual do Centro-Oeste

Profª Drª Sheila Marta Carregosa Rocha – Universidade do Estado da Bahia

Prof. Dr. Rui Maia Diamantino – Universidade Salvador

Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará

Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande

Prof. Dr. William Cleber Domingues Silva – Universidade Federal Rural do Rio de Janeiro

Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

Ciências Agrárias e Multidisciplinar

Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano

Prof. Dr. Antonio Pasqualetto – Pontifícia Universidade Católica de Goiás

Profª Drª Daiane Garabeli Trojan – Universidade Norte do Paraná

Profª Drª Diocléa Almeida Seabra Silva – Universidade Federal Rural da Amazônia
Prof. Dr. Écio Souza Diniz – Universidade Federal de Viçosa
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul
Prof. Dr. Fágner Cavalcante Patrocínio dos Santos – Universidade Federal do Ceará
Profª Drª Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
Prof. Dr. Júlio César Ribeiro – Universidade Federal Rural do Rio de Janeiro
Profª Drª Lina Raquel Santos Araújo – Universidade Estadual do Ceará
Prof. Dr. Pedro Manuel Villa – Universidade Federal de Viçosa
Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará
Profª Drª Talita de Santos Matos – Universidade Federal Rural do Rio de Janeiro
Prof. Dr. Tiago da Silva Teófilo – Universidade Federal Rural do Semi-Árido
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

Ciências Biológicas e da Saúde

Prof. Dr. André Ribeiro da Silva – Universidade de Brasília
Profª Drª Anelise Levay Murari – Universidade Federal de Pelotas
Prof. Dr. Benedito Rodrigues da Silva Neto – Universidade Federal de Goiás
Prof. Dr. Edson da Silva – Universidade Federal dos Vales do Jequitinhonha e Mucuri
Profª Drª Eleuza Rodrigues Machado – Faculdade Anhanguera de Brasília
Profª Drª Elane Schwinden Prudêncio – Universidade Federal de Santa Catarina
Prof. Dr. Ferlando Lima Santos – Universidade Federal do Recôncavo da Bahia
Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria
Prof. Dr. Igor Luiz Vieira de Lima Santos – Universidade Federal de Campina Grande
Prof. Dr. José Max Barbosa de Oliveira Junior – Universidade Federal do Oeste do Pará
Profª Drª Magnólia de Araújo Campos – Universidade Federal de Campina Grande
Profª Drª Mylena Andréa Oliveira Torres – Universidade Ceuma
Profª Drª Natiéli Piovesan – Instituto Federaci do Rio Grande do Norte
Prof. Dr. Paulo Inada – Universidade Estadual de Maringá
Profª Drª Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande

Ciências Exatas e da Terra e Engenharias

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto
Prof. Dr. Alexandre Leite dos Santos Silva – Universidade Federal do Piauí
Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás
Profª Drª Carmen Lúcia Voigt – Universidade Norte do Paraná
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande
Prof. Dr. Marcelo Marques – Universidade Estadual de Maringá
Profª Drª Neiva Maria de Almeida – Universidade Federal da Paraíba
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista

Conselho Técnico Científico

Prof. Msc. Abrãao Carvalho Nogueira – Universidade Federal do Espírito Santo
Prof. Msc. Adalberto Zorzo – Centro Estadual de Educação Tecnológica Paula Souza
Prof. Dr. Adailson Wagner Sousa de Vasconcelos – Ordem dos Advogados do Brasil/Seccional Paraíba
Prof. Msc. André Flávio Gonçalves Silva – Universidade Federal do Maranhão
Profª Drª Andreza Lopes – Instituto de Pesquisa e Desenvolvimento Acadêmico
Profª Msc. Bianca Camargo Martins – UniCesumar
Prof. Msc. Carlos Antônio dos Santos – Universidade Federal Rural do Rio de Janeiro
Prof. Msc. Cláudia de Araújo Marques – Faculdade de Música do Espírito Santo
Prof. Msc. Daniel da Silva Miranda – Universidade Federal do Pará
Profª Msc. Dayane de Melo Barros – Universidade Federal de Pernambuco

Prof. Dr. Edwaldo Costa – Marinha do Brasil
 Prof. Msc. Eliel Constantino da Silva – Universidade Estadual Paulista Júlio de Mesquita
 Prof. Msc. Gevair Campos – Instituto Mineiro de Agropecuária
 Prof. Msc. Guilherme Renato Gomes – Universidade Norte do Paraná
 Prof^a Msc. Jaqueline Oliveira Rezende – Universidade Federal de Uberlândia
 Prof. Msc. José Messias Ribeiro Júnior – Instituto Federal de Educação Tecnológica de Pernambuco
 Prof. Msc. Leonardo Tullio – Universidade Estadual de Ponta Grossa
 Prof^a Msc. Lilian Coelho de Freitas – Instituto Federal do Pará
 Prof^a Msc. Liliani Aparecida Sereno Fontes de Medeiros – Consórcio CEDERJ
 Prof^a Dr^a Lívia do Carmo Silva – Universidade Federal de Goiás
 Prof. Msc. Luis Henrique Almeida Castro – Universidade Federal da Grande Dourados
 Prof. Msc. Luan Vinicius Bernardelli – Universidade Estadual de Maringá
 Prof. Msc. Rafael Henrique Silva – Hospital Universitário da Universidade Federal da Grande Dourados
 Prof^a Msc. Renata Luciane Polsaque Young Blood – UniSecal
 Prof^a Msc. Solange Aparecida de Souza Monteiro – Instituto Federal de São Paulo
 Prof. Dr. Welleson Feitosa Gazel – Universidade Paulista

Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG)	
S612a	<p> Simpósio Brasileiro de Engenharia Física (14 : 2019 : Santarém) Anais [...] / XIV Simpósio Brasileiro de Engenharia Física, 23-25 outubro 2019, Santarém, PA; organizadores Nelson de Souza Amorim... [et al.]. – Ponta Grossa, PR: Atena, 2020. </p> <p> Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web ISBN 978-65-86002-15-7 DOI 10.22533/at.ed.157200203 </p> <p> 1. Engenharia física – Congressos. I. Título. </p> <p style="text-align: right;">CDD 573.724</p>
Elaborado por Maurício Amormino Júnior – CRB6/2422	

Atena Editora
 Ponta Grossa – Paraná - Brasil
www.atenaeditora.com.br
contato@atenaeditora.com.br

APRESENTAÇÃO

O curso de Engenharia Física da Universidade Federal de São Carlos foi criado no ano 1999 e foi pioneiro nesta área no Brasil. No ano de 2019, o curso de engenharia física no Brasil completou 20 anos. Nesse contexto, a Universidade Federal de São Carlos (UFSCar) e a Universidade Federal do Oeste do Pará (UFOPa) promoveram o XIV Simpósio Brasileiro de Engenharia Física que foi realizado na cidade de Santarém-PA no período de 23 a 25 de Outubro de 2019 na Universidade Federal do Oeste do Pará – Campus Tapajós com o tema “Jubileu de 20 anos da Engenharia Física no Brasil”.

Com a proposta de promover o conhecimento científico e inovação tecnológica bem como a integração entre especialistas, docentes e discentes da área, foram discutidos os 20 anos de existência do curso no Brasil e o intercâmbio de informações técnicas-científicas através de minicursos e palestras relacionados as diferentes temáticas da Engenharia Física e suas perspectivas futuras.

A coleção Anais do XIV Simpósio Brasileiro de Engenharia Física é uma obra que tem como objetivo divulgar os diversos trabalhos que participaram do evento através de trabalhos acadêmicos que abordaram diferentes temas, tais como: termodinâmica, propriedades dielétricas de materiais, ciência dos dados e machine learning, internet das coisas, deep learning, processos oxidativos avançados, energia solar, gerenciamento de projetos, física quântica e automação. Deste modo a obra contribui para disseminar os resultados obtidos pelos acadêmicos e fortalecer a diversidade científica no país, de forma multidisciplinar.

Comitê Organizador

SUMÁRIO

CAPÍTULO 1	1
A IMPORTÂNCIA DO REALIMENTADOR NA EFICIÊNCIA DE UM CICLO DE RANKINE UTILIZANDO O EES	
Muller Gabriel da Silva Chaves Carlos Eduardo Ribeiro Silva Vitor Azevedo Pinto Carlos Célio Sousa da Cruz	
DOI 10.22533/at.ed.1572002031	
CAPÍTULO 2	11
ANÁLISE TEÓRICA DAS PROPRIEDADES DIELÉTRICAS DA MACAÚBA (<i>Acrocomia acuelata</i>)	
Alex Torres da Silva Nelson de Souza Amorim	
DOI 10.22533/at.ed.1572002032	
CAPÍTULO 3	19
APLICAÇÃO DE TÉCNICAS DE DATA SCIENCE E MACHINE LEARNING EM UM PROBLEMA DE CLASSIFICAÇÃO DE UM DATASET DE MARKETING BANCÁRIO	
Yasmin Braga Teixeira João Vitor Rebelo Viana Josecley Fialho Góes Anderson Alvarenga de Moura Meneses	
DOI 10.22533/at.ed.1572002033	
CAPÍTULO 4	28
AQUISIÇÃO DE DADOS DO CONSUMO ELÉTRICO EM UMA EDIFICAÇÃO DA UFOPA UTILIZANDO CONCEITOS DE IOT	
Leonardo Paz Amoêdo Dalton Felipe Silva Varão João Elias Brasil Bentes Júnior Anderson Alvarenga de Moura Meneses	
DOI 10.22533/at.ed.1572002034	
CAPÍTULO 5	37
DEEP LEARNING PARA REGRESSÃO DE POTÊNCIA ELÉTRICA DE UMA USINA DE ENERGIA DE CICLO COMBINADO	
Mauro Sérgio dos Santos Moura Anderson Alvarenga de Moura Meneses	
DOI 10.22533/at.ed.1572002035	
CAPÍTULO 6	46
DEGRADAÇÃO DE CORANTES EM MEIO AQUOSO EMPREGANDO DIÓXIDO DE TITÂNIO NA FORMA DE FILMES FINOS PREPARADOS SOBRE SUBSTRATO CERÂMICO COMERCIAL	
Graziele Daiana Sena de Sousa Adriano Cesar Rabelo	
DOI 10.22533/at.ed.1572002036	

CAPÍTULO 7	59
FATORES CRÍTICOS QUE INTERFEREM NO GERENCIAMENTO DO TEMPO EM PROJETOS DE ENGENHARIA: ESTUDO DE CASO EM SANTARÉM – PA	
Raíssa Coelho Almeida Kevin de Matos Costa	
DOI 10.22533/at.ed.1572002037	
CAPÍTULO 8	70
OBTENÇÃO DA EQUAÇÃO DE KLEIN-GORDON-FOCK EM COORDENADAS DO CONE DE LUZ	
Jorge Kysnney Santos Kamassury Damião Pedro Meira Filho Sérgio Antônio de Souza Farias Natalie Von Paraski	
DOI 10.22533/at.ed.1572002038	
CAPÍTULO 9	83
RÁPIDO RECONHECIMENTO DE MODULAÇÕES ANALÓGICAS E DIGITAIS VIA REDES RESIDUAIS PROFUNDAS	
Jorge Kysnney Santos Kamassury Vinícius Felipe de Oliveira da Silva	
DOI 10.22533/at.ed.1572002039	
CAPÍTULO 10	98
REVISÃO DE LITERATURA SOBRE A AUTOMAÇÃO NO ENSINO DE FÍSICA NO BRASIL	
Davi Henrique da Silva Pedroso Gabriel Gonçalves da Silva Gilson Fernandes Braga Junior	
DOI 10.22533/at.ed.15720020310	
CAPÍTULO 11	109
DIAGNÓSTICO DOS MICROSSISTEMAS DE ENERGIA SOLAR FOTOVOLTAICO INSTALADOS NAS COMUNIDADES RURAIS DO MUNICÍPIO DE SANTARÉM	
Fabiane da Conceição Almeida Manoel Roberval Pimentel Santos	
DOI 10.22533/at.ed.15720020311	
SOBRE OS ORGANIZADORES	119
ÍNDICE REMISSIVO	121

RÁPIDO RECONHECIMENTO DE MODULAÇÕES ANALÓGICAS E DIGITAIS VIA REDES RESIDUAIS PROFUNDAS

Data de aceite: 27/01/2020

Jorge Kysnney Santos Kamassury

Universidade Federal de Santa Catarina - UFSC,
Centro Tecnológico - CTC
Florianópolis – Santa Catarina
<http://lattes.cnpq.br/1350512148935889>

Vinícius Felipe de Oliveira da Silva

Universidade Federal de Santa Catarina - UFSC,
Centro Tecnológico - CTC
Florianópolis – Santa Catarina
<http://lattes.cnpq.br/5788623208337073>

RESUMO: O reconhecimento automático de modulação (AMR), empregado em sistemas de comunicação para o processo de demodulação no receptor, tem notáveis aplicações no contexto militar e civil. Todavia, em virtude do elevado desenvolvimento de técnicas de comunicação sem fio, a quantidade de métodos e parâmetros de modulação tem aumentado rapidamente, tornando o reconhecimento de modulação uma tarefa desafiadora. Esse aspecto torna-se ainda mais agravante pelo fato de que os métodos convencionais para esse reconhecimento, exigem quase sempre o conhecimento prévio dos parâmetros do canal e do sinal, podendo ser imprecisos até mesmo para condições moderadas. Assim, para sistemas de comunicação sem fio,

onde os esquemas de modulação mudam conforme o ambiente, a necessidade de AMR é indiscutível, exigindo novas abordagens, como é o caso do uso de técnicas de aprendizado de máquina, especialmente, as redes neurais convolucionais. Na prática, um dos grandes desafios enfrentados por essas redes para AMR reside no elevado tempo que elas demandam para treinamento, fato esse que dificulta sua aplicação em tempo real. Desse modo, visando alcançar um trade-off entre o desempenho de reconhecimento e o tempo para treinamento, projetamos duas arquiteturas de redes residuais profundas que além de exigirem menos tempo para treinamento, retornam desempenhos equivalentes às mais recentes arquiteturas da literatura.

PALAVRAS-CHAVE: Reconhecimento Automático de Modulações; Aprendizado de Máquina; ResNet; Tempo de Treinamento.

FAST RECOGNITION OF ANALOG AND DIGITAL MODULATIONS VIA DEEP RESIDUAL NETWORKS

ABSTRACT: Automatic Modulation Recognition (AMR), used in communication systems for the receiver demodulation process, has notable applications in the military and civil contexts. However, due to the high development of wireless communication techniques, the

number of modulation methods and parameters has been increasing rapidly, making modulation recognition a challenging task. This aspect is further aggravated by the fact that conventional methods for this recognition almost always require prior knowledge of channel and signal parameters and may be inaccurate even under moderate conditions. Thus, for wireless communication systems, where modulation schemes change according to the environment, the need for AMR is unquestionable, requiring new approaches, such as the use of machine learning techniques, especially convolutional neural networks. In practice, one of the major challenges faced by these AMR networks is their high training time, which makes their application difficult in real time. Thus, in order to achieve a trade-off between recognition performance and training time, we designed two deep residual network architectures that, in addition to requiring less training time, return performances equivalent to the latest literature architectures.

KEYWORDS: Automatic Modulation Recognition; Machine Learning; ResNet; Training Time.

1 | INTRODUÇÃO

O reconhecimento automático de modulação (*automatic modulation recognition*, AMR) conceituado como a identificação autônoma de modulação no receptor em um sistema de comunicação, tem sido tradicionalmente empregado em sistemas de comunicações militares (análise de ameaças, vigilância e guerra eletrônica) (ZHU e NANDI, 2015). Além dessa clássica aplicação, nos últimos anos, o AMR tem recebido especial atenção por assessorar sistemas de Rádio Cognitivo (RC), uma tecnologia de comunicação sem fio que interage de modo inteligente com o ambiente de operação com enfoque tanto no acesso oportunista quanto na utilização eficiente do espectro de frequência (DOBRE, ABDI, *et al.*, 2007). Auxiliando RCs na etapa de sensoriamento espectral, o processo de AMR permite identificar usuários primários e obter ganho de eficiência espectral pela não adição de *overhead* para estimação do meio (BAHRANI, DERAKHTIAN e ZOLGHADRASLI, 2017).

Na literatura, as técnicas de AMR mais convencionais estão categorizadas em: métodos baseados em verossimilhança (*likelihood-based*, LB) e métodos baseados em características (*feature-based*, FB) (WU, LI e FANG, 2018). Embora teoricamente alcancem a solução ideal, os métodos LB demandam elevado esforço computacional e quase sempre necessitam de informações prévias dos transmissores, o que pode ser fatalmente inviável para diversas aplicações. Os métodos FB, por sua vez, atuam na extração de características e nos critérios de classificação, sendo, em geral, constituídos de dois subsistemas, a saber: o extrator de características e o classificador (por exemplo, árvore de decisão, máquinas de vetores de suporte, redes neurais artificiais, etc.). De fato, apesar de serem mais fáceis de implementar, o desempenho dos métodos FB depende diretamente das características extraídas

e do tipo de classificador, o que afeta a robustez da abordagem visto que, na maioria dos casos, as características extraídas devem ser projetadas manualmente para a modulação e canal correspondentes (ZHOU, YIN, *et al.*, 2019). Assim, diante do atual cenário, no qual há um crescente desenvolvimento de técnicas de comunicação sem fio e, por consequência, a quantidade de métodos e parâmetros de modulação, o reconhecimento de modulação tem se tornado uma tarefa desafiadora para os métodos tradicionais (O'SHEA, CORGAN e CLANCY, 2016).

Nesse contexto, os métodos de aprendizado profundo (*deep learning*, DL) vêm se manifestando como uma ferramenta alternativa e robusta para AMR. Empregando redes multicamadas para extrair a representação interna dos dados brutos, os métodos DL aprendem as características automaticamente (vide Figura 1).

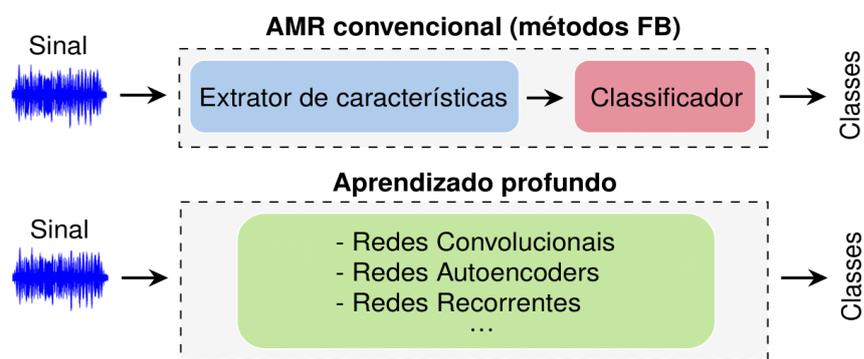


Figura 1: Métodos convencionais (FB) em comparação com os métodos de aprendizado profundo.

Fonte: Autores

Dentre alguns métodos DL recentemente aplicados para AMR, citam-se: *deep belief network* (MENDIS, WEI e MADANAYAKE, 2016), *autoencoders* (DAI, ZHANG e SUN, 2016), redes neurais convolucionais (*convolutional neural network*, CNN) (O'SHEA, CORGAN e CLANCY, 2016) e redes neurais recorrentes (*recurrent neural network*, RNN) (WU, LI e FANG, 2018). Recentemente, outras arquiteturas como DenseNet (*densely connected networks*) (LIU, YANG e GAMAL, 2017), CLDNN (*convolutional long short-term deep neural network*) (WEST e O'SHEA, 2017) e ResNet (*residual network*) (O'SHEA, ROY e CLANCY, 2018), também foram empregadas para a referida tarefa.

Reconhecendo que o tempo de treinamento é um fator determinante para o uso dos métodos DL em aplicações de tempo real, Ramjee et al. (2019) recentemente empregou técnicas de redução de dimensionalidade e subamostragem para reduzir o tempo de treinamento/validação de arquiteturas como CLDNN e ResNet (sendo essa última a mais rápida). Nesse sentido, propomos nesse trabalho duas arquiteturas ResNet que exigem menos tempo para treinamento, bem como retornam

desempenhos similares ao resultado obtido pela arquitetura proposta em Ramjee et al. (2019).

2 | MODELO DO SISTEMA DE MODULAÇÃO

Em geral, o reconhecimento de modulação pode ser analisado como um problema de classificação de N classes. Uma representação genérica do sinal recebido $r(t)$ pode ser expressa por

$$r(t) = \alpha(t) \exp[j(2\pi f_0 t + \theta_0(t))] s(t) + n(t) \quad (1)$$

onde $s(t)$ denota o envelope complexo em banda-base do sinal transmitido, $\alpha(t)$ é a resposta ao impulso do canal, $\theta_0(t)$ e f_0 representam as compensações de fase e frequência da portadora devidas ao oscilador local e efeito Doppler díspares causadas pelo movimento e $n(t)$ é o ruído instantâneo do canal.

Isto posto, o objetivo fundamental de qualquer classificador de modulações incorre em fornecer a probabilidade $P(s(t) \in N_i | r(t))$ para o sinal recebido $r(t)$, onde $N_i(t)$ representa a i -ésima modulação (classe). Para tal propósito, podemos recorrer aos métodos DL, para os quais, processa-se inicialmente um conjunto de dados de treinamento para definir os parâmetros da rede, e em seguida, a acurácia de classificação é calculada para um conjunto de dados de teste (GOODFELLOW, BENGIO e COURVILLE, 2016).

2.1 Conjunto de dados

Neste trabalho, utilizaremos o conjunto de dados que possui 10 tipos de modulações, a saber:

- Digitais: BPSK, QPSK, 8PSK, 16QAM, 64QAM, BFSK, CPFSK e PAM4;
- Analógicas: WB-FM e AM-DSB.

Incluindo parâmetros de modulações usados comercialmente e imperfeições realistas de canal como deslocamento de taxa de amostragem, AWGN, desvanecimento de múltiplos caminhos e desvio de frequência, esse conjunto de dados foi gerado sinteticamente através do GNU Radio (O'SHEA e WEST, 2016).

O referido conjunto possui 1.200.000 exemplos normalizados (cada um com 128 amostras, sendo 8 amostras por símbolo) que estão estruturados em vetores 2128 com as partes real e imaginária separadas em amostras de tempo complexas ($1 \mu s$ de intervalo de amostragem). Em razão da simplicidade e flexibilidade tanto para operações matemáticas quanto para o projeto de *hardware*, $r(t)$ é usualmente representado no formato IQ (fase e quadratura). Os rótulos desses exemplos incluem tanto a razão sinal-ruído (*signal-to-noise ratio*, SNR) quanto o tipo de modulação. As

SNRs das amostras estão distribuídas uniformemente no intervalo $[-20, +18]$ com passo de 2 dB.

3 I REDES NEURAIS CONVOLUCIONAIS

As CNNs são redes neurais que empregam a convolução em vez da multiplicação geral de matrizes em pelo menos uma de suas camadas (GOODFELLOW, BENGIO e COURVILLE, 2016). O emprego da operação de convolução, que é linear, permite que as CNNs explorem informações em estruturas organizadas no tempo e no espaço. Dessa forma, essas redes são capazes de aprenderem representações invariantes à escala, translação, rotação e transformação.

Em geral, as arquiteturas das CNNs são constituídas de três tipos de camadas: camada convolucional, camada de agrupamento (*pooling*) e camada densa (*fully connected*).

3.2 Camadas convolucionais

Em detalhe, as camadas convolucionais possuem filtros (núcleos de convolução) para processar o sinal recebido, onde para cada filtro, um neurônio está conectado a apenas um subconjunto dos neurônios da camada anterior. Os filtros são os responsáveis pela formação dos mapas de características.

Para compreendermos como esses núcleos de convolução atuam, suponhamos que a l -ésima camada de uma rede seja uma camada convolucional, para a qual, N_k^l e L_k^l denotam a quantidade e o tamanho dos filtros, enquanto N_s e L_s^l correspondem à quantidade e ao tamanho das entradas. Nesse ínterim, a operação de convolução na l -ésima camada é definida por

$$h_k^l = \sigma(u^l \times W_k^l + b_k^l) \quad (2)$$

onde

$$(u^l \times W_k^l)_i = \sum_{j=-\infty}^{\infty} u(j)W_k^l(i-j) \quad (3)$$

Nas equações acima:

- $u \in \mathcal{R}^{N_s \times L_s^l}$ é o conjunto de entradas;
- $W \in \mathcal{R}^{N_k \times L_k^l}$ é o conjunto de filtros;
- $b \in \mathcal{R}^{N_s}$ é o *bias* para cada saída;
- $h^l \in \mathcal{R}^{N_k \times L_0^l}$ é o conjunto da saída (mapa de características), onde L_0^l é o tamanho da saída;
- $\sigma(\cdot)$ é a função de ativação.

Na prática, a função de ativação mais empregada para esse tipo de camada é a ReLU (*rectified linear unit*) que supera o problema do desvanecimento do gradiente e converge bem mais rápido do que as funções sigmóide e tangente hiperbólica.

3.3 Camadas de agrupamento

Essas camadas são usualmente empregadas imediatamente depois das camadas convolucionais e atuam modificando o conjunto de saída da camada convolucional de uma determinada região por uma estatística resumida das saídas mais próximas (GOODFELLOW, BENGIO e COURVILLE, 2016). A média, a média ponderada e *max pooling* são algumas das funções que podem ser empregadas por esse tipo de camada para realizar tal estatística.

Por exemplo, supondo que a saída de uma camada convolucional seja seguida por uma camada de agrupamento que use a função *max pooling*, nesse caso, a saída h^{l+1} será dada por

$$h_k^{l+1}(i) = \max\{h_k^l[m^{l+1}(i-1)+1], \dots, h_k^l[m^{l+1}(i-1)+L_p]\} \quad (4)$$

tal que

$$i \leq \frac{L_0^l - L_p^{l+1}}{m^{l+1}} + 1 \quad (5)$$

onde L_p^{l+1} é o tamanho da janela de agrupamento e m^{l+1} é o *stride*, ou seja, a margem entre duas janelas adjacentes. Desse modo, com a aplicação da função *max pooling*, a informação reportada é o valor máximo de uma vizinhança retangular.

3.4 Normalização em lote

A camada de normalização em lote (*batch normalization*, BN) atua acelerando o aprendizado profundo da rede a partir da redução interna da covariância (IOFFE e SZEGEDY, 2015), alterando assim a distribuição de saída de cada camada durante a etapa de treinamento.

Para entendermos a ação da camada BN, considere um único minilote dado por $B = \{x_1, x_2, \dots, x_d\}$ e a saída da camada BN como y_i . Nesse caso, sejam a média (μ_B) e a variância (σ_B^2) para B dadas por

$$\mu_B = \frac{1}{d} \sum_{i=1}^d x_i, \quad \sigma_B^2 = \frac{1}{d} \sum_{i=1}^d (x_i - \mu_B)^2 \quad (6)$$

a normalização será obtida pela relação

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (7)$$

e a saída y_i alcançada através da expressão:

$$y_i = \gamma \hat{x}_i + \beta$$

onde γ e β devem ser aprendidos durante o treinamento da arquitetura. O termo ϵ é uma pequena quantidade usada para evitar a divisão por zero.

3.5 Camada densa e a função softmax

Em geral, as CNNs possuem uma ou mais camadas totalmente conectadas (*fully connected*). Nesse tipo de camada, cada neurônio da camada anterior é conectado a cada um dos neurônios da próxima camada. Desse modo, o resultado para cada um deles pode ser obtido a partir da equação (2).

Na prática, as camadas densas são usadas no final das redes a fim de mapear os valores intermediários para cada uma das saídas finais possíveis. Para um problema de classificação, por exemplo, objetiva-se que somente uma classe seja ativada no final, de modo que, para forçar esse resultado usualmente é acoplada uma função à última camada densa. Para o aprendizado supervisionado, a regressão *softmax* é uma das funções mais utilizadas. Essa função é um classificador multiclasse generalizado da regressão logística cuja saída é um conjunto de distribuições de probabilidade de diferentes classes. Nesse caso, supondo que h_L seja a entrada para uma camada com *softmax*, essa função retorna y_o que pode ser denotada por

$$P(y_o = c | h_L, W_L, b_L) = \frac{\exp(W_{Lc} h_L + b_{Lc})}{\sum_{i=1}^n \exp(W_{Li} h_L + b_{Li})}$$

onde $c = 1, \dots, n$. Conforme indica a equação (9), o neurônio com saída máxima é selecionado como resultado da classificação

3.6 Resnet

Desenvolvida recentemente para permitir a propagação eficiente de atributos em redes profundas, a ResNet funciona a partir da criação de caminhos de atalho entre diferentes camadas na rede (HE *et al.*, 2016). A Figura 2 ilustra um exemplo de bloco residual; nesse caso, o bloco é constituído de duas camadas convolucionais, para o qual, u e $H(u)$ denotam respectivamente a entrada e saída do bloco residual, enquanto $F(u)$ refere-se à saída da primeira camada (função de mapeamento residual).

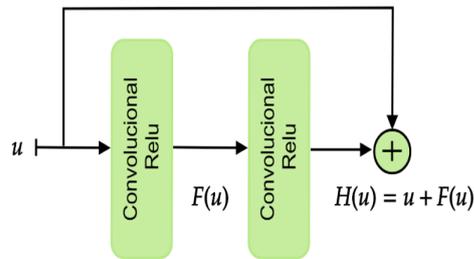


Figura 2: Bloco residual.

Fonte: Autores

Em vez de aprender o mapeamento $H(u) = u$ que é mais complicado para a rede profunda, a ResNet adiciona um caminho de atalho conectando a entrada à saída do bloco residual, isto é

$$H(u) = F(u) + u \quad (10)$$

de forma que a rede aprenda o mapeamento dado por:

$$F(u) = H(u) - u \quad (11)$$

De fato, ao adicionar esse atalho, um mapeamento de identidade é criado, viabilizando assim que uma rede profunda possa ter a mesma capacidade de aprendizado que uma rede rasa.

4 | ARQUITETURAS PROPOSTAS

Inspirados pela arquitetura apresentada por O'Shea et al. (2018), projetamos duas ResNets usando somente cinco pilhas residuais seguidas por duas camadas densas.

4.1 Resnet-P1

A primeira arquitetura proposta está ilustrada na Figura 3. Nessa arquitetura, cada pilha residual é composta por: uma camada convolucional (com função de ativação linear), uma camada de normalização em lote, uma unidade residual e uma camada de agrupamento. Em cada unidade residual, há duas conexões de atalho: a primeira adiciona a entrada da unidade a sua respectiva saída, enquanto a segunda conexão adiciona a saída da camada de normalização da segunda camada convolucional à saída da unidade residual. Nas duas primeiras camadas convolucionais da unidade residual, utiliza-se a função ReLU, enquanto na terceira camada aplica-se a função linear. Todas as camadas convolucionais da unidade residual são seguidas por camadas de normalização para evitar *overfitting* e acelerar

o aprendizado da rede.

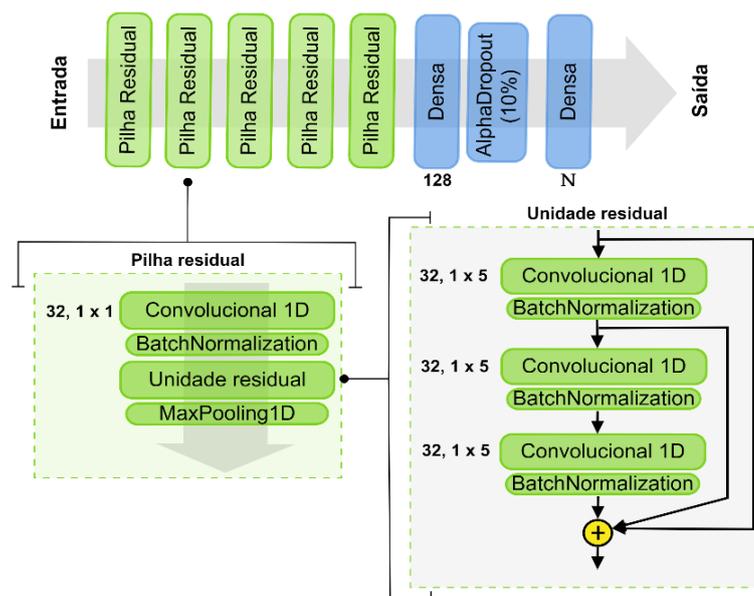


Figura 3: ResNet – P1.

Fonte: Autores

No que se refere às camadas densas, a penúltima camada usa uma função de ativação SELU (*scaled exponential linear unit*) sendo seguida por *Alphadropout* (KLAMBAUER, UNTERTHINER e MAYR, 2017) de 10% que empregamos para aumentar a capacidade de generalização da rede. Para a última camada, aplicamos a função *softmax*.

O primeiro parâmetro de cada camada convolucional da Figura 3. representa a quantidade de filtros enquanto o segundo parâmetro denota o tamanho de cada filtro. Para as duas camadas densas, utilizamos 128 e N neurônios, em ordem de profundidade da rede, onde N refere-se à quantidade de classes de modulações do conjunto de dados.

4.2 Resnet-P2

De modo a reduzir ainda mais a complexidade da primeira rede proposta, projetamos a ResNet apresentada na Figura 4. De fato, as principais diferenças dessa arquitetura em relação à ResNet-P1 são:

- Remoção da camada convolucional intermediária (bem como a camada de normalização) da unidade residual;
- Inclusão de mais uma camada densa à rede principal;
- Aplicação da função ReLU para a camada convolucional da pilha residual.

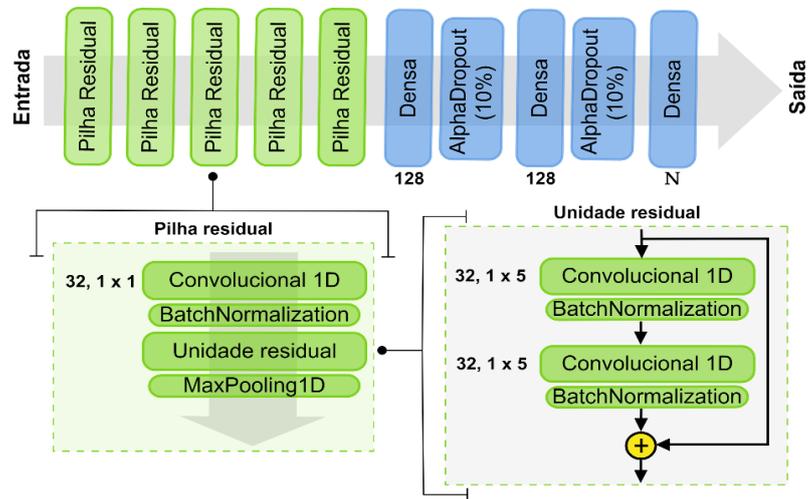


Figura 4: ResNet – P2.

Fonte: Autores

5 | RESULTADOS E DISCUSSÕES

As etapas de treinamento e teste com o conjunto de dados descrito na subseção 3.1 foram realizadas usando a biblioteca Keras com Tensorflow como *backend*. Para todas as arquiteturas usamos a função Adam para a otimização dos pesos das redes - com uma taxa de aprendizagem de 0.001 - e entropia cruzada categórica para avaliar a função perda (*loss*). Ademais, usamos um *batch size* de 1024, bem como 30 épocas para o processo de treinamento (quantidade média de épocas observada para a convergência da rede). As implementações foram feitas na plataforma colab (*google colaboratory*) que nos permitiu o uso da GPU Tesla K80.

Para realizar as simulações, o conjunto de dados foi dividido em 50% para treinamento e 50% para validação e teste. Vale mencionar que os exemplos para treinamento e teste são selecionados aleatoriamente.

A quantidade de parâmetros treináveis (N_p) e o percentual de redução do tempo médio de treinamento (T_m) de cada arquitetura estão apresentados na Tabela 1. Observa-se que ambas as arquiteturas propostas demandam menos tempo para treinamento quando comparadas com a ResNet otimizada apresentada por Ramjee et al. (2019). A ResNet-P2, por exemplo, exige apenas 43% do tempo de treinamento que a arquitetura de referência demanda.

Arquitetura	N_p	$T_m(\%)$
ResNet - Ramjee	144.154	_____
ResNet - P1	101.386	≈ 25 ↓
ResNet - P2	91.642	≈ 43 ↓

Tabela 1: Treinamento das arquiteturas.

Fonte: Autores

No que concerne à acurácia de classificação (ilustrada na Figura 5), verifica-se que as arquiteturas propostas alcançam desempenhos similares ao resultado obtido usando a rede de referência.

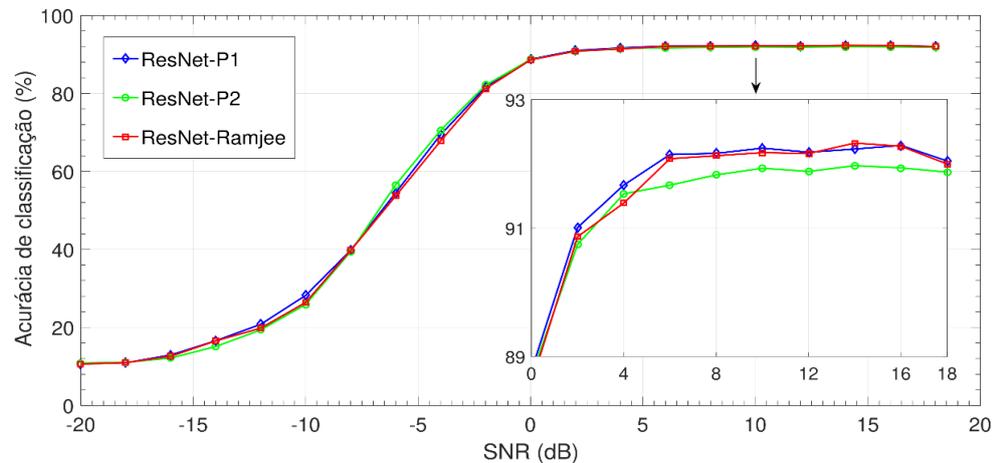


Figura 5: Comparação das acurácias de classificação das arquiteturas propostas com a ResNet usada por Ramjee et al. (2019)

Fonte: Autores

Para avaliar o quão efetiva é a classificação obtida através das arquiteturas propostas para cada tipo de modulação do conjunto de dados, fazemos uso da matriz de confusão (especificamente para as SNRs $\{-4, 8\}$ dB). Nessa matriz, as linhas e colunas correspondem às modulações corretas (rótulos verdadeiros) e às modulações previstas (rótulos preditos), nessa ordem, enquanto a diagonal principal representa, para cada modulação, o percentual de classificações corretas da modulação em relação à quantidade total de dados dessa modulação. As Figuras 6 e 7, por exemplo, apresentam as matrizes de confusão obtidas a partir da ResNet-P2.

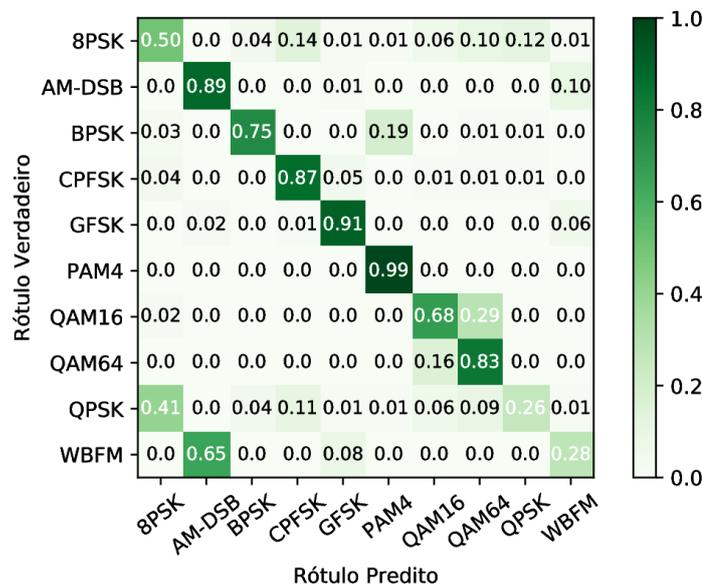


Figura 6: Matriz de confusão da ResNet-P2 em SNR -4 dB.

Fonte: Autores

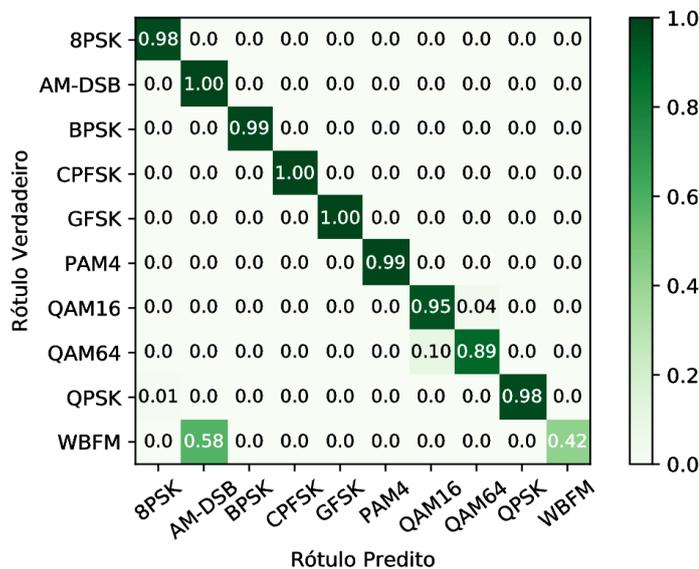


Figura 7: Matriz de confusão da ResNet-P2 em SNR +8 dB.

Fonte: Autores

É possível observar que as maiores confusões ocorrem entre as modulações digitais 16-QAM e 64-QAM e as modulações analógicas AM-DSB e WBFM. A confusão entre as modulações QAM se deve ao fato de elas eventualmente ocuparem a mesma região com uma combinação de símbolos específicos, visto que a constelação 16-QAM está contida na constelação 64-QAM. Já a confusão entre as modulações analógicas ocorre pelo fato de a mensagem ser um sinal de voz. Nesse caso, temos períodos de silêncio onde apenas a portadora está sendo enviada (O'SHEA e HOYDIS, 2017).

De fato, recorrendo-se às técnicas de redução de dimensionalidade e subamostragem, podemos diminuir ainda mais o tempo de treinamento das redes. Entretanto, conforme é demonstrado por Ramjee et al. (2019), o uso dessas técnicas pode prejudicar significativamente o desempenho das redes, em especial, para baixas SNRs. Para efeitos de comparação e a fim de replicar os melhores resultados obtidos por Ramjee et al. (2019), reduzimos a dimensionalidade de cada entrada de amostra vetorial usando a técnica de subamostragem uniforme (ELDAR, 2015) e treinamos a ResNet de referência. Nesse caso, usamos vetores de amostras com dimensão (264). Observou-se que apesar de reduzir o tempo de treinamento em aproximadamente 30% em relação à ResNet-Ramjee, essa abordagem reduz a acurácia de classificação dessa arquitetura para baixas SNRs. Conforme visualiza-se na Figura 8, para o intervalo de $[-8,0]$ dB, a arquitetura que faz uso da subamostragem (ResNet-SU) tem desempenho inferior - em torno de 8% - quando comparado com às demais arquiteturas.

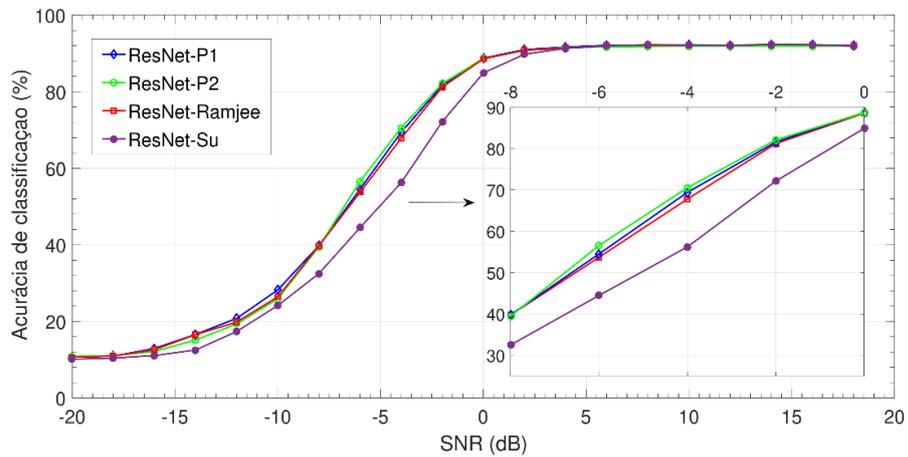


Figura 8: Comparação das acurácias de classificação das arquiteturas propostas com a ResNet usada por Ramjee et al (2019) (2128 e 264).

Fonte: Autores

Confrontando as matrizes de confusão apresentadas nas Figuras 6 e 9, tem-se uma noção do quão essa redução de desempenho afeta a classificação correta das modulações, em particular, as modulações BPSK e CPFSK.

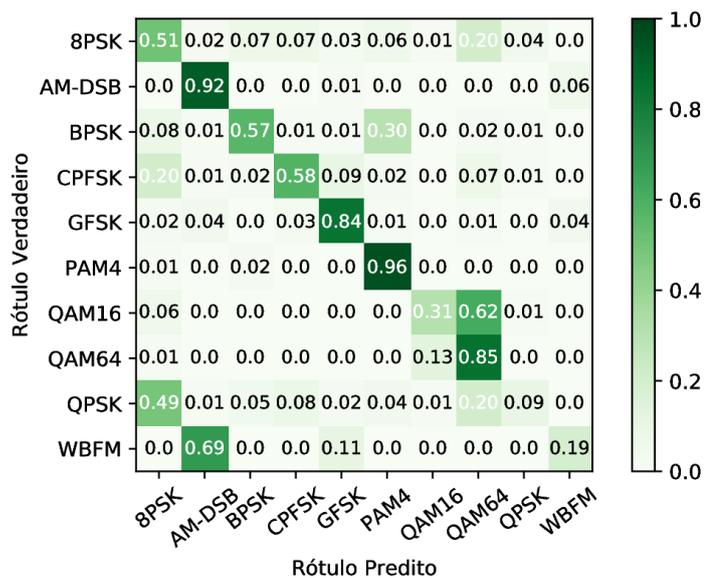


Figura 9: Matriz de confusão da ResNet-Ramjee em SNR -4 dB com subamostragem uniforme.

Fonte: Autores

6 | CONSIDERAÇÕES FINAIS

Neste trabalho, propomos duas diferentes arquiteturas de redes residuais profundas para a tarefa de AMR. As arquiteturas propostas alcançaram desempenhos similares àqueles obtidos por Ramjee et al. (2019), com a vantagem de demandar menos tempo na etapa de treinamento. A ResNet-P2, por exemplo, exigiu somente 43% do tempo que a arquitetura de referência levou para treinar, e não comprometeu

a acurácia de classificação para baixas SNRs que, por sua vez, são reconhecidamente de interesse prático. Os resultados obtidos evidenciam assim que as arquiteturas propostas são bem-sucedidas em estabelecer um compromisso entre a acurácia de classificação e o tempo gasto para treinamento.

REFERÊNCIAS

BAHRANI, S.; DERAKHTIAN, M.; ZOLGHADRASLI, A. Effect of channel prediction on automatic modulation classification for adaptive OFDM systems. In: IRANIAN CONFERENCE ON ELECTRICAL ENGINEERING, 20., 2012, Tehran. **Proceedings** ... Tehran: IEEE, 2012. p. 1280-1285.

DAI, A.; ZHANG, H.; SUN, H. Automatic modulation classification using stacked sparse auto-encoders. In: INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING, 13., 2016, Chengdu. **Proceedings**... Chengdu: IEEE, 2016. p. 248-252.

DOBRE, O. A. et al. Survey of automatic modulation classification techniques: classical approaches and new trends. **IET Communications**, v. 1, n. 1, p. 137-156, April 2007.

ELDAR, Y. C. **Sampling Theory: Beyond Bandlimited Systems**. 1. ed. [S.l.]: Cambridge University Press, 2015.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. Disponível em: <<http://www.deeplearningbook.org>>. Acesso em: 12 jun. 2019

HE, K. et al. Deep Residual Learning for Image Recognition. In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2016, Las Vegas. **Proceedings**... Las Vegas: IEEE, 2016. p. 770-778.

IOFFE, S.; SZEGEDY, C. Batch normalization: accelerating deep network training by reducing internal covariate shift. In: INTERNATIONAL CONFERENCE ON INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 32, 2015, Lille. **Proceedings**... Lille: JMLR, 2015. p. 448-456.

KLAMBAUER, G.; UNTERTHINER, T.; MAYR, A. Self-Normalizing Neural Networks. In: CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 31., 2017, Long Beach. **Proceedings**... Long Beach: NIPS, 2017. p. 1-10.

LIU, X.; YANG, D.; GAMAL, A. E. Deep neural network architectures for modulation classification. In: ASILOMAR CONFERENCE ON SIGNALS, SYSTEMS, AND COMPUTERS, 51., 2017, Pacific Grove. **Proceedings**... Pacific Grove: IEEE, 2017. p. 915-919.

MENDIS, G. J.; WEI, J.; MADANAYAKE, A. Deep learning-based automated modulation classification for cognitive radio. In: INTERNATIONAL CONFERENCE ON COMMUNICATION SYSTEMS, 2016, Shenzhen. **Proceedings**... Shenzhen: IEEE, 2016. p. 1-6.

O'SHEA, T. J.; CORGAN, J.; CLANCY, T. C. Convolutional radio modulation recognition networks. In: INTERNATIONAL CONFERENCE ON ENGINEERING APPLICATIONS OF NEURAL NETWORKS, 17., 2016, Aberdeen. **Proceedings**... Aberdeen: Springer, 2016. p. 213-226.

O'SHEA, T.; HOYDIS, J. An introduction to deep learning for the physical layer. **IEEE Transactions on Cognitive Communications and Networking**, v. 3, n. 4, p. 563-575, Dec 2017.

O'SHEA, T. J.; ROY, T.; CLANCY, T. C. Over-the-air deep learning based radio signal classification. **IEEE Journal of Selected Topics in Signal Processing**, v. 12, n. 1, p. 168-179, Feb 2018.

O'SHEA, T. J.; WEST, N. Radio Machine Learning Dataset Generation with GNU Radio. **Proceedings of the GNU Radio Conference**, v. 1, n. 1, Sep 2016.

RAMJEE, S. et. al. **Fast deep learning for automatic modulation classification**. 2019. Disponível em: <https://arxiv.org/abs/1901.05850>. Acesso em: 2 jun. 2019

WEST, N.; O'SHEA, T. Deep architectures for modulation recognition. In: INTERNATIONAL SYMPOSIUM ON DYNAMIC SPECTRUM ACCESS NETWORKS, 2017, Piscataway. **Proceedings...** Piscataway: IEEE, 2017. p 1-6.

WU, Y.; LI, X.; FANG, J. A deep learning Approach for modulation recognition via exploiting temporal correlations. In: INTERNATIONAL WORKSHOP ON SIGNAL PROCESSING ADVANCES IN WIRELESS COMMUNICATIONS, 19., 2018, Kalamata. **Proceedings...** Kalamata: IEEE, 2018. p. 1-5.

ZHOU, S. et al. A robust modulation classification method using convolutional neural networks. **EURASIP Journal on Advances in Signal Processing**, v. 1, n. 1, p. 21, Mar 2019.

ZHU, Z.; NANDI, A. **Automatic Modulation Classification: Principles, Algorithms and Applications**. 1. ed. West Sussex: Wiley, 2015.

ÍNDICE REMISSIVO

A

Acompanhamento do consumo 28, 30
Aprendizado de máquina 19, 20, 21, 22, 37, 38, 83
Aprendizagem profunda 37

C

Campo eletromagnético clássico 70, 72, 79, 81
Ciclo de rankine 1, 4
Ciência de dados 19, 20
Comunidades rurais 109, 110
Constante dielétrica 11, 12, 13, 14, 15, 17
Coordenadas do cone de luz 70, 71, 72, 74, 75, 76, 77, 78, 79, 81
Cronogramas 59, 60, 61, 62, 67

E

Ees 1, 2, 4, 5, 9
Eficiência 1, 2, 4, 6, 7, 8, 9, 28, 29, 30, 31, 33, 35, 36, 37, 46, 50, 56, 84, 111, 115, 119
Eficiência energética 28, 29, 30, 31, 33, 35, 36, 119
Energia 2, 3, 4, 5, 6, 8, 11, 12, 26, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 41, 44, 49, 50, 75, 109, 110, 111, 112, 116, 117, 118, 119, 120
Energia elétrica 2, 3, 28, 29, 36, 37, 41, 44, 109, 110, 111, 117, 120
Energia solar 109, 110, 111, 117
Engenharia 7, 10, 11, 18, 36, 37, 44, 46, 58, 59, 62, 69, 103, 107, 108, 117, 119, 120
Ensino-aprendizado 98
Equação de klein-gordon-fock 70
Experimento 98, 100, 102, 104, 107

F

Falhas 61, 109, 115, 116, 117, 119
Fator de perda 11, 12, 13, 15, 16, 17
Filmes finos 46, 50, 51
Fotocatálise heterogênea 46, 47, 48

G

Gerenciamento 28, 29, 33, 59, 60, 61, 62, 63, 68, 69

I

Interdisciplinaridade 98, 102, 103, 106
Internet das coisas 26, 28, 30, 36, 44

K

K-nearest neighbors 19, 20, 21

M

Macaúba 11, 12, 13, 17, 18

Marketing bancário 19

Ms project 63

P

Potência elétrica 37

Processos oxidativos avançados 46, 47, 48, 57, 58

Projetos 30, 59, 60, 61, 62, 63, 67, 68, 69, 100, 103, 106, 120

Propriedades dielétricas 11, 12, 18

R

Realimentador 1, 2, 3, 4, 6, 7, 8, 9

Reconhecimento automático de modulações 83

Redes neurais 19, 21, 25, 38, 83, 84, 85, 87

Regressão 20, 37, 38, 43, 44, 89

Resnet 89, 90, 91

S

Substrato cerâmico 46

T

Tecnologia 1, 29, 36, 56, 57, 69, 70, 84, 98, 99, 100, 104, 105, 106, 107, 117, 120

Tempo de treinamento 83, 85, 92, 94

Tratamento de águas residuais 46, 57

 **Atena**
Editora

2 0 2 0