

Redes Neurais Profundas com Função de Base Radial sob Domínio Complexo

Palavras-Chave: Redes neurais, CVNNs, Aprendizado Profundo

Autores(as):

Vinicius Henrique Luiz, FEEC – UNICAMP

Prof^(a). Dr^(a). Dalton Soares Arantes, FEEC – UNICAMP

INTRODUÇÃO:

Nos últimos anos, com o avanço dos serviços em nuvem, análise de big data e internet das coisas (IoT), o processamento em tempo real tornou-se crucial. Aplicações como sistemas de transporte inteligentes e Indústria 4.0 exigem o processamento de grandes volumes de dados, frequentemente realizado na nuvem. Isso aumenta a demanda por data centers e redes de alta capacidade, necessitando de melhorias nas próximas gerações de comunicações wireless e ópticas. Redes neurais artificiais de valores reais (RVNNs) têm sido utilizadas para diversas aplicações, mas são subótimas para variáveis complexas. Redes neurais de valores complexos (CVNNs) foram propostas para melhorar a performance e velocidade de convergência, embora ainda sejam pouco exploradas. A rede neural de função de base radial em domínio complexo (C-RBF) destaca-se por sua baixa complexidade computacional, mas enfrenta problemas de convergência em sistemas dependentes de fase. Este projeto visa estender as C-RBFs rasas para múltiplas camadas, aumentando a capacidade de generalização sem aumentar significativamente a complexidade. A implementação da C-RBF profunda em Python resultou na aceitação de um artigo para apresentação no "19th International Symposium on Wireless Communication Systems".

METODOLOGIA, RESULTADOS E DISCUSSÃO:

Equalização de Canal

No contexto das telecomunicações, a transmissão de dados utiliza um canal físico, como cabo coaxial, fibra óptica ou ar (sem fio), para enviar sinais de um transmissor a um receptor. Durante a transmissão, o sinal pode sofrer distorções e interferências, como atenuação, ruído AWGN e dispersão. A equalização de canal é uma técnica usada para minimizar essas distorções, permitindo que o sinal chegue ao receptor o mais próximo possível do original. Existem diferentes tipos de

equalizadores, como o estático, que utiliza uma combinação linear de amostras do sinal recebido, e o adaptativo, que ajusta seus parâmetros dinamicamente para se adaptar às variações do canal.

A Figura 1 apresenta um esquema básico de equalização de canal, onde x_i representa os símbolos transmitidos, y_i são os símbolos após terem sido afetados pelos efeitos do canal e \hat{x}_i são os símbolos recuperados pelo equalizador.




Figura 1: Esquema simplificado de equalização de canal.

A C-RBF e PT-RBF profundas são comparadas usando duas arquiteturas de duas camadas. Foram realizadas 50 rodadas de simulação com 5000 dados de treinamento e 100.000 de teste. Cada iteração consistiu em 10.000 épocas de treinamento com fator de paciência de 1000 épocas (early stopping) e batch size de tamanho 100. Os parâmetros das arquiteturas, como passos adaptativos e número de neurônios em cada camada, são mostrados na Tabela 1.

CVNNs	η_w	η_b	η_γ	η_σ	Neurônios	oshape
C-RBF Profunda	0.01	0.01	0.03	0.01	25	25
C-RBF Profunda	0.01	0.01	0.03	0.01	25	25
PT-RBF Profunda	0.05	0.05	0.03	0.05	6	5
PT-RBF Profunda	0.05	0.05	0.03	0.05	5	1

Tabela 1: Parâmetros da C-RBF e PT-RBF profundas para o problema de equalização de canal.

Calculamos os valores médios de BER (Taxa de Erro de Bits) e MSE (Erro Quadrático Médio) para a C-RBF e a PT-RBF com duas camadas escondidas, conforme apresentado na Tabela 2.

CVNNs	$\overline{\text{BER}}$	$\overline{\text{MSE}}$
C-RBF Profunda	3.10×10^{-4}	1.40×10^{-3}
PT-RBF Profunda	7.21×10^{-4}	4.20×10^{-3}

Tabela 2: Resultados da C-RBF e PT-RBF profundas para o problema de equalização de canal.

Função de Valor Complexo Sintética

A definição da aproximação da função complexa sintética é dada por $Z = Z_1^2 + Z_2^2$, onde Z_1 e Z_2 são números complexos com módulo menor que 2,5.

As arquitetura de CVNNs utilizadas foram a C-RBF com duas camadas, ambas com 10 neurônios, e a PT-RBF Profunda com duas camadas, ambas com 6 neurônios. Para treinamento foram utilizadas 1000 amostras e para teste 2000 amostras. Os parâmetros das redes, otimizados por tentativa e erro, estão detalhados na Tabela 3.

CVNNs	η_w	η_b	η_γ	η_σ	Neurônios	oshape
C-RBF Profunda	0.01	0.01	0.03	0.01	10	10
C-RBF Profunda	0.01	0.01	0.03	0.01	10	10
PT-RBF Profunda	0.05	0.05	0.03	0.05	6	6
PT-RBF Profunda	0.05	0.05	0.03	0.05	6	6

Tabela 3: Parâmetros da C-RBF e PT-RBF profundas para a Função de Valor Complexo Sintética.

Foram conduzidas 50 simulações utilizando diferentes conjuntos de dados de treinamento para ambos os cenários. As redes foram treinadas ao longo de 5.000 épocas, utilizando uma estratégia de parada antecipada (early stopping) com fator de paciência de 1000 épocas, e um batch size de tamanho 10.

Os resultados obtidos das médias de RMSE, RMSE Absoluto, Fase RMSE são mostrados na Tabela 4.

CVNNs	$\overline{\text{RMSE}}$	$\overline{\text{RMSE}} \text{ Absoluto}$	$\overline{\text{Fase RMSE}}$
C-RBF Profunda	8.03×10^{-2}	6.17×10^{-2}	13.35°
PT-RBF Profunda	2.42×10^{-1}	1.86×10^{-1}	35.47°

Tabela 4: Resultados para as diferentes arquiteturas CVNNs para Aproximação Função de Valor Complexa.

Com isso, foi verificado que a C-RBF Profunda apresentou melhor êxito nos resultados, mostrando os menores valores médios de RMSE total, RMSE de ângulo e RMSE absoluto.

CONCLUSÕES:

As redes neurais no domínio complexo estão ganhando interesse, especialmente para dados complexos. A proposta de estender as redes de função de base radial (C-RBFs) para múltiplas camadas visa melhorar a capacidade de generalização mantendo baixa complexidade computacional. As C-RBFs rasas são viáveis para processamento adaptativo de sinais, apesar de limitações em sistemas dependentes de fase. Estender essas redes para múltiplas camadas pode beneficiar aplicações como canais wireless dinâmicos e imagens no domínio da frequência. O projeto busca avançar o conhecimento e criar uma base sólida para futuras pesquisas e aplicações práticas, com a C-RBF profunda mostrando potencial em testes de equalização de canal e funções de valor complexo.

BIBLIOGRAFIA

- G. Knieps, "Internet of things, big data and the economics of networked vehicles", *Telecommunications Policy*, vol. 43, pp. 171–181, Mar. 2019.
- T. P. Raptis, A. Passarella, and M. Conti, "Data management in industry 4.0: State of the art and open challenges", *IEEE Access*, vol. 7, pp. 97052–97093, July 2019.
- S. Barzegar, M. Ruiz, A. Sgambelluri, F. Cugini, A. Napoli, and L. Velasco, "Soft failure detection, localization, identification, and severity prediction by estimating QoT model input parameters", *IEEE Transactions on Network and Service Management*, vol. 18, pp. 2627–2640, Sept. 2021.
- A. Hirose, *Complex-valued neural networks*. Berlin, Germany: Springer, 2 ed., 2012.
- A. Hirose and S. Yoshida, "Generalization characteristics of complex-valued feedforward neural networks in relation to signal coherence", *IEEE Transactions on Neural Networks and Learning Systems*, vol. 23, pp. 541–551, Apr. 2012.
- K. S. Mayer, *Complex-valued neural networks and applications in telecommunications*. PhD thesis, State University of Campinas, Nov. 2022.

D. Loss, M. C. F. De Castro, P. R. G. Franco, and F. C. C. De Castro, "Phase transmittance RBF neural networks", *Electronics Letters*, vol. 43, pp. 882–884, Aug. 2007.

K. S. Mayer, C. Muller, J. A. Soares, F. C. C. De Castro, and D. S. Arantes, "Deep phase-transmittance RBF neural network for beamforming with multiple users", *IEEE Wireless Communications Letters*, vol. 11, pp. 1498–1502, July 2022.