

APLICAÇÃO DE REDES NEURAIS PARA RECUPERAÇÃO DO ESPECTRO DE FASE

LORENZZO VILELA DA SILVA¹; ISAAC CAMPELO VICTOR DE SOUZA²;
MADANA N'BANA³; MARCELO LEMOS ROSSI⁴

¹Universidade Federal de Pelotas – lezandrosw@gmail.com

²Universidade Federal de Pelotas – isaacvcampelo@gmail.com

³Universidade Federal de Pelotas – madananbana5@gmail.com

⁴Universidade Federal de Pelotas – marcelo.rossi@ufpel.edu.br

1. INTRODUÇÃO

As redes neurais têm sido amplamente adotadas em múltiplas áreas nos dias atuais, dada a sua capacidade de aprender representações complexas a partir de grandes volumes de dados. Modelos como o MLP (Perceptron Multicamadas) têm sido aplicados com sucesso em tarefas de classificação e regressão, mas, apesar de sua simplicidade, apresentam limitações em problemas mais complexos, como a recuperação de sinais modulados de rádio frequência (RF) (LeCun, Y. et al., 2015). Tais limitações são especialmente evidentes em tarefas que exigem a recuperação de espectro de fase, onde o custo computacional e a dificuldade de convergência de redes não convolucionais tornam a solução ineficiente.

Com a atual parceria com a ANATEL (Agência Nacional de Telecomunicações), começamos nossas pesquisas no campo da modulação de radiofrequência (RF), uma área crítica para o setor de telecomunicações. Durante o desenvolvimento de soluções para análise de sinais de RF, surgiu um desafio técnico: para realizar uma análise eficiente dos sinais, normalmente utilizamos a Transformada Rápida de Fourier (FFT), que gera dois espectros importantes - o espectro de amplitude e o espectro de fase. No entanto, a ANATEL fornece apenas o espectro de amplitude, que é de maior interesse prático, pois carrega a maior parte das informações do sinal (Allen & Mills, 2016). Por outro lado, o espectro de fase, essencial para a demodulação de sinais, está ausente, o que dificulta a realização de tarefas como a reconstrução ou decodificação do sinal original. No início deste estudo, exploramos a possibilidade de MLPs para a recuperação do espectro de fase a partir do espectro de amplitude.

Neste sentido, este trabalho busca estudar o comportamento de redes neurais MLP que avaliar a possibilidade da utilização delas na otimização a recuperação de fase de sinais FM (Frequência Modulada) a partir de seu espectro de amplitude, com o objetivo de melhorar a eficiência de métodos computacionais para sinais de radiofrequência (RF). A principal motivação é substituir abordagens tradicionais, como Gerchberg-Saxton, Hybrid Input-Output, e Difference Map, que requerem alto poder computacional e possuem altos custos de tempo de execução, por uma abordagem mais eficiente com redes neurais.

Além do mais, alguns testes realizados com estes algoritmos demonstraram que eles possuem a capacidade de recuperação de um espectro de fase que permite obtermos uma transformada inversa de Fourier com valores reais, porém os resultados obtidos não são únicos e também não são equivalente

a um sinal de FM e, dessa forma, estamos buscando mecanismos que permitam melhorar o resultado do processo para a condição dos sinais que estamos trabalhando.

Com isso foram realizados alguns testes que permitiram entendimento de como as MLP funcionam, para, em uma próxima etapa, achar alguma forma de utilizarmos de redes neurais no processo de recuperação do espectro de fase dos sinais de FM. A compreensão das redes neurais se deu pela aplicação delas em problemas clássicos de classificação, sendo algumas das observações apresentadas neste trabalho.

2. METODOLOGIA

Foi utilizada a plataforma Google Colab para a elaboração de códigos de MLP utilizando a biblioteca TensorFlow. Além do mais, foram utilizados alguns conjuntos de dados clássicos como os dígitos MNIST, Fashion MNIST e Cat Vs Dog.

Foram testadas algumas topologias redes neurais não convolucionais (MLPs) com o objetivo de entendermos o funcionamento delas. Iniciamos a jornada com as redes neurais utilizando as tarefas clássicas de reconhecimento de dígitos e classificação de imagens com o intuito de verificar sua aplicabilidade na tarefa de recuperação de fase de sinais FM. Os conjuntos de dados utilizados nos testes preliminares foram os seguintes:

1. **Reconhecimento de Dígitos (MNIST):** O modelo MLP foi treinado no conjunto de dados MNIST, que contém imagens de dígitos manuscritos em uma resolução de 28x28 pixels. O objetivo foi classificar as imagens corretamente em uma das 10 classes (dígitos de 0 a 9). A rede foi composta por uma camada Flatten seguida por uma camada densa com 128 neurônios e função de ativação ReLU, e uma camada final com 10 neurônios para as 10 classes. O treinamento foi realizado por 60 épocas, com uma taxa de acurácia razoável nos resultados, embora a rede não tenha mostrado desempenho ideal para tarefas de maior complexidade como a recuperação de sinais RF.
2. **Reconhecimento de Peças de Roupas (Fashion MNIST):** O modelo MLP também foi aplicado ao conjunto de dados Fashion MNIST, que contém imagens de roupas (como camisetas, calças, vestidos, etc.) em uma resolução de 28x28 pixels. O objetivo foi classificar cada imagem em uma das 10 categorias de roupas. O modelo foi estruturado de forma semelhante ao do MNIST, com camadas Flatten e Dense. O modelo foi treinado por 6 épocas, apresentando um desempenho moderado na tarefa de classificação, embora as redes MLP não fossem as mais indicadas para tarefas mais complexas, como a recuperação de fase de sinais RF.
3. **Classificação de Cães e Gatos (Cats vs Dogs):** Em seguida, testamos a rede MLP no conjunto de dados Cats vs Dogs, que consiste em imagens de cães e gatos. Cada imagem foi convertida para escala de cinza e

redimensionada para 150x150 pixels. O objetivo foi classificar cada imagem como "gato" ou "cachorro". O modelo foi novamente estruturado com camadas Flatten e Dense, com uma camada final sigmoide para a classificação binária. O treinamento foi realizado por 10 épocas. Embora o modelo tenha mostrado resultados razoáveis na diferenciação entre cães e gatos, o desempenho foi insuficiente quando a tarefa foi estendida para a recuperação de sinais RF, onde variabilidade de fase e outras complexidades não foram bem tratadas pela rede MLP.

3. RESULTADOS E DISCUSSÃO

Reconhecimento de Dígitos (MNIST): O modelo MLP aplicado ao conjunto de dados MNIST obteve um resultado com uma média de acerto de 97%. Este desempenho está dentro das expectativas para um modelo simples de rede neural totalmente conectada. O conjunto de dados MNIST, sendo relativamente simples e bem estruturado, foi eficaz para testar a capacidade do modelo de reconhecer padrões em imagens de dígitos manuscritos.

Apesar de o MLP ter se saído bem nesse caso, com boa precisão na classificação dos dígitos, esse modelo não se mostrou adequado para tarefas de maior complexidade, como a recuperação de fase de sinais FM, devido à sua limitação em capturar relações mais complexas, como a variabilidade de fase e os padrões presentes nos sinais RF.

Reconhecimento de Peças de Roupas (Fashion MNIST): Para o conjunto de dados Fashion MNIST, que apresenta imagens de peças de roupas, o modelo MLP obteve uma média de acerto de aproximadamente 80%. Embora tenha apresentado um bom desempenho para a classificação de roupas em 10 categorias distintas, o modelo não conseguiu lidar de forma tão eficiente com a variabilidade dos dados, especialmente nas imagens mais complexas. Isso demonstra a limitação de MLPs em tarefas de classificação de imagens que exigem uma compreensão mais profunda dos padrões visuais e características espaciais presentes nas imagens.

Essa média de acerto de 80% é aceitável para uma tarefa relativamente simples, mas, como já mencionado, o desempenho seria ainda mais limitado se a tarefa fosse mais complexa ou envolvesse sinais RF, que possuem uma estrutura muito diferente.

Classificação de Cães e Gatos (Cats vs Dogs): No caso da classificação de cães e gatos, o desempenho foi mais modesto, com uma média de acerto de 50%, o que é equivalente a uma taxa de aleatoriedade. Isso ocorre devido à dificuldade em classificar imagens de cães e gatos que são visualmente similares e podem ter variações substanciais em termos de cor, forma e outros parâmetros que não são tão facilmente capturados por redes MLP. Para tarefas como essa, uma rede convolucional seria uma abordagem mais robusta, pois ela consegue capturar melhor os padrões locais e características espaciais.

O baixo desempenho nessa tarefa também reforçou a ideia de que as redes MLP não são adequadas para classificação de imagens mais complexas,

como a classificação de animais ou recuperação de sinais RF, onde há mais complexidade nas variações dos dados.

4. CONCLUSÕES

Os testes realizados demonstraram que, embora os modelos MLP sejam capazes de obter resultados satisfatórios para tarefas simples de classificação de imagens como o reconhecimento de dígitos e a classificação de roupas, eles não são adequados para recuperação de fase de sinais FM, que exigem um modelo mais robusto. A média de acerto nos testes de reconhecimento de dígitos foi de 97%, nas peças de roupas foi de 80%, e na classificação de cães e gatos foi de 50%. Em função desses resultados, foi decidido que redes convolucionais (CNNs) seriam mais apropriadas para a tarefa de recuperação de fase de sinais FM, uma vez que oferecem melhor desempenho em tarefas que envolvem dados com variações espaciais e de fase.

Esses resultados são a base para o entendimento de como redes neurais não convolucionais podem ser eficazes em tarefas de classificação de imagens simples, mas limitadas em contextos mais complexos como o processamento de sinais RF. A partir disso, a pesquisa seguirá com a aplicação de CNNs para melhorar a recuperação de fase de sinais FM e explorar soluções mais rápidas e eficientes.

5. REFERÊNCIAS BIBLIOGRÁFICAS

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, London, v.521, n.7553, p.436-444, 2015.

SHANNON, R.V.; ZENG, F.G.; KAMATH, V.; WYGONSKI, J.; EKELID, M. Speech recognition with primarily temporal cues. *Science*, Washington, v.270, n.5234, p.303-304, 1995.