

RESUMO APRESENTAÇÃO ORAL PADRÃO - CENTRO DE TECNOLOGIA
(CT)/ENGENHARIA ELÉTRICA

**PROCESSAMENTO DE SINAIS E APRENDIZADO DE MÁQUINAS PARA
COMUNICAÇÕES**

Gabriel De Queiroz Antunes (g.queirozantunes@poli.ufrj.br)

Marcele Oliveira Kuhfuss De Mendonça (marcele.kuhfuss@smt.ufrj.br)

Paulo Sergio Ramirez Diniz (diniz@smt.ufrj.br)

Métodos de aprendizagem de máquina ou “machine learning” (ML) têm obtido sucesso em diversos campos, desde medicina a veículos automatizados e recentemente também no campo da comunicação sem fio. No meio de comunicação sem fio, o sistema “orthogonal frequency-division multiplexing” (OFDM) é amplamente utilizado e foi escolhido como sistema de estudo. O sistema OFDM possui vantagens como mitigar o efeito de interferência entre símbolos e entre blocos de transmissão. Estes tipos de interferência são causados pelo canal, que é o meio entre transmissor e receptor (PRASAD, 2014).

O objetivo deste trabalho é estudar métodos ML para substituir blocos básicos de transmissão e recepção do sistema OFDM. Utilizaremos “deep learning” seguindo o princípio de sistema OFDM poder ser subdividido em blocos mais simples de processamento (GOODFELLOW et al., 2016).

Um dos blocos de interesse no sistema OFDM é o estimador do canal. Através da estimativa do canal é possível amenizar o efeito do canal no sinal transmitido. Visando a substituir o estimador de canal, começamos estudando o tipo mais básico de redes neurais, chamadas “fully connected neural networks” (FCNN). Inicialmente trabalhamos com “dataset” composto por imagens simples (dígitos de 0 a 10). Investigamos os efeitos da mudança de parâmetros principais da rede tais como número de camadas, de neurônios por camada e tamanho dos “mini-batches”. Observamos, principalmente, que utilizar muitos neurônios e camadas acaba aumentando o risco de “overfitting”, ou seja, de o modelo ser complexo demais para o escasso conjunto de dados. Quando aumentamos o “mini-batch”, a rede demora mais para convergir, o que confirma que a escolha de “mini-batches” grandes dificulta a utilização de gradientes para achar o mínimo global (BEYLEVELD et al., 2019). Tais parâmetros, portanto, devem ser escolhidos com cuidado. Esse tipo de rede pode ser utilizado para obter uma melhor estimativa do canal, se pelo menos um conjunto de estimativas do canal estiver disponível para treinamento.

Depois começamos a trabalhar com redes neurais convolucionais (CNN) pois estas podem ser úteis para aproveitar algum tipo de correlação entre elementos vizinhos do sinal. Continuamos trabalhando com os mesmos “datasets”, mas agora verificando o efeito das variações dos filtros utilizados pela CNN tais como quantidade de filtros, tamanho do filtro e no passo das camadas convolucionais da rede. Nos experimentos, o parâmetro que mais chamou atenção foi o passo, que podemos usar para economizar processamento da máquina, mas fazendo passos maiores que 2 tivemos uma piora significativa no modelo. Isso pode ser aproveitado também para o estimador de canal se houver correlação entre elementos vizinhos do sinal em análise. Os próximos passos consistem em estudar redes “generative adversarial networks” (GAN) que poderão auxiliar na geração do conjunto de treino, composto por amostras dos coeficientes do canal, pois na prática pode ser que não tenha muitas amostras do canal para o projeto, e começar a experimentar com sinais OFDM.

REFERÊNCIAS BIBLIOGRÁFICAS

BEYLEVELD, G. et al. A Visual, Interactive Guide to Artificial Intelligence. Pearson's Addison-Wesley imprint, 2019.

GOODFELLOW, I. et al. Deep Learning. MIT Press, London, England, 2016.

PRASAD, R, OFDM for Wireless Communications Systems. Artech House Publishers, Boston, 2004.