

**Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**

---

# Extensão Intervalar da Camada de Convolução de Redes Neurais Convolucionais

Lucas Mendes Tortelli<sup>1</sup>

Ciência da Computação, CDTEc, UFPel, Pelotas, RS

Aline Brum Loreto<sup>2</sup>

Campus Cachoeira do Sul, UFSM, Cachoeira do Sul, RS

Marilton Sanchotene de Aguiar<sup>3</sup>

Programa de Pós-Graduação em Computação, UFPel, Pelotas, RS

## 1 Introdução

Redes neurais convolucionais (*Convolutional Neural Network-CNN*), pertencem à classe de algoritmos de aprendizado de máquina capazes de reconhecer padrões e formas bidimensionais [1].

Sistemas computacionais são caracterizados pela imprecisão em cálculos, uma vez que valores numéricos são aproximados para um subconjunto finito dos números reais. Utiliza-se a Matemática Intervalar [3] para automatizar o cálculo do erro computacional com limites confiáveis. Representando um valor  $x$  em um intervalo  $X$  em que  $\underline{x} \leq x \leq \bar{x}$ .

Neste trabalho, é proposta a extensão intervalar da camada de convolução de uma CNN, a fim de diminuir os erros numéricos gerados.

## 2 Metodologia

As CNNs são inspiradas pelos campos receptivos, assim a extração de informação é realizada de forma implícita. A extração de características tem de ocorrer de forma automática, desta maneira a variabilidade e a riqueza dos dados não será perdida [2].

A estrutura de CNN utilizada neste trabalho foi conforme apresentado na Figura 1, em que é composta por uma camada de entrada, que receberá a imagem a ser analisada. Posteriormente passará por uma sequência de camadas de convolução e de *pooling*, sendo essa responsável pela extração dos mapas de características. Por último a *Multi Layer Perceptron* (MLP) terá o resultado da última camada de convolução para o treinamento.

A camada de convolução é composta por uma ou mais entradas (mapas de características) e filtros que serão aplicados sobre a entrada. Os resultados obtidos consistem

---

<sup>1</sup>lmtortelli@inf.ufpel.edu.br

<sup>2</sup>aline.loreto@gmail.com

<sup>3</sup>marilton@inf.ufpel.edu.br

2




Figura 1: Arquitetura de uma Rede Neural Convolutiva [4]

nas informações que melhor abstraem a entrada, desta maneira somente as características relevantes são propagadas.




Figura 2: Exemplo de execução de uma camada de convolução. [4]

As operações realizadas na camada de convolução são suscetíveis a geração de erros por conta do sistema de ponto flutuante, que não há garantias de exatidão. Desta maneira aplicando a extensão intervalar sobre cada camada de convolução garantirá maior exatidão numérica, pois as soluções terão controle automatizado sobre o cálculo do erro.

### 3 Conclusão

A utilização da matemática intervalar na camada de convolução, fornece medidas de controle para o erro numérico gerado, controlando a propagação deste erro para as camadas subsequentes através dos mapas de características. Assim se obtém uma solução com maior exatidão para realizar o treinamento na MLP.

### Agradecimentos

Os autores agradecem ao CNPq (SETEC/MEC No17/2014,Proc.468487/2014-0).

### Referências

- [1] S. Haykin. Redes Neurais: Princípio e Práticas, Bookman, São Paulo,2001.
- [2] Y. LeCun, L. Bottou, Y. Bengio and P. Haffner: *Gradient-Based Learning Applied to Document Recognition*, Proceedings of the IEEE, 86(11):2278-2324,1998.
- [3] R. E. Moore. Methods and applications of interval analysis, SIAM,Philadelphia ,1979.
- [4] LeNet, DeepLearning. Disponível em [goo.gl/a4Ph1](http://goo.gl/a4Ph1) . Acesso em: 20 março. 2016.