

UMA PROPOSTA DE EXTENSÃO INTERVALAR PARA REDES NEURAIS CONVOLUCIONAIS E ANÁLISE DA SUA APLICAÇÃO NO PROCESSAMENTO DE IMAGENS INTERVALARES

IVANA P. I. STEIM¹; LUCAS M. TORTELLI¹; MARILTON S. AGUIAR¹; ALINE B. LORETO²;

¹UFPel – {patricia.steim, lmtortelli, marilton} @ inf.ufpel.edu.br

²UFSM – alineloreto@gmail.com

1. INTRODUÇÃO

Um dos grandes ramos da computação está relacionado ao processamento digital de imagens. Este consiste em técnicas para tratabilidade de imagens, desde a captação até a transformação. As operações presentes nas etapas de transformação da imagem visam melhorar a qualidade visual de certos aspectos estruturais, facilitando a percepção humana e interpretação automática por meio de máquina, visando aperfeiçoar qualquer processamento que necessite de informações nítidas (PEDRINI; SCHWARTZ, 2008).

Segundo RUSSEL; NORVIG (2013), Redes Neurais Artificiais, consistem em uma estrutura de aprendizado de máquina. Estas redes são especificadas a partir de um conjunto de neurônios de entrada, que recebem dados, valores numéricos ou mesmo imagens como é o caso das Redes Neurais Convolucionais (do inglês, *Convolutional Neural Network* – CNN). Essas redes contêm adicionalmente camadas que são bancos de filtros de processamento de imagens que podem ser configurados por exemplo, dependendo da aplicação, como detectores de bordas (LECUN et. al., 2015). As informações a serem processadas são repassadas às camadas de funções que estimulam ou não estes neurônios. No contexto de processamento de imagens, as CNNs são uma classe de algoritmos de aprendizagem de máquina, capazes de aprender com as informações presentes na imagem através de convoluções realizadas.

Sistemas computacionais representam os valores numéricos de forma discreta, não sendo precisos em exatidão ao valor real em seus cálculos numéricos, pois a máquina realiza suas operações no sistema de ponto flutuante, que consiste em um subconjunto dos números reais. Com isto, erros podem ser acrescentados durante a execução de processos, seja por arredondamento ou por truncamento, causando problemas numéricos no uso de imagens e redes neurais. Para suprimir este problema utiliza-se a aritmética intervalar.

A matemática intervalar proposta por MOORE (1966) busca automatizar o cálculo do erro computacional científico com limites confiáveis. Nesta forma de representação numérica os valores pontuais não são aproximados, o que ocorre é a representação do valor real x em um intervalo X que o contém. Os erros originados para tratamento dos valores são tratados pela aritmética intervalar e pelos arredondamentos direcionados. O tamanho do intervalo é utilizado como medida de qualidade por RATSCHEK; ROKNE (1988).

Este trabalho tem como finalidade a utilização de uma Rede Neural por Convolução Intervalar, com imagens intervalares conforme proposta de LYRA (2003), visando controlar a propagação do erro numérico gerado durante todo o processo e obter resultados com maior exatidão.

2. METODOLOGIA

Uma imagem digital intervalar é uma matriz A de ordem $m \times n$, que representa uma imagem especialmente discretizada e digitalizada em forma intervalar, onde cada tom de cinza torna-se um intervalo cuja diferença entre limite inferior e superior é um valor aceitável em relação ao lugar no espaço. Cada a_{ij} em A é denominado por pixel intervalar, que contém o intervalo que define a variação Γ da intensidade luminosa deste pixel (LYRA et. al., 2003). São considerados vizinhos N8 do pixel intervalar os pixels com uma unidade de distância deste, sendo 4 vizinhos de borda e outros 4 vizinhos de diagonal.

A matemática intervalar é uma teoria que pode proporcionar uma solução ao controle rigoroso e automático de erros presentes em operações numéricas computacionais e no tratamento e modelagem da incerteza na computação, como na transformação de valores contínuos a discretos para representar uma imagem. Um intervalo é o subconjunto $\{x \in \mathfrak{R} / \underline{x} \leq x \leq \bar{x}\}$ não vazio de números reais fechado e limitado, onde o intervalo real é denotado por $X = [\underline{x}, \bar{x}]$, sendo \underline{x} é o limite inferior e \bar{x} é o limite superior do intervalo. IR é o conjunto de todos os intervalos reais, ou seja, $IR = \{[\underline{x}, \bar{x}] / \underline{x}, \bar{x} \in \mathfrak{R}, \underline{x} \leq \bar{x}\}$

Segundo FERSON et. al. (2002), historicamente o primeiro método para computar o intervalo solução é o método chamado de extensão intervalar. Nele, repete-se a computação formando o programa passo-a-passo, substituindo cada operação elementar de números reais pela correspondente operação da aritmética intervalar.

Redes Neurais por Convolução são uma classe de algoritmos de aprendizado, que são capazes de aperfeiçoar com eficácia o mapeamento de imagens e sinais, através de operações sobre a entrada. Estas redes são compostas por camadas, onde é realizado o processamento sobre a entrada para a extração das características da mesma. A camada de Convolução, que consiste na principal operação, realiza sua execução visando extrair informações da entrada, descartando todos os ruídos, formas e cores discrepantes (BASTIEN et. al., 2012). Isto visa aumentar a representatividade da imagem a cada passo.

Como pode ser notado, a grande quantidade de operações presente em uma Rede Neural por Convolução a torna mais propícia a conter erros numéricos. E como com esta estrutura o aprendizado é feito de forma iterativa e com diversas operações sobre a entrada, ocorre uma propagação do erro caso não seja feito um controle ou utilização de métodos numéricos que controlem esta inexatidão.

Desta maneira, utilizam-se os princípios da aritmética intervalar com redes CNNs para a criação de uma estrutura que contenha a representatividade de tal classe de algoritmo, sem perder a precisão numérica nos passos intermediários.

A Equação (1) apresenta a operação de convolução intervalar sobre uma entrada real.

$$X_{ij}^l = \sum_a^{m-1} \sum_b^{n-1} W_{ab} I_{(i+a)(j+b)}^{l-1} \quad (1)$$

onde W é o *kernel* de convolução, I na imagem real de entrada, X o mapa de características intervalares gerado na operação de convolução, a e b são as dimensões espaciais do *feature map*, i e j são as dimensões da entrada I .

Apesar da estrutura da rede estar seguindo os princípios da aritmética intervalar, a entrada a qual esta é submetida não pertence ao tipo intervalar. Neste trabalho as imagens intervalares são geradas calculando as distâncias entre o pixel e sua vizinhança de 8, e criando o intervalo do pixel com o menor diâmetro encontrado, excetuando-se diâmetros nulos. Alteramos o valor real original do pixel pela

diminuição e soma deste valor, formando os valores inferior e superior do intervalo de tons de cinza do referido pixel intervalar LYRA (2003). Sendo \mathfrak{I} uma imagem intervalar, tem-se a seguinte reformulação da camada de convolução, para abrigar completamente operações, sobre entradas intervalares.

$$X_{ij}^l = \sum_a^{m-1} \sum_b^{n-1} W_{ab} \mathfrak{I}_{(i+a)(j+b)}^{l-1} \quad (2)$$

As demais camadas presentes na rede neural por convolução intervalar não foram alteradas, pois estas não eram dependentes do tipo da entrada.

3. RESULTADOS E DISCUSSÃO

A fim de analisar os resultados obtidos utilizando uma rede CNN Intervalar (TORTELLI, 2016) com Imagens Intervalares (LYRA et. al., 2003), como definido através da Equação (2). Para isto foram utilizados um total de 559 imagens no formato PNG, monocromáticas e com resolução espacial de 66x72, aplicando-se vizinhança de 8 para a geração de cada imagem de forma intervalar.

As imagens estão agrupadas em três classes distintas, sendo elas: Carros, Prédios e Mão. Nesta execução utilizou-se as mesmas definições apresentadas em trabalhos relacionados, que pode ser observada em:

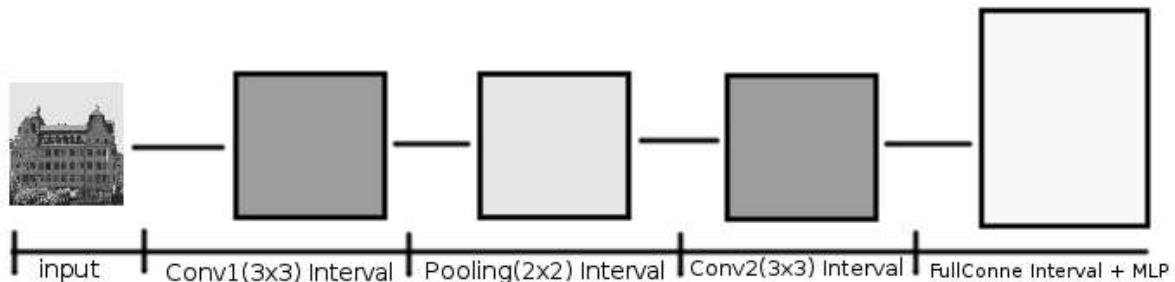


Figura 1: Estrutura da Rede CNN Intervalar proposta

Todas as implementações foram realizadas na linguagem de programação Python, conjuntamente com a biblioteca IntPy (BARRETO; CAMPOS, 2008) para introduzir o tipo intervalar.

A Tabela 1 apresenta o erro médio absoluto aplicado sobre todos *feature maps* gerados no término de cada camada de convolução. Nota-se, através das análises, que o erro fora controlado de uma convolução para a outra, e o intervalo tornou-se menor indicando sua melhora.

Tabela 1: Erro médio absoluto e desvio padrão após as operações de convolução

	Erro	Desvio Padrão	
		Real x Intervalo	Intervalo
Convolução 1	$1.69 \times 10^{-10} < 6.985302565$	2.80604×10^{-10}	16.08147843
Convolução 2	$1.37 \times 10^{-10} < 4.469382159$	2.69923×10^{-10}	9.939810112

Os valores altamente valorados apresentados na Tabela 1 estão diretamente ligados ao método de geração de imagens intervalares, e como ele utiliza seus vizinhos para a criação do pixel intervalar. Desta maneira, os intervalos gerados contêm diâmetro elevado, indicando a variação de luminância do pixel intervalar.

4. CONCLUSÕES

Com o uso da matemática intervalar, desde a inserção com imagens intervalares ao processamento das camadas de convolução com filtro intervalar da rede neural utilizada, pode-se notar que a informação numérica real original da imagem foi representada de forma íntegra, visto que o subconjunto contínuo do intervalo contém o valor da luminosidade real original.

Foi admitido um alto valor no intervalo para adequação a visualização das imagens intervalares, utilizando-se seus valores mínimos e máximos de intervalo, de forma a percepção ao olho humano dos tons de luminosidade nos pixels, sendo o valor original encapsulado no intervalo. A diferença de luminosidade entre pixels vizinhos afetava diretamente no tamanho do diâmetro do novo pixel intervalar gerado, na criação da nova imagem, intervalar.

Foi realizado o cálculo do erro médio absoluto e diâmetro médio dos intervalos, considerando todas as imagens processadas e ficou demonstrada a importância da aritmética intervalar quando se procura maior exatidão em cálculos numéricos, quando observou-se que o tamanho do erro diminuiu na passagem da informação pelas camadas de convolução, bem como o tamanho médio dos intervalos.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- BARRETO, R M.; CAMPOS, M.A. IntPy: Um Framework Intervalar em Python In: **VIII Encontro Regional de Matemática Aplicada e Computacional – R3** (ERMAC 2008 – R3), 2008, Natal-RN
- BASTIEN, F., LAMBLIN, P., PASCANU, R., BERGSTRA, J., GOODFELLOW, I., BERGERON, A., BOUCHARD, N., WARDE, D., BENGIO, Y., Theano: new features and speed improvements. In: **PROC. OF NIPS DEEP LEARNING WORKSHOP**, 2012.
- FERSON, S.I, GINZBURG, L., KREINOVICH, V. Absolute bounds on the mean of sum, product, etc.: A probabilistic extension of interval arithmetic, In: **SIAM WORKSHOP ON VALIDATED COMPUTING**, Toronto, 2002.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, New York, v. 521, n. 14539, p. 436 – 444, 2015.
- LYRA, A. **Uma fundamentação matemática para o processamento de imagens digitais intervalares**. 2003. 183f. Tese (Doutorado em Ciências) – Curso de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Norte.
- LYRA, A., BEDREGAL, R. C., DÓRIA NETO, A. D, BEDREGAL, B. R. C. The Interval Digital Images Processing, In: **PROCEEDINGS OF THE 5TH WSEAS INTERNATIONAL CONFERENCE ON MATHEMATICAL METHODS AND COMPUTATIONAL TECHNIQUES IN ELECTRICAL ENGINEERING**, Athens, 2003. p.1–5.
- MOORE, R. E. **Interval Analysis**. Englewood Cliffs: Prentice Hall, 1966.
- PEDRINI, H., SCHWARTZ, W. R., **Análise de Imagens Digitais: Princípio, Algoritmos e Aplicações**, Thomson, São Paulo, p.497, 2008.
- RATSCHEK, H., ROKNE, J. **New Computer Methods for Global Optimization**. Horwood Publishing Limited, 1988.
- RUSSEL, S., NORVIG, P.; **Inteligência Artificial**, 3^a Ed,Campus, Elsevier, Rio de Janeiro, p. 990 ,2013.
- TORTELLI, Lucas Mendes. **Extensão intervalar aplicado em Redes neurais por convolução**. 2016. Monografia (Bacharelado em Ciências da Computação) - Centro de Desenvolvimento Tecnológico da Universidade Federal de Pelotas.