

Identificação de Câncer em Exames por Imagens de Ultrassom Utilizando Redes Neurais Artificiais

Lidiane Silva Oliveira¹, Ricardo Costa P. Santos²

^{1 2} Instituto de Informática - Instituto Federal de Educação, Ciência e Tecnologia
do Sudeste de Minas Gerais (IFSudesteMG)

Juiz de Fora - MG - Brasil

{lidianesoliveira20@gmail.com, ricardo.cpsantos@gmail.com}

Abstract. *This work intends to continue following the work to aid the diagnosis of cancer through imaging exams, using the classification task supervised through the FeedForward Artificial Neural Networks (RNA) and the image descriptors. Cancer has grown a lot over the years, just as technology has been growing, so here they will be linked to each other, mainly to help medicine. We use free software to help the faster diagnosis of ultrasound cancer. . An artificial neural network has been developed for pattern recognition in image descriptors that are extracted from nodule-containing ultrasound. From the application of the network, it is possible to observe results superior to 70% of correctness in the nodules classification with the tested network configurations. By adding the shape and location descriptors to the training set, it was observed that the result was even better, reaching 76% of nodule classification accuracy. This indicates that image descriptors provide a good description of the problem for classifying nodules as malignant or benign.*

Resumo. *Este trabalho pretende dar continuidade na sequência de trabalhos de auxílio á diagnósticos de câncer através de exames de imagens, utilizando a tarefa de classificação supervisionada através das Redes Neurais Artificiais (RNA) FeedForward e dos descritores de imagens. O câncer tem crescido muito com o passar dos anos, assim como a tecnologia vem crescendo, então aqui estarão ligados um ao outro, com objetivo auxiliar principalmente a medicina. Utilizamos softwares gratuitos para auxiliar o diagnóstico mais rápido de câncer em ultrassom. . Foi desenvolvida uma rede neural artificial para reconhecimento de padrões em descritores de imagens que são extraídos de ultrassom que contém nódulos. A partir da aplicação da rede, podem-se observar resultados superiores a 70% de acerto na classificação dos nódulos com as configurações de rede testadas. Ao adicionar os descritores de forma e localização ao conjunto de treinamento, observou-se que o resultado foi ainda melhor, alcançando 76% de acerto na classificação dos nódulos. Isso indica que os descritores de imagem apresentam uma boa descrição do problema para classificação de nódulos como maligno ou benigno.*

1. Introdução

O Câncer é o nome dado a um conjunto de mais de 100 doenças que têm em comum o crescimento desordenado (**maligno**) de células que invadem os tecidos e órgãos. Existem diversos tipos de câncer, sendo que o mesmo pode se desenvolver em qualquer órgão ou tecido, como, por exemplo, o pulmão, o cólon, a mama, a pele, os ossos ou os tecidos neurais (MINHA VIDA, 2019).

Na medicina, a **ultrassonografia** ou ecografia, é um método de exame de imagem que utiliza ondas ultrassônicas que, ao atravessarem os tecidos dos órgãos estudados, retornam em forma de ecos, fornecendo imagens instantâneas durante o procedimento. **Ultrassom** é um som cujas ondas sonoras possuem frequências acima do limite audível para o ser humano, ou seja, acima de 20.000 Hz. Para fins de obtenção de imagens (ultrassonografia), a frequência varia entre 1 e 10 MHz (Figura 1):




Figura 1. Ultrassonografia

A capacidade de estabelecer um diagnóstico clínico preciso, analisar e interpretar imagens para facilitar tomada de decisão, e finalmente, ajudar prever o tratamento de várias doenças, com bases informações derivadas do exame de ultrassonografia é o desafio proposto por esse trabalho.

Para tanto, foi realizada uma revisão sistemática, no site do Periódicos da Capes sobre Redes Neurais Artificiais (RNAs), com o objetivo de entender o funcionamento e como poderia ser usada esse trabalho.

2.Revisão Sistemática

Primeiramente foi realizada uma pesquisa por artigos científicos nas principais bases acadêmicas. As fontes da busca foram: Capes, Google Acadêmico, e em sites americanos. Foram procurados artigos escritos em Português e Inglês, sendo grande parte em inglês.

Utilizou-se a string de busca: (tumor OR cancer) AND (ressonância OR tomografia OR ultrassom OR resonance OR tomography OR ultrasound) AND image AND ("neural network" OR "rede neural").

Foram encontrados 4.663 artigos. Após a leitura de títulos e resumos detectou-se que 4.648 desses artigos não eram de interesse central para o trabalho, pois eram focados principalmente em aspectos da medicina.

Fleck (2016) analisa métodos uma abordagem transversal, descritiva, analítica, quantitativa, com ênfase em diagnóstico, aprovado pelo Comitê de Ética e Conselho de Pesquisa.

Uma rede neural híbrida baseada nos mapas de Kohone, auto-organizáveis e rede de perceptron multi camada (MLP) foram utilizados, e esse modelo foi escolhido por ser uma rede razoavelmente pequena e, como resultado, aprende mais rápido e alcança uma boa generalização com um conjunto de dados de treinamento de tamanho razoavelmente pequeno. O conjunto de treinamento consistiu em imagens de pacientes submetidos colposcopia, e janeiro de 2009 a maio de 2010 de um serviço de ginecologia da cidade de Criciúma (Santa Catarina, Brasil). Uma amostra de conveniência foi estimada combinando 179 imagens diretamente no formato JPEG digital (negando assim a necessidade de digitalizar as imagens) e autorizadas por consentimento informado imagens originais. A base de dados de imagens (n=170) foi subdividido em 48 imagens para treinamento, 58 imagens para testes e 64 imagens para validação, proporções sugeridas em estudos anteriores. O treinamento da rede neural foi realizado após os dados coleção e foi dividido em duas partes. Primeiro, as imagens foram processados sem filtro, resultando em 66 ensaios, com uma taxa de precisão de 65%. Na segunda etapa, cada imagem foi processada pelo usuário com aprimoramento de contraste e então a distância euclidiana de cada imagem foi encontrada.

A etapa após o processamento é dividida em treinamento, teste e validação. Nesta fase, foi usado o aplicativo desenvolvido pelo Grupo de Pesquisa em Computação Inteligência Aplicada e pelo Grupo de Pesquisa em Tecnologia da Informação e Comunicação em Saúde da Universidade

Em um segundo caso, segundo Yamashita (2008), para treinar a rede neural, é preciso selecionar imagens pré-operatórias de RM da cabeça com tumores cerebrais supratentorial dos dados de imagem do nosso hospital base. Os critérios de inclusão foram os seguintes: 1) novo diagnóstico de tumor cerebral supratentorial em um hospital entre janeiro de 1996 e Janeiro de 2006; 2) diagnóstico histológico; e 3) disponibilidade de um completo conjunto de imagens pré-contraste ponderadas em T1 (T1WIs), imagens ponderadas em T2 (T2WIs) e T1WIs pós-contraste. Casos com tumores recorrentes foram excluídos. Categorias de tumor cerebral encontradas em menos de 11 casos também foram excluídos.

Havia 126 tumores cerebrais de 126 pacientes (61 homens e 65 mulheres, faixa etária de 1 a 85 anos; idade média de 46,8 anos) que no total, 58 pacientes tinham gliomas de alto grau, 37 tinham gliomas de baixo grau, 19 tinham tumores cerebrais metaestáticos e 12 tinham linfomas malignos.

Azimi (2014) numa breve introdução à metodologia da RNA envolve três etapas básicas, a saber: coleta, divisão e redução de dados. A coleta de dados é o processo de seleções variáveis de entrada e saída de acordo com os parâmetros definidos pela população do estudo. A divisão é o exame da normalidade dos dados, a fim de para modificar ou excluir os valores que são obviamente incongruente. Redução é o processo da RNA.

Em trabalho desenvolvido por Milligan(2001), as imagens funcionais foram formadas em 6 indivíduos saudáveis (3 homens, 3 mulheres, faixa etária de 20 a 37 anos) em um sistema de 1,5 T (SignaTM, General Electric, Milwaukee) usando a sequência de imagem cito-planaradicional (EPI) em cinco indivíduos, com cinco fatias . Foram obtidas 100 imagens (TR / TE = 3000/60 ms) com cinco períodos de descanso e cinco períodos de estimulação fotográfica começando com o repouso. Os períodos de estimulação e descanso compreenderam 10 repetições cada, isto é, 30 s. Em um sujeito, oito fatias com 64 imagens (TR / TE = 4000/66 ms) foram obtidas começando com um período de descanso com duração de 10 repetições (ou seja, 40 s), seguidas de três períodos de estímulo alternativo com os três períodos de descanso compreendendo nove repetições, ou seja, 36. A resolução foi $3 \times 3 \times 4$ mm.

Zhang(2009) selecionaram quatro tipos de imagens de RM consideradas mais informativas em relação ao diagnóstico de doença hepática focal. Os resultados iniciais mostraram que o LiverANN poderia classificar 50 casos do conjunto de dados de treinamento e 30 casos de teste nos cinco tipos de lesões focais no fígado; a precisão do treinamento no primeiro conjunto foi de 100%, enquanto a precisão do teste no último conjunto foi ótima de 93,3% (28/30). A diferença entre os resultados obtidos para os 30 casos de teste quando avaliados por um radiologista experiente e os resultados obtidos quando o LiverANN foi empregado. O LiverANN classificou erroneamente dois CHCs como metástases.

Em Magma (2004), um sistema de apoio à decisão clínica é uma ferramenta para melhorar a qualidade da decisão clínica, sendo definido como um sistema de conhecimento ativo que gera conselhos específicos para cada novo caso. Ele integra três características principais: conhecimento médico que resolve os casos da doença dados do paciente com informações biomédicas específicas de cada paciente e aconselhamento específico para cada caso com base no conhecimento médico e nos dados do paciente.

Foi criada uma base de dados com um conjunto de resultados de ressonância magnética de 430 tumores de tecidos moles (62% benignos, 38% malignos) provenientes de cinco centros hospitalares europeus diferentes, com o objetivo de desenvolver um classificador automático benigno / maligno de STT usando um conjunto de técnicas de reconhecimento de padrões.

3. Descritores de Textura

Classificar padrões em imagens é um procedimento utilizado em diversas áreas, como medicina, indústria, agricultura e outras. Existem várias formas de classificar imagens, uma delas é utilizando descritores de textura. Desenvolvidos por Haralick(1973), que considera qualitativamente a classificação de padrões em imagens.

Segundo Pedrini e Schwartz (2008), uma das formas mais complexas para se analisar uma imagem, está na obtenção de características suficientes que possam servir para uma correta classificação, seguindo a tarefa de reconhecimento de padrões. Quando comparado às características usadas na interpretação humana, observa-se que a textura é uma das características mais relevantes pelo sistema visual humano, pois a mesma consegue descrever informações sobre a distribuição espacial, variação de luminosidade, arranjo estrutural das superfícies e relações entre regiões vizinhas.

De acordo com essa definição, pode-se dizer que as informações texturais podem ser consideradas adequadas para análise de imagens. Haralick, em seu estudo, definiu quatorze medidas estatísticas, a serem calculadas a partir das matrizes de co-ocorrência (Haralick *et al.*, 1973).

Na Figura 2, que tem como proposta a exemplificação da geração da matriz de co-ocorrência, ao lado de cada matriz intermediária calculamos a matriz de co-ocorrência. Simbolizamos uma imagem como uma matriz de tons de cinza e apresentamos o cálculo da matriz intermediária para a distância de 1 (um) e 2 (dois) pixels, com variação do ângulo em 0° e 45°. Após o cálculo da matriz intermediária é calculada a matriz de co-ocorrência. Os valores da matriz de co-ocorrência, representa a probabilidade de determinado valor de cinza ocorrer na posição indicada. Assim sendo no total de ocorrências da matriz intermediária cada novo valor da matriz será ele mesmo sobre n (Figura 2):

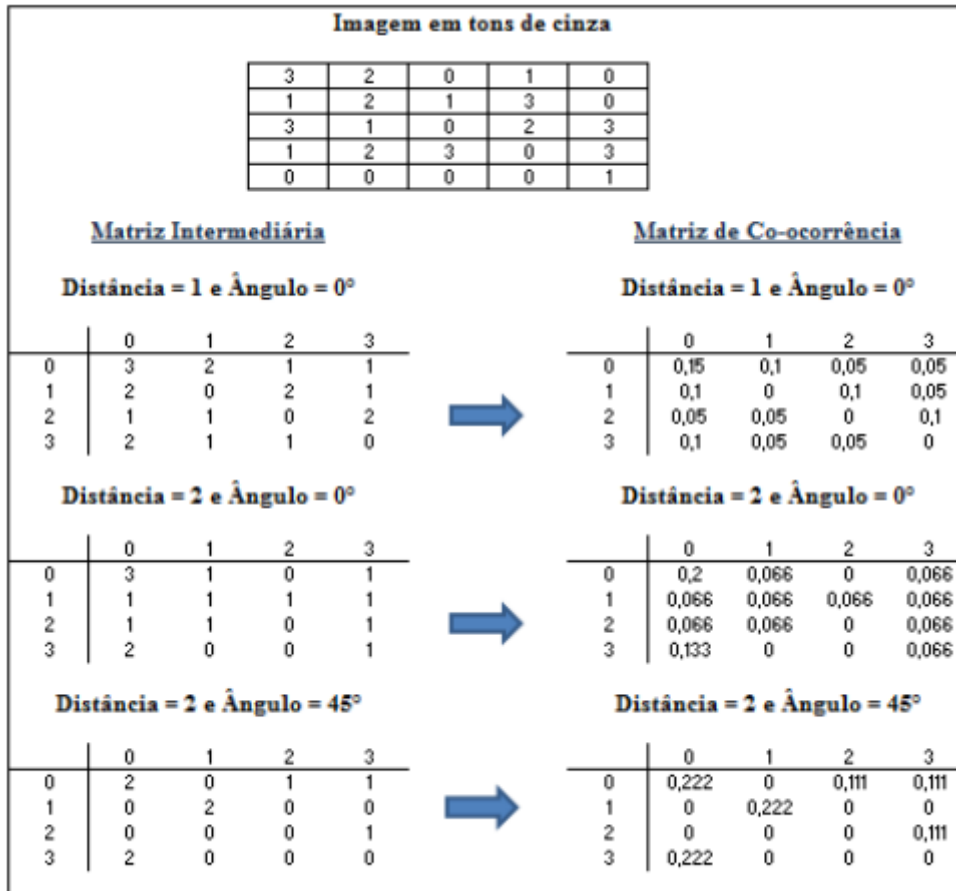


Figura 2. Exemplo da Matriz Intermediária e da Matriz de Co-ocorrência.

São seis os descritores de imagem mais relevantes, e que serão utilizados no presente trabalho:

- Segundo Momento Angular: também conhecido como energia, expressa a uniformidade de uma textura.

$$\sum_{i=0}^{Hg} \sum_{j=0}^{Hg} p^{2i.j} \quad (1)$$

- Entropia: expressa a desordem contida na textura.

$$-\sum_{i=0}^{Hg} \sum_{j=0}^{Hg} p_{i.j} \log(p_{i.j}) \quad (2)$$

- Contraste: caracteriza-se pela diferença entre os tons de cinza.

$$\sum_{i=0}^{Hg} \sum_{j=0}^{Hg} (i - j)^2 p_{i,j} \quad (3)$$

- Medida de heterogeneidade: a variância apresenta valores altos quando os tons de cinza desviam do nível de cinza médio, independentemente da localização dos elementos da matriz e da frequência espacial que a textura apresenta. A equação apresenta a variância em X e a equação em Y.

$$\sum_{i=0}^{Hg} \sum_{j=0}^{Hg} (i - \mu_i)^2 p_{i,j} \quad (4)$$

Ou

$$\sum_{i=0}^{Hg} \sum_{j=0}^{Hg} (j - \mu_j)^2 p_{i,j} \quad (5)$$

- Correlação: mede a dependência linear entre os tons de cinza presentes em uma imagem.

$$\frac{1}{\sigma_i \sigma_j} \sum_{i=0}^{Hg} \sum_{j=0}^{Hg} (i - \mu_i)(j - \mu_j) p_{i,j} \quad (6)$$

- Por fim, Homogeneidade: a qual assume valores altos quando a textura apresenta pequenas variações de níveis de cinza entre os pares de pixels.

$$\sum_{i=0}^{Hg} \sum_{j=0}^{Hg} \frac{1}{1+(i-j)^2} p_{i,j} \quad (7)$$

Sendo:

- Hg: nível de cinza máximo na imagem.
- μ_i e μ_j : valores médios das distribuições.
- σ_i e σ_j : desvio padrão das distribuições.

4. Redes Neurais Artificiais (RNA)

Uma RNA pode ser definida como sendo uma estrutura de processamento (rede), passível de implementação em computadores, composta por um número de unidades interconectadas (neurônios artificiais), sendo que, cada unidade, apresenta um comportamento específico de entrada/saída (computação local), determinado pela sua função de transferência, pelas interconexões com outras unidades, dentro de um raio de vizinhança e, naturalmente, pelas entradas externas (Guindane, 2014) (Figura 3):

$$(XW_1)\mathbf{w} = \mathbf{y}$$

$$\begin{bmatrix} 1 & x_{11} & \dots & x_{1d} \\ 1 & x_{21} & \dots & x_{2d} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & \dots & x_{nd} \end{bmatrix} \times \begin{bmatrix} w_{01} & w_{01} & \dots & w_{0m} \\ w_{11} & w_{11} & \dots & w_{1m} \\ \vdots & \vdots & \vdots & \vdots \\ w_{d1} & w_{d1} & \dots & w_{dm} \end{bmatrix} \times \begin{bmatrix} w_{01} \\ w_{11} \\ \vdots \\ w_{d1} \end{bmatrix} = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_n \end{bmatrix}$$

Figura 5. Fórmula Matemática de uma RNA(2)

É importante perceber que a matriz W é a camada oculta da rede neural e cada coluna dessa matriz é um neurônio da camada oculta. Nós podemos pensar no vetor w como uma camada de saída com um único neurônio, que recebe o sinal dos neurônios anteriores, pondera-os e produz a saída final da rede.

A rede neural acima (Figura 5), não é muito interessante do ponto de vista prático, pois só consegue representar funções lineares. Felizmente, podemos arrumar isso facilmente, alterando o modelo da seguinte forma (Figura 6):

$$\phi(XW_1)\mathbf{w} = \mathbf{y}$$

Figura 6. Fórmula Matemática de uma RNA(3)

Em que ϕ é alguma **função não linear diferenciável**. Ela precisa ser diferenciável, pois vamos treinar a rede neural com gradiente descendente. O tipo mais comum de função não linear que utilizamos é a **unidade linear retificada**, ou ReLU (Figura 7):




Figura 7. Gráfico de uma função não linear

Formalmente, a ReLU é definida, como foi mostrado na (Figura7). Essa função tem propriedades muito interessantes, como ser parcialmente linear, o que facilita na hora do treinamento, e ter derivadas muito simples: 0, se $x < 0$ e 1, se $x > 0$. (Na prática, o ponto onde a derivada não está definida é implementado como fazendo parte de alguma das regiões onde ela é estável).

Deste trabalho foi a função Adam, utiliza uma ideia similar ao AdaGrad e ao RMSProp, contudo o momentum é usado para tanto para o momento (novamente, não confundir com momentum) de primeira quanto o de segunda ordens, tendo assim α e γ para controlar W e g , respectivamente. A influência de ambos diminui com o tempo de forma que o tamanho do passo diminua conforme se aproxima do mínimo. Uma variável auxiliar m é usada para facilitar a compreensão:

$$m_{t+1} = \alpha_{t+1} g_t + (1 - \alpha_{t+1}) \nabla L \quad (8)$$

$$(W_t) m_{t+1} = m_{t+1} \sqrt{1 - \alpha_{t+1}} \quad (9)$$

m é o momento de primeira ordem de ∇L e m é m após a aplicação do fator de decaimento. Então, precisa-se calcular os gradientes g usado para normalização:

$$g_{t+1} = \gamma_{t+1} g_t + (1 - \gamma_{t+1}) \nabla L (W_t)^2 \quad (10)$$

$$g_{t+1} = g_{t+1} \sqrt{1 - \gamma_{t+1}} \quad (11)$$

g é o momento de segunda ordem de ∇L . A atualização dos parâmetros é então calcula da seguinte forma:

$$W_{t+1} = W_t - \eta m_{t+1} \sqrt{g_{t+1}} + \epsilon \quad (12)$$

É um sistema massivamente paralelo e distribuído, composto por unidades de processamento simples que possuem uma capacidade natural de armazenar e utilizar conhecimento (Haykin, 1999). Apresentam diversas características em comum com o sistema nervoso: O processamento básico de informação ocorre em diversas unidades simples denominadas de neurônios artificiais ou simplesmente neurônios (ou nós).

Uma das maiores dificuldades encontradas no uso das redes neurais é a escolha das melhores arquiteturas e parametrizações, uma vez que esse processo é experimental e demanda um grande tempo de execução. Na prática, o processo deve ser aplicado com o intuito de testar vários métodos de aprendizado e as diferentes configurações que uma rede possa ter para a resolução de um problema em específico.

Em geral, podemos identificar três classes de arquiteturas de rede fundamentalmente diferentes: redes Feedforward com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes (Miranda *et al.*, 2009).

Uma RNA extrai seu poder computacional através de sua habilidade de aprender e de generalizar. A generalização se refere ao fato de a rede neural produzir saídas adequadas para novas entradas durante a aprendizagem, tornando possível a resolução de problemas complexos. Entretanto, as redes neurais precisam ser integradas em uma abordagem consistente de engenharia de sistemas, onde um problema complexo é decomposto em um número de tarefas relativamente simples, de acordo com a capacidade inerente à RNA (Haykin, 2001).

A utilização da RNA para um fim específico tem relação direta com a eficiência com que esta fornece respostas próximas aos dados de saídas reais. Para isso, o neurônio

artificial deve ser capaz de aprender uma determinada tarefa (Eyng, 2008). De acordo com Eynget *al.* (2009) e Fileti (2010), ao aplicar RNAs em um controlador de um processo de produção de etanol por fermentação, cujas características também indicam a não-linearidade do sistema, os resultados foram muito satisfatórios, superando a estratégia de controle tradicional (linear).

Apesar de muitas vezes eficiente, esta abordagem não retrata a realidade dos sistemas físicos, podendo resultar em soluções subótimas. Devido à capacidade de modelar com fidelidades ações não lineares, as RNAs se constituem uma importante ferramenta para o controle de sistemas (Braga, 2000). De acordo com Braga *et al.* (2007) um modelo básico de RNA possui diferentes componentes, dentre os quais:

- Conjunto de sinapses: conexões entre os neurônios da RNA. Cada uma delas possui um peso sináptico;
- Integrador: realiza as somas dos sinais de entrada da RNA, ponderados pelos pesos sinápticos;
- Função de ativação: restringe a amplitude do valor de saída de um neurônio;
- Biais: valor aplicado externamente a cada neurônio e tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação.

As RNAs configuram-se como uma tecnologia embasada em raízes multidisciplinares, sendo fundamentada pela neurociência, matemática, física, estatística, ciência da computação e engenharia. Como resultado do acelerado desenvolvimento tecnológico, as redes neurais passaram a ter aplicações em diferentes campos como, por exemplo, em processos de modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle de processos. Para que a rede neural forneça resultados satisfatórios, além de uma arquitetura adequada, o processo de treinamento e validação deve ser efetuado com qualidade. Dessa forma, se faz necessário fornecer à rede dados representativos da dinâmica do processo, onde a determinação destes valores deve ser efetuada de modo a propiciar uma rede que forneça bons resultados sem que haja um esforço computacional excessivo (Alves Sobrinho, T.*et al.*, 2011).

5. Metodologia

Foi localizada uma base de imagens que se encaixou com o propósito do trabalho, a base foi encontrada em um repositório americano: Medical ImageDatabase.

A Unidade de Engenharia Biomédica do Instituto Internacional de Tecnologia de Sirindhorn apresenta um banco de dados de imagens de ultrassom do câncer de mama fornecidas pelo Departamento de Radiologia da Universidade de Thammasat e pelo Centro de Câncer de Mama da Rainha Sirikit da Tailândia. O banco de dados de imagens de ultrassonografia pode ser baixado gratuitamente e podem ser usadas livremente, seja qual for o propósito (Medical ImageDatabase).

Após a aquisição das imagens, as mesmas foram separadas em dois grupos: o primeiro grupo foi de imagens que possuem câncer, e logo em seguida foi montado o

segundo grupo de imagens que não possuem câncer. As imagens foram Recortadas e redimensionadas para que todas tivessem o mesmo tamanho.

Acabamos optando por usar a ferramenta Orange Canvas, uma ferramentas mais atual, com recursos melhores, foram feitos vários testes com as seis variáveis, mudando e retirando as mesma, modificando os parâmetros, até chegarmos no melhor resultado, usando todas as variáveis.

O cálculo os valores dos descritores para as imagens da referida base já mencionada, foi realizado, gerando uma planilha, onde cada linha representa um conjunto de descritores de uma imagem (Figura 8):

	A	B	C	D	E	F	G	H
1	Tabela de dados das imagens sem câncer							
2	Codigo	Segundo	Entropia	Contraste	Variância	Correlação	Homogeneidade	
3								
4	Case-2-U-2-1.jpg	0.0701437	1.2808490	0.4905063	58.862968	4225.7360	0.778481012658228	
5	Case-2-U-2-2.jpg	0.0443166	1.4735070	0.5678797	56.867405	4727.3627	0.7536550632911391	
6	Case-2-U-2-3.jpg	0.0780203	1.2472316	0.5768987	100.80299	5935.3376	0.7493354430379746	
7	Case-3-U-5-0.jpg	0.1075878	1.1474528	0.4856012	172.67303	7904.1233	0.782262658227848	
8	Case-3-U-5-3.jpg	0.1030287	1.1251225	0.5748417	44.185701	2992.6366	0.7515031645569621	
9	Case-6-U-12-1.jpg	0.0453767	1.6042533	0.9699367	96.703055	6684.5096	0.7024925539836187	
10	Case-7-U-97-0.jpg	0.0473467	1.5204964	1.1205696	116.80240	7128.0757	0.6746138946380938	
11	Case-9-U-18-1.jpg	0.0180278	1.8894156	1.1862341	137.04393	8979.1196	0.6549512429119647	
12	Case-10-U-20-0.jpg	0.0995185	1.1467469	0.4071202	77.188861	4659.0743	0.8055537974683543	
13	Case-10-U-20-1.jpg	0.0165598	1.9004159	1.4186708	250.04013	11641.515	0.6199815281516697	
14	Case-12-U-23-2.jpg	0.0188364	1.8934738	2.3750000	126.30697	8342.7956	0.5597339364967806	
15	Case-13-U-24-1.jpg	0.0549538	1.4409151	0.9862341	224.84935	10034.344	0.678037043931496	
16	Case-16-U-27-2.jpg	0.0587453	1.3684250	0.8305379	23.756118	2231.3756	0.6980854430379749	
17	Case-17-U-28-1.jpg	0.0777111	1.3533381	1.1373411	133.65661	6048.1018	0.69862603846367	

Figura 8. Tabela preenchida com os dados gerados pelo descritor

Após o cálculo dos descritores, dois gráficos da estatística descritiva foram usados a fim de que seja possível projetar um cenário para esse problema.

Foi realizados gráficos de projeções, e notamos que, em quase todas as projeções, as classes estavam ocupando a mesma região no domínio de cada variável, indicando que a classificação tenderia a uma tarefa difícil. Após análises das projeções foi constatado que as variáveis de Medida de heterogeneidade e de Correlação apresentam uma classificação mais clara, sendo assim os mais importantes dentro do contexto. A fim de exemplificar essa análise, duas projeções podem ser vistas logo abaixo (Figura 9 e Figura 10):

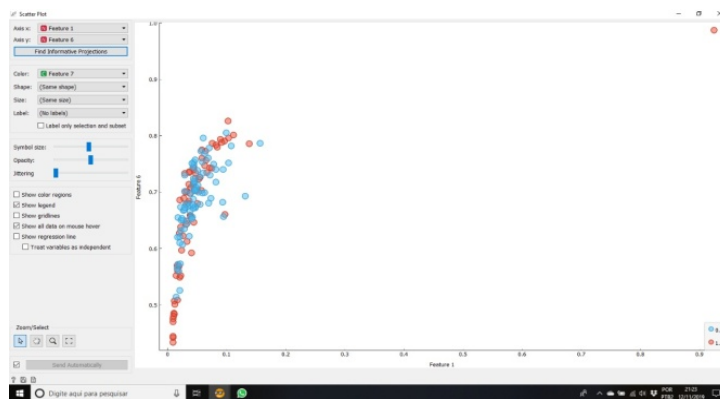



FIGURA 9 GRÁFICOS DE PROJEÇÃO GERADOS PELA FERRAMENTA ORANGE CANVAS, TAREFA DIFÍCIL DE CLASSIFICAÇÃO



Figuras 10. Gráficos de projeção gerados pela ferramenta Orange Canvas, tarefa simples de classificação.

Através de histogramas de frequência, vimos que as classes não assumem uma frequência destacadamente maior em uma parte específica da escala de cada variável. Nessa análise percebemos que realmente existe um problema de difícil solução, e também vimos que as variáveis de Medida de heterogeneidade, de Correlação, e de Homogeneidade continua sendo as mais importantes para o problema de classificação (Figura 11 e Figura 12):


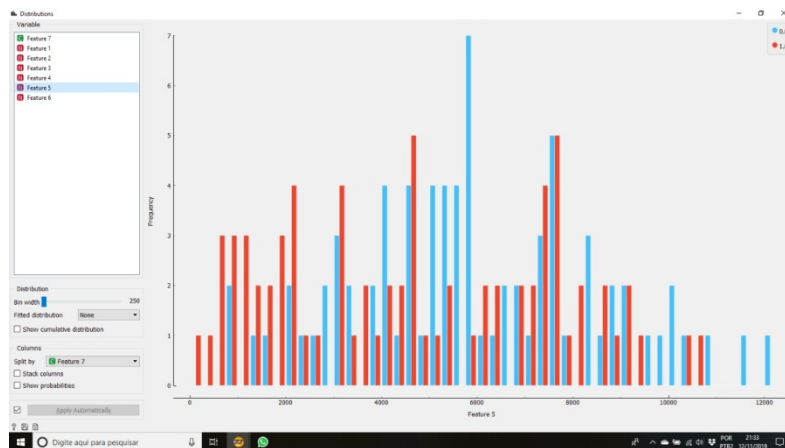


FIGURA 11 . GRÁFICOS DE PROJEÇÃO GERADOS PELA FERRAMENTA ORANGE CANVAS, TAREFA DIFÍCIL DE CLASSIFICAÇÃO.



Figuras 12. Gráficos de projeção gerados pela ferramenta Orange Canvas, tarefa simples de classificação.

Foram realizados vários testes, sem alteramos a estrutura da rede, para fazer o treinamento da rede neural, com as imagens previamente selecionadas. Logo após, foi feita uma nova seleção nas imagens, retirando as imagens de tons mais escuros, para aprimorar o resultado, segundo exemplo a seguir (Figura 13):



Figura 13. Imagem de ultrassonografia classificada com câncer

Ainda sem obter resultados satisfatórios, combinações dentre os descritores originalmente gerados, foi utilizada.

6. Resultado

A avaliação da rede neural foi feita a partir das matrizes de confusão gerada pelo Orange Canvas após a execução do treinamento de cada rede. Essas matrizes são de treinamento, validação, teste e uma matriz final que considera o mais coerentes da rede. A análise dos resultados foi feita considerando a matriz de confusão final (Figura 16) e observando os valores encontrados para falso positivos e falso negativos, bem como o acerto final da rede na classificação dos nódulos. Foram testadas algumas arquiteturas de rede variando o número de neurônios na camada escondida. A arquitetura que apresentou melhor resultado durante as simulações foi a que continha 38 neurônios (Figura 14). Os resultados mostrados neste trabalho são referentes a essa disposição dos neurônios na camada escondida, e apresentou um desempenho de 76% de acertos, e 24% de valores falso positivos e falso negativos. Conforme mostra (Figura 15):

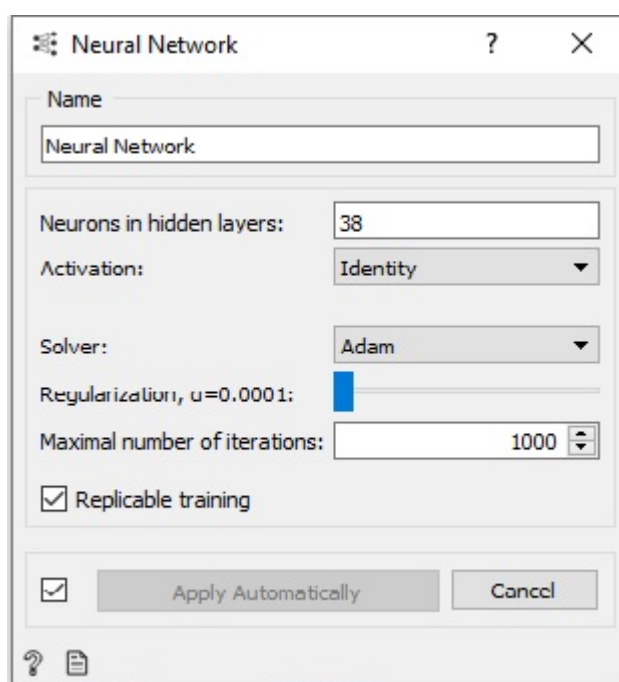


Figura 14. Configuração da RNA

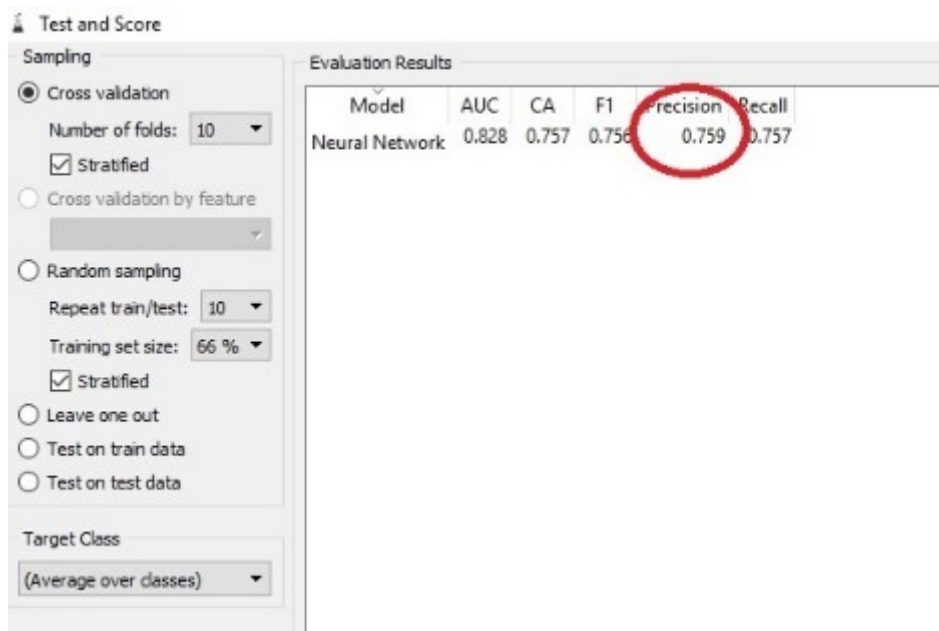


Figura 15. Tela melhor resultado

		Predicted		Σ
		0.0	1.0	
Actual	0.0	56	22	78
	1.0	15	59	74
Σ		71	81	152

Figura 16. Matriz de confusão

7. Conclusão

A extração de descritores de imagem apresentou uma boa base de dados para se encontrar um padrão para classificação de nódulos em ultrassom como maligno ou benigno. A rede neural mostrou-se eficaz para a aplicação, embora não se tenha conseguido reduzir os falso-negativos a zero para nenhuma das arquiteturas de rede testadas. As características presentes no banco de dados foram extraídas a partir de um processamento local das imagens, ou seja, sabia-se onde estava o nódulo na imagem e a técnica foi aplicada apenas no local do tumor.

Assim, este trabalho não substitui a avaliação das imagens por um médico, mas representa um apoio à decisão trazendo um avanço importante dado a dificuldade do diagnóstico do câncer que, no caso de um diagnóstico incorreto, pode prejudicar o início de um tratamento mais adequado destinado a casos malignos.

Este estudo teve como objetivo a proposta de metodologia de identificação de câncer em imagens de ultrassom, baseado em algumas ferramentas tecnológicas gratuitas como Orange Canvas. Portanto como base nos resultados expostos acima, pode-se concluir que os objetivos geral e específico deste estudo foram atingidos com a implementação de identificação de câncer em imagens de ultrassom.

Referências

- Alecrim, E. (2004) **Redes neurais artificiais**. Disponível em: <<https://www.infowester.com/redesneurais.php>> Acesso em 15 de nov. de 2019.
- Arakeri, M. P. and Reddy, G. R. M. (2015) Computer-aided diagnosis system for tissue characterization of brain tumor on magnetic resonance images. **SIViP**, n. 9, p. 409 - 425.
- Azimi, P. *et al.* (2015) Artificial neural networks in neurosurgery. **Neurol Neurosurg Psychiatry**, n. 86, p. 251 - 256.
- Chen, W. *et al.* (2005) 3-D ultrasound texture classification using run difference matrix. **Ultrasound In Med. & Biol.**, v. 31, n. 6, p. 763 -770.
- Facure, M. (2017) **Introdução às redes neurais artificiais**. Disponível em: <<https://matheusfacure.github.io/2017/03/05/ann-intro>> Acesso em 15 de nov. de 2019.
- Fleck, L. *et al.* (2016). Redes neurais artificiais: princípios básicos. **Inovação e Tecnologia**, v. 1, n. 13, p. 47-57.
- Garcia-Gómez, J. M. *et al.* (2004) Benign / malignant classifier of soft tissue tumors using MR imaging. **Magma**, n. 16, p. 194 - 201.
- Gómez, W. *et al.* (2016) Evolutionary pulse-coupled neural network for segmenting breast lesions on ultrasonography. **Neurocomputing**, n. 175, p. 877 - 887.

- Kia, S. *et al.* (2013) Computer-aided diagnosis (CAD) of the skin disease based on an intelligent classification of sonogram using neural network. **Neural Comput.&Applic.**, n. 22, p. 1049 - 1062.
- Lange, A. W. O. *et al.* (2002) Cluster analysis of biomedical image time-series. **International Journal of Computer Vision**, v. 46, n. 2, p. 103 - 128.
- Maxwell. (2019) **Redes neurais artificiais.** Disponível em: <https://www.maxwell.vrac.puc-rio.br/5566/5566_6.PDF> Acesso em 15 de nov. de 2019.
- Minha Vida. (2019) **Câncer: sintomas, tratamentos e causas.** Disponível em: <<https://www.minhavidade.com.br/saude/temas/cancer>> Acesso em 15 de nov. de 2019.
- Oliveira, W. E. B. Orientador: Sandro Roberto Fernandes. (2016) 14 f. **Classificação de imagens de satélite utilizando descritores de textura.** Trabalho de Conclusão de Curso (Graduação em Sistemas de Informação) - Núcleo de Informática, Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais, Juiz de Fora.
- Significados. (2019) **Significado de ultrassom.** Disponível em: <<https://www.significados.com.br/ultrassom>> Acesso em 15 de nov. de 2019.
- Strzelecki, M. *et al.* (2006) Classification and segmentation of intracardiac masses in cardiac tumor echocardiograms. **Computerized Medical Imaging and Graphics**, n. 30, p. 95 - 107.
- Teixeira, E. F. Orientador: Sandro Roberto Fernandes. (2016) 15 f. **Desenvolvimento de uma ferramenta computacional para classificação de padrões em imagens.** Trabalho de Conclusão de Curso (Graduação em Sistemas de Informação) - Núcleo de Informática, Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais, Juiz de Fora.
- Usp. (2019) **Redes neurais artificiais.** Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural>> Acesso em 15 de nov. de 2019.
- Yamashita, A. *et al.* (2008) Performance evaluation of radiologists with artificial neural network for differential diagnosis of intra-axial cerebral tumors. **AJNR Am J Neuroradiol**, n. 29, p. 1153 - 1158.
- Zhang, X. *et al.* (2009) Application of an artificial neural network to the computer-aided differentiation of focal liver disease in MR imaging. **Radiol. Phys. Technol.**, n. 2, p. 175 - 182.
- Zhu, W. *et al.* (2016) Data and feature mixed ensemble based extreme learning machine for medical object detection and segmentation. **Multimed. Tools Appl.**, n. 75, p. 2815 - 2837.

