

Segmentação Inteligente de Gorduras em Tomografias Abdominais Visando Recomendações para Combater a Recidiva do Câncer de Mama

Carlos Estellita Neto
Centro de Ciência e Tecnologia
Universidade Estadual do Ceará
Fortaleza, Brasil
carlos.estellita@aluno.uece.br

Ana Luiza Bessa de Paula Barros
Centro de Ciência e Tecnologia
Universidade Estadual do Ceará
Fortaleza, Brasil
analuiza.barros@uece.br

Gustavo Augusto Lima de Campos
Centro de Ciência e Tecnologia
Universidade Estadual do Ceará
Fortaleza, Brasil
gustavo.campos@uece.br

Rafael Lopes Gomes
Centro de Ciência e Tecnologia
Universidade Estadual do Ceará
Fortaleza, Brasil
rafa.lopes@uece.br

Thelmo Pontes de Araújo
Centro de Ciência e Tecnologia
Universidade Estadual do Ceará
Fortaleza, Brasil
thelmo.araujo@uece.br

Gláucia Posso Lima
Centro de Ciências da Saúde
Universidade Estadual do Ceará
Fortaleza, Brasil
glauucia.posso@uece.br

Sara Maria Moreira Lima Verde
Centro de Ciências da Saúde
Universidade Estadual do Ceará
Fortaleza, Brasil
sara.maria@uece.br

Resumo—De acordo com o Instituto Nacional do Câncer (INCA), atualmente um dos principais riscos para desenvolvimento de câncer é o excesso de peso corporal. O excesso de gordura ocasiona um estado de inflamação crônica de baixa intensidade, que acarreta um aumento na produção de citocinas inflamatórias de desbalanço de adipocitocinas conduzindo ao estímulo de cascatas carcinogênicas que favorecem o desenvolvimento da doença. A Organização Mundial da Saúde (OMS) destaca também que o excesso de gordura corporal é um importante fator de risco envolvido com a gênese de 13 tipos oncológicos distintos, entre esses o de mama. Ferramentas de processamento de imagens têm sido cada vez mais empregadas no contexto médico, para ajudar na reconstrução de imagens, detecção de anomalias, classificação de doenças, e segmentação de diferentes segmentos anatômicos. Neste contexto, este trabalho apresenta a descrição informal da primeira versão de um programa inteligente para segmentar tecido adiposo subcutâneo e visceral em imagens de tomografia computadorizada de abdômen, a fim de auxiliar profissionais da saúde a desenvolver um plano de recomendações personalizado para aconselhar pessoas a prevenir a recidiva do câncer de mama. O programa integra técnicas de pré-processamento de imagens com uma sequência de várias heurísticas simples, envolvendo as noções de superpixels e de similaridade por vizinhança. Nesta primeira versão, o programa está produzindo resultados aceitáveis de segmentação de gordura subcutânea, enquanto ainda precisará ser aprimorados para o caso da segmentação de gordura visceral.

Palavras-chave—Segmentação de Imagens do Abdômen, Tomografia Computadorizada, Câncer de Mama, Superpixels, Similaridade por Vizinhança, Heurísticas.

I. INTRODUÇÃO

Conforme o *Global Cancer Observatory* (GLOBOCAN), no ano de 2020 foram confirmados mais de 2 milhões de casos de câncer de mama ao redor do mundo, sendo de maior prevalência entre as mulheres e também a maior causa de mortalidade por câncer no sexo feminino. No Brasil, para o triênio de 2023 a 2025, o câncer de mama feminino, estão sendo estimados mais de 73 mil novos casos da doença, com uma proporção de 41,89 casos por 100.000 mulheres, apenas no Brasil [1]. Em todas as regiões do território nacional, o câncer de mama é a primeira causa de morte por câncer na população feminina em todas as regiões do Brasil, com exceção na região Norte [2], destacando a importância do cuidado ao paciente.

Até o fim de 2020, sobreviventes de câncer de mama em todo o mundo chegavam a 7 milhões dentro de 5 anos após o diagnóstico [3]. A recidiva tardia, que pode ocorrer entre 5 e 20 anos após o diagnóstico, é motivo de preocupação. Desta forma, torna-se de extrema necessidade que haja um diagnóstico precoce eficiente, pois quando os casos são detectados e tratados previamente, a mortalidade por câncer é reduzida [4], ajudando à uma sobrevivida maior.

Um dos fatores de relevância para o desenvolvimento de câncer de mama é o elevado índice de massa corporal (IMC) associado ao aumento na quantidade de gordura [5, 6]. O excesso de gordura conduz ao estado de inflamação crônica de baixa intensidade, com maior quantidade de citocinas

inflamatórias circulantes e desbalanço entre as adipocitocinas as quais estimulam as cascatas carcinogênicas de proliferação celular e inibem a morte celular programada [6]. De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), a proporção de mulheres com 20 ou mais anos de idade acima do peso mais que dobrou no Brasil, tendo um aumento de 14,5% para 30,2% entre os anos de 2003 e 2019 [7]. Além disso, quanto maior a faixa etária, maior é o predomínio de sobrepeso. Por exemplo, 57,0% das mulheres são vítimas do excesso de gordura na faixa de 25 a 39 anos [7].

Apesar de muito usado como estimativa das proporções de massa muscular e de gordura corporal, o Índice de Massa Corporal (kg/m^2) não mostra uma correlação significativa com a taxa de sobrevivência de pacientes com câncer. Correlações bem maiores são obtidas quando considerados os percentuais de massa muscular esquelética, gordura subcutânea, gordura visceral e gordura intramuscular.

Nessa perspectiva, o uso de diversas tecnologias para a prevenção do câncer de mama e sua recidiva, várias delas envolvendo equipamentos e outros recursos computacionais, vêm sido apontadas como importantes não apenas como ferramenta de pesquisa, mas como factíveis na prática clínica, visando garantir ao indivíduo maior autocuidado e propiciar um estado de saúde adequado. Técnicas de processamento de imagens utilizadas no âmbito da saúde visando melhorar a qualidade de vida dos usuários.

Neste contexto, este trabalho consiste em uma abordagem para a segmentação de gorduras em imagens de tomografia computadorizada de abdômen, a fim de auxiliar profissionais da saúde a desenvolver um plano de recomendações personalizado para aconselhar pessoas a prevenir a recidiva do câncer de mama. A abordagem proposta consiste em um programa de computador inteligente que integra técnicas de pré-processamento de imagens com uma sequência de várias heurísticas simples, envolvendo as noções de superpixels e de similaridade por vizinhança, para distinguir os diferentes tipos de gordura. O artigo apresenta uma descrição informal da *pipeline* do programa.

O artigo foi estruturado em mais cinco seções. A Seção II apresenta o contexto geral no qual se desenvolveu este estudo. A Seção III apresenta alguns trabalhos relacionados e a fundamentação teórica associados ao programa. A Seção IV apresenta o esboço da *pipeline* no programa inteligente. A Seção V apresenta os resultados e discussões a respeito do desempenho do programa. A Seção VI apresenta as conclusões e os aprimoramentos que deverão ser realizados em uma segunda versão do programa.

II. O CONTEXTO

O projeto MAMA, uma parceria dos programas de pós graduação em Ciência Computação e em Nutrição da Universidade Estadual do Ceará, em andamento atualmente, visa o desenvolvimento de uma organização de agentes inteligentes, em um ambiente de computação em nuvem, capaz de interagir com os profissionais de saúde e a paciente visando

resolver os problemas de avaliação nutricional, diagnóstico e recomendações personalizadas de mudanças de hábitos.

No cenário global ainda existe uma lacuna relevante a ser preenchida pelo desenvolvimento de sistemas de processamento de informações que sejam capazes de realizar duas funcionalidades principais: 1. Diagnóstico individualizado de prevenção da recidiva de câncer, com o olhar sobre fatores modificáveis de peso, composição corporal, alimentação e atividade física, que possibilite a percepção das pacientes; e 2. Recomendações individualizadas para direcionar essas pacientes para a mudança em seus hábitos de saúde e estilo de vida e promover melhor a qualidade de vida e sobrevida, conforme sugerido pela *American Society of Clinical Oncology* [8].

O sistema proposto no projeto MAMA fundamenta-se principalmente em noções de Inteligência Artificial (IA), especialmente a noção de agentes artificiais inteligentes e de aprendizado profundo, para resolver os problemas de interação com os usuários do sistema, de avaliação nutricional, diagnóstico e recomendações personalizadas à paciente. Nos últimos anos, a IA se tornou uma força transformacional significativa em várias indústrias, incluindo a área da saúde. Com sua capacidade de processar e analisar dados, as técnicas de IA podem ajudar a prever problemas de saúde, identificar fatores de risco, recomendar intervenções de saúde, entre outras tarefas [9].

O projeto propõe um grupo formado por três agentes artificiais Papo, Tomo e Rec, para interagir com os agentes humanos Paciente e Profissional de saúde por meio de sensores e atuadores virtuais, isto é, todos devidamente programados para: (a) Perceber as informações a respeito do estado nutricional da agente Paciente e/ou de imagens de tomografia computadorizada tomadas na altura da terceira vértebra lombar (L3) por ser a que melhor representa os compartimentos corporais; (b) Selecionar ações preventivas adequadas às informações percebidas; e (c) Enviar as ações selecionadas para os agentes humanos. O agente artificial Papo será executado nos *smartphones* dos agentes humanos. Os agentes artificiais Rec e Tomo são executados em servidores nas nuvens.

Sendo o agente artificial Tomo mais relevante para o contexto deste artigo, os seus sensores percebem as imagens de tomografia computadorizada tomadas na altura da L3 do agente Paciente, que são enviadas pelo agente Papo. Em seguida, Tomo deve analisar cada imagem TC, estimar os percentuais de tecidos muscular e adiposo e enviar o resultado para o agente Rec.

O agente Tomo será concebido como reativo baseado em modelos, executando um *loop* percepção-ação envolvendo uma série de quatro etapas: (a) Os sensores de Tomo percebem as imagens TC; (b) Empregando técnicas de Processamento de Imagens, um módulo de segmentação particiona a imagem TC em regiões que correspondam aos diversos tipos de tecido (ósseo, muscular, muscular visceral, adiposo subcutâneo, adiposo visceral e adiposo intramuscular) e calcula os valores da área de cada região; (c) Considerando os valores da área de cada região de tecido, o agente estima os percentuais da massa muscular esquelética e das massas adiposas; e (d) Os

atuadores de Tomo enviam para o agente Rec os percentuais estimados.

Como as imagens TC rotuladas ainda não estão disponíveis em número suficiente para o uso de técnicas de aprendizado de máquina supervisionado (isto é, com a segmentação desejada realizada por especialista humano e conhecida pelo programa), a princípio, os métodos e técnicas de Inteligência Artificial e Visão Computacional a serem desenvolvidos nesta etapa serão os não-supervisionados executados em nuvem, pois apresentam maior complexidade e demandam mais recursos computacionais. O programa inteligente descrito neste artigo consiste em uma das investigações desenvolvidas pelo grupo de pesquisa em torno da concepção de um programa que seja adequado para o agente artificial Tomo.

III. REFERENCIAL TEÓRICO

A aplicação de técnicas de processamento de imagens e de aprendizagem de máquina, entre outras técnicas de inteligência artificial (IA) são comuns em problemas de segmentação de gorduras em imagens de tomografias abdominais. Existem diversos trabalhos relacionados ao assunto, uns focando mais nas técnicas de pré-processamento da imagem, outros nas técnicas de IA que podem ser utilizadas para identificar e separar as diferentes regiões de gordura em imagens de tomografia abdominal.

A. Trabalhos Relacionados

Um dos primeiros trabalhos a respeito do assunto, o trabalho descrito em [10] apresenta uma estrutura computacional hierárquica, multi-classe, multi-característica e baseada em afinidade difusa para segmentação de tecidos em imagens médicas. A abordagem foi aplicada para segmentação automática de gordura abdominal. Uma avaliação da precisão da abordagem indicou a presença de viés e limites de concordância comparáveis à variabilidade interobservador inerente à segmentação manual.

Em [11] os autores desenvolveram e avaliaram um algoritmo automatizado para segmentar o abdômen em imagens TC visando quantificar a composição corporal. Foi desenvolvida uma rede neural convolucional baseada na arquitetura U-Net, treinada para realizar a segmentação abdominal em um conjunto de dados de 2430 exames de TC bidimensionais e foi testada em 270 exames de TC. O algoritmo foi testado em um conjunto de dados separado de 2.369 pacientes com carcinoma hepatocelular (CHC). As diferenças no desempenho da segmentação foram avaliadas usando análise de variância bidirecional com correção de Bonferroni. Em comparação com a segmentação de referência, o modelo para este estudo alcançou pontuações relevantes. O desempenho foi igual ou superou ao da segmentação do manual especializada. O modelo generalizou bem em vários níveis do abdômen e pode ser capaz de quantificar métricas de composição corporal em exames tridimensionais de TC.

Em [12] foi proposto um algoritmo de segmentação de gordura abdominal a partir de imagens TC usando rotulagem de múltiplos órgãos e redes neurais convolucionais 3D, visando

análise de composição corporal. O trabalho propõe uma nova estrutura para segmentação de múltiplos órgãos de regiões abdominais usando redes de atenção de órgão com conexões reversas que são aplicadas a visualizações 2D, do volume de TC 3D e estimativas de saída que são combinados por fusão estatística explorando a similaridade estrutural. As redes são treinadas em visualizações 2D (fatias). Foram anotadas manualmente treze estruturas por quatro avaliadores humanos e confirmadas por um especialista sênior em 236 casos normais. Os experimentos mostraram que a abordagem proposta fornece bons resultados e supera os métodos de ponta baseados em patches 2D e 3D.

No estudo realizado em [13] foi proposto um algoritmo baseado em aprendizado profundo, usando a arquitetura U-Net, para segmentar a gordura abdominal em imagens TC, visando realizar análises de composição corporal, ou seja, para medir a gordura abdominal nestas imagens. O desempenho da rede neural foi avaliado em cortes sequenciais de TC de três indivíduos e imagens de TC selecionadas aleatoriamente das regiões abdominal superior, central e inferior de 100 indivíduos. Os resultados demonstraram que o aprendizado profundo, acrescido de técnicas de aumento de dados, pode ser empregado para quantificar com precisão e rapidez informações sobre composição corporal com um pequeno número de imagens de treinamento.

O trabalho em [14] descreve um método de segmentação de tecido adiposo abdominal usando aprendizado profundo denominado EFNet, ou seja, uma rede neural convolucional a partir de tomografias computadorizadas. O modelo foi avaliado com diferentes conjuntos de dados e comparado com redes de aprendizado profundo existentes. O modelo proposto EFNet superou outros modelos recentes nos resultados e demonstrou bom desempenho para a segmentação do tecido adiposo abdominal, além de ser rápido. O método proposto demonstra ser adequado para segmentação de tecido adiposo abdominal na prática clínica.

Em [15] foi concebida uma rede neural convolucional automatizada (A-CNN) para segmentar o tecido adiposo abdominal a partir de imagens radiológicas. O modelo proposto foi testado com um conjunto de dados CT e comparado com modelos CNN existentes. A abordagem proposta superou os métodos de aprendizado profundo existentes em relação aos resultados da segmentação. O método proposto é rápido, com bom desempenho em tomografia computadorizada de baixa dose em escala limitada, e demonstra a força de fornecer uma ferramenta computadorizada eficiente para segmentação na prática clínica.

Dessa forma, uma análise da acurácia dos modelos propostos em estudos relacionados é fundamental para avaliar o progresso na área de segmentações médicas. A tabela abaixo apresenta um resumo das métricas de acurácia alcançadas pelos trabalhos extraídos e expando o que este presente trabalho se dispõe a implementar.

Artigos	Acurácia			
	Subcutânea	Visceral	Gordura T.	Órgãos
Modelo [10]	NA	NA	95%	NA
Modelo [11]	93%	97%	NA	NA
Modelo [12]	NA	NA	NA	89%
Modelo [13]	99%	98%	NA	NA
Modelo [14]	99%	98%	NA	NA
Modelo [15]	98%	98%	98%	NA
Presente Trabalho	X	X	NA	NA

Tabela I: Tabela de acurácias dos objetos segmentados dos respectivos modelos. NA: Não se aplica; X: Segmentações que o estudo se dispõe a implementar.

B. Fundamentação Teórica

Esta seção identifica os principais referenciais teóricos fundamentando esta primeira versão do programa inteligente para a segmentação das imagens. Vale ressaltar que o programa agrega dois procedimentos; um para a realização do processo de pré-processamento das imagens, e outro para a realização do processo de segmentação da imagem pré-processada.

O programa foi desenvolvido considerando imagens de tomografias axiais computadorizadas de abdômen da região tomada na altura L3 de dimensões 512×512 . O formato de arquivo das imagens é DICOM (*Digital Imaging and Communications in Medicine*), comumente usado no ambiente da saúde para padronização da comunicação de informações médicas [16, 17]. Imagens DICOM podem ser redimensionadas para a escala Hounsfield [18], que mede a radiodensidade dos tecidos.

Uma observação importante: As imagens da tomografias computadorizadas da L3, foram anonimizadas. O uso destas imagens para pesquisa foi aprovado pelo Comitê de Ética em Pesquisa do Instituto do Câncer do Ceará no Parecer No. 4.617.764, publicado na Resolução No. 466 /12 do Conselho Nacional de Saúde. O banco de imagens DICOM juntamente com as imagens padrão ouro (segmentação manual realizada por um especialista médico) foram cedidas pelo Prof. Dra. Sara Maria Moreira Lima Verde, do Programa de Pós-Graduação em Nutrição e Saúde da Universidade Estadual do Ceará.

A equalização de histograma é uma técnica amplamente utilizada no processamento de imagens para melhorar seu contraste, sendo o objetivo principal desta técnica é redistribuir as intensidades dos pixels de uma imagem, de forma a tornar o histograma da imagem mais uniforme [19]. O histograma de uma imagem é uma representação gráfica da distribuição da intensidade dos pixels [19].

A equalização do histograma é realizada em três etapas: primeiro, é calculado o histograma da imagem original. Em seguida, é calculada a Função de Densidade Acumulada, (*Cumulative Distribution Function* - CDF) do histograma, que representa a probabilidade de um pixel ter sua intensidade menor ou igual a um valor específico. E por fim, as intensidades dos pixels originais são reescaladas para os novos valores com base na CDF [21].

A tabela de radio-densidade é uma ferramenta importante

para interpretação de imagens de tomografia. Esta apresenta valores de densidade radiográfica para diferentes objetos. A radio-densidade em si, se trata da capacidade de um objeto absorver e espalhar a radiação. Ela é influenciada pela sua densidade, espessura e composição química, também como pela energia e tipo de radiação usada para obter a imagem [18].

Simple Linear Iterative Clustering (SLIC) é uma abordagem mais eficiente do que a segmentação pixel a pixel, pois reduz o número de elementos a serem processados, além de conter informações mais significativas da imagem. É um algoritmo de segmentação que agrupa pixels em superpixels (SPs), que são regiões compactas e homogêneas de pixels, com base em parâmetros atribuídos pelo programador, como número de superpixels e compacidade [22]. O SLIC é um método bastante eficiente com relação ao custo computacional, assim como bastante eficaz para delimitação dos limites nas imagens [22].

A Transformada de Distância Euclidiana (EDT), devido a ser um método para calcular a distância dos pixels até o fundo da imagem em imagens binárias, possui o intuito de nos informar o quão distante está um superpixel do fundo da imagem [23].

IV. O PROGRAMA INTELIGENTE

A abordagem de segmentação empregada no programa inteligente envolve dois procedimentos fundamentais. O primeiro procedimento, referente ao pré-processamento, possui o intuito de tornar a imagem o mais adequada possível para o processo de segmentação. O segundo, o procedimento referente à segmentação, visa identificar os objetos desejáveis na imagem. A *pipeline* apresentada na Figura 1 especifica em módulos esses dois procedimentos.

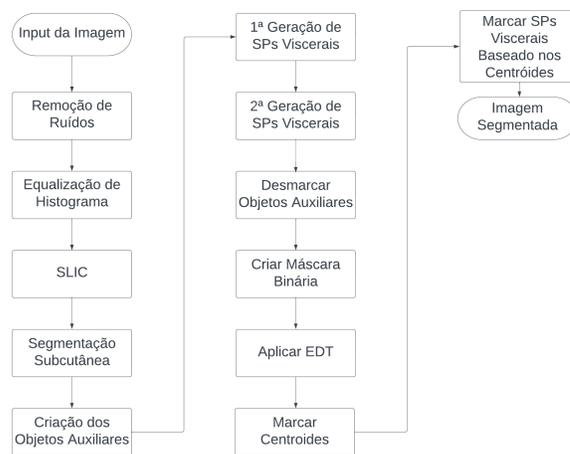


Figura 1: *Pipeline* do programa inteligente

Recebida a imagem em formato DICOM, o primeiro procedimento é decomposto em três módulos de pré-processamento. Primeiramente, os valores dos pixels são reescalados para valores inteiros. Em seguida, o procedimento identifica o maior componente conexo na imagem e o remove [24]. A

seguir, aplica-se a equalização de histograma para aumentar o contraste da imagem.

Após isso, é iniciada a implementação de um algoritmo para a *clusterização* dos pixels considerando o algoritmo SLIC, baseado na similaridade de cor e semelhança de localização dos pixels. Esta parte do procedimento é importante, pois é dessa forma que são gerados os superpixels, os quais carregam mais informações que pixels comuns, além de permitirem o surgimento de diversas heurísticas considerando características de alto nível da imagem.

Logo após o término do pré-processamento, o procedimento inicia a identificação da gordura subcutânea. Para a segmentação desta gordura, para todo superpixel, o procedimento calcula a média de intensidade dos pixels componentes e, com base nesse valor, caso a intensidade geral esteja dentro do intervalo proposto pela tabela de radio-densidade, o SP é segmentado como gordura subcutânea.

Após a segmentação subcutânea, é possível que ocorram SPs de gordura visceral segmentados como subcutâneos. Assim, é necessário que o procedimento distinga os diferentes tipos de gordura. Considerando que a gordura visceral está em contato direto com os músculos, e com os órgãos e ossos do corpo, com o auxílio da tabela de radio-densidade, todos os demais objetos presentes na tomografia são segmentados como *objetos auxiliares*.

Seguindo em frente na *pipeline*, o procedimento considera que os superpixels segmentados como gordura subcutânea e em contato com três ou mais objetos auxiliares, foram erroneamente segmentados como subcutâneos, e assim são segmentados como gordura visceral. Desta maneira, o programa cria a primeira geração de superpixels representantes de gordura visceral.

É possível que essa heurística distinga apenas alguns superpixels de gordura visceral. Entretanto, a partir desta primeira geração de SPs viscerais, para melhorar a distinção entre as gorduras, primeiramente, o procedimento analisa os superpixels que estão em contato com quatro ou mais SPs segmentados como gordura visceral ou objeto auxiliar. Esta análise ocorre repetidas vezes até que não haja mais alteração na quantidade de superpixels de gordura visceral. Dessa forma, aumenta a probabilidade de que todos os superpixels de gordura visceral tenham sido segmentados. Em seguida, o procedimento dessegmenta os segmentos de objetos auxiliares, mantendo as segmentações previamente realizadas.

Nesta etapa do processo, é possível que nem todos os superpixels tenham sido corretamente segmentados após a segmentação visceral. Dessa forma, o procedimento agrega uma nova heurística para aprimorar a eficiência da segmentação, ou seja, gera uma máscara binária da tomografia, onde os pixels brancos representam a tomografia em si, e os pretos representam o fundo da imagem. Em seguida, o procedimento de segmentação implementa técnicas de *flood_fill* em conjunto com aplicações de morfologia matemática [25, 26] para garantir que o interior do abdômen na tomografia esteja inteiramente preenchido, sem ar (gases), de acordo com [24]. Posteriormente, o procedimento executa o EDT visando

calcular a distância normalizada (de 0 a 1) dos pixels do abdômen até o fundo da imagem. Quanto mais longe do fundo, mais intenso é o pixel, quanto mais próximo, menos intenso é o nível de cinza do pixel.

Em seguida, o procedimento calcula o centroide de todos os superpixels com o objetivo de determinar o quão próximo do fundo estão os SPs e, assim que possível, designar com maior exatidão quais são os superpixels mais externos, os quais representam a gordura subcutânea, e os mais internos, que representam a gordura visceral, com base no mapa de distância gerado pelo EDT. Nesta heurística, o procedimento de segmentação analisa cada um dos superpixels da imagem, aqueles que estão segmentados como subcutâneos e a uma distância de 0.3 ou mais até o fundo da imagem, são considerados SPs do tipo visceral e o procedimento é finalizado.

V. RESULTADOS

Esta seção foi dividida em duas subseções. A primeira subseção ilustra a entrada e a saída resultante do processamento realizado por cada um dos módulos componentes dos procedimentos de pré-processamento e de segmentação no programa inteligente, e a avaliação de desempenho do programa proposto utilizando um banco de imagens de dimensões 512×512 composto por 204 tomografias axiais computadorizadas de abdômen na altura da L3. A segunda seção discute os resultados obtidos e propõe aprimoramentos na concepção de uma segunda versão do programa inteligente.

A. Ilustração e Avaliação de Desempenho do Programa

Esta subseção apresenta o resultado do processamento entrada-saída considerando uma imagem específica do banco de imagens, de cada um dos módulos componentes dos dois procedimentos no programa inteligente, descrito na *pipeline*.

A Figura 2 mostra as etapas da geração dos superpixels.

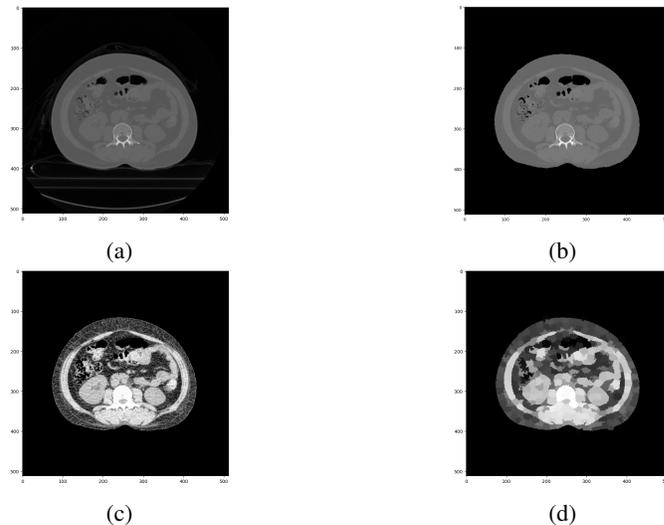


Figura 2: (a) Imagem original; (b) Imagem após remoção de ruídos; (c) Imagem após equalização de histograma; (d) Imagem após formação dos superpixels.

A Figura 2.a apresenta a imagem original em formato DICOM. Na Figura 2.b, o resultado do procedimento de pré-processamento ao retirar os ruídos da tomografia. Em seguida é aplicada a equalização de histograma mostrada na Figura 2.c. Após a equalização de histograma, é aplicado o algoritmo SLIC e o resultado é mostrado na Figura 2.d.

Na Figura 3.a são criadas as segmentações de azul para os superpixels de gordura subcutânea com base na média de intensidade de seus pixels. De verde, na Figura 3.b, são os superpixels que compõem os objetos auxiliares. Os SPs de vermelho na Figura 3.c representam aqueles que encontraram três ou mais objetos auxiliares próximos, dando início à primeira geração de SPs viscerais. A na Figura 3.d apresenta a geração final de todos os SPs viscerais segmentados por vizinhança e com os objetos auxiliares dessegmentados.

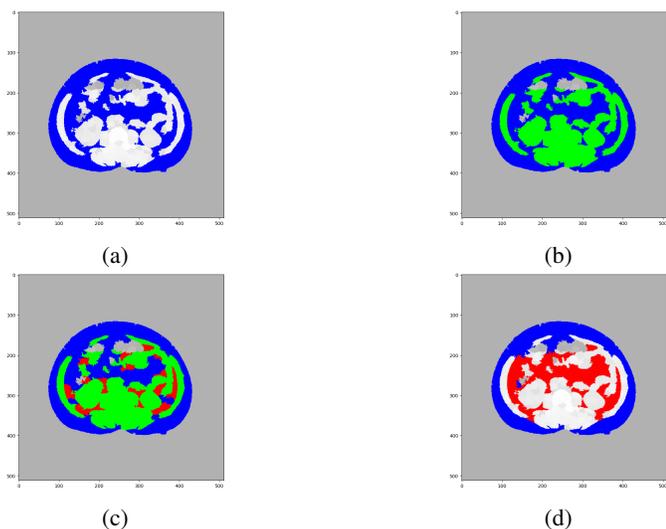


Figura 3: (a) SPs subcutâneos segmentados; (b) Criação dos objetos auxiliares; (c) Primeira geração de superpixels viscerais; (d) Todos os SPs viscerais segmentados e objetos auxiliares dessegmentados.

A Figura 4.a apresenta a máscara binária da região do corpo do paciente. A partir disso, é aplicado a Transformada de Distância Euclidiana para identificar o mapa de distância dos pixels da máscara binária, presente na Figura 4.b. Na Figura 4.c, apresenta o centroide de cada superpixel. Na Figura 4.d, é apresentada a segmentação com base da análise da distância dos centroides no mapa de distância. Esta imagem representa o estágio final de segmentação, que deverá ser analisada por um especialista.

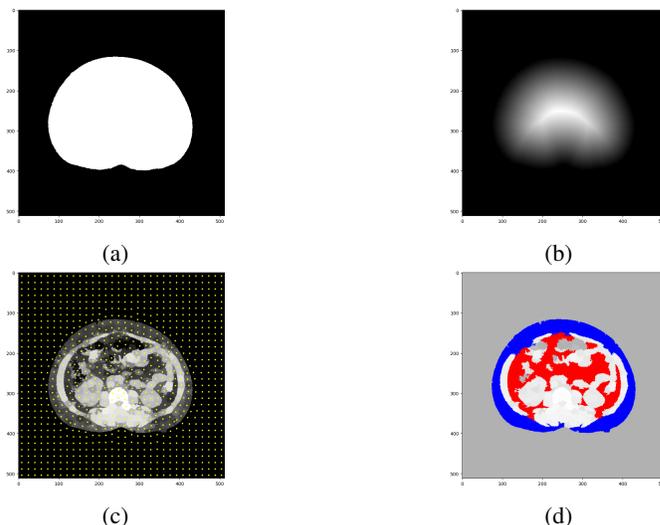


Figura 4: (a) Máscara binária da região do corpo; (b) EDT da máscara binária; (c) centroides marcados nos superpixels; (d) Segmentação final.

Foi feita uma contagem dos SPs subcutâneos e viscerais antes e após a heurística de segmentação baseado em centroides e EDT. Quando se observa o comportamento dos superpixels na Figura 5.a, nota-se que existem SPs segmentados como subcutâneos, mas que estão a uma distância maior que a esperada; enquanto na Figura 5.b, após a aplicação desse método, a distribuição dos SPs subcutâneos tornou-se mais homogênea.

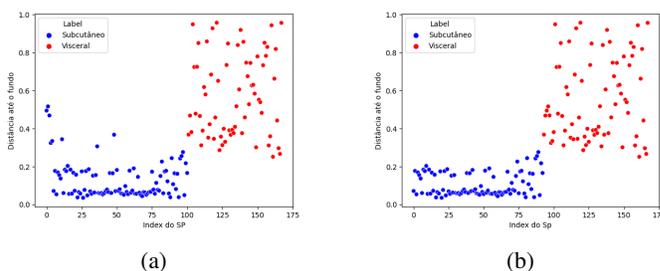


Figura 5: (a) Gráfico antes da heurística de EDT e centroides; (b) Gráfico pós heurística de EDT e centroides.

Após a realização do processo de segmentação em todo o banco de imagens, considerando as 204 tomografias axiais computadorizadas de abdômen na altura L3, o programa conseguiu alcançar o seguinte desempenho: (a) uma acurácia geral de 76,51%, com desvio padrão de 8,502%, para a gordura subcutânea; (b) uma acurácia geral de 45,96%, com desvio padrão de 13,435%, para gordura visceral.

B. Discussão

O programa proposto para segmentação obteve melhores resultados em tomografias de pessoas que tinham gordura subcutânea em maior quantidade, além de uma camada de músculo próxima à gordura subcutânea que seja bastante nítida

e robusta. Em algumas imagens sem esta última característica, a segmentação visceral sobressegmentava e acabava por prejudicar a segmentação subcutânea. Com essas características citadas, a Figura 6 ilustra uma imagem que obteve uma acurácia de 89,29% em segmentação subcutânea.

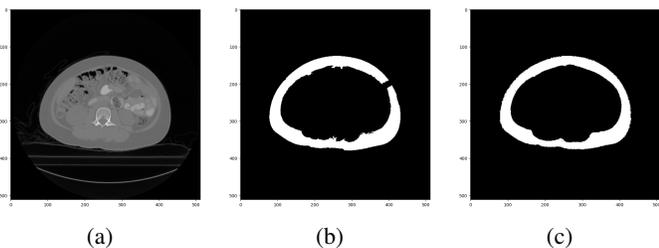


Figura 6: (a) Imagem original(2); (b) Máscara binária da gordura subcutânea; (c) Padrão ouro da gordura subcutânea.

Em tomografias de pacientes que apresentavam uma fina camada de músculo próxima à gordura subcutânea, o SLIC, por sua vez, em alguns momentos, agrupa estes pixels de músculo com pixels de gordura subcutânea, fazendo com que o SP carregue informações equivocadas. Assim, a abordagem de segmentar um superpixel com base em sua vizinhança eventualmente faz com que a segmentação visceral sobressegmente a segmentação subcutânea, fazendo com que as duas acurácias diminuíssem. Além disso, segmentar um superpixel como gordura a partir da média geral da intensidade dos pixels mostrou-se ineficiente, por não conseguir classificar corretamente todos os SPs de gordura. A Figura 7 ilustra uma das segmentações subcutâneas que não apresentou bom desempenho, possuindo uma acurácia de 67,27%.

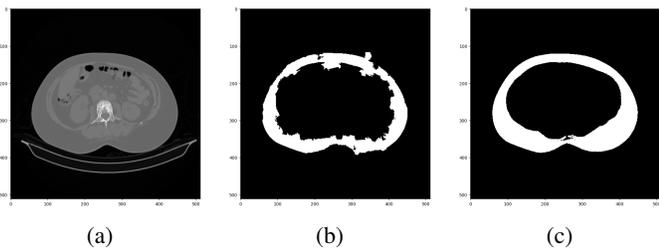


Figura 7: (a) Imagem original(3); (b) Máscara binária da gordura visceral; (c) Padrão ouro da gordura subcutânea.

O método desenvolvido apresentou baixo desempenho na segmentação de gordura visceral, devido a alguns fatores. Primeiro, a criação da primeira geração de SPs viscerais está limitada aos superpixels segmentados como *objetos auxiliares*, ou seja, está limitada à disposição dos órgãos, músculos e ossos presentes na tomografia. Segundo, a abordagem de segmentar ou dessegmentar um superpixel com base na sua vizinhança majoritariamente não funciona de forma adequada, pois caso a camada de músculo próxima à gordura subcutânea não esteja aparente o suficiente na tomografia, é possível que SPs subcutâneos sejam erroneamente segmentados como viscerais.

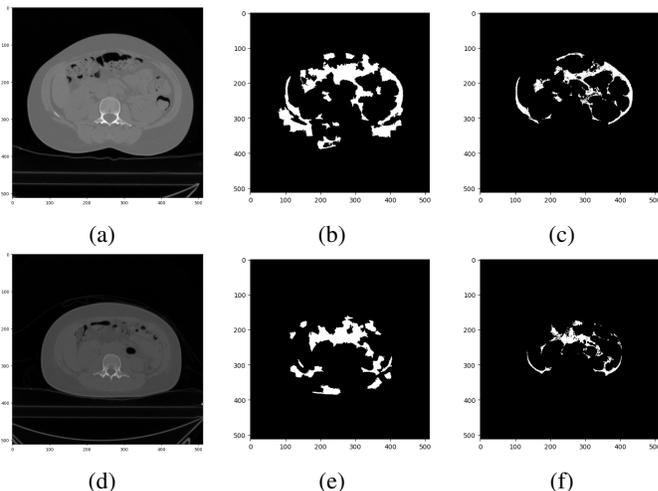


Figura 8: (a) Imagem original(4); (b) Máscara binária da gordura visceral; (c) Padrão ouro da gordura visceral; (d) Imagem original(6); (e) Máscara binária da gordura visceral; (f) Padrão ouro da gordura visceral.

Terceiro, a abordagem de superpixel não é boa para segmentar gorduras de indivíduos com pouca gordura visceral, devido ao fato de ser bem menos aparente em pessoas com baixo teor deste tipo de gordura. Além disso, gordura interna às vísceras foram consideradas com gorduras visceral pelo método proposto. A Figura 8 demonstra como que a segmentação visceral se comportou em algumas das imagens do *dataset*.

VI. CONCLUSÃO E TRABALHOS FUTUROS

Esta primeira versão do programa inteligente proposto neste artigo visou agregar estudos na área de segmentação de gorduras em tomografias de abdômen, com foco no auxílio aos profissionais da saúde na garantia de melhor qualidade de vida para indivíduos com risco à recidiva do câncer de mama, tendo em vista que o sobrepeso é um fator crucial para o desenvolvimento de câncer. Atualmente, o câncer de mama é um grande problema global devido a alta taxa de portadores últimos anos.

Nesta primeira versão do programa, a abordagem buscou discernir gordura subcutânea de gordura visceral a partir de heurísticas simples considerando a noção de superpixels. A segmentação de gordura subcutânea apresentou uma acurácia total de 75%. Em casos específicos, obteve uma acurácia acima de 85%. Já para a segmentação de gordura visceral, a segmentação obteve uma acurácia baixa, aproximadamente 46%, e esporadicamente superior a 60%.

A segunda versão do programa inteligente está sendo elaborada considerando os aspectos positivos e, principalmente, os aspectos negativos a serem eliminados. No que diz respeito ao pré-processamento, a depender do nível e tipo de ruído, a limiarização pode ser realizada de maneira global ou de modo variável, por métodos como o de Otsu e suas variantes, podendo gerar resultados significativamente melhores. Apesar de conseguir segmentar tecido muscular esquelético e tecido adiposo, a simples limiarização da imagem não é capaz de

discriminar os diversos tipos de tecido adiposo, já que todos possuem valores próximos em Unidades Hounsfield (HU). Para obter o grau de discriminação desejado, há a hipótese de que é necessário adaptar técnicas de segmentação baseadas em regiões, como as técnicas por crescimento, divisão e fusão de regiões. Algumas variações da técnica de *watershed* também serão adaptadas e testadas.

Além da inserção de outras técnicas de pré-processamento de imagens, e da integração de técnicas de *Machine Learning* para diversas finalidades, está sendo concebido um classificador capaz de identificar a imagem com predominância de características de gordura subcutânea, para ser processada pelo programa inteligente na versão atual, ou com predominância de características de gordura visceral, para ser processada pela segunda versão do programa.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Pesquisa e Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte ao desenvolvimento deste trabalho.

REFERÊNCIAS

- [1] GLOBOCAN, "900-world-fact-sheets.pdf", [ONLINE]. Disponível em: <https://gco.iarc.fr/today/data/factsheets/populations/900-world-fact-sheets.pdf>. Acesso em 01/06/2023.
- [2] GOV. "Mortalidade", [Online]. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-cancer-de-mama/dados-e-numeros/mortalidade>. Acesso em 11/02/2023.
- [3] WHO, "Breast cancer", [Online]. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/breast-cancer>. Acesso em 01/06/2023.
- [4] WHO, "Cancer", [Online]. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/cancer>. Acesso em 14/02/2023.
- [5] WHO, "Obesity causes cancer and is major determinant of disability and death, warns new WHO report", [Online]. Disponível em: <https://www.who.int/europe/news/item/03-05-2022-obesity-causes-cancer-and-is-major-determinant-of-disability-and-death-warns-new-who-report>. Acesso em 12/02/2023.
- [6] INCA, "Câncer e obesidade: um alerta do INCA", [Online]. Disponível em: <https://www.inca.gov.br/sites/ufu.sti.inca.local/files/media/document/rrc-38-artigo-cancer-e-obesidade-um-alerta-do-inca.pdf>. Acesso em 12/02/2023.
- [7] GOV "Pesquisa do IBGE mostra aumento da obesidade entre adultos", [ONLINE]. Disponível em: <https://www.gov.br/pt-br/noticias/saude-e-vigilancia-sanitaria/2020/10/pesquisa-do-ibge-mostra-aumento-da-obesidade-entre-adultos>. 02/06/2023.
- [8] Wash D, Srivatsa S, George R, Ellis B, Aljehani M, E. Gross M, K. Basho R, Matasci N, Swisher C. "Individualized treatment estimates to inform on personalized cancer care decisions for treatment selection and treatment management". Journal of Clinical Oncology. 2023 ASCO Annual Meeting. 2023.
- [9] Wang F, Preininger A. "AI in Health: State of the Art, Challenges, and Future Directions". Yearb Med Inform. 08, 2019.
- [10] Pednekar, A. N. Bandekar, I. A. Kakadiaris and M. Naghavi, "Automatic Segmentation of Abdominal Fat from CT Data". 2005 Seventh IEEE Workshops on Applications of Computer Vision (WACV/MOTION'05). Volume 1. Breckenridge. CO. USA. pp. 308-315, doi: 10.1109/ACV-MOT.2005.31. 2005.
- [11] Weston AD, Korfiatis P, Kline TL, Philbrick KA, Kostandy P, Sakinis T, Sugimoto M, Takahashi N, Erickson BJ. "Automated Abdominal Segmentation of CT Scans for Body Composition Analysis Using Deep Learning". Radiology. 03, 2019.
- [12] Wang Y, Zhou Y, Shen W, Park S, Fishman EK, Yuille AL. "Abdominal multi-organ segmentation with organ-attention networks and statistical fusion". Medical Image Analysis. 07, 2019.
- [13] Grainger AT, Krishnaraj A, Quinones MH, Tustison NJ, Epstein S, Fuller D, Jha A, Allman KL, Shi W. "Deep Learning-based Quantification of Abdominal Subcutaneous and Visceral Fat Volume on CT Images". Academic Radiology. 2021.
- [14] Wang, Z., Hounye, A.H., Zhang, J. et al. "Deep learning for abdominal adipose tissue segmentation with few labelled samples". International Journal of Computer Assisted Radiology and Surgery. 2022.
- [15] Micomyiza C, Zou B, Li Y. "An effective automatic segmentation of abdominal adipose tissue using a convolution neural network". Diabetes & Metabolic Syndrome: Clinical Research & Reviews. 09, 2022.
- [16] W. Dean Bidgood, Jr., Steven C. Horii, Fred W. Prior, Donald E. Van Syckle. "Understanding and Using DICOM, the Data Interchange Standard for Biomedical Imaging". 1997.
- [17] Lim, J., Zein, R. "The Digital Imaging and Communications in Medicine (DICOM): Description, Structure and Applications". Capítulo 3. 2006.
- [18] DenOtter TD, Schubert J. "Hounsfield Unit". StatPearls Publishing. 2022.
- [19] R. C. Gonzalez and R. E. Woods. "Digital Image Processing". 3a Edição. Capítulo 3. Pearson Prentice Hall. 2008.
- [20] Stephen M. Pizer, E. Philip Amburn, John D. Austin, Robert Cromartie, Ari Geselowitz, Trey Greer, Bart ter Haar Romeny, John B. Zimmerman, Karel Zuiderveld. "Adaptive histogram equalization and its variations". Computer Vision, Graphics, and Image Processing. Volume 39. 09, 1987.
- [21] Krutsch, R., Tenorio, D. "Histogram equalization". Freescale Semiconductor. 2011.
- [22] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua and S. Süsstrunk. "SLIC Superpixels Compared to State-of-the-Art Superpixel Methods". IEEE Transactions on Pattern Analysis and Machine Intelligence. Volume 34. 11, 2012.
- [23] Danielsson, P. E. "Euclidean distance mapping". Computer Graphics and Image Processing. 1980.
- [24] Gabriel Furtado Lins Melo, "Segmentação Não Supervisionada de Tecido Adiposo Subcutâneo em Imagens de Tomografia Computadorizada Utilizando Morfologia Matemática e Transformadas de Distância", TCC, Universidade Estadual do Ceará, Centro de Ciências e Tecnologia Curso de Graduação em Ciência da Computação, Fortaleza, Brasil, 2022.
- [25] Chudasama, D., Patel, T., Joshi, S., Prajapati, G. I. "Image segmentation using morphological operations". International Journal of Computer Applications. 2015.
- [26] Soille, P. "Morphological Image Analysis". 2a Edição doi:10.1007/978-3-662-05088-0. 2004.