

ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO

PMR2500

Projeto de Conclusão do Curso II

Ano 2017



Entrega Trabalho Final

Reconhecimento Automático de Cálculos Renais em Imagens
Médicas

Alunos:

Douglas Augusto Rezende Dias - Nº USP 7633152

Marcelo Kuniyoshi Suzart Cunha - Nº USP 803794

Orientador:

Prof. Dr. Eduardo Lobo Lustosa Cabral

14 de Novembro de 2017

DOUGLAS AUGUSTO REZENDE DIAS
MARCELO KUNIYOSHI SUZART CUNHA

RECONHECIMENTO AUTOMÁTICO DE CÁLCULOS RENAIIS EM IMAGENS MÉDICAS

Texto apresentado à Escola Politécnica da
Universidade de São Paulo como requisito
para a conclusão do curso de graduação
em Engenharia Mecatrônica, junto ao
Departamento de Engenharia Mecatrônica
e de Sistemas Mecânicos (PMR).

Orientador:

Prof. Dr. Eduardo Lobo Lustosa Cabral

São Paulo

2017

FICHA CATALOGRÁFICA

Augusto Rezende Dias, Douglas; Kuniyoshi Suzart Cunha, Marcelo.

Reconhecimento Automático de Cálculos Renais em Imagens Médicas – São Paulo, 2017.

90 p.

Monografia (Graduação em Engenharia Mecatrônica) — Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos (PMR).

1.Imagens médicas. 2. Reconhecimento automático de cálculos renais. 3.Processamento de imagens. 4. Aprendizado de máquina. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos (PMR).

AGRADECIMENTOS

Agradecemos a Dra. Tânia C. Michailowsky pelo auxílio na interpretação médica das imagens.

RESUMO

A metodologia inicial consistiu em adquirir as informações disponíveis de pedras em imagens de pacientes. Mais especificamente, capturar em uma matriz, as informações de pedras tais como tamanho e posições (x,y) e altura (distância relativa entre cortes transversais de imagens tomográficas) dos centroides de cada pedra. Para fazer isso com as centenas de imagens que tínhamos disponíveis, criamos um programa em MATLAB que linearizou/destacou as imagens brancas e permitiu clicar nas imagens que sabíamos que eram pedras, orientados por uma médica radiologista. Em seguida, com esses dados, fizemos uma análise estatística para determinar a região de maior probabilidade de ocorrência de pedra nas imagens médicas.

SUMÁRIO

1	INTRODUÇÃO.....	12
1.1	APRESENTAÇÃO DO PROBLEMA	12
1.2	OBJETIVOS	13
1.3	MOTIVAÇÃO	14
1.4	CONSIDERAÇÕES ÉTICAS	15
2	ESTADO DA ARTE.....	16
3	REVISÃO BIBLIOGRÁFICA.....	21
4	REQUISITOS DO PROJETO.....	24
4.1	DEFINIÇÃO DAS PARTES INTERESSADAS	24
4.2	DEFINIÇÃO DOS REQUISITOS.....	25
4.3	ARQUITETURA E COMPORTAMENTO DO PROJETO	26
5	METODOLOGIA	26
5.1	METODOLOGIA DE PROCESSAMENTO DAS IMAGENS	26
5.2	METODOLOGIA DE DESENVOLVIMENTO DO ALGORITMO	29
6	PRÉ-PROCESSAMENTO DE IMAGENS	32
7	PROCESSAMENTO DE IMAGENS.....	35
7.1	EXTRAÇÃO DE COMPONENTES BRANCOS.....	35
7.2	DENSIDADE AO REDOR DOS COMPONENTES BRANCOS	39
7.3	SEGMENTAÇÃO DO RIM	42
7.4	METADADOS DICOM	46
7.5	RECORTE DOS RINS.....	48
8	INTERFACE HOMEM-MÁQUINA	49
8.1	INTERFACE PARA COLETAR DADOS DAS PEDRAS.....	49
8.2	INTERFACE PARA COLETAR DADOS DOS RINS	51
9	TRATAMENTO ESTATÍSTICO	53
9.1	DADOS DAS PEDRAS.....	53
9.2	DADOS DOS RINS.....	61
10	DESENVOLVIMENTO DOS ALGORITMOS DE DIAGNÓSTICO	62
10.1	PREDIÇÃO BASEADA NA DISTRIBUIÇÃO NORMAL	62
10.2	PREDIÇÃO BASEADA EM NAIVE BAYES	63
10.3	PREDIÇÃO DE PROBABILIDADE EMPÍRICA.....	69
11	RESULTADOS	74
11.1	RESULTADOS DA EXTRAÇÃO DE DADOS DAS IMAGENS.....	74
11.2	RESULTADOS DOS ALGORITMOS DE DIAGNÓSTICO	75
12	CONCLUSÕES.....	81

13	REFERÊNCIAS BIBLIOGRÁFICAS	83
14	APÊNDICES	86
14.1	APÊNDICE A	86
14.2	APÊNDICE B	88
14.3	APÊNDICE C	90

LISTA DE FIGURAS

Figura 3-1 Curva da distribuição normal (forma de sino). As barras verticais mostram a distância da média em múltiplos de desvio-padrão.	23
Figura 5-1 Técnica do k-fold: dada uma amostra disponível de aprendizado e o plano de realizar 10 iterações, então deve-se dividir a amostra em 10 partes, treinar em 9 delas, e deixar sempre uma parte para testes.	31
Figura 6-1 Visualização da imagem de TC no software proprietário da GE (esquerda) e em no ambiente MATLAB (direita).	34
Figura 7-1 Imagem TC Original.....	35
Figura 7-2 Imagem binária resultante com componentes brancos	36
Figura 7-3 Tabela resultante após o processamento em ambiente MATLAB.	36
Figura 7-4 Limiar da máscara identificando pedras.....	37
Figura 7-5 Limiar de máscara muito baixo	38
Figura 7-6 Limiar máscara sem identificar pedra	39
Figura 7-7 Extração de vários pontos brancos cuja vizinhança terá a densidade calculada	40
Figura 7-8 Exemplo de ponto branco que foi retirado da imagem anterior. Trata-se de parte da seção da coluna vertebral.	40
Figura 7-9 Extração utilizada no cálculo de densidade de vizinhança de componente branco retirado neste exemplo da figura 7-7.	41
Figura 7-10 Nesta figura foi tratado o componente branco que se destaca no centro da seção da coluna vertebral	41
Figura 7-11 Componente branco bem próximo à mesa em que paciente está deitado. Importante destacar pois o algoritmo irá tratar esse tipo de ponto também... ..	41
Figura 7-12 Por fim uma pedra propriamente dita, retirada da figura 7-7. A densidade de sua vizinhança será útil na construção de uma função de probabilidade para diagnosticar cada componente branco candidato a ser pedra.	42
Figura 7-13 Ferramenta de visualização de médias e desvios padrões em unidades HU do software proprietário da GE. Na legenda, 1 e 3 se referem as médias em HU das áreas retangulares sobre os rins enquanto que 2 se refere a média em HU do fígado (39,7 HU).	42
Figura 7-14 Resultado do processamento da imagem de forma a selecionar pixels com intensidade próxima a 1050. Nesse teste as 3 maiores áreas de componentes conectados foram selecionadas.....	44
Figura 7-15 Detecção de bordas (função “canny”).	45
Figura 7-16 Imagem TC sobreposta a imagem com rótulo da borda do rim.....	46
Figura 8-1 Interface gráfica de rotulação indicando posição do clique do mouse para usuário (esquerda). Tabela de rotulação dos componentes brancos com posição (x,y) do centróide e informação se é pedra.	49
Figura 8-2 Interface gráfica final com máscara vermelha de rotulação indicando posição do clique do mouse para usuário (esquerda) e Interface gráfica final após o clique do mouse indicando mancha branca registrada.....	51
Figura 8-3 Observar o polígono elaborado manualmente. Polígonos como esse foram feitos para cada imagem com rim em toda a amostra.....	52
Figura 8-4 Imagem do recorte obtido de um rim. Os recortes foram feitos cuidadosamente para minimizar a contaminação da imagem com tecidos vizinhos, o que poderia deturpar os cálculos de densidades dos rins.....	53
Figura 8-5 Mesma imagem que a figura 8-4, porém em formato DICOM. O formato DICOM possui mais detalhe e foi efetivamente recortado, porém para fins de visualizar a imagem em um computador Windows, foi utilizado o formato JPEG.....	53

Figura 9-1 Centroides de cálculos renais de todas as imagens sobrepostos em uma imagem de fundo arbitrária para melhor visualização.	54
Figura 9-2 Pontos médios dos centroides de cálculos renais de todas as imagens sobrepostos em uma imagem de fundo arbitrária para melhor visualização.	55
Figura 9-3 Distribuição estatística dos valores de x para as pedras do lado esquerdo.....	57
Figura 9-4 Distribuição estatística dos valores de x para as pedras do lado direito.....	57
Figura 9-5 Distribuição estatística dos valores de localização y para as pedras do lado esquerdo.....	58
Figura 9-6 Distribuição estatística dos valores de localização y para as pedras do lado direito.....	59
Figura 9-7 Distribuição estatística dos valores de localização z para as pedras do lado esquerdo.....	59
Figura 9-8 Distribuição estatística dos valores de localização z para as pedras do lado direito.....	60
Figura 9-9 Distribuição estatística dos valores de área obtidos para todas as pedras da amostra. Observar a comparação com outras curvas estatísticas conhecidas.	61
Figura 10-1 Imagem que mostra uma classificação feita com o algoritmo baseado em distribuição normal	63
Figura 10-2 Cabeçalho da lista que contém os dados dos mais de 300 mil componentes brancos disponíveis.....	64
Figura 10-3 Pé da lista, mostrando os últimos componentes brancos.....	64
Figura 10-4 Distribuição de resultados para 31 combinações de entradas. Notar que existem pontos sobrepostos.	65
Figura 10-5 Imagem mostrando pedra no rim corretamente detectada.....	67
Figura 10-6 Gráfico que mostra a dependência da acurácia com o valor de limiar mínimo.....	68
Figura 10-7 Gráfico que mostra como a ocorrência de falsos-negativos aumenta com o aumento do limiar mínimo	69
Figura 10-8 Curva obtida da função f, utilizada em cada parcela da função P. ..	71
Figura 10-9 Classificação correta de pedra e de não-pedra utilizando "a" = 0,3	73
Figura 10-10 Classificação incorreta de pedra utilizando "a" = 0,25	74
Figura 11-1 Acurácia do algoritmo com o valor de limiar escolhido para selecionar pedra.	77
Figura 11-2 Dependência da ocorrência de falsos-negativos com o valor de limiar escolhido para selecionar pedra.	78
Figura 11-3 Acurácia do algoritmo com o alfa escolhido entre 0,2 e 0,3..	79
Figura 11-4 Dependência da ocorrência de falsos-negativos com o alfa escolhido.	80
Figura 11-5 Dependência da ocorrência de falsos-positivos com o alfa escolhido.	81

LISTA DE TABELAS

Tabela 1 Dados obtidos das imagens processadas. Vale observar que os valores aqui mostrados se referem a número de pixels (tanto em área como em distâncias) .	56
Tabela 2 Dados calculados das imagens obtidas recortando os rins.	61
Tabela 3 - Resultados de probabilidade obtidos para 10 componentes brancos avaliando apenas x e y.	66
Tabela 4 Cronograma final apresentado na disciplina PMR 2500 (2016).....	90
Tabela 5 Cronograma atualizado na disciplina PMR 2500 (2017).....	91

1 INTRODUÇÃO

1.1 APRESENTAÇÃO DO PROBLEMA

Atualmente milhares de tomografias computadorizadas são realizadas e analisadas por médicos todos os dias. Por meio de uma pesquisa com profissionais da área de radiologia percebemos que laudos de grau de dificuldade bastante baixo como sinusite, cálculo renal, entre outros, representam um alto percentual da quantidade diária de laudos realizados.

Sob o ponto de vista da engenharia, as áreas de aprendizado de máquina e visão computadorizada são campos cada vez mais desenvolvidos e promissores devido aos avanços de pesquisas e às possibilidades de aplicações práticas. Uma das aplicações que atualmente tem sido discutida é o diagnóstico médico automático por meio de processamento digital de imagens de raios-x, tomografia, ressonância magnética, etc.

Como uma grande parte da especialidade de diagnósticos por imagem envolve o reconhecimento de padrões com o objetivo de detectar alterações nos formatos dos órgãos humanos de forma a indicar doenças e anomalias, o aprendizado de máquina e visão computadorizada surgem como uma solução capaz de aumentar a eficácia do processo.

Os cálculos renais (conhecidos popularmente como pedras nos rins) consistem em massas sólidas formadas por pequenos cristais. Esta formação ocorre no rim, mas a pedra pode ser encontrada tanto no rim quanto em outra parte do trato urinário. Podem ser formados por diferentes minerais (cálcio, cistina, estruvita ou ácido úrico) e possuir diferentes formatos. O tamanho pode passar de 6 milímetros causando dores ao paciente e possivelmente exigindo cirurgia para retirada da pedra, dependendo de sua localização. A detecção do cálculo ocorre geralmente após uma crise de dor quando então o paciente procura algum médico e é submetido a diversos exames. Imagens de raio-X, tomografia e ressonância magnética são exames utilizados para detectar a pedra. Essas imagens são interpretadas pelo médico uma a uma. Nos Estados Unidos meio milhão de pessoas descobrem que possuem pedras nos rins por ano (National Kidney Foundation, 2016). No mundo, a incidência de cálculos renais é

bastante alta chegando a atingir 5% das mulheres e 12% dos homens (Jones, et al., 2013), sendo as pedras de cálcio as mais comuns (Tamm, et al., 2003).

A tomografia computadorizada é um método de aquisição de imagens extremamente útil para a detecção de cálculos renais. A imagem é adquirida através da emissão de raios-X com múltiplos detectores dispostos de tal forma a obter cortes transversais contíguos do corpo do paciente. Esses cortes têm espessuras selecionadas pelo operador, podendo ser posteriormente processados e reconstruídos em outros planos e até gerar imagens tridimensionais, dependendo do aparelho utilizado. Cada corte corresponde a uma matriz relacionada a fatores que são função da atenuação do feixe de raio-X pelo elemento em questão sendo posteriormente convertido em imagem em tons de cinza, segundo a escala de densidade de Hounsfield (por exemplo, ao ar é atribuída a densidade -1000HU e à água 0 HU). No caso dos rins, por exemplo, a densidade média é de 30 HU com desvio padrão de 10 HU (WEGENER, 1992).

Na análise da complexidade do problema vale ressaltar a grande variabilidade das imagens, as características dos rins nas imagens com relação aos demais órgãos e a determinação de quais cortes transversais marcam o início e o fim de um rim. Comparando imagens de diferentes pacientes percebem-se grandes variações entre elas, onde podem existir diversos tipos de cálculo renal com formatos e tamanhos diferentes e que podem estar em diferentes partes do trato renal. Além disso, os rins têm formatos e tamanhos distintos dependendo do paciente. Analisando as características morfológicas das imagens dos rins, percebe-se que detectar as regiões dos rins nas imagens é tarefa difícil. Eles possuem características de textura muito similares aos demais órgãos ao seu redor, o que dificulta sua detecção e segmentação na imagem.

1.2 OBJETIVOS

Nesse contexto, a tecnologia proposta neste trabalho busca desenvolver um método para auxiliar o médico no processo de detectar a pedra no rim (ou ausência de pedra) e fazer o diagnóstico. A contribuição prática será o aumento da quantidade de exames feitos pelo médico no mesmo intervalo de tempo, causando uma diminuição no custo de cada exame.

O objetivo, portanto, é desenvolver, utilizando conceitos de aprendizado de máquina e visão computacional, um método capaz de interpretar e diagnosticar imagens tomográficas com elevado grau de acerto de forma automática, distinguindo pacientes com cálculo renal de pacientes saudáveis.

1.3 MOTIVAÇÃO

Como citado anteriormente, a incidência de cálculos renais na população mundial é extremamente alta. Sob a óptica médica, o laudo desse tipo de doença é algo bastante simples e que toma pouco tempo quando considerado individualmente. Entretanto, por sua grande frequência o tempo total gasto para a detecção da mesma é bastante grande.

A área da radiologia, ramo da medicina dedicado ao diagnóstico de anomalias e doenças por meio de imagens médicas, tem como base fundamental o reconhecimento de padrões com o objetivo de detectar alterações nos órgãos humanos. Com o recente avanço de técnicas de aprendizado de máquina e visão computacional, a eficiência e produtividade humana nesta área da medicina podem ser potencializadas.

Caso fosse possível automatizar o laudo médico de doenças simples que provavelmente não implicam em riscos grandes para os pacientes, como cálculos renais, sinusite, entre outras, ou acelerar o seu processo de detecção com auxílio de ferramentas computacionais, os médicos poderiam ater-se ao laudo de doenças mais difíceis de detecção e mais prejudiciais à saúde dos pacientes.

Assim, escolhendo especificamente a doença de cálculo renal, o presente trabalho tem a motivação de desenvolver um método capaz de interpretar e diagnosticar imagens tomográficas de forma eficiente e com baixo percentual de erros de forma automática. Dessa maneira, busca-se criar uma ferramenta que pode acelerar o processo de detecção da doença, contribuindo para o aumento da produtividade médica e possibilitando que os médicos possam se focar no laudo de doenças mais prejudiciais aos pacientes.

1.4 CONSIDERAÇÕES ÉTICAS

Estamos lidando diretamente com informações médicas sensíveis de pacientes reais. Dessa forma, temos o compromisso de não expor/divulgar quaisquer imagens ou informações médicas específicas associadas ao nome do paciente. Para evitar qualquer tipo de incidente, todos os dados referentes aos nomes dos pacientes são ocultados, excluindo dessa forma qualquer possibilidade de divulgação das informações pessoais do paciente e garantindo que as imagens de tomografia que estão sendo analisadas sejam utilizadas no intuito puramente científico e de pesquisa.

2 ESTADO DA ARTE

Existem diversos trabalhos na área de pesquisa em processamento de imagens médicas digitais para o reconhecimento de doenças e/ou anormalidades em órgãos. Neles, abordam-se diversas técnicas para o processamento de imagens utilizando algoritmos de aprendizado de máquina e segmentação de imagens que sejam capazes de analisar imagens obtidas por exames convencionais (tais como, ultrassonografia, tomografia computadorizada e ressonância magnética) e extrair dados relevantes. Assim, busca-se auxiliar o médico, causando uma economia de tempo e um aumento na qualidade dos laudos.

Gonzalez e Woods (RAFAEL C. GONZALEZ, 2008) apresentam uma metodologia para processamento de imagens com foco em aplicações médicas. Essa metodologia consiste em etapas a serem seguidas desde a leitura de uma imagem até a obtenção de resultados.

No campo de análise de imagens médicas para reconhecimento de cálculo renal, também popularmente conhecidas como pedras no rins, a grande maioria dos trabalhos utilizam a aquisição de imagens por meio de ultrassonografia (US) e tomografia computadorizada (TC). A maioria deles tem como objetivo analisar as diferenças de eficácia na segmentação de imagens utilizando diferentes algoritmos para o reconhecimento de determinada região do rim, agrupando/destacando na imagem de saída os próprios rins, alguma outra região de interesse do órgão, ou o cálculo renal em si.

Observa-se ainda que dentro do processamento de imagens médicas, para cada caso específico, órgãos diferentes, regiões diferentes do corpo, tipos de imagem diferentes (TC, US ou ressonância magnética – RM, por exemplo) as técnicas e algoritmos variam, não havendo um algoritmo universal para segmentação de imagens médicas. Por esse motivo, a escolha de um algoritmo no caso de imagens adquiridas por meio de TC deve se basear nos parâmetros específicos desta tecnologia (SHARMA N., 2010).

Com relação ao problema de pedras nos rins, duas abordagens predominam nos trabalhos:

- Trabalhos em que a partir de uma imagem na qual se sabe previamente que existem pedras nos rins, obter sua localização exata (até estimando seu tamanho).

- Trabalhos que utilizam além das imagens, informações como: concentrações de substâncias no sangue, idade do paciente, sexo, etc.

Ebrahimi e Mariano (Ebrahimi, et al., 2015), utilizando Tomografia Computadorizada dos Rins, desenvolveram um programa que aplica técnicas de processamento de imagens e princípios geométricos para definir a fronteira de segmentação da imagem do rim. O programa foi testado em 39 pacientes divididos em dois grupos: com e sem pedras nos rins, o resultado foi 33 resultados corretos e apenas 6 resultados inconsistentes, indicando o potencial do programa para detectar pedras nos rins de maneira eficaz. Ainda, de acordo com estes dois pesquisadores, o escaneamento TC é a ferramenta mais utilizada para obter imagens dos rins.

Tamilselvi e Thangaraj (2011) foram além ao propor e estudar uma técnica que objetiva detectar a região de surgimento da pedra no rim, possibilitando sua detecção antes que se torne um problema e, portanto, com potencial de evitar seu crescimento apenas com mudanças alimentares, sem a realização de procedimentos como cirurgia ou fragmentação da pedra. Utilizaram a técnica de Crescimento da Região Semeada (*Seeded Region Growth* - SRG) com limite mínimo de textura para identificar a posição e tamanho da pedra no rim.

Chougule e Mane (2015) propuseram uma metodologia para detecção de pedras utilizando redes neurais em que se busca estabelecer um tratamento preventivo antes que o cálculo se torne muito grande ou até mesmo que se forme. Chougule utilizou não apenas imagens, mas também dados de concentração sanguínea de algumas substâncias, idade e sexo somados ao tratamento de imagens de ultrassonografia.

Uma abordagem similar foi feita por Liu, Wang e Turkebey (Wang et al. 2015) que desenvolveram um método de filtragem e aprimoramento de imagens por fluxo de variação total (VT) para reduzir o ruído da imagem nos rins e manter a aparência característica dos cálculos renais. Elegem-se as possíveis regiões da imagem que contenham pedras através do parâmetro de *Maximally Stable Extremal Region* (MSER), que caracteriza os valores de intensidade extrema para detectar manchas pequenas nas imagens. Finalmente, características de textura e forma extraídas das imagens são computadas por meio de quantização vetorial que é uma técnica muito utilizada no campo de aprendizado de máquina, para classificação de cálculos. Aplicando esse método em 192 pacientes obteve taxa de falso positivo em 8 pacientes. Apesar do método maximizar a sensibilidade em comparação com outros métodos, ele não é aplicável a cálculos renais de menor tamanho. Consequentemente, para exames de prevenção ele não é utilizável, sendo uma deficiência nesse aspecto.

Tamilselvi (TAMILSELVI, 2014) estudou técnicas de segmentação de imagens de US propondo soluções com custo computacional menos elevado. Como métodos de segmentação, utilizou o sistema de inferência *neuro fuzzy* adaptativo (*Adaptive Neuro Fuzzy Inference System - ANFIS*), segmentação de regiões interiores e exteriores baseadas em transformada *Watershed* (*Inner Outer Regions Based on new Enhanced-Watershed Segmentation method - IOREWS*) e indicadores de região por método de segmentação de contorno (*Region Indicator with Contour Segmentation Method - RICS*). Com o primeiro método obteve resultados de 52,45% para sensibilidade, 99,77% para especificidade e 99,63% para exatidão, sendo mais eficaz que SVM e Redes Neurais (Neural Networks - NN). O segundo método obteve valores de 85,67%, 99,72% e 99,67% sendo superior ao ANFIS, SVM e NN. O terceiro método, RICS, foi o que produziu os melhores resultados, sendo superior a todos anteriores, com 94,35%, 99,84% e 99,82% para sensibilidade, especificidade e exatidão, respectivamente.

O trabalho de Nicolae et al. (NICOLAE, 2011) trata os ruídos em imagens de US utilizando filtros e buscando o aprimoramento nas imagens. Os ruídos nas imagens podem ser vistos como pequenas manchas e devem ser eliminados para posterior processamento, segmentação e reconhecimento de uma parte de interesse da imagem. Por esse motivo, nesse trabalho é realizado um estudo comparativo de diferentes filtros por meio do software MATLAB. Filtros como os de média, não lineares, Wiener, Gaussiano etc., foram comparados indicando suas vantagens e desvantagens.

Uma abordagem utilizando da simetria das imagens de US de rins é proposta por Raja (RAJA et al., 2013). Nela, busca-se quantificar as pedras nos rins de pacientes para monitoração de evolução da doença. Novamente se realizam os passos de filtragem e ressaltamento de imagens e em seguida a análise de texturas é feita calculando a entropia local da imagem, seguida da seleção de um limiar, operações morfológicas, janelamento de objeto e determinação de ponto de semente. Para utilizar da simetria da imagem com os rins, os algoritmos baseiam-se apenas em operações de convolução o que resulta numa implementação mais rápida para classificação de cálculos renais. Utilizou-se mais de 200 imagens de US de rins, resultando em uma segmentação correta das regiões de interesse em 70% das imagens utilizando filtros de média (limiar de 0,6), 80% usando filtros de Wiener (limiar de 0,8) e 100% para filtros Gaussianos (limiar de 0,7).

Sivakalai (SIVAKALAI, 2015) trabalhou com processamento de imagens de tomografia computadorizada focando em múltiplos limiares mínimos com segmentação

contínua e discreta. Na primeira etapa de seu trabalho removeu ruído usando filtro mediano e equalização adaptativa de histograma. Em seguida as imagens segmentadas de pedras são selecionadas utilizando um método de fixação chamado *Multitheres*. Também foram utilizados vários métodos de segmentação como limiar mínimo binário, múltiplos limiares mínimos, segmentação contínua e segmentação discreta.

Kumaran e Sathyavathy (N. SENTHIL KUMARAN, 2016) propõem um método para identificar cálculo renal dividido em duas etapas. No primeiro a imagem TC escaneada do abdômen é particionada em diferentes grupos utilizando o método *spatial fuzzy c-means*, bastante usado na resolução de problemas por meio de aprendizado de máquina. A partir dos grupos divididos, a região dos rins é selecionada e submetida ao segundo estágio no qual o método *fuzzy level set* é aplicado. Os autores compararam este método aos métodos de limiar e nível definido e analisam essa comparação quantitativamente utilizando dois parâmetros: coeficiente de similaridade de Jaccard (coeficiente estatístico que relaciona a similaridade entre conjuntos de amostras) e exatidão. De acordo com os autores, dentre distintas modalidades de imagens médicas (Ultrassom, Ressonância Magnética, etc.) a Tomografia computadorizada é a preferida para detectar e diagnosticar anormalidades nos rins tais como pedras. O trabalho deles provê uma segmentação automatizada de cálculo renal a partir de imagens de tomografia computadorizada do abdômen.

Savaliya Nirali et al (SAVALIYA NIRALI, 2014), propuseram uma abordagem para identificar cálculo renal utilizando imagens de ultrassom e usando o software MATLAB. Imagens médicas são corrompidas por diferentes tipos de ruído e remover estes ruídos é uma tarefa bastante desafiadora. Segundo este autor, imagens de ultrassom são amplamente utilizadas devido a seu baixo custo e possibilidade de formar imagens em tempo real. Ainda segundo os autores um dos piores tipos de ruídos é o ruído *speckle*, que é multiplicativo, aleatório e inerente a imagens geradas por ultrassom, tendendo a reduzir o contraste da imagem assim como borrá-la. Os autores utilizaram diferentes técnicas para remover o ruído tais como: filtro de média, filtro de mediana, filtro de *Lee*, filtro de *Kuan*, filtro de *Frost* e filtro de Difusão. Estes autores perceberam que os filtros permitiram remover ruído, mas que também causaram a perda de detalhes importantes para o diagnóstico.

Skounakis et al (Skounakis, et al., 2014) apresentou um método com foco em diagnóstico de variadas patologias de rins incluindo pedras. Neste método, inicialmente cria-se um modelo padrão em 3-D em que os médicos estabelecem as regiões dos rins e suas patologias nas imagens. Em seguida, as regras e parâmetros

do modelo padrão são tratados como material de aprendizado para o sistema de reconhecimento automático. Na etapa final, com o sistema treinado, leigos puderam utilizar o sistema para obter diagnósticos de novos pacientes. Após treinar o sistema com 20 imagens de ressonância magnética, obteve-se taxa de 97,2% de sucesso na identificação dos locais dos rins, sendo que 96,1% foi a taxa de acurácia referente a pacientes com anormalidades.

Mangayarkarasi et al (MANGAYARKARASI, 2015) também utilizaram filtro de mediana para remover ruído tipo *speckle* ao trabalhar com diagnóstico e detecção de anormalidades nos rins utilizando imagens de ultrassom (sendo as principais: pedras, cistos e infecções). Foi feita uma segmentação utilizando a técnica de limiarização e de crescimento de região (algoritmo *Seeded Region Growing* - SRG).

3 REVISÃO BIBLIOGRÁFICA

DICOM:

DICOM é um acrônimo para Digital Imaging and Communications in Medicine. DICOM é tanto um protocolo de comunicação quanto um formato de arquivo, isso significa que pode armazenar informação médica como imagens de ultrassom e de ressonância magnética juntamente com as informações do paciente, tudo isso em um único arquivo. O formato DICOM garante que todos esses dados permaneçam juntos assim como permite que esses dados possam ser transferidos eficazmente entre dispositivos que suportam o formato. Para que sejam visualizadas em um computador pessoal, as imagens DICOM precisam de um pacote de software específico para esse formato, uma vez que o sistema operacional Windows não reconhece arquivos DICOM como arquivos de imagens.

DICOM se difere de outros formatos de imagens uma vez que agrupa informações em grupos de dados. Um arquivo DICOM consiste de um cabeçalho (header) e grupos de dados de imagens, tudo isso empacotado em um único arquivo.

Respeitar a privacidade do paciente é importante quando as imagens são utilizadas em apresentações, arquivos de aulas ou publicações. Uma maneira simples e eficaz de garantir a preservação da privacidade dos pacientes é exportar a imagem DICOM para outros formatos de imagens tais como JPEG e TIFF. O cabeçalho (header) de informações é perdido e então a identidade do paciente não pode ser obtida a partir da imagem resultante.

Tomografia computadorizada:

Tomografia computadorizada (TC) é um procedimento de diagnóstico por imagem não invasivo que utiliza raios-X e tecnologia da computação para produzir imagens horizontais ou axiais do corpo. Um exame de TC revela imagens detalhadas de qualquer parte do corpo, incluindo ossos, músculos e órgãos. Em raios-X padrão um feixe de energia é direcionado à parte do corpo sendo estudada. Um anteparo atrás do corpo então captura as variações de energia do feixe depois do mesmo ter atravessado pele, ossos músculos e outros tecidos. Na Tomografia computadorizada o raio-X é movido em círculo em torno do paciente e esse movimento permite muitas visões diferentes do mesmo órgão ou estrutura. A informação do raio-X é enviada a

um computador que então interpreta os dados e os exibe em uma forma bidimensional no monitor. Esses exames podem ser feitos com ou sem "contraste", uma substância ingerida ou injetada no paciente que faz com que o tecido sendo estudado fique mais nítido. Neste trabalho de conclusão de curso especificamente, os exames analisados foram realizados sem a utilização de contraste nos pacientes.

Além da localização e tamanho da pedra e da saúde geral do rim, a Tomografia Computadorizada permite avaliar a densidade da pedra em Hounsfield units (HU). A unidade Hounsfield, medida pela Tomografia Computadorizada se relaciona com a densidade do tecido ou da pedra. Godfrey Newbold Hounsfield foi um engenheiro eletricitista britânico. Foi agraciado com o Nobel de Fisiologia ou Medicina de 1979, por ter participado da criação do diagnóstico de doenças pela tomografia axial computadorizada. Vários estudos/trabalhos foram feitos para avaliar o uso de unidades Hounsfield na Urologia, principalmente para determinar o tipo de material que formou a pedra. Entender qual é o material que está na composição da pedra é informação de crucial importância para determinar qual tipo de tratamento terapêutico (técnica percutânea, terapia extracorpórea por ondas de choque ou uretero-nefrolitotripsia flexível) será adotado pelo médico para eliminar a pedra. Ainda a adição de informações como pH da urina e presença de cristais podem aumentar a acurácia da predição quando utilizadas em conjunto com as unidades Hounsfield.

As imagens de Tomografia computadorizada são feitas de pixels, cada um deles sendo uma escala de cinza que vai de 1 (preto) até 256 (branco). Esse valor corresponde a quantidade de raios-X que passam através da estrutura analisada, e podem ser medidos por unidades Hounsfield (HU). HU tem sido utilizada para avaliar e quantificar tecidos e fluidos, por exemplo se a radiodensidade da água for definida como zero, então gordura teria uma HU negativa, e o sangue e outros tecidos um HU positivo. Utilizando unidades Hounsfield é possível identificar 256 níveis de cinza que são indistinguíveis para o olho humano nu. Nos estudos em Urologia recentes, HU tem sido importante não apenas para identificar a pedra, mas também tem sido considerada sua utilização para auxiliar o médico a decidir qual tratamento é o mais adequado.

Além de considerar apenas a unidade Hounsfield, alguns estudos procuraram determinar a eficácia de medir a densidade Hounsfield (Hounsfield Density-HD), que consiste na razão entre a unidade Hounsfield e o máximo diâmetro transversal, para determinar o material da composição da pedra, no entanto não existe um consenso

entre as diversas referências pesquisadas que garanta com certeza um relação tabelada precisa entre o valor do parâmetro HU encontrado para uma pedra específica e sua composição.

Distribuição Normal:

A distribuição normal é a mais importante distribuição estatística considerando tanto termos práticos quanto termos teóricos. Sua importância prática é devido à enorme quantidade de fenômenos naturais e sociais em que a distribuição de uma dada amostra segue a Normal. Sua importância teórica se deve a grande facilidade de converter dados amostrais para percentuais e vice-versa, se a média e o desvio-padrão forem conhecidos. A curva da distribuição normal se assemelha a um sino, e a área sob sua curva soma 100% de probabilidade. Isso significa que a probabilidade de uma observação assumir um valor entre dois pontos quaisquer é igual à área debaixo da curva compreendida entre esses dois pontos.




Figura 3-1 Curva da distribuição normal (forma de sino). As barras verticais mostram a distância da média em múltiplos de desvio-padrão.

A distribuição normal possui quatro propriedades notórias:

- 1- Sua curva é simétrica
- 2-Possui um máximo para $x = 0$, e nesse caso sua ordenada vale 0,39
- 3-Tende a zero quando x tende a $+\infty$ e a $-\infty$
- 4-Possui dois pontos de inflexão cujas abscissas valem média + DP e média - DP.

Para enquadrar uma certa amostra como uma distribuição normal existem os testes de normalidade tais como: teste do Papel de Probabilidade, teste de

Kolmogorov-Smirnov, teste de Anderson-Darling, teste de Shapiro-Wilk e teste de Ryan-Joiner, também é amplamente utilizado o simples teste visual, plotando o histograma da amostra desejada juntamente com uma curva normal de mesmo desvio-padrão e mesma média a fim de averiguar se as duas curvas se assemelham.

Naive Bayes

Os métodos de Naive Bayes são um conjunto de algoritmos de aprendizado baseados na aplicação do teorema de Bayes com a ingênua premissa de que existe independência entre cada par de características intervenientes. Dada uma variável y e um vetor de dados x_1 até x_n , o teorema de Bayes afirma o seguinte:

$$P(y | x_1, \dots, x_n) = \frac{P(y)P(x_1, \dots, x_n | y)}{P(x_1, \dots, x_n)}$$

Mas utilizando a premissa de independência ingenua:

$$P(x_i | y, x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n) = P(x_i | y),$$

Pra todo i , essa relação é simplificada para:

$$P(y | x_1, \dots, x_n) = \frac{P(y) \prod_{i=1}^n P(x_i | y)}{P(x_1, \dots, x_n)}$$

Esse método será utilizado neste trabalho em um dos algoritmos tentados, no qual houve a premissa de que as variáveis intervenientes são independentes entre si, mesmo sem haver uma garantia formal de que essa afirmação seja verdadeira, daí o nome do método - Naive.

4 REQUISITOS DO PROJETO

4.1 DEFINIÇÃO DAS PARTES INTERESSADAS

Devemos definir quais serão os agentes beneficiados e quais serão afetados com o projeto. Como relatado na apresentação do problema, um ganho de tempo da detecção de pedras nos rins significa um ganho econômico para as clínicas de diagnóstico. Este ganho se realiza pelo lado do custo, que é reduzido pela diminuição de tempo dedicado pelo médico funcionário da clínica à atividade de olhar e analisar imagem por imagem. O médico é um agente afetado, pois o êxito do projeto implica na

menor necessidade de médicos, ou em outras palavras, implica que um médico radiologista auxiliado pelo programa desenvolvido neste projeto será capaz de realizar o trabalho de dois, três ou mais médicos. Um terceiro agente afetado é o próprio paciente que será beneficiado pela possibilidade de obter um diagnóstico mais rapidamente e também pela possibilidade de obter exame a preços menores. Dessa forma, três partes interessadas são afetadas pelo projeto: as clínicas de diagnóstico, os médicos radiologistas e os pacientes.

4.2 DEFINIÇÃO DOS REQUISITOS

A análise dos requisitos do sistema foi discutida com médicos radiologistas que possuem ampla experiência na atividade de realizar laudos de pacientes suspeitos de terem pedras nos rins.

O resultado deste Trabalho de Conclusão de Curso consistirá em um recurso ou programa que auxiliará o médico no momento de diagnosticar as imagens de um paciente. Após as imagens terem sido obtidas por tomografia, o médico irá abri-las no programa neste programa e este programa irá analisar as dezenas de imagens (o exame de um único paciente gera mais de 100 imagens) e irá mostrar se o paciente tem pedra ou não, indicando em qual imagem está a pedra, com um alto grau de certeza.

Dessa forma o comportamento do programa final deve ser balizado por dois princípios:

1 - Velocidade: o programa precisa ser veloz dado que propósito do programa consiste em reduzir o tempo gasto pelo médico na detecção da pedra ou na determinação da ausência de pedra. O ganho de tempo do médico na definição dos diagnósticos é a motivação econômica deste trabalho e também é a justificativa da viabilidade da futura utilização do programa em clínicas reais. Portanto, velocidade é um requisito crucial para o programa que se propõe neste Trabalho de Conclusão de Curso.

2 - Confiabilidade: o programa deve indicar o laudo com alto grau de certeza, caso contrário, torna-se um inimigo do médico por atrapalhar ao invés de ajudar, uma vez que em caso de fracasso do programa o médico terá que fazer o retrabalho de analisar cada imagem. Deve-se assim determinar uma taxa de acerto que envolva

tanto os casos de erros de não detecção de pedra que existem (falso negativo) e detecção de pedras que não existem (falso positivo).

Dessa forma os requisitos funcionais do programa são listados a seguir:

- Importar imagens obtidas pelo aparelho de tomografia
- Tratar e processar as imagens
- Fazer o julgamento em cada imagem
- Mostrar ao usuário do programa o resultado da análise de cada paciente

Os requisitos não-funcionais do programa são listados a seguir:

- Realizar a análise de vários pacientes em sequência (pipeline)
- Avaliar a probabilidade (determinada empiricamente) do diagnóstico de cada paciente

4.3 ARQUITETURA E COMPORTAMENTO DO PROJETO

O sistema foi concebido para funcionar no ambiente da sala do médico radiologista. A etapa de realização do exame é anterior à atuação do sistema em si e é realizada pelo técnico, que lida com o paciente, posiciona-o deitado na máquina de Tomografia Computadorizada, obtém as imagens, e as salva.

A utilização do nosso programa propriamente dito é realizada pelo médico, que deve importar as imagens obtidas, dar o comando de início e em seguida validar o resultado gerado pelo programa.

5 METODOLOGIA

5.1 METODOLOGIA DE PROCESSAMENTO DAS IMAGENS

No presente trabalho são testadas algumas técnicas indicadas no estudo da literatura. A metodologia de processamento das imagens utilizada em nosso projeto consistiu nas seguintes etapas:

1. Aquisição das imagens
2. Processamento das imagens
 - Suavização para eliminar ruídos
 - Identificação e localização das pedras
 - Cálculo do tamanho das pedras
 - Localização dos rins (análise de centroide dos rins)
 - Análise estatística da localização de pedras.
 - Análise estatística se uma dada mancha é rim ou não
3. Análise dos resultados e validação

A primeira etapa da análise do problema consiste na inspeção das imagens de TC e para melhor compreensão do problema. A partir dessa análise, poder-se-á reduzir o escopo de técnicas de processamento de imagens para a resolução do problema proposto, refinar os requisitos de solução e entender as características específicas dos rins tais como sua textura nas imagens, variações de tamanho e forma, posições (x,y) e altura (distância relativa entre cortes transversais e tentativa de observar padrões), entre outras.

Com a pesquisa do estado da arte busca-se entender as soluções já propostas para o problema por outros pesquisadores e também compreender as restrições de cada uma. A partir dos resultados já obtidos em outros trabalhos, conseguiremos analisar a precisão e desempenho da solução final proposta neste trabalho.

A etapa de modelagem do problema consiste no levantamento dos requisitos para solução do sistema. No APÊNDICE A, podemos ver os diagramas de casos de uso e de classes para o projeto de software do presente trabalho.

Na etapa de processamento de imagens, inicialmente temos como desafio a identificação das pedras e extração de suas posições (x,y) e áreas nas imagens. Através de uma análise estatística das localizações dos cálculos renais possivelmente será possível já estabelecer uma classificação se dados pontos brancos são pedra, dado que na maioria das vezes os cálculos estão localizados nas mesmas regiões.

Serão estudadas técnicas de segmentação com o intuito de identificar os rins e localizar seus centroides. Essa identificação, contudo, será de difícil execução visto que as imagens dos rins não apresentam grandes diferenças em termos de textura em relação aos demais órgãos vizinhos. Consequentemente, essa etapa será a mais complexa

Além disso, existe a dificuldade de parametrizar as alturas dos cortes nos quais o rim realmente aparece na imagem. Para um dado paciente várias imagens são feitas (correspondendo a cortes transversais em diferentes alturas) e os rins não aparecem em todos esses cortes.

Nossa abordagem inicial para segmentação dos rins será obter os cortes que se referem aos rins por meio da altura desses cortes e a altura esperada da posição dos rins. Para localizar o rim no corte serão utilizados como referências a posição da coluna vertebral e a altura da mesa em que o paciente se encontra deitado, que nas imagens consistem respectivamente de uma mancha branca notória na região central do corpo e de uma linha branca na extremidade inferior. Essas duas referências sempre estão presentes em todas imagens dos cortes.

Obtidos os rins segmentados nas imagens, podemos calcular seus centroides sem grandes problemas. Com os dados dos centroides dos rins em todas imagens, realizar-se-ão análises estatísticas para determinar se uma dada mancha é rim ou não. Com isso, busca-se tornar o processo de identificação dos cálculos renais mais preciso com a extração de mais dados relevantes (pode-se, por exemplo, determinar a distância média dos cálculos ao centroide do rim e excluir aqueles que estejam distantes demais).

Vale observar que talvez a segmentação e localização dos rins nas imagens não traga grandes melhorias na classificação se dado componente branco é cálculo renal. Como anteriormente dito, as posições (x,y) das pedras normalmente se localizam nas mesmas regiões e não são acompanhadas por outros pontos brancos diferentes de cálculos. Assim, as etapas de localização dos rins e análise estatística se uma dada mancha é rim ou não seriam desnecessárias.

Para analisar e validar resultados, é necessária a geração de imagens processadas e os atributos extraídos. Assim, para avaliar se nosso algoritmo está, por exemplo, identificando a região correta da localização dos rins é necessária uma saída no formato de imagens para que possamos validar este fato, sobrepondo a imagem original com as bordas de segmentação. No caso de detecção de pedras nos rins, é interessante gerar tanto uma saída no formato da imagem original como uma de resultado do teste (TRUE, caso paciente com pedras e FALSE, caso contrário). Dessa maneira podemos ver o local do cálculo (se existente) determinado pelo programa e compará-lo com o resultado determinado por radiologistas, verificando a porcentagem de acertos do algoritmo para posteriormente validá-lo ou não.

Neste projeto, serão analisadas imagens de tomografia computadorizada de cerca de 20 pacientes com cálculo renal e de 20 pacientes saudáveis (cada exame de um paciente possui cerca de 200 imagens). O trabalho visa criar um algoritmo capaz de aprender com estas imagens (cerca de 8000) e em seguida ser capaz de diagnosticar, isto é, detectar a presença de pedras nos rins em imagens de exames além da amostra inicial. Dessa forma, busca-se aumentar ainda mais o acervo de imagens para tornar as análises estatísticas mais precisas.


5.2 METODOLOGIA DE DESENVOLVIMENTO DO ALGORITMO

Para desenvolver o algoritmo de diagnóstico fizemos inicialmente algumas seções de *brainstorm* para intuir e elaborar quais dados poderiam influir na decisão do algoritmo e como ou qual relevância cada tipo de dado poderia ter na decisão, obviamente contamos com a opinião de médicos radiologistas durante esta etapa, no entanto a partir deste momento a capacidade analítica e matemática próprias de Engenharia foram exigidas pois é necessário sistematizar a informação disponível e até mesmo decidir qual informação é relevante e qual não é para que a máquina possa classificar os pacientes de forma automática. Tendo então os dados dos pacientes da amostra e sabendo que os futuros pacientes fornecerão dados diferentes porém do mesmo tipo. É razoável raciocinar que estamos construindo uma função cujas entradas serão dados de um específico paciente e os parâmetros da função, isto é, seus coeficientes devem ser construídos empiricamente de modo iterativo a partir dos dados disponíveis na amostra que podemos chamar de amostra de aprendizado.

Fazendo algumas considerações de forma a demonstrar o desafio da construção dessa função de predição, olhemos para as variáveis x e y da localização da pedra em uma dada seção transversal. Salta aos olhos que se trata de uma variável de extrema importância na decisão que se faz ao julgar se um componente branco é pedra ou não. De fato, após obter as posições x e y de todas as pedras da amostra obtivemos a posição central, isto é, posição média tanto para o lado esquerdo quanto para o lado direito, separadamente. Salta aos olhos então que ao diagnosticar um novo paciente que apresente em alguma de suas imagens uma mancha branca com variáveis x e y exatamente no centro da média o algoritmo deve acusar probabilidade máxima de presença de pedra renal para esta imagem deste paciente, ou seja, probabilidade igual a 1. Salta aos olhos também que na ausência de manchas brancas, ou melhor, componentes brancos, em um intervalo razoavelmente distante do centro da média

esta dada imagem deste paciente deve ser classificada com a menor probabilidade possível de apresentar pedra, isto é, zero. Considerando não apenas x e y separadamente mas sim a distância (d) que pode ser obtida a partir de x e y do componente branco dado e o centro médio de pedras da amostra de aprendizado podemos simplificarmente adotar uma função $f(d)$ = probabilidade de ser pedra onde:

$$f(x) = 1 - d/D \text{ p/ } 0 < d < D \text{ e } f(x) = 0 \text{ p/ } d > D$$



Onde $D = 10$ mm foi adotada como a distância a partir da qual a chance de haver pedra é nula. Razoalmente pode-se concordar com dois pontos dessa curva, o ponto de máxima probabilidade e o ponto de mínima. No entanto restam ainda infinitos pontos cuja influência na probabilidade não é facilmente mensurável. Ou seja, o desafio é definir qual é o verdadeiro formato da curva que liga o ponto $(0 ; 1)$ ao ponto $(D ; 0)$ e que talvez não seja uma reta. Outro desafio é ainda definir o quanto uma determinada variável influencia na decisão. Qual o peso de uma variável específica, tal como a distância do componente branco ao centro médio de pedras da amostra de aprendizado.

Com isso posto, podemos resumir que o desafio de construir a função de elaboração de diagnóstico para um dado novo paciente, consiste nos seguintes pontos:

- Determinar quais variáveis estão associadas com a presença de pedra renal.
- Determinar qual a relevância/influência de cada uma destas variáveis na decisão final.

Dessa forma, a construção do algoritmo seguiu etapas iterativas, nas quais tentou-se ajustar os coeficientes da função inicialmente proposta, após testar a função obtida em um conjunto da amostra de aprendizado que ficou reservado para testes naquela rodada específica. Esta técnica de teste de algoritmos conhecida como k-fold. Consiste em reduzir a amostra de aprendizado a 80% da amostra disponível inicialmente, e utilizar os 20% restantes para efetivamente testar a eficácia do algoritmo. Perceba que dessa forma é mantida uma honestidade na construção do algoritmo e garante-se que o teste está preparando o mesmo para enfrentar problemas reais. Caso o autor do algoritmo utilize 100 % da amostra disponível como amostra de aprendizado e depois faça o teste em um subconjunto igual a por exemplo 20% dessa amostra, esta ocorrendo uma forma de trapaça, que pode deixar o algoritmo viciado e certamente menos robusto para abordar e solucionar um problema real que virá de fora da amostra de aprendizado. A imagem a seguir mostra o conceito da técnica do k-fold:




Figura 5-1 Técnica do k-fold: dada uma amostra disponível de aprendizado e o plano de realizar 10 iterações, então deve-se dividir a amostra em 10 partes, treinar em 9 delas, e deixar sempre uma parte para testes.

Deve-se esclarecer ainda que a técnica k-fold é apenas uma dentro de um conjunto de técnicas que objetivam avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados. Trata-se do conceito de Validação Cruzada. Este conceito é amplamente empregado em problemas onde o objetivo da modelagem é a predição. Busca-se então estimar o quão preciso é este modelo na prática, ou

seja, o seu desempenho para um novo conjunto de dados. O conceito central das técnicas de validação cruzada é o particionamento do conjunto de dados em subconjuntos mutuamente exclusivos, e posteriormente, utiliza-se alguns destes subconjuntos para a estimação dos parâmetros do modelo (dados de treinamento) e o restante dos subconjuntos (dados de validação ou de teste) são empregados na validação do modelo. Diversas formas de realizar o particionamento dos dados foram sugeridas, sendo as três mais utilizadas: o método holdout, o leave-one-out, e o k-fold.

Com base nesta exposição de racional para construir funções de realização de diagnóstico de exemplares futuros baseadas em amostras disponíveis, poderemos então mostrar quais foram os três principais estratégias de construção da função de predição que adotamos, assim como relatar as dificuldades envolvidas e resultados obtidos em cada uma delas.

6 PRÉ-PROCESSAMENTO DE IMAGENS

Após a leitura de imagens médicas no formato “dicom”, as imagens foram abertas para visualização sem a utilização do programa proprietário da GE (empresa fabricante do aparelho de tomografia computadorizada utilizado para a aquisição das imagens médicas). Assim, inicialmente estudou-se a utilização de três ferramentas de software para abertura e processamento de imagens: Medical Imaging Interaction Toolkit (MITK) (The Medical Imaging Interaction Toolkit, 2017), MATLAB e Open Source Computer Vision Library (OpenCV) (Open Source Computer Vision Library, 2017).

A primeira ferramenta, MITK (The Medical Imaging Interaction Toolkit, 2017), é um software aberto para desenvolvimento de processamento iterativo de imagens médicas que inclui diversas bibliotecas em C++ otimizadas para o processamento de imagens médicas e biblioteca para abrir imagens médicas no formato padronizado “dicom” já integrada à ferramenta. O MITK suporta apenas os sistemas operacionais Windows e Ubuntu.

O software MATLAB (MathWorks, 2017), consiste de um software interativo desenvolvido pela empresa *MathWorks* que é voltado para o cálculo numérico. Ele possibilita análises numéricas, cálculo com matrizes, processamento de sinais, construção de gráficos e interfaces com o usuário.

O OpenCV (Open Source Computer Vision Library, 2017), por sua vez, é uma ferramenta bastante utilizada tanto em ambiente acadêmico como comercial com forte enfoque em eficiência computacional e aplicações em tempo real. As bibliotecas do OpenCV são desenvolvidas em C/C++ com a possibilidade de desenvolver interfaces em C, C++, Python, Java e suporta sistemas operacionais Windows, Mac OS, iOS e Android.

A plataforma MATLAB foi a escolhida para o desenvolvimento do protótipo inicial por nossa familiaridade com ela, disponibilidade de grande variedade de ferramentas para processamento de imagens e pelo fato de que não temos como requisito de projeto o processamento das imagens médicas em tempo real (alta performance não é extremamente necessária nessa primeira abordagem).

Para o projeto final de software pode-se optar por uma biblioteca aberta. Isso se deve à grande comunidade de usuários ativos contribuindo para o desenvolvimento da biblioteca, grande quantidade de recursos (vídeos, documentações bastante completas, etc.) e alta performance (maior velocidade de processamento, alocação de memória mais eficiente, entre outros). O ambiente do OpenCV, entretanto, não possui bibliotecas nativas para lidar com imagens do tipo “dicom”. Dessa forma, é necessária a inclusão no ambiente de desenvolvimento integrado (IDE) uma biblioteca para lidarmos com imagens “.dcm”.

Ao abrir as imagens “dicom” para visualização utilizando funções tanto na plataforma MATLAB como da biblioteca incluída ao OpenCV as imagens abertas apresentaram distorção visual quando comparadas às imagens apresentadas na saída do programa da GE (software disponibilizado pela própria empresa para abertura das imagens “dicom”) como mostrado na Figura 6-1.





Figura 6-1 Visualização da imagem de TC no software proprietário da GE (esquerda) e em no ambiente MATLAB (direita).

Dessa forma, transformamos as imagens de formato .dicom para formato .jpeg a fim de obter imagens visualmente adequadas.

O problema desta extração está no fato de que o programa da GE nos possibilita salvar apenas uma imagem de cada vez. Estamos trabalhando com milhares de imagens (40 pacientes x ~200 imagens/paciente = ~8000 imagens) e para realizar a extração de todas elas utilizamos o programa DICOM Converter da empresa DICOM Apps que faz a conversão “.dcm” para “.jpg”.

7 PROCESSAMENTO DE IMAGENS

7.1 EXTRAÇÃO DE COMPONENTES BRANCOS

Uma vez obtidas todas as imagens em formato “jpeg” começamos a etapa de processamento de imagens.




Figura 7-1 Imagem TC Original.

Inicialmente realizamos a limiarização de cada imagem a fim de detectar pixels mais brancos. Em seguida realizamos um processo morfológico de fechamento usando um elemento estruturante no formato de disco de 4 pixels de diâmetro. Esse processamento morfológico é utilizado para eliminar pixels pretos dentro das regiões brancas da imagem usando binarização. O passo a seguir é realizar a segmentação da imagem binária para identificar os componentes (objetos) brancos e finalmente calcular as áreas e centróides de todos esses objetos brancos.

Uma imagem original e sua respectiva imagem binária e tabela resultantes do processamento são mostrados na Figura 7-1, Figura 7-2 e Figura 7-3, respectivamente.




Figura 7-2 Imagem binária resultante com componentes brancos

Variables - ct.Area		ct.Area		ct.Centroid			ct.Is_Kidney_Stone	
ct	1x1 ct_image	15x1 double		15x2 double			15x1 double	
Property	Value	1	2	1	2	3	1	2
Area	15x1 double	1	166	1	110.6747	351.3614	1	0
Centroid	15x2 double	2	5	2	138	464	2	0
Is_Kidney_Stone	15x1 double	3	7	3	147	465	3	0
Image_ID	'1PA4IM100'	4	8	4	156.5000	466	4	0
		5	146	5	168.9521	393.0342	5	0
		6	10	6	168.5000	467	6	0
		7	220	7	264.1364	466.5182	7	0
		8	54	8	204.5741	393.7593	8	0
		9	6	9	208.8333	351.1667	9	0
		10	588	10	257.3861	357.6514	10	0
		11	532	11	266.0846	391.4662	11	0
		12	2	12	358.5000	217	12	0
		13	122	13	372.5492	369.7213	13	0
		14	25	14	372.6400	454.1200	14	0
		15	142	15	416.9437	317.7676	15	0
		16		16			16	

Figura 7-3 Tabela resultante após o processamento em ambiente MATLAB.

O trecho do código em MATLAB que realiza o processamento de uma imagem para identificar componentes claros é mostrada no Apêndice B.




Figura 7-4 Limiar da mascara identificando pedras




Figura 7-5 Limiar de máscara muito baixo




Figura 7-6 Limiar máscara sem identificar pedra

7.2 DENSIDADE AO REDOR DOS COMPONENTES BRANCOS

Fizemos um quadrado em volta de todos os pontos brancos presentes nas imagens, em seguida subtraímos os pixels brancos, e então dividimos os pixels restantes pelo valor da área do quadrado. Este procedimento nos permite obter um parâmetro a mais (densidade de pixels na vizinhança de cada ponto branco) que será utilizado em conjunto com os demais parâmetros (x, y, z e área) para determinar a chance de que um dado ponto branco seja pedra.




Figura 7-7 Extração de vários pontos brancos cuja vizinhança terá a densidade calculada



Figura 7-8 Exemplo de ponto branco que foi retirado da imagem anterior. Trata-se de parte da seção da coluna vertebral.




Figura 7-9 Extração utilizada no cálculo de densidade de vizinhança de componente branco retirado neste exemplo da figura 7-7.



Figura 7-10 Nesta figura foi tratado o componente branco que se destaca no centro da seção da coluna vertebral



Figura 7-11 Componente branco bem próximo à mesa em que paciente está deitado. Importante destacar pois o algoritmo irá tratar esse tipo de ponto também.



Figura 7-12 Por fim uma pedra propriamente dita, retirada da figura 7-7. A densidade de sua vizinhança será útil na construção de uma função de probabilidade para dignosticar cada componente branco candidato a ser pedra.

7.3 SEGMENTAÇÃO DO RIM

O programa da GE possui uma ferramenta que possibilitou examinar a média e desvio padrão da região dos rins em unidades HU nas imagens. A partir de uma inspeção visual nessa região, percebemos que o rim apresentava em grande parte das imagens uma média que variava em torno de 33 HU. Isso pode ser observado na Figura 5-4 abaixo:




Figura 7-13 Ferramenta de visualização de médias e desvios padrões em unidades HU do software proprietário da GE. Na legenda, 1 e 3 se referem as médias em HU das áreas retangulares sobre os rins enquanto que 2 se refere a média em HU do fígado (39,7 HU).

Por esse motivo, buscamos entender a equivalência entre HU e a intensidade em tons de cinza. Partindo desse ponto, tentamos determinar se os rins possuem um nível de cinza isolado, que permitiria identificá-lo, mesmo em meio a órgãos vizinhos, coisa que para o olho humano analisando a imagem de tomografia é muito difícil pois não se vê diferença de intensidade de cinza entre esses diferentes órgãos.

A partir de uma inspeção dos pixels das imagens e dos próprios dados de médias e desvios padrões em HU do programa da GE, podemos observar que as diferenças entre as características do rim e dos demais órgãos é muito pequena. Por esse motivo, a utilização das imagens no formato jpeg não é recomendável pois tem resolução de apenas 8 bits enquanto que as dicom têm 16 bits. Perderíamos muitos dados ao utilizar as imagens jpeg.

Assim, inicialmente filtramos as imagens dicom com um filtro de média de forma a tornar os valores de intensidade dos pixels mais uniformes. Em seguida fizemos então uma limiarização de cada imagem a fim de detectar pixels em torno do nível 1050. A partir disso criamos uma imagem binária com diversos pixels próximos desse nível. Conectamos os pixels de modo a selecionar apenas os componentes maiores uma vez que os rins ocupam áreas grandes na imagem, num processo similar ao utilizado para o processamento de manchas brancas anteriormente.

A partir desse processamento, foi possível obter componentes conectados e suas respectivas áreas. Selecionamos os 3 componentes de maior área e com o valor de intensidade de pixels próximo a 1050. Para que fosse possível a visualização, utilizamos as imagens jpeg apenas para esse fim, e obtivemos o seguinte resultado mostrado na Figura 5-5:




Figura 7-14 Resultado do processamento da imagem de forma a selecionar pixels com intensidade próxima a 1050. Nesse teste as 3 maiores áreas de componentes conectados foram selecionadas.

Já com essas medidas foi possível destacar os rins nas imagens. Entretanto, em grande parte das vezes os rins não são selecionados pois não estão entre os componentes conectados de maior área. Quando se aumenta demais os limiares máximo e mínimo próximo a 1050, começa a selecionar múltiplos órgãos. O mesmo ocorre quando se aumenta o número de componentes de grande área. A medida que testamos selecionar os 5 ou mais componentes de maior área os rins sempre estão presentes, contudo existem muitos órgãos ao seu redor também selecionados. Além disso, em muitos casos, apenas uma pequena região do rim é selecionada e assim ele não é segmentado perfeitamente.

Para aperfeiçoar este resultado pretendemos refinar este processo estabelecendo um critério relacionando as coordenadas x, y e z. Com essa informação adicional acreditamos que será possível detectar o rim com mais eficiência.

Uma vez isolados os componentes dos rins, para solucionar o problema que temos quando apenas uma parte do rim é selecionada utilizaríamos o algoritmo de crescimento de região. Dessa maneira, todos os pixels do rim seriam identificados a partir desse componente incompleto inicial até que a borda fechada do conjunto do rim

seja atingida. Em outras palavras, se iniciaria com o componente incompleto que já sabemos que se encontra sobre o rim. A partir desses pixels os pixels ao seu redor são incorporados aos componente ate que atinja-se a borda da fronteira do rim, segmentando-o assim por completo.

Para a extração dos centroides dos rins na imagem utilizamos a função “Canny” disponível em MATLAB para detectar as bordas de presentes na imagem. O método “Canny” encontra bordas procurando por máximo gradiente local na Imagem. Os gradientes são calculados usando as derivadas de um filtro Gaussiano. Além disso método utiliza dois limiares para detectar bordas fortes e fracas, o que o torna menos suscetível a incluir erros decorrentes de ruídos na imagem, detectando apenas bordas fracas verdadeiras. A imagem binária resultante após detecção de bordas pelo método “Canny” utilizando limiares default no MATLAB é mostrada na Figura 7-15.




Figura 7-15 Detecção de bordas (função “canny”).

Com isso, uma imagem binária com diversas bordas é gerada. Por meio do comando “bwlabel”, cada uma das bordas tem seus pixels conectados e é rotulada com números inteiros consecutivos. Através da inspeção manual da imagem binária visualiza-se o rótulo dado após a execução da função “bwlabel”. Escolhendo-se esse rótulo foi possível sobrepor as duas imagens original e binária como mostrado na Figura 7-16.




Figura 7-16 Imagem TC sobreposta a imagem com rótulo da borda do rim.

A segmentação dos rins ainda não foi concluída. A ideia do processo anteriormente descrito é localizar e segmentar os rins na imagem através da interação com o usuário. Dessa forma, uma das ideias que foram testadas consiste de segmentar com um clique do mouse sobre qualquer pixel de uma região que se saiba que faz parte do rim. Usando a técnica de crescimento de região todos os pixels do rim são identificados a partir desse ponto até que a borda fechada do conjunto do rim seja atingida. A outra abordagem que também está sendo realizada é buscar a borda mais próxima do clique do mouse, torna-la conjunto fechado a partir de aproximações, e rotular a borda como borda do rim utilizando processo semelhante ao já implementado para rotulação de cálculos renais. Uma vez determinada a borda do rim, calcular seu centroide não será problema.

7.4 METADADOS DICOM

A partir das imagens originais no formato dicom, pode-se extrair os metadados que acompanham a imagem referentes as condições em que as imagens foram extraídas como, por exemplo, o modelo do equipamento médico, a voltagem e frequência de aquisição das imagens, etc.

Dessa maneira, informações como altura da mesa onde o paciente estava posicionado, sexo do paciente, altura do corte em z, entre outros foram consideradas em conjunto com as imagens, sendo que, as informações realmente utilizadas para diagnosticar pedras foram cinco: localização do componente branco candidato a ser pedra (x, y e z), área e densidade de pixels do entorno do componente branco.

Além da localização e tamanho da pedra e da saúde geral do rim, a Tomografia Computadorizada permite avaliar a densidade da pedra em Hounsfield units (HU). A unidade Hounsfield, medida pela Tomografia Computadorizada se relaciona com a densidade do tecido ou da pedra. As imagens de Tomografia computadorizada são feitas de pixels, cada um deles sendo uma escala de cinza que vai de 1 (preto) até 256 (branco). Esse valor corresponde a quantidade de raios-X que passam através da estrutura analisada, e podem ser medidos por unidades Hounsfield (HU). HU tem sido utilizada para avaliar e quantificar tecidos e fluidos, por exemplo se a radiodensidade da água for definida como zero, então gordura teria uma HU negativa, e o sangue e outros tecidos um HU positivo. Utilizando unidades Hounsfield é possível identificar 256 níveis de cinza que são indistinguíveis para o olho humano nu. Nos estudos em Urologia recentes, HU tem sido importante não apenas para identificar a pedra, mas também tem sido considerada sua utilização para auxiliar o médico a decidir qual tratamento é o mais adequado. O fabricante do aparelho de TC também fornece a relação matemática entre densidade de pixels e unidades HU, que é dada por:

$$HU = RescaleSlope \times pixelDensity - RescaleIntercept$$

onde os coeficientes *RescaleSlope* e *RescaleIntercept* também são fornecidos pelo fabricante e são dados por: *RescaleSlope* = 1; e *RescaleIntercept* = -1024.

Além de considerar apenas a unidade Hounsfield, alguns estudos procuraram determinar a eficácia de se medir a densidade Hounsfield (Hounsfield Density-HD), que consiste na razão entre a unidade Hounsfield e o máximo diâmetro transversal, para determinar o material da composição da pedra, a seguinte tabela mostra os resultados obtidos por um estudo específico:

Ranges and Means with 95% confidence interval for HU and HD of Urinary Stones

Stone groups	95% confidence interval for mean		Minimum	Maximum
	Lower bound	Upper bound		
HU				
Calcium oxalate	448.2	760.8	495	1250
Uric acid	260.3	348.7	274	401
Calcium phosphate	435	631	290	945
Struvite	282.5	373.6	225	396
Cystine	108.9	191.6	112	215
HD				
Calcium oxalate	49.94	68.19	53	179.8
Uric acid	23.63	41.2	15.8	43
Calcium phosphate	37.97	52.6	29.22	98
Struvite	20.29	38.2	14.87	39.9
Cystine	11.52	16.09	11.97	14.95

HU = Hounsfield unit; HD = Hounsfield density

7.5 RECORTE DOS RINS


Assim como percorremos todas as imagens clicando em cada pedra renal para coletar seus dados de área e localização, também percorremos todas as imagens que tinham rins recortando polígonos em torno deles para coletar os dados dos mesmos como por exemplo textura (que consiste na média das intensidades dos rins).

8 INTERFACE HOMEM-MÁQUINA

8.1 INTERFACE PARA COLETAR DADOS DAS PEDRAS

Criamos uma interface gráfica homem-máquina para facilitar a rotulação dos componentes brancos que são pedras de rim. Assim, com o evento de um clique do mouse sobre a imagem médica aberta, captura-se as coordenadas (x,y) do clique, busca-se o centroide do componente branco mais próximo a esse ponto e rotula-se tal componente como pedra.

A Figura 8-1 mostrada a seguir apresenta a interface homem-máquina para rotulação de pedras. Nela, pode-se ver o cursor do mouse o mais próximo possível do cálculo. Assim, busca-se o centroide branco mais próximo do local clicado e rotula-se tal ponto como pedra. A tabela do ambiente MATLAB na figura mostra que a rotulação teve êxito após o clique (rótulo de valor igual a 1 para centroide do cálculo).



x do centroide	y do centroide	É pedra (1) ou não é (0)
110,7	351,4	0
138,0	464,0	0
147,0	465,0	0
156,5	466,0	0
169,0	393,0	0
168,5	467,0	0
264,1	466,5	0
204,6	393,8	0
208,8	351,2	1
257,4	357,7	0

Figura 8-1 Interface gráfica de rotulação indicando posição do clique do mouse para usuário (esquerda). Tabela de rotulação dos componentes brancos com posição (x,y) do centróide e informação se é pedra.

Ao observar-se que algumas vezes devido ao limiar utilizado para tornar a imagem binária pontos brancos não foram detectados (e consequentemente algumas

pedras não puderam ser rotuladas), percebeu-se a necessidade de aprimorar a interface.

Além disso, após o clique do mouse, visualmente não era possível saber onde efetivamente uma pedra havia sido registrada pelo programa, (clitava-se sobre um ponto branco, porém poderia ocorrer de a pedra ser rotulada num outro ponto branco diferente que o desejado pelo usuário). Não era possível supervisionar o que fora feito uma vez que apenas comparar as posições x e y dos pixels de pontos brancos capturados pelo clique não era eficiente. Por exemplo, ao passar por uma imagem uma vez clicou-se próximo a uma mancha que acreditava-se ser pedra, porém ela estava tão próxima a primeira, que a segunda mancha branca foi a salva pelo clique e nada foi percebido até posterior análise das coordenadas x e y . Isso pode causar uma perda de qualidade nas informações de localização x e y dos centroides de cálculos renais, tornando o modelo final de predição mais impreciso.

Para capturar essas informações de forma mais sistemática e eficiente, a interface foi aprimorada com um mecanismo que funcionou como uma máscara de cada imagem: ao avançar na análise das imagens, os pontos brancos que satisfaziam o limiar necessário para ser considerado ponto branco e portanto candidato a ser pedra recebiam uma mancha de vermelho. Dessa forma ao analisar todas as imagens em sequência, pudemos passar por cada imagem rapidamente, sabendo que se alguma pedra estivesse presente, ela estaria marcada em vermelho. Evidentemente outras manchas também poderiam receber a marca vermelha, então cabia a aquele que estivesse analisando diferenciar qual mancha era pedra e qual não era. Dessa forma, toda vez que se deparou com uma pedra, ela estava manchada de vermelho e nós clicávamos nela. Pode-se assim ajustar-se o limiar para selecionar-se os pontos suficientemente claros de forma a conter os cálculos, resolvendo um dos problemas anteriormente citados.

Para solucionar o problema de supervisionamento, adicionamos na interface um método que gerava um rótulo “x” sobre o ponto capturado pelo clique do mouse. Assim foi possível demonstrar que o programa realmente registrou a mancha a qual nos referimos. A solução final da interface é mostrada na Figura 6-2 abaixo:




Figura 8-2 Interface gráfica final com máscara vermelha de rotulação indicando posição do clique do mouse para usuário (esquerda) e Interface gráfica final após o clique do mouse indicando mancha branca registrada

Em seguida, realizamos um laço para percorrer todas as imagens de todos os pacientes e utilizamos as funções criadas para processar todas as imagens uma a uma e extrair os dados (área e centroide) dos componentes brancos que realmente são cálculos renais.

Dessa forma, pudemos percorrer todas as imagens, utilizando este programa de MATLAB, capturando as informações das pedras, por vezes utilizando a ajuda de um médico radiologista de ampla experiência, para sanar dúvidas, como por exemplo: pedras muito pequenas ou pedras muito grandes, e também pedras que apareciam em muitas imagens. Nestes casos, a orientação do especialista foi imprescindível.

8.2 INTERFACE PARA COLETAR DADOS DOS RINS

Com o propósito de estudar e adquirir informações mais detalhadas sobre os rins, elaboramos um programa em MATLAB que permitiu recortar os rins das imagens. Esses recortes foram feitos por meio de polígonos, cujos vértices foram determinados por meio de cliques feitos visualmente. Para que a rotina fosse mais eficiente em relação ao tempo e à informação, a imagem mostrada para ser clicada era em formato JPEG, mas a informação capturada vinha da imagem original em formato DICOM. Com esses recortes foi possível obter uma coleção de dados como as áreas dos rins e em seguida obter a média dessas áreas. A interface pode ser mostrada nas imagens a seguir:




Figura 8-3 Observar o polígono elaborado manualmente. Polígonos como esse foram feitos para cada imagem com rim em toda a amostra.




Figura 8-4 Imagem do recorte obtido de um rim. Os recortes foram feitos cuidadosamente para minimizar a contaminação da imagem com tecidos vizinhos, o que poderia deturpar os cálculos de densidades dos rins.



Figura 8-5 Mesma imagem que a figura 8-4, porém em formato DICOM. O formato DICOM possui mais detalhe e foi efetivamente recortado, porém para fins de visualizar a imagem em um computador Windows, foi utilizado o formato JPEG.

9 TRATAMENTO ESTATÍSTICO

9.1 DADOS DAS PEDRAS

Após a extração das posições (x,y) de todas as pedras em todas as imagens utilizando a interface homem-máquina, imprimiram-se todos os pontos dos centroides dos cálculos renais rotulados sobrepostos em uma imagem arbitrária. Na Figura 7-1 a seguir é mostrado o resultado:




Figura 9-1 Centroides de cálculos renais de todas as imagens sobrepostos em uma imagem de fundo arbitrária para melhor visualização.

De posse desse conjunto de dados, pudemos também calcular a média de localização em x, a média de localização em y, o desvio padrão assim como a maior distância em relação à média. Tal procedimento foi feito para cada um dos dois lados, já que evidentemente, se isso fosse feito sem considerar que são dois lados, o resultado de média de localização cairia próximo a coluna vertebral, um dado não muito útil para a resolução do problema dado sua simetria. Os pontos médios de x e y para os dois lados são mostrados na imagem a seguir:




Figura 9-2 Pontos médios dos centroides de cálculos renais de todas as imagens sobrepostos em uma imagem de fundo arbitrária para melhor visualização.

Além disso, foram calculadas as áreas mínima e máximas das pedras obtidas, assim como média em z, e o desvio padrão em z, novamente para os dois lados. O tratamento das informações em z, permite observar e registrar a ocorrência das pedras situando-as em relação à altura do corte da imagem do paciente. A tabela com os dados obtidos após a primeira etapa de cálculos estatísticos é mostrada a seguir na Tabela 1.

Área média	60.02
Área máxima	560
Área mínima	1
Desvio Padrão Área	97.53
Média Posição lado direito (xy)	(326.97, 279.25)
Média Posição lado esquerdo (xy)	[174.57, 284.30]
Desvio Padrão lado direito (xy)	[15.28, 28.06]
Desvio Padrão lado esquerdo (xy)	[19.50, 26.54]
Raio máximo do cálculo a média do lado direito	65.09
Raio máximo do cálculo a média do lado esquerdo	119.73
Altura média lado esquerdo (z)	-129.9
Altura média lado direito (z)	-132.1
Desvio padrão da Altura lado esquerdo (z)	33.36
Desvio padrão da Altura lado direito (z)	37.71
Máxima distância da média lado esquerdo (z)	112.47
Máxima distância da média lado direito (z)	95.90

Tabela 1 Dados obtidos das imagens processadas. Vale observar que os valores aqui mostrados se referem a número de pixels (tanto em área como em distâncias)




Figura 9-3 Distribuição estatística dos valores de x para as pedras do lado esquerdo.




Figura 9-4 Distribuição estatística dos valores de x para as pedras do lado direito.




Figura 9-5 Distribuição estatística dos valores de localização y para as pedras do lado esquerdo.




Figura 9-6 Distribuição estatística dos valores de localização y para as pedras do lado direito




Figura 9-7 Distribuição estatística dos valores de localização z para as pedras do lado esquerdo.




Figura 9-8 Distribuição estatística dos valores de localização z para as pedras do lado direito.




Figura 9-9 Distribuição estatística dos valores de área obtidos para todas as pedras da amostra. Observar a comparação com outras curvas estatísticas conhecidas.

9.2 DADOS DOS RINS

Com a análise individual de cada rim, que teve sua imagem recortada e posteriormente analisada, obtivemos os dados de densidade dos rins, tais como, densidade máxima encontrada, densidade mínima, média de densidade considerando todos os rins da amostra, e desvio padrão para essa amostra de densidades. Essas informações podem ser visualizadas na Tabela a seguir:

Densidade máxima de Rim	1134.70
Densidade mínima de Rim	931.25
Densidade Média de Rim	1048.06
Desvio padrão da densidade dos Rins	11.39

Tabela 2 Dados calculados das imagens obtidas recortando os rins.

10 DESENVOLVIMENTO DOS ALGORITMOS DE DIAGNÓSTICO

10.1 PREDIÇÃO BASEADA NA DISTRIBUIÇÃO NORMAL

A predição de pedras baseada em distribuição normal se baseia na premissa de que as cinco variáveis analisadas se distribuem como uma normal e esse fato permite que adotemos intervalos de valores para essas variáveis que nos permitam afirmar com certo nível percentual de certeza que determinado componente branco por apresentar valores dentro daquela faixa específica é pedra. Dessa forma a saída que o algoritmo oferece é o resultado de dizer se é pedra ou não é. Evidentemente a sensibilidade do algoritmo depende de qual intervalo (distância em relação à média) foi adotado. O raciocínio para classificar um componente branco é razoavelmente simples. Adotamos um intervalo de confiança de 95% o que implica uma distância de 2 desvios-padrão em relação à média, e analisamos o componente branco, para cada uma de suas cinco características (localização x, y e z, área e densidade de vizinhança). Se o dado componente satisfazer o intervalo para cada um dos cinco parâmetros então é considerado pedra com 95% de certeza.




Figura 10-1 Imagem que mostra uma classificação feita com o algoritmo baseado em distribuição normal

O espaço para flexibilizar esse algoritmo de acordo com a amostra seria apenas alterar o intervalo de confiança escolhido, o que não é muito eficaz, como foi constatado em testes que mostraram muitos falsos positivos e falsos negativos. Dessa forma, foram desenvolvidos mais dois algoritmos, baseados em raciocínios distintos, descritos a seguir.

10.2 PREDIÇÃO BASEADA EM NAIVE BAYES

O algoritmo de Naive Bayes, utiliza o teorema da probabilidade condicional, que implica na prática que a probabilidade de um evento acontecer, condicionado a ocorrência de outros eventos que sejam independentes é igual ao produto das probabilidades de cada evento independentemente. É chamado de Naive por admitir a

premissa de que as características são independentes entre si, o que não pode ser provado e que não necessariamente seja válida. É utilizada principalmente na avaliação de fenômenos biológicos. No caso deste trabalho por exemplo, não há como provar formalmente que a distância da pedra em x seja independente de sua área, ou de sua distância em y. No entanto, o algoritmo utilizando o princípio de Naive Bayes admite essa premissa. Dessa forma o algoritmo utilizou 5 propriedades presentes nas imagens para realizar um aprendizado e julgar eficazmente qual componente branco é pedra e qual não é. As 5 propriedades utilizadas em cada componente branco são:

- Localização x
- Localização y
- Localização z
- Área
- Densidade calculada em sua vizinhança

Para ensinar e testar o algoritmo usando Naive Bayes utilizando a amostra de imagens disponíveis, organizamos todos os componentes brancos em uma lista, que totalizou um pouco mais de 306 mil componentes brancos. O cabeçalho e o pé da lista são mostrados nas imagens abaixo:

	A	B	C	D	E	F	G	H	I	J	K	L
1	x	y	z	area	density	gender	age	patient_state	table_height	number_PA	number_IM	is_stone
2	254.63	420.13	-424.95	666	563.96f	1	27	1	115.5	0	0	0
3	106.43	274.31	-424.95	2358	2278f	1	27	1	115.5	0	0	0
4	105.5		245	-424.95	2	1317.5f	1	27	1	115.5	0	0
5		127	241	-424.95	1	1209.3f	1	27	1	115.5	0	0
6	142.5		484	-424.95	2	-816.72f	1	27	1	115.5	0	0
7	201.67		289	-424.95	1357	1448.4f	1	27	1	115.5	0	0
8	316.91	295.86	-424.95	1406	1561.1f	1	27	1	115.5	0	0	0
9	371.5		483	-424.95	2	-772.48f	1	27	1	115.5	0	0

Figura 10-2 Cabeçalho da lista que contém os dados dos mais de 300 mil componentes brancos disponíveis.

306089	378.67	181	-356.75	18	723.87f	0	39	1	105.5	22	82	0
306090	382	189.5	-356.75	2	602.39f	0	39	1	105.5	22	82	0
306091	394.83	183.5	-356.75	12	808.82f	0	39	1	105.5	22	82	0
306092	409.29	174.47	-356.75	258	917.99f	0	39	1	105.5	22	82	0
306093	420.48	312.09	-356.75	227	1050.8f	0	39	1	105.5	22	82	0
306094	435.09	240.36	-356.75	230	718.06f	0	39	1	105.5	22	82	0

Figura 10-3 Pé da lista, mostrando os últimos componentes brancos.

Claramente, de todos esses mais de 300 mil componentes brancos a quase totalidade consiste de não-pedras, que são traquéia, ossos de costelas, do esterno, da coluna vertebral, da bacia etc, e o objetivo do algoritmo é atribuir uma probabilidade a

cada uma delas de ser ou não ser pedra, utilizando as variáveis que estão presentes nas 5 primeiras colunas da esquerda.

Implementamos ainda uma rotina que criou diferentes combinações das 5 entradas disponíveis para alimentar o algoritmo de Naive Bayes. Com 5 variáveis sabemos da teoria de Análise Combinatória que existem $2^5 = 32$ possibilidades de combinação, exceto a combinação que não utiliza nenhuma variável, ou seja existem 31 possibilidades de entradas para o algoritmo. Esse número também é obtido ao se somar número de combinações de 5 elementos tomados 1 a 1; tomados 2 a 2; tomados 3 a 3; tomados 4 a 4 e tomados 5 a 5.

$$31 = \binom{5}{1} + \binom{5}{2} + \binom{5}{3} + \binom{5}{4} + \binom{5}{5}$$

Após executar as 31 combinações de entradas, obtivemos os resultados gerados para cada caso, tais como: percentual de diagnósticos corretos e percentual de falsos negativos. Uma distribuição de resultados é mostrada na imagem a seguir:




Figura 10-4 Distribuição de resultados para 31 combinações de entradas. Notar que existem pontos sobrepostos.

A partir dessa distribuição deve-se decidir qual combinação é a mais adequada. Nós consideramos que o erro de falso negativo é muito grave e deve ser evitado ao máximo, mesmo que isso implique em sacrificar levemente o percentual total de predições corretas. Na distribuição acima temos então a escolha pela combinação marcada pelo x em vermelho como sendo a combinação que produziu os resultados mais adequados para um contexto médico em que diagnosticar um paciente doente como saudável seria um caso simplesmente inaceitável.

Para exemplificar o resultado do algoritmo de Naive Bayes em alguns componentes brancos reais, a tabela a seguir mostra a probabilidade produzida especificamente considerando apenas as posições x e y:

x	y	Probabilidade de ser pedra
256,93	423,00	0
126,00	380,00	0
130,00	381,00	0
141,50	316,80	0,585
165,89	258,00	0,95
201,00	391,00	0
255,00	268,00	0
259,26	322,00	3,29e-5
368,00	485,00	0
371,50	485,00	0

Tabela 3 - Resultados de probabilidade obtidos para 10 componentes brancos avaliando apenas x e y.

Os dez componentes brancos cuja análise foi apresentada na figura acima, são referentes a um paciente e no caso houve um componente acusado com chance elevada (95%) de ser pedra, enquanto outro apresentou chance razoável (58,5%). Dessa forma esse paciente, para o qual esses 10 componentes brancos se referem é um paciente diagnosticado com pedra no rim. A pedra encontrada pode ser mostrada na imagem a seguir:




Figura 10-5 Imagem mostrando pedra no rim corretamente detectada.

Na imagem acima, além de mostrar que a pedra foi corretamente detectada é importante notar que o componente branco logo abaixo foi corretamente classificado como não-pedra. Neste caso é uma seção de osso de costela.

Os resultados gerados com as diversas combinações usando as 5 variáveis mostraram que as mais relevantes foram x, y, z e densidade da vizinhança do componente branco.

Além de analisar o impacto de cada uma das cinco variáveis na saída do algoritmo, avaliamos também o impacto da variação de limiar mínimo de probabilidade necessária para um componente branco ser considerado pedra. Como é de se esperar exigindo um limiar mais elevado tende-se a aumentar a acurácia, no entanto aumenta

também a tendência de ocorrerem falsos negativos, pois por exemplo, uma pedra que estava afastada no centro médio de pedras, ou com qualquer outra característica distante da média pode receber uma baixa probabilidade de ser pedra, não passar do limiar mínimo e ser considerada não-pedra, produzindo assim um diagnóstico falso-negativo, o que não é aceitável. Portanto, a escolha de um limiar adequado é crítica para a efetiva realização dos diagnósticos, mesmo que isso implique em menor acurácia ao gerar um maior número de falsos-positivos. As duas imagens a seguir são o resultado de execução do algoritmo com diversos valores de limiar:




Figura 10-6 Gráfico que mostra a dependência da acurácia com o valor de limiar mínimo




Figura 10-7 Gráfico que mostra como a ocorrência de falsos-negativos aumenta com o aumento do limiar mínimo

Na figura acima podemos notar como aumenta a ocorrência de falsos-negativos, especialmente para limiar acima de 0,7. Devemos então adotar valores de limiar abaixo de 0,7 pois não é aceitável dizer a um paciente doente que ele está saudável. Como podemos notar também da figura 10-5, a acurácia não é grandemente afetada em torno de limiar = 0,7.

10.3 PREDIÇÃO DE PROBABILIDADE EMPÍRICA

Na predição empírica de diagnósticos é criada uma função que soma as contribuições dos cinco fatores intervenientes. Cada parcela do somatório se refere a um fator específico e possui peso que é determinado empiricamente. As parcelas do somatório por si só são funções do parâmetro a que se referem. E os pesos podem ser inicialmente já estimados com certa qualidade uma vez que durante o algoritmo anterior (Naive Bayes) já foi observado o impacto de cada uma das cinco variáveis. A função que dá o valor da chance de um componente branco ser pedra será a função $P(x,y,z,t,A)$. É uma função cujas variáveis são a localização da pedra em x, y e z; o

valor da densidade da vizinhança do componente branco (t) e o valor da área do componente branco (a). A função P é dada por:

$$P(x, y, z, t, A) = f\left(\left|\frac{x_i - \bar{x}}{3 \times \sigma_x}\right|\right) \times \alpha_x + f\left(\left|\frac{y_i - \bar{y}}{3 \times \sigma_y}\right|\right) \times \alpha_y + f\left(\left|\frac{z_i - \bar{z}}{3 \times \sigma_z}\right|\right) \times \alpha_z \\ + f\left(\left|\frac{t_i - \bar{t}}{3 \times \sigma_t}\right|\right) \times \alpha_x + f\left(\left|\frac{A_i - \bar{A}}{3 \times \sigma_A}\right|\right) \times \alpha_A$$

As funções f (parâmetro) utilizadas na função P(x,y,z,t,A) são funções do tipo:

$$f(x) = \frac{L}{1 + e^{-k \times (x - x_0)}}$$

Onde k=-12; L=1; x0 = 0,5

Estes três parâmetros foram determinados por meio de processos iterativos assim como a escolha pelo valor de três desvios padrões que está presente no denominador dos módulos nas funções f(x) dentro da função P(x,y,z,t,A). O princípio que baseia essa escolha é afirmar que variáveis com distância maior que três desvios padrões do centro de suas médias podem caracterizar que esse componente branco específico sendo avaliado tem probabilidade zero de ser pedra, do ponto de vista da contribuição dessa característica especificamente.

A forma da curva do gráfico da função f dada com esse parâmetros (k=-12; L=1; x0 = 0,5) é mostrada na imagem a seguir:




Figura 10-8 Curva obtida da função f , utilizada em cada parcela da função P .

Observa-se como a probabilidade de um componente branco é alta quando um dado parâmetro seu está próximo a média, ou seja, x desse parâmetro é próximo de zero (entre zero e 0,2) para x entre 0,2 e 0,8 ocorre uma queda acentuada porém quase linear, e para x acima de 0,8 a contribuição de probabilidade se aproxima rapidamente de zero. Para as características de distância em x , em y e em z a compreensão é imediata. Para as características de área e de densidade de pixels na vizinhança do componente branco o raciocínio é análogo, dada uma medida desta característica e dada a média dessa característica específica para a amostra de pedras que tivemos, quanto mais próximo a medida estiver do centro da amostra, isto é, da média, maior a probabilidade deste indivíduo específico ser classificado como pedra.

Os pesos α de cada parcela são determinados empiricamente de forma iterativa. Para a estimativa inicial foi utilizado o conhecimento obtido durante a execução do algoritmo de Naive Bayes. Observamos que as contribuições de x, y e t (densidade da vizinhança do componente branco) são iguais entre si e são maiores que as demais; observamos também que a contribuição de z é maior que a contribuição de A (área do componente branco). Dada essa relação hierárquica observada entre as contribuições

das cinco características, elaboramos uma maneira de simular diferentes valores de alfa variando um único parâmetro, para isso criamos as seguintes equações:

$$\alpha_x = \alpha_y = \alpha_t = a$$

$$\alpha_z = \frac{3}{2} \times \alpha_A = \frac{3}{5} \times (1 - 3 \times a)$$

$$\alpha_A = \frac{2}{5} \times (1 - 3 \times a)$$

Dessa forma fica estabelecida uma relação interna entre os cinco alfas, e o valor dos memos pode ser variado com o propósito de refinar o algoritmo. Após obter o valor da probabilidade de um componente branco ser pedra utilizando a função com todos os parâmetros internos explicados acima, devemos ainda escolher um limiar para decidir a partir de qual valor de probabilidade um determinado componente branco pode ser considerado pedra ou não. Com um mesmo limiar de 80% por exemplo e variando apenas o parâmetro “a” nota-se a diferença de sensibilidade na detecção de pedras como mostrado pelas duas imagens a seguir:




Figura 10-9 Classificação correta de pedra e de não-pedra utilizando " a " = 0,3




Figura 10-10 Classificação **incorreta** de pedra utilizando " α " = 0,25

11 RESULTADOS

11.1 RESULTADOS DA EXTRAÇÃO DE DADOS DAS IMAGENS

A interface homem-máquina desenvolvida e a automação para a abertura de todas as imagens de todos os pacientes funcionaram de forma correta. Consequentemente, foi possível processar todas as imagens e rotular todos os cálculos renais presentes nas imagens. Esta etapa (processar e rotular todos os cálculos) exigiu a inspeção visual de cada uma das 7762 imagens. Isso foi feito utilizando o programa de MATLAB, que para facilitar e diminuir a ocorrência de erros

neste trabalho repetitivo, colocava manchas vermelhas em cima de todas as manchas brancas candidatas a serem pedras.

Dessa forma, os dados de todas as 7762 imagens (aproximadamente) foram extraídos. Enfatizando que esses dados são: a localização x, y e z dos componentes brancos, a área dos componentes brancos e a densidade obtida da vizinhança dos componentes brancos. Esses cinco tipos de dados foram extraídos de cada um dos 306.094 componentes brancos encontrados nas 7762 imagens que compõem a coleção de exames de 38 pacientes. Esses 306.094 componentes brancos são partes do corpo tais como ossos das costelas, osso da coluna vertebral, cartilagem da traqueia, osso do esterno, pontos do intestino e até pedras em outros órgãos. Desses 306.094 componentes brancos, 526 eram efetivamente pedra nos rins, distribuídas em 38 pacientes. As distribuições desses dados foram apresentadas em forma de histogramas e tentamos mostrar que se aproximam e podem ser enquadradas como distribuição normal, essa premissa é utilizada posteriormente na construção do 1º algoritmo de diagnóstico da imagem.

As imagens dos rins foram utilizadas para calcular a média de densidade nos mesmos. No entanto a tentativa de efetivamente segmentar os rins não foi bem sucedida, principalmente devido ao fato de que o tecido do rim é bem parecido com tecidos vizinhos além da variabilidade da localização do rim e de sua geometria, que por vezes apresenta uma estrutura mais escura interna, por exemplo, que é a principal veia que passa pelo rim assim como as pequenas veias afluentes.

As interfaces construídas para extrair funcionaram muito bem, tanto a interface para extrair dados das pedras quanto a interface para extrair dados dos rins. Durante a utilização dessas interfaces alguns erros pontuais ocorreram, como por exemplo, clicar em um componente branco que não era pedra. Então para não permitir que esses erros deformassem as estatísticas a serem obtidas, eles foram retirados da matriz de dados final.

Por fim podemos afirmar que a etapa de extração de dados das imagens foi bem sucedida, permitindo obter uma coleção de informações de todos os 306.094 componentes brancos que serviu de alimentação para os algoritmos de diagnóstico desenvolvidos em seguida.

11.2 RESULTADOS DOS ALGORITMOS DE DIAGNÓSTICO

Os algoritmos desenvolvidos e descritos no capítulo 10 foram baseados em diferentes estratégias de abordar e cada um apresentou resultados diferentes dependendo de valores escolhidos para seus parâmetros internos. Refinamentos nestes parâmetros podem ser feitos indefinidamente. Nós fizemos vários melhoramentos de iteração em interação, visando obter os melhores resultados de diagnóstico. Para metrificar o sucesso de cada algoritmo adotamos a medida da acurácia, que nada mais é do que a razão entre o número de componentes brancos classificados corretamente pelo número total de componentes brancos.

$$Acurácia = \frac{\text{Número de componentes brancos classificados corretamente}}{\text{Número total de componentes brancos}}$$

A acurácia por si só no entanto não revela a qualidade do algoritmo completamente. É necessário considerar dentro de um mesmo nível de acurácia quais foram as taxas de falsos-negativos e falsos-positivos, pois dado o contexto médico não é aceitável emitir um diagnóstico falso-negativo, isto é, não podemos admitir a possibilidade de dizer a um paciente doente que ele está saudável. Esse tipo de consideração guiou algumas decisões tomadas de escolha de parâmetros principalmente no terceiro algoritmo - Predição Empírica, que então foram testados e aprimorados a cada ciclo de teste. Dessa forma, para exibir os resultados obtidos de acurácia e de falsos-negativos nada melhor do que plotar a curva com essas variáveis em função do parâmetro ou coeficiente que estava sendo testado.

Resultados do algoritmo baseado em Distribuição Normal:

O algoritmo de distribuição normal, como exposto na seção 10.1, utiliza uma faixa de desvios-padrão, aplica essa faixa para as cinco variáveis e filtra os componentes brancos que satisfazem as faixas para cada variável (localização x, y, z, densidade do entorno (t), e área do componente branco). Segue a tabela que mostra os resultados obtidos:

Coeficiente	Acurácia	Falsos-Negativos	Falsos-Positivos
1	0,9972	325	542
1,5	0,9946	151	1488
2,0	0,9888	57	3365

Pode-se observar claramente que existe um dilema entre aumentar a acurácia e diminuir a ocorrência de falsos negativos. Esse dilema irá aparecer também nos resultados dos próximos algoritmos a seguir:

Resultados do algoritmo baseado em Naive Bayes:

O algoritmo de Naive Bayes foi utilizado com 31 combinações diferentes das cinco variáveis disponíveis, fizemos isso com a finalidade de determinar qual combinação produziria diagnósticos com maior eficácia na prática, evitando dessa forma fazer uma escolha arbitrária baseada apenas na intuição. Foi surpreendente por exemplo constatar que a variável de densidade no entorno do componente branco (t) tinha mais influência do que a variável de valor da área do componente branco. O algoritmo de Naive Bayes fornece uma probabilidade baseada na amostra de aprendizagem à qual o mesmo foi exposto e baseado no exemplar sendo classificado no momento. Cabe a nós então escolher o limiar, isto é, o valor mínimo dessa probabilidade para que um determinado componente seja classificado como pedra. Ao fazer essa análise para diversos valores de limiares (entre 0 e 1), obtivemos a curva da imagem a seguir, que mostra a dependência da acurácia desse algoritmo com o valor de limiar escolhido:




Figura 11-1 Acurácia do algoritmo com o valor de limiar escolhido para selecionar pedra.

Já a dependência do número de falsos-negativos com a variação do limiar pode ser mostrada a seguir:




Figura 11-2 Dependência da ocorrência de falsos-negativos com o valor de limiar escolhido para selecionar pedra.

Pode-se observar que para um valor de limiar entre 0,1 e 0,6 é possível obter uma acurácia elevada e manter uma baixa ocorrência de falsos-negativos.

Resultados do algoritmo de Predição de Probabilidade Empírica:

Como exposto na seção 10.3 este algoritmo produz a probabilidade de um componente branco ser pedra baseado em uma função que recebe contribuições das cinco variáveis. Experimentalmente observa-se que a contribuição de cada variável não é igual às demais e para refletir essa diversidade de contribuições são utilizados pesos que multiplicam cada parcela. Então a contribuição de cada variável impacta cada parcela e a proporção entre elas é igual à proporção entre seus pesos. Foi criado então um parâmetro (alfa) que controla essas proporção por meio de funções expostas no capítulo 10.3. Variando esse parâmetro obtivemos uma curva de valores de acurácia, uma curva para a ocorrência de falsos-negativos e uma curva para a ocorrência de falsos-positivos, que são expostas a seguir:




Figura 11-3 Acurácia do algoritmo com o alfa escolhido entre 0,2 e 0,3..




Figura 11-4 Dependência da ocorrência de falsos-negativos com o alfa escolhido.




Figura 11-5 Dependência da ocorrência de falsos-positivos com o alfa escolhido.

Nesse algoritmo podemos notar o forte dilema que existe ao escolher entre uma acurácia elevada e baixa ocorrência de falsos-negativos. Escolhendo um alfa igual a 0,21 haveria uma baixa ocorrência de falsos-negativos, no entanto a acurácia seria baixa. Na região para alfa entre 0,21 e 0,25 a acurácia melhora bastante (de 0,90 para 0,95) enquanto que a ocorrência de falsos-negativos não piorou muito. Dessa forma a escolha mais adequada para o valor de alfa certamente se encontra nessa região.

12 CONCLUSÕES

Podemos concluir este trabalho afirmando que o objetivo de criar uma tecnologia capaz de auxiliar o médico no processo de detectar pedras nos rins foi em grande parte alcançado. Obtivemos êxito tanto na etapa de extrair as informações da amostra de exames de imagem disponível quanto na etapa de criar algoritmos capazes de aprender com essa amostra e fazer novos diagnósticos com elevada taxa de acerto. A etapa seguinte que levaria o trabalho a cumprir seu objetivo com ainda mais profundidade seria a construção de uma interface pronta para ser utilizada pelo

médico radiologista em seu ambiente de trabalho, nas clínicas médicas, examinando pacientes novos todos os dias.

Algumas observações merecem ser destacadas. Ao fazer o diagnóstico de cada imagem nós supomos que uma vez feita a classificação da imagem, já pode ser considerado pronto o diagnóstico do paciente se a classificação da imagem indicar pedra. Dessa forma nós não procuramos separar na etapa de testes os pacientes individualmente, mas sim testar a totalidade das imagens e considerar que uma dada imagem que possua pedra indica necessariamente que o paciente do qual aquela imagem foi gerada é doente, isto é, possui pedra. De fato, uma maior organização deste aspecto seria necessária numa etapa posterior (em uma continuação do trabalho); pois para mostrar que o paciente é saudável necessariamente todas as suas imagens precisam ser negativas para presença de pedra.

Outro ponto importante é a capacidade de escolher variáveis relevantes para serem utilizadas nos critérios de avaliação, e determinar qual o peso de cada variável na decisão final, nós escolhemos exatamente cinco variáveis: as localizações x , y e z do componente branco, a densidade do entorno do componente branco e a área do componente branco. Ao utilizar o algoritmo de Naive Bayes fizemos uma descoberta por exemplo, contra intuitiva, que é o fato de que a densidade de pixels (t) no entorno do ponto branco possui maior relevância na avaliação do que a própria área do componente branco. Isto pode ser explicado por que a área é bastante visual enquanto que a densidade no entorno do componente não pode ser mensurada a olho nu. A bem da verdade, é difícil de perceber no olho diferenças de tonalidade de cinza que caracterizam os tecidos dos diversos órgãos que circundam os rins do ser humano. No entanto, ao processar as imagens é possível mensurar e obter a média destes valores, que foram então analisados e testados em sua influência de alterar o resultado. Para testar a influência de cada uma das variáveis, nós fizemos todas as 31 combinações possíveis com as cinco variáveis (exceto obviamente o caso em que nenhuma variável é utilizada) e testamos cada uma destas combinações no algoritmo de Naive Bayes. O resultado então nos surpreendeu ao mostrar que a combinação com x, y, z e t produzia melhores resultados do que a combinação x, y, z e A .

Dessa forma é importante comentar dois pontos que poderiam ser desenvolvidos em um trabalho posterior. Primeiro, seguindo na mesma linha de metodologia e de raciocínio, a próxima etapa para aprofundar os resultados do trabalho seria colocar em prática os algoritmos desenvolvidos com a anuência de uma clínica e acompanhamento de um médico radiologista, para então efetivamente mensurar os benefícios produzidos pelo projeto, que são ganho de tempo na realização do exame e

diminuição do custo do exame uma vez que seria possível realizar mais exames por médicos, isto é, um mesmo médico conseguiria emitir mais diagnósticos utilizando nossa ferramenta do que sem ela. E o ganho percentual obtido só poderia ser medido em um ambiente clínico real.

O segundo ponto se refere a alterar as próprias técnicas utilizadas durante o desenvolvimento do algoritmo. Isto poderia ser feito, utilizando técnicas de Aprendizado de Máquina, que no entanto necessariamente exigiriam maior poder computacional do que o disponível e utilizado durante este projeto. Trabalhando com Aprendizado de Máquina seria possível mapear uma quantidade maior de variáveis e trabalhar inclusive com os metadados, que são as informações não extraídas diretamente da imagem, tais como idade, sexo do paciente, peso, altura do paciente e assim por diante, a fim de elaborar um super algoritmo capaz de digerir todas essas informações e produzir diagnósticos potencialmente de maior acurácia e menor ocorrência de falsos-negativos.

Por fim, destacando a dificuldade em obter a localização e segmentação do rim, esta ocorreu devido ao fato de que o rim possui tecido orgânico que na imagem acinzentada do exame não se distingue dos tecidos vizinhos e também devido ao fato de que a geometria e até a localização do mesmo no ser humano varia bastante. Em algumas pessoas os rins estão mais acima, em outras os rins estão mais abaixo. Em algumas pessoas os vasos sanguíneos interiores ao rim são maiores do que em outras além de formar uma imagem preta em forma de teia no interior do rim que dificulta a sua segmentação. Com isso posto, podemos afirmar no entanto que os algoritmos alimentados somente com informações dos componentes brancos propriamente ditos obtiveram êxito no objetivo de produzir taxas de acurácia elevadas.

Devemos adicionar ainda o valor médio encontrado a partir de unidades HU para a densidade dos rins, que é de 1048, e está detalhada na Tabela 2 no capítulo 9.2. Essa informação apesar de não ter sido utilizada nos algoritmos é importante pois não foi encontrada na literatura e pode ser usado em trabalhos posteriores.

13 REFERÊNCIAS BIBLIOGRÁFICAS

Ebrahimi Saman e Mariano Vladimir Y. Image Quality Improvement in Kidney Stone Detection on Computed Tomography Images [Periódico] // Journal of Image and Graphics Vol. 3, No. 1. - Junho de 2015. - pp. 40-46.

Jones Jeremy and Knipe Henry Urolithiasis [Online] // Radiopaedia. - 2013. - 11 30, 16. - <https://radiopaedia.org/articles/urolithiasis>.

LIU J., WANG, S., TURKBEY, E.B. Computer-aided detection of renal calculi from noncontrast CT images using TV-flow and MSER features. [Periódico] // Medical physics. - 2015. - pp. 144-153.

MANGAYARKARASI T., JAMAL, D.N., Development of Patient Assistive Tool for Detection of Abnormalities in Kidney [Periódico] // Indian Journal of Science and Technology. - 2015.

MathWorks MATLAB [Online] // MathWorks. - 2017. - 12 de 2 de 2017. - <https://www.mathworks.com/products/matlab.html>.

N. SENTHIL KUMARAN S. SATHYAVATHY Segmentation of Renal Calculi from CT Abdomen Images by Incorporating FCM and Level Set Approaches [Periódico] // International Journal of Advanced Research in Computer and Communication Engineering. - 2016. - pp. 132-138.

National Kidney Foundation Kidney Stones [Online] // National Kidney Foundation. - 2016. - 30 de 11 de 2016. - <https://www.kidney.org/atoz/content/kidneystones>.

NICOLAE C.M. AND MORARU, L., Image analysis of kidney using wavelet transform [Relatório] / Annals of the University of Craiova-Mathematics and Computer Science Series. - 2011. - pp. 27-34.

Open Source Computer Vision Library OpenCV [Online] // OpenCV. - 2017. - 20 de 3 de 2017. - <http://opencv.org/>.

RAFAEL C. GONZALEZ RICHARD E. WOODS. Digital Image Processing [Livro]. - 2008. - Third Edition.

RAJA R.A. , RANJANI, J.J Segment based Detection and Quantification of Kidney Stones and its symmetric Analysis using Texture Properties based on Logical Operators with Ultra Sound Scanning [Conferência] // IJCA Proceedings on International Conference on Computing and information Technology. - [s.l.] : Foundation of Computer Science, 2013. - pp. 8-15.

SAVALIYA NIRALI SHAN MANASI J., SHETH DHRUMIL H., RAVIYA KAPIL S Analysis of Renal Calculi in Ultrasound Image Using Matlab [Periódico] // Journal of Information, Knowledge and Research in Electronics and Communication Engineering. - 2014. - pp. 993-997.

SHARMA N. AGGARWAL , L. M. Automated medical image segmentation techniques. [Periódico] // Journal of Medical Physics. - Jan-Mar de 2010. - 35. - pp. 3-14.

SIVAKALAI S., LAURENCE AROQUIARAI, I. Fuzzy-Rough Multi Thresholding [Periódico] // Indian Journal of Engineering. - 2015. - 30 : Vol. 12. - pp. 345-349.

Skounakis E., Banitsas, K., Badii, A., Tzoulakis, S., Maravelakis, E. e Konstantaras A. A multiplatform for semiautomatic 3-D detection of kidneys and their pathology in real time [Periódico] // IEEE Transactions on Human-Machine Systems. - 2014. - 1 : Vol. 44. - pp. 146-153.

SNEHA A. MANE CHOUGULE A Review on Neural Network Methodology for Diagnosis of Kidney Stone [Periódico] // International Journal of Science and Research. - p. 300.

Tamilselvi M.P. e Thangaraj D.P. Computer aided diagnosis system for stone detection and early detection of kidney stones [Periódico] // Journal of Computer Science. - 2 : Vol. 7. - p. 250.

TAMILSELVI P.R. Computer Aided Detection System For Renal Calculi Using Effective Segmentation Approaches [Artigo]. - 11 de 2014.

Tamm Eric P., Silverman Paul M. e Shuman William P. RSNA Radiology [Periódico] = Evaluation of the Patient with Flank Pain and Possible Ureteral Calculus // Radiology. - 8 de 2003. - 2 : Vol. 228. - pp. 319-329.

The Medical Imaging Interaction Toolkit MITK [Online] // MITK. - 2017. - 20 de 3 de 2017. - <http://mitk.org/wiki/MITK>.

WEGENER O.H., Whole-body computed tomography [Livro]. - [s.l.] : Blackwell Wissenschafts-Verl, 1992.

14 APÊNDICES

14.1 APÊNDICE A

Diagrama de casos de uso


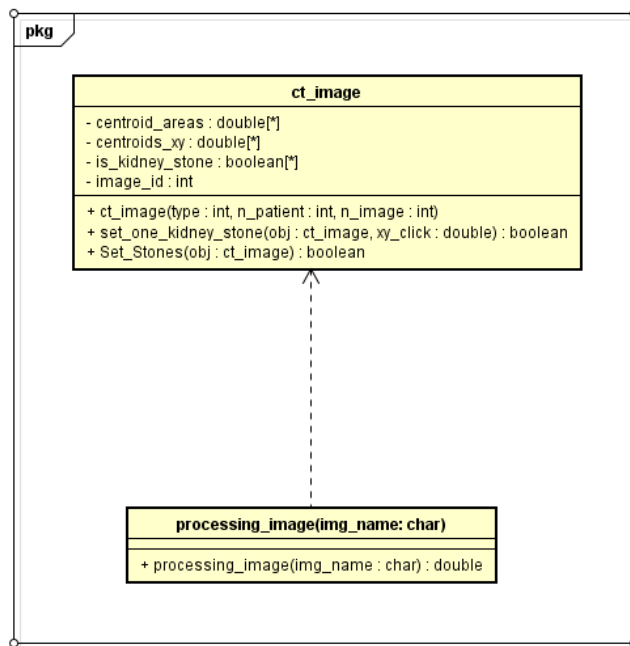


Diagrama de classes



14.2 APÊNDICE B

Função em MATLAB para o processamento de uma imagem.

```
% Processamento de 1 imagem

function [area centroid is_stone] = processing_image (img_name)

%Original Image
im = imread(img_name);
figure('Name',strcat('Original -', img_name),'NumberTitle','off');
imshow(im, []);

%Convert image to binary image, based on threshold
imbw = im2bw(im,0.90);

%Create morphological structuring element - disk
se = strel('disk',2,4);

%Morphologically close image - fill gaps and irregularities
imm = imclose(imbw,se);
% figure('Name',strcat('Processed -', img_name),'NumberTitle','off');
% imshow(imm, []);

%Find connected components in binary image
cc = bwconncomp(imm,8);

%Measure properties Centroid and Area of image regions cc and return
in table format
stat_tab = regionprops('table',cc,'Centroid','Area');

%Create zero column to be added, indicating whether the bright region
is a renal calculi
m = zeros(size(stat_tab,1),1);
m = array2table(m, 'VariableNames', {'Is_Kidney_Stone'});

stat_tab = [stat_tab m];
stat = table2array(stat_tab);
```



```
area = stat(:,1);  
centroid = stat(:,2:3);  
is_stone = stat(:,4);
```

14.3 APÊNDICE C

Cronograma proposto na entrega final da disciplina PMR2499 - Projeto Básico de Conclusão de Curso em dezembro de 2016:

Meses Tarefas	01	02	03	04	05	06	07	08	09	10	11
Revisão da literatura	X	X									
Obtenção das imagens	X	X									
Fundamentos de visão computacional e aprendizado de máquina	X	X	X								
Processamento das imagens				X	X	X	X	X			
Análise de resultados e validação									X	X	
Documentação											X

Tabela 4 Cronograma final apresentado na disciplina PMR 2500 (2016)

Após atualização, novo cronograma proposto para disciplina PMR2500 - Projeto de Conclusão de Curso I é apresentado abaixo:

Meses Tarefas	01	02	03	04	05	06	07	08	09	10	11
Revisão da literatura	X	X									
Obtenção das	X	X									

imagens											
Fundamentos de visão computacional e aprendizado de máquina	X	X	X								
Processamento das imagens				X	X	X	X	X			
Análise de resultados e validação						X	X	X	X	X	
Documentação						X	X	X	X	X	X

Tabela 5 Cronograma atualizado na disciplina PMR 2500 (2017)