



SEGMENTAÇÃO DE IMAGENS UTILIZANDO LUDIFICAÇÃO

TRABALHO DE CONCLUSÃO DE CURSO
ENGENHARIA DA COMPUTAÇÃO

HENRIQUE JOSÉ AMORIM DE ANDRADE
ORIENTADOR: PROF. BRUNO JOSÉ TORRES FERNANDES



UNIVERSIDADE DE PERNAMBUCO
ESCOLA POLITÉCNICA DE PERNAMBUCO
GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO

HENRIQUE JOSÉ AMORIM DE ANDRADE

SEGMENTAÇÃO DE IMAGENS UTILIZANDO
LUDIFICAÇÃO

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Recife, dezembro de 2014.

De acordo,

Recife,

_____/_____/____

Orientador da Monografia

Dedico este trabalho a meus pais.

Agradecimentos

Primeiramente, agradeço a Universidade de Pernambuco pelas experiências vivenciadas durante a graduação e pelas futuras portas que se abrirão. Demonstro minhas sinceras gratidões a todos os professores que me ensinaram a perceber "o copo cheio", e nunca hesitaram em abrir caminhos para o fortalecimento do conhecimento de seus alunos. Agradeço aos professores que me orientaram durante boa parte da graduação: Prof. Bruno, Prof. Byron e Prof. Carmelo, muitas vezes se esforçando mais do que o necessário para atender nossas vontades. Agradeço a todos os que fizeram parte da Academia na minha vida, dos meus primeiros monitores de programação a meus companheiros de pesquisa.

Agradeço também a minha família que durante esses anos me apoiaram nos momentos bons e ruins, me estimularam a tentar o diferente e me ensinaram a não ficar parado sob qualquer circunstância. Agradeço o amor infinito que recebo todos os dias. Com vocês aprendi que entender e aceitar o mundo nos torna sólidas fortalezas resistentes às intempéries do futuro.

Agradeço a todos os meus amigos, não importa o quanto distante vivam e com que frequência os vejo, carrego um pouco de todos comigo na minha rotina. Peço perdão pelos momentos em que precisei me afastar e me ausentar para o desenvolvimento deste e de outros trabalhos durante a graduação. Meus amigos me ensinaram a perceber e aproveitar os tantos mundos fantásticos que habitam as mentes das pessoas e que o melhor momento de nossas vidas é sempre o *agora*.

Agradeço a todos os fatores, na universidade, em casa e do governo federal brasileiro por me possibilitarem realizar meu primeiro intercâmbio aos Estados Unidos, sou eternamente grato. Agradeço a todos os meus amigos e professores que cruzaram meu caminho e somaram a esta experiência que tanto se traduz neste trabalho. Vocês me fizeram perceber que o topo do mundo é *logo ali* para quem o quer atingir. Com vocês percebi que *querer fazer algo* é mais importante do que *querer ser alguém*.

Resumo

Uma imagem pode ter suas regiões segmentadas por diferentes modos. Algoritmos oferecem soluções diversas, tentando aproximar seus resultados das segmentações realizadas por humanos especialistas. Sendo essa atividade originalmente humana, as abordagens de segmentação por computador ainda não se compararam às formas utilizadas pelo homem para categorizar regiões dentro de uma imagem. Este trabalho propõe a utilização da capacidade humana, por intermédio de um programa de computador, de realizar segmentação de vasos sanguíneos em imagens de retinas oculares. Um jogo digital foi desenvolvido, utilizando conceitos de ludificação e *game design*, para que este pudesse servir de plataforma para realização de segmentação realizada por um jogador humano. Os resultados provenientes das partidas desse jogo servem de entrada para o método de combinação de segmentações, o STAPLE, aproveitando os diferentes desempenhos em uma segmentação colaborativa. O jogo abstrai, para o jogador, o fato da imagem ser uma retina, transformando-o em uma superfície planetária com a ajuda de elementos visuais, oferecendo imersão ao jogador. Ele deve adicionar água ao planeta, preenchendo o espaço coberto por vasos sanguíneos, atingindo o objetivo da segmentação para este problema. O jogo oferece um ambiente de simulação, reagindo às ações do jogador, atraindo-o para continuar segmentando a imagem. Sua dinâmica é atraente e permite, mesmo com ferramentas simples de segmentação, boas taxas de acerto, precisão e cobertura.

Abstract

Different segmentation patterns structure an image. Some segmentation techniques offer close enough results to the ones achieved by humans. As a pure human activity, segmentation approaches compare to skills of a man on delimiting regions inside an image. Thus, this work proposes a way of using this potential through an interactive computer tool for performing segmentations of blood vessels in eyes retina images. A digital game, which is a framework of image segmentation, using gamification, and game design to deliver this task to a human. The results from this game are inputs for the combining algorithm STAPLE, which assures consistency in a collaborative segmentation process. The game itself makes the player unaware of the segmentation of a retina and makes him immerse in a planet with a help of a virtually created ambient. The player must put water in the planet and fill the gaps covered by blood vessels, performing segmentation tasks. The game offers a simulation environment that reacts to the player actions and attracts him to continue his segmentation task. It has attractive dynamics and achieves good classification, precision and recall, although the game simple drawing tools.

Sumário

INTRODUÇÃO	1
1.1 CARACTERIZAÇÃO DO PROBLEMA	1
1.2 OBJETIVOS	1
1.2.1 <i>Objetivos Específicos</i>	2
1.3 ESTRUTURA DO DOCUMENTO	2
2 SEGMENTAÇÃO DE IMAGEM	3
2.1 INTRODUÇÃO	3
2.2 MÉTODOS DE SEGMENTAÇÃO	4
2.2.1 <i>Limiarização</i>	4
2.2.2 <i>Crescimento de Região</i>	5
2.3 SEGMENTAÇÃO COLABORATIVA DE IMAGENS	6
2.4 STAPLE	8
3 PROJETO MARTE	11
3.1 CONCEPÇÃO	11
3.2 ESPECIFICAÇÕES DE IMPLEMENTAÇÃO	12
3.3 ARQUITETURA DO JOGO	13
3.4 FERRAMENTAS	17
3.4.1 <i>Perfurar</i>	17
3.4.2 <i>Canal</i>	19
3.4.3 <i>Raios X</i>	20
3.4.4 <i>Aterro</i>	20
3.5 AGENTES	20
3.6 DECISÕES DE INTERAÇÃO	22
4 RESULTADOS E ANÁLISES	24
4.1 METODOLOGIA	24
4.2 RESULTADOS DAS SEGMENTAÇÕES	25
4.3 ANÁLISE DAS FERRAMENTAS	28
4.4 ANÁLISE DO JOGO	31
5 CONCLUSÃO	33
6 BIBLIOGRAFIA	34
APÊNDICE A: IMAGENS DE RETINA UTILIZADAS NO JOGO	36
APÊNDICE B: SEGMENTAÇÕES DAS IMAGENS DE RETINA	37
APÊNDICE C: HISTÓRIA DO JOGO	38
APÊNDICE D: RESULTADOS DAS PARTIDAS COM ALGORITMO STAPLE	38
ANEXO A: RESULTADOS COMPARATIVOS DO STAPLE	41

Índice de Figuras

FIGURA 1: SEGMENTAÇÃO POR LIMIARIZAÇÃO. À ESQUERDA A IMAGEM ORIGINAL E À DIREITA O RESULTADO DA SEGMENTAÇÃO, COM REGIÃO DE INTERESSE EM BRANCO.....	4
FIGURA 2: HISTOGRAMA DA IMAGEM ORIGINAL DA FIGURA 1.....	5
FIGURA 3: LIMIARIZAÇÃO COM O MÉTODO DE NIBLACK. (A) IMAGEM ORIGINAL, (B) RESULTADO DA SEGMENTAÇÃO COM O MÉTODO DE NIBLACK, E (C) RESULTADO DA SEGMENTAÇÃO COM LIMIARIZAÇÃO SIMPLES.....	5
FIGURA 4: REPRODUÇÃO DO PROCESSO DE REPLICAÇÃO DE IMAGEM MÉDICA PARA SEGMENTAÇÃO POR GRUPO DE ESPECIALISTAS DO MIRALAB [9].....	7
FIGURA 5: AMOSTRA DE TRÊS IMAGENS SEGMENTADAS POR TRÊS INDIVÍDUOS DIFERENTES APRESENTADOS NO TRABALHO DE MARTIN ET AL [6].....	8
FIGURA 6: MOTIVOS PARA TOLERAR ERROS DE SEGMENTAÇÃO HUMANA, COMO APRESENTADOS POR MARTIN ET AL [6], ONDE (A) É A IMAGEM ORIGINAL E (B) A (D) SÃO SEGMENTAÇÕES REALIZADAS POR DIFERENTES INDIVÍDUOS.....	8
FIGURA 7: CAMADAS DESENHADAS NA TELA PRINCIPAL. (A) O BACKGROUND, (B) A SUPERFÍCIE E (C) AS ANIMAÇÕES DAS INTERAÇÕES.....	13
FIGURA 8: IMAGENS DESENHADAS NO BACKGROUND. AS ESTRELAS MENORES (A), QUE SE MOVEM MAIS LENTAMENTE ESTÃO AO FUNDO. AS MAIORES (B) SÃO DESENHADAS SOBRE AS MENORES E SE MOVEM MAIS RÁPIDO, CRIANDO O EFEITO PARALLAX.....	14
FIGURA 9: APLICAÇÃO DE MÁSCARA NAS IMAGENS DAS RETINAS. A IMAGEM ORIGINAL (A), A MÁSCARA UTILIZADA (B) E O RESULTADO DE SUA APLICAÇÃO (C), PARA MAIOR SEMELHANÇA COM A FORMA DE UM PLANETA.....	15
FIGURA 10: ELEMENTOS QUE COMPÕEM A CAMADA DA SUPERFÍCIE DO PLANETA.....	15
FIGURA 11: DIMENSÕES DOS ELEMENTOS NA TELA. SW E SH INDICAM AS PROPORÇÕES DA TELA ENQUANTO PD INDICA O TAMANHO DE UM DOS LADOS DA IMAGEM.....	16
FIGURA 12: O USUÁRIO ATUA SOBRE A IMAGEM ORIGINAL (A). O RESULTADO DE SUAS AÇÕES É DESENHADO COMO EM (B), MAS A SEGMENTAÇÃO É UMA IMAGEM A PARTE COMO EM (C).....	17
FIGURA 13: FRAMES DA EXECUÇÃO DA PERFURAÇÃO.....	19
FIGURA 14: FRAMES DA EXECUÇÃO DO CANAL.....	19
FIGURA 15: RECorte DO PLANETA COM FERRAMENTA DE RAIOS X. AS DUAS IMAGENS POSSUEM COLORAÇÃO LEVEMENTE DIFERENTES POR CAUSA DA EVOLUÇÃO DA ESTAÇÃO NO PLANETA, MAS SÃO IMAGENS ADQUIRIDAS NA MESMA PARTIDA.....	20
FIGURA 16: ALGUNS FRAMES DA ANIMAÇÃO DO MONSTRO DO JOGO.....	21
FIGURA 17: À ESQUERDA, OS AGENTES QUE PERCORREM O MAPA COM ÁGUA. À DIREITA, APARIÇÃO DO MONSTRO APÓS UM MOVIMENTO INDEVIDO.....	21
FIGURA 18: TELA DO JOGO EM UMA PARTIDA AVANÇADA.....	22
FIGURA 19: COMBINAÇÃO DE TODAS AS SEGMENTAÇÕES DA IMAGEM 2.....	26
FIGURA 20: RESULTADO DA FERRAMENTA DE PERFURAÇÃO COM ARTEFATOS.....	28
FIGURA 21: MUITOS VAZAMENTOS PROPICIAM A APARIÇÃO DOS MONSTROS.....	29
FIGURA 22: ARTEFATOS DA FERRAMENTA DE CANAL.....	29
FIGURA 23: POSSÍVEL RESULTADO DE UMA SEGMENTAÇÃO UTILIZANDO A FERRAMENTA DE RAIOS X. EM VERMELHO, OS PÍXEIS CLASSIFICADOS CORRETAMENTE COMO VASO SANGUÍNEO.....	30
FIGURA 24: POSSÍVEL RESULTADO DO USO DA FERRAMENTA DE ATERRO. EM AZUL OS PÍXEIS ERRADOS, EM VERMELHO OS PÍXEIS CORRETOS E A ÁREA VERDE É A ÁREA DE APLICAÇÃO DA FERRAMENTA DE ATERRO.....	30

Índice de Tabelas

TABELA 1: COMANDOS DO JOGO.	23
TABELA 2: CARACTERÍSTICAS DOS INDIVÍDUOS AVALIADOS NESTE TRABALHO.	24
TABELA 3: COMPARAÇÃO ENTRE MÉDIAS DAS TAXAS DE ACERTO, PRECISÃO E COBERTURA POR FAIXA ETÁRIA.	25
TABELA 4: SEGMENTAÇÕES POR IDADE.	26
TABELA 5: RESULTADOS PARA TODAS AS SEGMENTAÇÕES DA IMAGEM 2 COMBINADAS COM STAPLE.	26
TABELA 6: COMPARAÇÃO ENTRE RESULTADOS STAPLE E MÉDIA DAS TAXAS DE TODAS AS SEGMENTAÇÕES REALIZADAS.....	27

Introdução

1.1 Caracterização do Problema

A segmentação de imagens de retina ocular humana é uma tarefa já descrita por muitos algoritmos que comparam seus resultados com um padrão segmentado por humanos especialistas [1]. Quando um homem é apresentado a uma imagem, ele consegue identificar os elementos que compõem o cenário imediatamente, por ser uma tarefa natural. Porém, quando é necessário delimitar em desenho as bordas de cada um dos elementos, os algoritmos são mais rápidos do que os humanos [2]. Além da diferença entre os tempos de desenho destas segmentações, o desempenho humano é afetado por elementos externos, como por exemplo sua vontade em realizar aquela tarefa. Uma pessoa pode realizar uma segmentação detalhada por horas, caso solicitada. Se solicitada uma segunda vez, para uma mesma imagem, seu desempenho poderá ser inferior quando comparado com a primeira segmentação.

Apesar do tempo de segmentação e dos efeitos naturais sobre a concentração humana, os resultados da segmentação realizada por um especialista, de uma maneira geral, são superiores quando comparados aos resultados da máquina. Por isto, servem como padrão para comparação [3]. Assumindo isto, este trabalho discute um método de extração de potencial humano, reduzindo suas perdas de concentração e maximizando a atração ao problema. Transformar problemas reais em abstrações lúdicas é um modo de motivar e atrair um indivíduo a resolvê-los. Essas abstrações variam entre quebrar o problema em problemas menores, até representá-los de uma forma diferente da original, visando manter este nível de concentração e garantir a qualidade da resolução do problema [4].

Para isto, um problema de segmentação de imagens pode ser abordado como um jogo digital que tenta aproximar o desempenho do jogador ao de um especialista, utilizando técnicas de desenvolvimento de jogos. O Projeto de Mecanismo de Avaliação da Retina com Técnicas de Entretenimento (MARTE) é uma ferramenta simples de segmentação na forma de jogo. Seus resultados podem ser combinados de forma colaborativa entre jogadores a fim de obter melhores resultados no geral.

1.2 Objetivos

Como objetivo, este trabalho concebe uma ferramenta de segmentação colaborativa através de um jogo digital. Esta ferramenta contém recursos para prender a atenção do

Introdução

jogador e permiti-lo realizar segmentações, reduzindo a perda de interesse à medida que suas interações com o jogo ocorrem.

Os resultados obtidos com as segmentações são combinados entre si, através de uma técnica de combinação de segmentações, para a obtenção das melhores taxas de classificação realizadas pelos indivíduos.

1.2.1 Objetivos Específicos

Este trabalho tem os seguintes aspectos como objetivos específicos:

- A criação de um jogo digital que permita a realização de segmentação de vasos sanguíneos em imagens de retinas oculares e que suavize a exaustão e a perda de concentração do jogador;
- Utilizar os resultados dessa ferramenta como entradas de um algoritmo de combinação de segmentação de imagens.

1.3 Estrutura do Documento

Este documento está estruturado em cinco capítulos. O Capítulo 2 mostra uma revisão de algumas técnicas de segmentação, considerando também segmentações realizadas por seres humanos e um método de combinar segmentações diferentes para obtenção de um único resultado. O Capítulo 3 descreve a ferramenta proposta neste trabalho e suas peculiaridades. No Capítulo 4, as segmentações obtidas são discutidas e a ferramenta analisada. Por fim, o Capítulo 5 apresenta conclusões acerca das contribuições e sugestões para a continuação de utilização da técnica de ludificação, além de sugestões para extensão do jogo proposto como ferramenta de segmentação de imagens.

2 Segmentação de Imagem

2.1 Introdução

O processo de segmentação, de acordo com Gonzalez e Woods [5], subdivide imagens em suas regiões e objetos constituintes, reduzindo a quantidade de detalhes às regiões de interesse da aplicação. Os segmentos de imagem utilizados em classificadores, e portanto, a qualidade da segmentação, afetam diretamente os resultados de classificação. Diversos algoritmos que realizam segmentação de imagem estão descritos na literatura. Eles podem ser categorizados de acordo com a relação entre píxeis, como descreve Gonzalez; ou de acordo com qual informação da imagem é interpretada, como descreve Martin et al [6].

Este capítulo discute algumas formas clássicas de segmentação presentes na obra de Gonzalez. Essas abordagens de segmentação de imagem são dependentes da qualidade da imagem para gerarem bons resultados. Idealmente, um algoritmo deveria reproduzir o comportamento humano de segmentação, como aponta Cinque et al.: “É necessário lembrar que a avaliação final [da segmentação de imagens] é realizada por um ser humano e este critério subjetivo depende de suas capacidades práticas” [7]. Independente do algoritmo aplicado, sua medição de qualidade será por fim realizada por achares humanos. Como solução viável para esse problema, este capítulo também discute uma forma de segmentação que é realizada de forma colaborativa por humanos.

Essa solução levanta um outro problema, como também discute Martin et al. Apesar da capacidade superior de segmentação de um homem em relação a uma máquina, existe um problema que põe em risco a consistência da segmentação: cada indivíduo apresentará um resultado diferente de segmentação. Para isto, por fim, este trabalho sugere um método de combinação de segmentações de imagem, o STAPLE [8], como forma de unificar segmentações realizadas por diferentes indivíduos para uma única imagem.

O capítulo é dividido em descrições de métodos de segmentação simples, uma discussão de segmentação colaborativa de imagens e, por fim, o método de combinação de segmentações, o STAPLE.

Segmentação de Imagem

2.2 Métodos de Segmentação

2.2.1 Limiarização

Esta técnica segmenta imagens de acordo com as intensidades dos píxeis ou as propriedades destes valores. A Figura 1 ilustra o resultado do processo de limiarização. A imagem colorida foi transformada em tons de cinza e recebeu um filtro de limiar, onde a região de interesse é o texto da imagem.

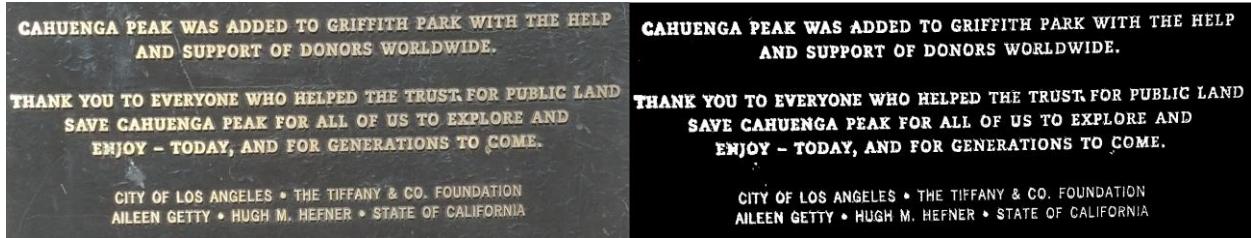


Figura 1: Segmentação por limiarização. À esquerda a imagem original e à direita o resultado da segmentação, com região de interesse em branco.

Um valor limiar θ é escolhido para classificar o píxel p e separá-lo em uma das duas classes de píxeis: os que fazem parte da região de interesse e os que não fazem, como na expressão:

$$g(x, y) = \begin{cases} 1 & \text{se } p > \theta \\ 0 & \text{se } p \leq \theta \end{cases} \quad (1)$$

Quando um limiar constante θ é aplicado em toda a imagem, o processo é chamado de limiarização global. Caso esse limiar varie, o processo é chamado de limiarização variada. Quando este limiar é local, o processo só é realizado dependendo das propriedades dos vizinhos do píxel p . Caso o limiar varie de acordo com o valor do píxel, esta limiarização variada é também chamada de adaptativa ou dinâmica. Segundo Gonzalez, as terminologias destes termos não são universais e é comum encontrá-las trocadas na literatura.

Um problema comum na limiarização global é a escolha do limiar. No processo da Figura 1 ele foi escolhido manualmente a partir de seu histograma, ilustrado na Figura 2. O objetivo da limiarização é minimizar o erro médio quando categorizando os píxeis. Uma abordagem presente na obra de Gonzalez para resolver este problema é o método de Otsu, que visa maximizar a variância entre as classes. Ele se fundamenta no princípio de que as classes bem separadas possuem valores de intensidade bem distintos e é um método baseado em cálculos sobre o histograma da imagem, ou seja, um vetor de uma dimensão.

Segmentação de Imagem



Figura 2: Histograma da imagem original da Figura 1.

Muitas vezes, a limiarização global não satisfaz o problema por causa das características da imagem. Iluminação, balanceamento de cores e ruído são alguns dos fatores que podem provocar uma má segmentação se utilizada a limiarização global. Para isto, os métodos variáveis realizam operações em regiões locais da imagem, como a limiarização de Niblack [8]. Esse método realiza operações em janelas da imagem, calculando o desvio padrão entre os pixels dela e classificando o pixel central de acordo com o seu limiar e seu valor de intensidade. O limiar deste pixel pode ser calculado por

$$\theta(x, y) = k \times \sigma(x, y) + m(x, y), \quad (2)$$

onde k é uma constante de controle que é positiva para objetos claros ou negativa para objetos escuros, $\sigma(x, y)$ o desvio padrão das intensidades da janela e $m(x, y)$ a média destas intensidades. A Figura 3 mostra um exemplo com limiar global e com o método de Niblack, calculado com janela 300x300 e k igual a 0,09.



Figura 3: Limiarização com o Método de Niblack. (a) Imagem original, (b) resultado da segmentação com o método de Niblack, e (c) resultado da segmentação com limiarização simples.

2.2.2 Crescimento de Região

O método de crescimento de região utiliza sementes para expandir regiões com vizinhos que possuem propriedades semelhantes, como a intensidade do pixel. A determinação das sementes iniciais depende da natureza do problema. Cada semente tenta agregar um dos pixels de sua vizinhança de 8 para compor o objeto segmentado, caso este novo pixel atenda a uma condição pré-estabelecida de conexão. Assim, este

Segmentação de Imagem

método continua agregando píxeis até que nenhum novo satisfaça as condições e ele pare.

Uma condição de conexão, por exemplo, é a diferença entre os píxeis avaliados ser menor ou igual a um limiar de tolerância, como descreve a condição X, onde Q é a avaliação e T um limiar de tolerância,

$$Q = \begin{cases} 1 & \text{diferença absoluta entre semente e píxel é } \leq T \\ 0 & \text{caso contrário} \end{cases}. \quad (3)$$

O crescimento de região com uma semente e vizinhança de 4 píxeis pode ser sumarizado de acordo com o algoritmo:

Algoritmo 1: Pseudocódigo de crescimento de região

Entradas: Píxel semente \vec{s} e imagem M ;

1. **Repita até** que imagem M_{seg} não mais se altere
 2. **Para** cada píxel p em M_{seg} **faça**
 3. **Para** cada píxel v na vizinhança-4 de p **faça**
 4. **Se** v respeitar a condição Q na eq. 3,
 desenhe píxel na posição de v na imagem M_{seg} ;
 5. **Fim**
 6. **Fim**
 7. **Fim**
 8. **Fim**
 9. **Fim**
-

2.3 Segmentação Colaborativa de Imagens

Existem métodos de segmentação de imagens onde o trabalho de extração de regiões é dividido ou até repetido por agentes segmentadores diferentes. É importante notar que é possível a implementação de uma forma de segmentação de imagens onde regiões são destacadas analisando propriedades diferentes, sendo este um processo puramente computacional, ou utilizando a capacidade humana. Este trabalho aborda a segmentação colaborativa entre indivíduos humanos e sua alta capacidade de generalização.

Utilizando ferramentas de desenho, específicas para o problema ou não, imagens são segmentadas visando obter diferentes padrões de regiões para que então um padrão médio seja identificado; ou ainda visando obter um consenso de segmentação entre o grupo que o realiza. Esta forma colaborativa de segmentação é descrita de formas diferentes em muitos trabalhos, como o realizado pelo MIRALab da Universidade de Geneva [9] para segmentação de tecido muscular e ósseo e o do Seung Lab do MIT, o EyeWire [10].

Segmentação de Imagem

A forma de segmentação colaborativa do MIRALab consiste em separar um grupo de indivíduos especialistas para segmentar uma imagem médica, de acordo com a Figura 4, onde a imagem é replicada para todos os indivíduos. Seus resultados são então analisados por um grupo menor de especialistas que validam as segmentações e constroem a imagem final segmentada utilizando as segmentações do primeiro grupo.

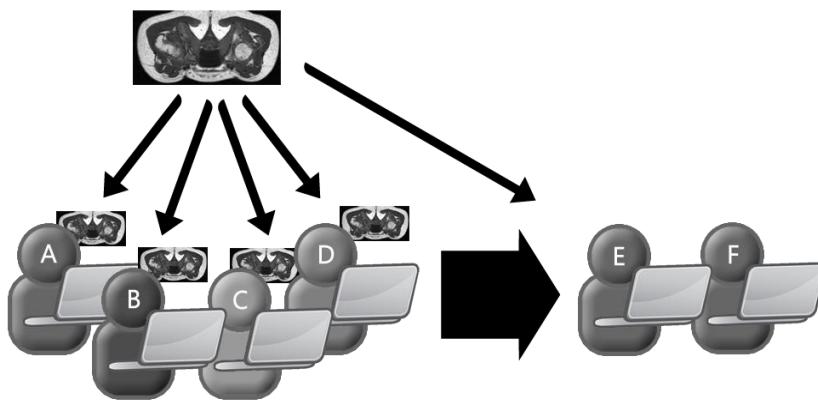


Figura 4: Reprodução do processo de replicação de imagem médica para segmentação por grupo de especialistas do MIRALab [9].

Um trabalho em específico, o de Martin et al. [6], introduz uma forma de avaliar resultados de segmentação de imagens utilizando conteúdo segmentado por humanos. Ele observa que os diferentes resultados das segmentações realizadas por seres humanos possuem uma consistência considerável e portanto podem ser utilizadas como provas para avaliação de algoritmos. A Figura 5, retirada de seu artigo, mostra três imagens segmentadas por três indivíduos diferentes. Em cada imagem, informações diferentes podem ser levadas em consideração por um homem ou um algoritmo para segmentá-las, como a continuidade do brilho, textura, continuidade das bordas, simetria e convexidade, além de informações de alto nível como reconhecimento de objetos. Ele também observa que é aceitável que um algoritmo não atinja um bom desempenho, analisando apenas uma das informações antes citadas. O esperado é que os algoritmos evoluam para usar de uma forma mais elaborada todas as informações disponíveis na imagem.

Segmentação de Imagem

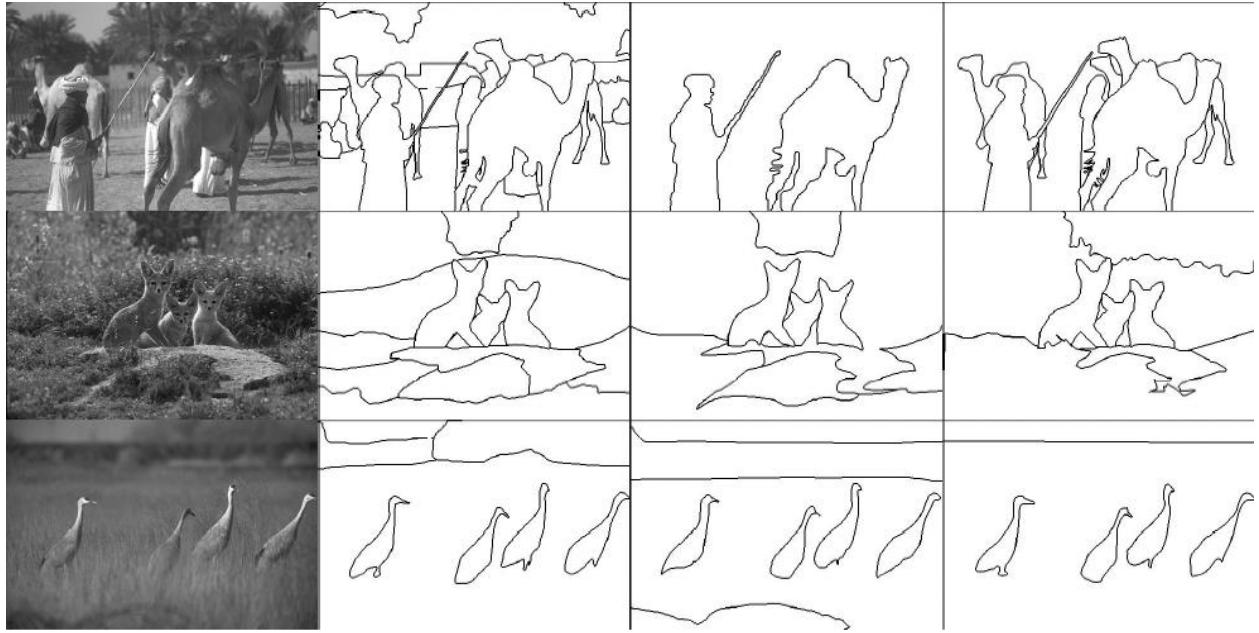


Figura 5: Amostra de três imagens segmentadas por três indivíduos diferentes apresentados no trabalho de Martin et al [6].

Sobre os resultados, Martin et al. anotam que uma mesma imagem pode receber níveis de granularidade diferentes, dependendo da vontade e prática do observador. Como mostra a Figura 6, também original do seu trabalho. É importante então, considerar os níveis diferentes de segmentação consistentes e não como segmentações erradas.

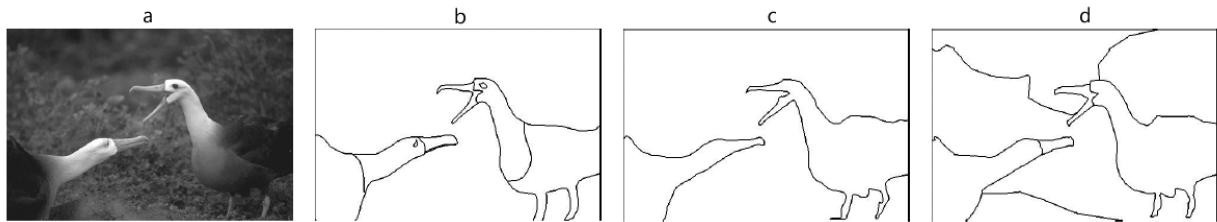


Figura 6: Motivos para tolerar erros de segmentação humana, como apresentados por Martin et al [6], onde (a) é a imagem original e (b) a (d) são segmentações realizadas por diferentes indivíduos.

2.4 STAPLE

O método de combinação de segmentações de imagem, STAPLE (do inglês, *Simultaneous Truth and Performance Level Estimation*), proposto por Simon Warfield [11] é um algoritmo que considera um conjunto de segmentações e calcula uma estimativa probabilística da correta segmentação, desconsiderando ruídos e erros gerados pela técnica utilizada. As segmentações podem ter sido realizadas por humanos ou por segmentações automatizadas. A estimativa probabilística é calculada com uma

Segmentação de Imagem

combinação ótima de segmentações, ponderando cada uma delas de acordo com o seu desempenho e com sua homogeneidade espacial. O STAPLE é recomendado para uso com imagens clínicas e seu resultado, quando utilizando entradas automáticas, pode ser comparado com segmentações realizadas por humanos.

No seu algoritmo, vetores p_j e q_j representam a sensibilidade e especificidade, respectivamente, de cada segmentação avaliada, onde a sensibilidade é a taxa dos píxeis de vaso classificadas corretamente e a especificidade é a taxa de píxeis de fundo classificados corretamente. Estes vetores são inicializados com valores próximos de 1. Em suas iterações, estimam-se os parâmetros de desempenho de cada segmentação que maximizam a função de verossimilhança através da probabilidade do que seria a segmentação resultado, e através da comparação entre o obtido e esperado. Uma maior quantidade de segmentações oferece um melhor resultado final, apesar de também apresentar um aumento do custo computacional. Não se discute se existe uma quantidade de segmentações que estabilize a qualidade dos resultados. O STAPLE está descrito no Algoritmo 1.

A cada iteração, uma estimativa probabilística do resultado da segmentação é calculada, baseado no conjunto de segmentações de entrada e no desempenho da iteração anterior. O método, quando comparado com outras técnicas de combinação de segmentação de imagens, apresenta boas taxas de acerto [12] que podem ser ainda melhores com imagens cuja segmentação se aproxime mais do padrão ouro, termo definido por Martin et al [6] para a segmentação ideal, aquela utilizada como base comparativa para todas as outras técnicas de segmentação.

Algoritmo 2: Pseudocódigo do STAPLE

1. Inicialize p_j e q_j com valores próximos de 1;
 2. Inicialize S_k com o somatório da matriz de pesos;
 3. **Enquanto** $S_k - S_{k-1} \neq 0$, **faça**
 4. Calcule a_i utilizando eq. 4;
 5. Calcule b_i utilizando eq. 5;
 6. Calcule a matriz de pesos w_i utilizando eq. 6
 7. Calcule p_j utilizando eq. 7;
 8. Calcule q_j utilizando eq. 8;
 9. Calcule S_k com o somatório da matriz de pesos;
 10. **Fim**
 11. **Retorne** Matriz de pesos w .
-

$$a_i = \prod_{j:D_{ij}=1} p_j \prod_{j:D_{ij}=0} (1 - p_j); \quad (4)$$

Segmentação de Imagem

$$b_i = \prod_{j:D_{ij}=0} q_j \prod_{j:D_{ij}=1} (1 - q_j); \quad (5)$$

$$w_i = \frac{a_i}{a_i + b_i}; \quad (6)$$

$$p_j = \frac{\sum_{i:D=1} w_i}{\sum_i w_i}; \quad (7)$$

$$q_j = \frac{\sum_{i:D=0} (1 - w_i)}{\sum_i (1 - w_i)}. \quad (8)$$

3 Projeto MARTE

No desenvolvimento de um jogo, animação, estudo do público, arquitetura, engenharia, psicologia, arte visual são algumas das partes fundamentais para a obtenção de um resultado satisfatório: um jogo que cumpra seu objetivo, seja ele de entreter ou educar. Jesse Schell em sua obra "*The Art of Game Design: a Book of Lenses*" [13], a qual este trabalho se inspira para o desenvolvimento do jogo, discute que a habilidade mais importante de um *game designer* é a de ouvir. Um jogo ou qualquer outro trabalho precisa entender seus objetivos e seus impactos para moldar-se a eles.

Este capítulo apresenta a ferramenta proposta, sua concepção e discussões de desenvolvimento, como parte do processo de ludificação da exaustiva tarefa de segmentação manual de imagens de retinas oculares.

3.1 Concepção

A segmentação manual de imagens é um processo longo e exaustivo que serve de referência para os algoritmos que a realizam automaticamente. Este trabalho propõe uma prática mais adequada a esta realidade: dar a tarefa de um algoritmo a um ser humano não especialista. Mesmo tendo conhecimento de que a atividade humana será realizada de forma diferente por cada indivíduo, resultados satisfatórios de segmentação comparados com os realizados por máquina podem ser obtidos, caso utilizado o universo correto de pessoas. Porém, esta forma de segmentação toma muito tempo do realizador, principalmente se a imagem possuir muitos detalhes.

As imagens escolhidas para este trabalho são parte de uma base de imagens criada para estudos sobre segmentação de vasos sanguíneos em imagens de retina. A base *Digital Retinal Images for Vessel Extraction*, em inglês "Imagens digitais de retina para extração de vasos sanguíneos" ou DRIVE [1], contém quarenta imagens coloridas separadas na metade para treino e teste. As imagens foram obtidas de um programa holandês de captura de imagens de retinopatias em diabéticos. Os indivíduos fotografados têm de 25 a 90 anos de idade. As imagens foram capturadas com oito bits por plano de cor representados em três canais: vermelho, verde e azul (RGB, em inglês), com cada retina tendo um diâmetro aproximado de 540 pixels e foram comprimidas no formato JPEG. Seguindo a representação de cor das imagens, o jogo utiliza, portanto, imagens com a mesma representação, ou imagens com um canal de transparência adicional, o canal alfa (ARGB, em inglês).

Como discutido por Niemeijer et al. [2], as imagens da base DRIVE levam em média 2 horas para serem segmentadas manualmente cada uma, utilizando um *software* simples de desenho. Quando a segmentação toma esse tempo, a fadiga do observador humano pode causar uma perda na precisão da segmentação. Comparando a técnica automática mais precisa, a de classificação por pixel, com um observador não tão preocupado com a precisão, o resultado humano ainda é significantemente melhor.

Assim, ludificar o processo cansativo de segmentação é uma saída para o problema da atenção e fadiga humana. Oferecer recursos ao observador para que seu desgaste seja amenizado ou diluído durante a tarefa é uma alternativa que pode ser atingida transformando a simples ferramenta de desenho em um jogo digital, ou em um ambiente interativo.

3.2 Especificações de Implementação

O primeiro protótipo foi desenvolvido em Java, focando nas plataformas móveis *Android*, portanto, utilizando seu *kit* de desenvolvimento de *software* (em inglês, SDK) específico [14]. Inicialmente, o jogo seria projetado para realizar segmentações em celulares e *tablets*. Mais tarde, o jogo foi adaptado para computador, por possuir melhor precisão e maior poder de processamento, sem desconsiderar o poder de processamento dos atuais aparelhos móveis. Depois da adaptação para computador, foi possível incrementar a experiência do jogador com mais recursos visuais, mas as segmentações são totalmente possíveis de serem realizadas com sucesso em celulares e *tablets*. A precisão de interação que o *mouse* oferece em contrapartida ao toque foi o fator mais importante para esta decisão de implementação.

Como motor gráfico, foi utilizada a biblioteca de desenho *Processing* [15] para Java. Desenvolvida pela parceria das *Tisch School of Arts, Fathom Information Design* e o estúdio de *software* para arte da UCLA, ela oferece recursos para manipulação 2D e 3D de vetores e primitivas geométricas, cor, processamento de imagens, interação humano-computador (seja *desktop, Android* ou *web*), entre outras ferramentas. Por ser gratuita e bem documentada, *Processing* é uma boa escolha para desenvolvimento de jogos e mídias interativas em Java.

A biblioteca *Processing* foi criada para facilitar o desenvolvimento de aplicações com ênfase em animação e facilitando a visualização do resultado. Seu núcleo consiste em execuções de um método de desenho que atualiza a tela. É possível declarar o que será executado antes, para inicialização do programa. As interações de entrada são manipuladas por *threads* e, portanto, são concorrentes dos métodos de desenho na tela.

É comum escrever métodos de atualização de dados no início dos métodos de desenho, para que a informação se atualize antes de ser exibida.¹

No início da discussão deste projeto, escolheu-se desenvolvê-lo para crianças, pois assim podemos nivelar o protótipo a partir dos humanos cuja coordenação motora ainda está em desenvolvimento. Para isto, procurou-se abstrair o fato de que seriam realizadas segmentações de imagens e de que os observadores estariam manipulando imagens de retina. Pela semelhança visual, decidiu-se representar as retinas como planetas, onde a tarefa de segmentação seria substituída pela tarefa de hidratá-lo. Todos os elementos visuais seriam baseados em jogos 8-bit. Esta decisão partiu do fato dos píxeis da imagem da retina ficarem aparentes quando ela é exibida com distância aproximada, dando a impressão de quadriculado típico de jogos de videogame de 8-bit. A partir daí, começaram os rascunhos do que seria a história do jogo. No contexto, o planeta é seco e precisa ser perfurado para extração de água subterrânea e preencher os leitos dos rios que estão secos. As decisões iniciais foram se alterando ao longo do desenvolvimento, a partir das respostas das crianças que manipularam as primeiras versões. Os resultados das segmentações das primeiras versões não foram levadas em consideração nos resultados deste trabalho.

3.3 Arquitetura do Jogo

O jogo estrutura-se em camadas que são desenhadas umas sobre as outras. Existem duas telas no jogo, uma inicial e a principal do jogo. A tela inicial possui apenas uma camada onde as imagens que a compõem são exibidas e outra camada que trata as interações do usuário. Durante o jogo, essa organização é mais complexa. São três camadas que realizam suas operações de atualização e de desenho independentemente: *background*, planeta e interação. A Figura 7 mostra as camadas da tela principal.

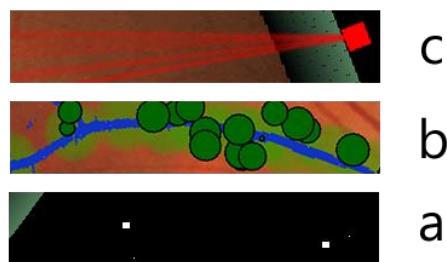


Figura 7: Camadas desenhadas na tela principal. (a) O background, (b) a superfície e (c) as animações das interações.

¹ Mais detalhes da descrição e utilização da biblioteca *Processing* em <https://www.processing.org/tutorials/overview/>

Projeto MARTE

A camada a ser desenhada primeiro a cada frame é o *background*. Ela é composta por duas imagens representando estrelas que se movem em velocidades diferentes. Como mostrado na Figura 8, (a) possui estrelas menores e se move da direita para esquerda, dando a impressão de rotação do planeta. (a) possui estrelas desenhadas numa proporção maior e se movendo com o dobro da velocidade da imagem ao fundo, também da direita para esquerda. Quando observado pelo jogador, o efeito das estrelas se movendo em velocidades diferentes é chamado de *parallax*, responsável por dar uma noção de profundidade. O *background* com estrelas fortalece a ideia de que a imagem a ser segmentada é um planeta.

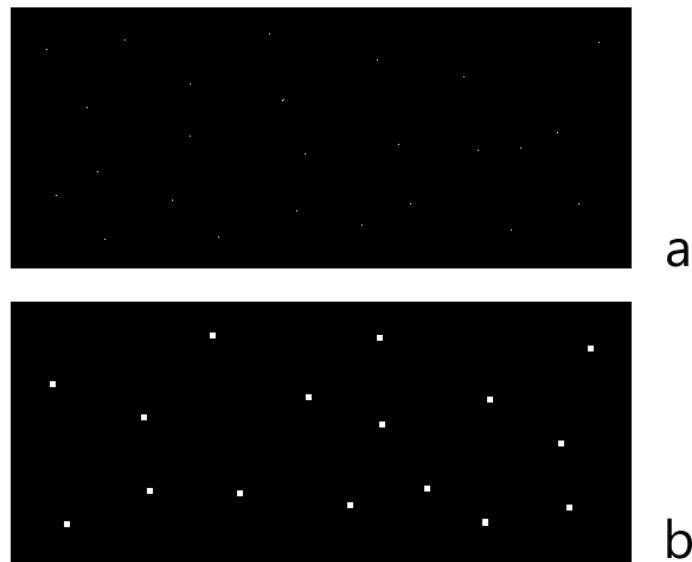


Figura 8: Imagens desenhadas no *background*. As estrelas menores (a), que se movem mais lentamente estão ao fundo. As maiores (b) são desenhadas sobre as menores e se movem mais rápido, criando o efeito *parallax*.

A próxima camada a ser desenhada após o *background* é a do planeta. Esta camada envolve a imagem da superfície do planeta, a água e os elementos vivos do jogo. Para transformar a imagem de retina em planeta, uma máscara circular foi aplicada. Nenhum pré-processamento além da máscara foi realizado sobre as imagens de retina. A Figura 9 mostra a simples mudança aplicada sobre a imagem original. Uma atmosfera é desenhada contornando o planeta, também para fortalecer o conceito que o jogo passa. As cores da atmosfera mudam a cada novo jogo, assim como a cor que sobrepõe o planeta. A tonalidade do planeta é levemente alterada a cada partida, sem prejudicar a percepção dos vasos sanguíneos.

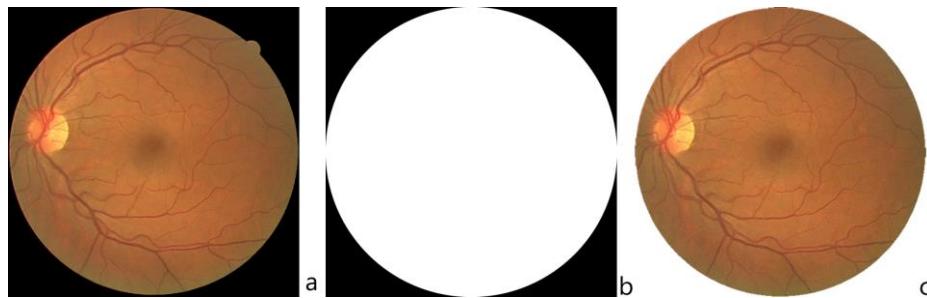


Figura 9: Aplicação de máscara nas imagens das retinas. A imagem original (a), a máscara utilizada (b) e o resultado de sua aplicação (c), para maior semelhança com a forma de um planeta.

Esta camada também é responsável por desenhar o satélite que circunda o planeta. As animações de disparo do satélite também são desenhadas nesta camada, mas apenas quando acionadas pela camada superior, a de interação com o jogador. Durante sua atualização, os elementos que a compõem interagem entre si de forma horizontal. A Figura 10 mostra os elementos que compõem esta camada, são eles o terreno do planeta, a água, a fauna e os agentes.



Figura 10: Elementos que compõem a camada da superfície do planeta.

A imagem do planeta é exibida centralizada na tela, permitindo ao jogador visualizar todo o trabalho realizado. A resolução da imagem é adaptada para qualquer tela, e é possível aproximar ou afastar a visualização. A Figura 11 mostra as proporções dos objetos e o ponto de referência de todos os elementos do Planeta, a origem, representada pelo vetor \vec{o} .

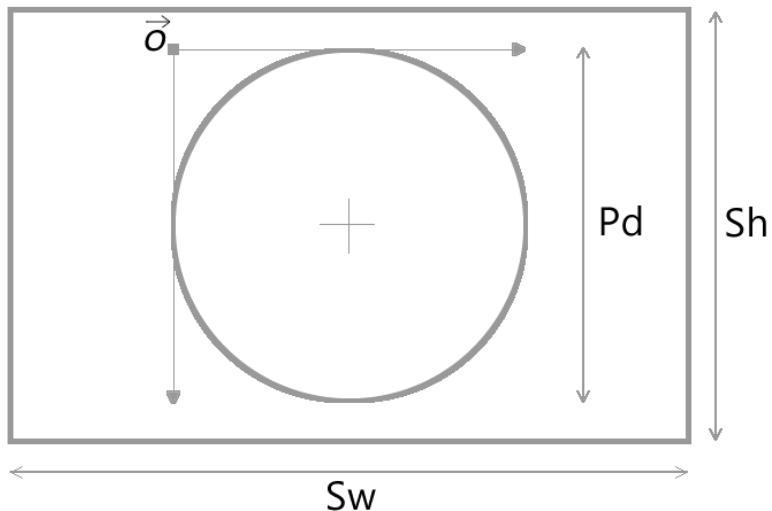


Figura 11: Dimensões dos elementos na tela. Sw e Sh indicam as proporções da tela enquanto Pd indica o tamanho de um dos lados da imagem.

O vetor \vec{o} é encontrado fazendo uma subtração do vetor que aponta para o centro da tela $\vec{S_c}$ com o vetor que aponta para o centro do planeta $\vec{P_c}$, multiplicado pela proporção atual Z da tela, como na equação 9

$$\vec{o} = \frac{(\vec{S_c} - \vec{P_c})}{Z}. \quad (9)$$

Realizando a translação da matriz principal de desenho, podemos considerar o vetor \vec{o} como a origem da tela e todos os elementos seguintes podem ser desenhados referenciando este vetor. Esta matriz transladada também possui sua proporção alterada para ser exibida ao jogador na dimensão que ele configurou. Ao fim da execução dos métodos de desenho desta camada, a matriz principal é novamente transladada ao eixo zero.

A água desenhada na tela é uma imagem transparente (o valor alfa de todos os seus pixels é igual a zero) do mesmo tamanho e na mesma posição da imagem do planeta. Os pixels, correspondentes à água, recebem alguma tonalidade pseudoaleatória cujos canais vermelho e verde variam de 0 a 100, com canal azul 255 em intensidade, além de possuírem valor máximo alfa, ou seja, não transparentes. Assim, os pixels desta imagem podem ser manipulados livremente pois a imagem será atualizada automaticamente na tela. A segmentação da imagem do planeta é impressa na imagem de água, sendo no final o resultado da segmentação da imagem de retina realizada pelo jogador, como esquematizado na Figura 12.

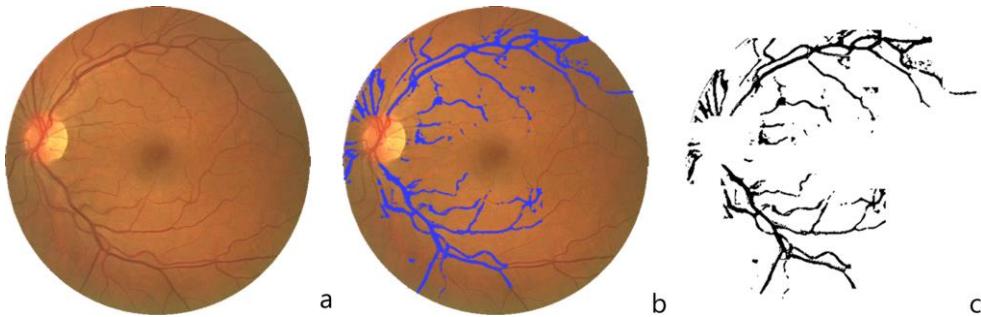


Figura 12: O usuário atua sobre a imagem original (a). O resultado de suas ações é desenhado como em (b), mas a segmentação é uma imagem a parte como em (c).

O resultado é salvo a cada 5 segundos do tempo da máquina em um arquivo PNG² no diretório onde o jogo está instalado, sobrescrevendo a imagem previamente salva para esta partida. Ao fim, temos uma imagem segmentada para cada partida. Caso nenhum clique tenha ocorrido no planeta, nenhuma imagem é salva, evitando o acúmulo de falsas segmentações.

A cada clique, a posição na tela é transladada para sua respectiva posição no planeta. Esta posição então é utilizada pelas ferramentas de segmentação. A obtenção da posição no planeta \vec{c} , a partir do clique na tela na posição \vec{m} é dada através da equação:

$$\vec{c} = \frac{(\vec{m} - \vec{o})}{Z}. \quad (10)$$

3.4 Ferramentas

As ferramentas do jogo foram pensadas para ser instrumentos interativos de pintura. Elas precisam ser mais dinâmicas do que as ferramentas de programas de desenho tradicional para caber no contexto do jogo, mas principalmente para realizar bem segmentações de imagem. Para a versão protótipo deste trabalho, quatro ferramentas foram implementadas: perfuração, canal, raio x, aterro.

3.4.1 Perfurar

A ferramenta de perfuração espalha água pelo terreno com o algoritmo de crescimento de região. Sua animação é cessada quando não há mais água disponível para desenhar, sendo este limite informado por parâmetro de jogo. Em uma primeira versão para *tablets*, era possível alterar a quantidade de píxeis-água que seriam desenhados mas esta função foi descontinuada e esta quantidade mantida fixa em 2000 píxeis. Quando

² Portable Network Graphics, formato de dados utilizado para imagens.

utilizada a ferramenta de perfuração dentro do planeta, uma semente \vec{s} é depositada no local do clique, indicando a partir de onde a região com água crescerá. O Algoritmo 2 descreve os procedimentos para sinalizar o crescimento da água. Já o Algoritmo 3 sumariza o processo de crescimento, ele faz parte da atualização da camada do planeta, portanto seu método é executado independente. A Figura 13 mostra alguns *frames* do algoritmo de perfuração. É importante notar que o Algoritmo 3 executa apenas uma vez por redesenho de *frame*, esta execução não-contínua nos permite visualizar o crescimento gradativo da região, pausando o cálculo do crescimento para desenhar a imagem, dando ao jogador *feedback* imediato a sua interação. Ao fim da perfuração, uma operação de fechamento é executada para evitar artefatos de segmentação. Na Figura 13 pode se comparar os resultados antes e depois da operação de fechamento em (d) e (e).

Algoritmo 3: Pseudocódigo de sinalização do local de perfuração

Entrada: Região \vec{c} no planeta que receberá semente;

1. Inicialize quantidade de água;
 2. **Se** água não estiver crescendo, **faça**
 3. Inicialize vetor V de posições a verificar;
 4. Adicione \vec{c} ao vetor V;
 5. Pinte água na posição \vec{c} ;
 6. Sinalize início de crescimento de água;
 7. **Fim**
-

Algoritmo 4: Pseudocódigo da ferramenta de Perfuração

1. **Se** houver água disponível **e** V não estiver vazio **faça**
2. Inicialize vetor N;
3. **Para** cada posição \vec{p} em V, **faça**
4. **Para** x de 1 a 2, **faça**
5. **Para** w de 0 a 360, **faça**
6. Calcule posição \vec{q} baseado em \vec{p} utilizando as equações 11 e 12;
7. **Se** houver água disponível **e** \vec{q} estiver dentro do planeta **e** a posição \vec{q} não contiver água, **faça**
8. Calcule distância d entre as intensidades dos pixels na posição \vec{q} e na posição \vec{s} na imagem do planeta utilizando Equação 13;
9. **Se** d for menor do que a precisão F , **faça**
10. Pinte água na posição \vec{q} ;
11. Adicione \vec{q} a N;
12. Decrementa a quantidade de água disponível;
13. **Fim**
14. **Fim**
15. **Fim**
16. **Fim**
17. **Fim**
18. Esvazie vetor V e adicione os elementos de N a V;

19. **Se não**
 20. Esvazie vetor V;
 21. Execute fechamento da imagem formada;
 22. **Fim**
-

$$q_x = r \times \cos(\alpha) + p_x; \quad (11)$$

$$q_y = r \times \sin(\alpha) + p_y. \quad (12)$$

$$d_{A,B} = \sqrt{(A_r - B_r)^2 + (A_g - B_g)^2 + (A_b - B_b)^2}. \quad (13)$$

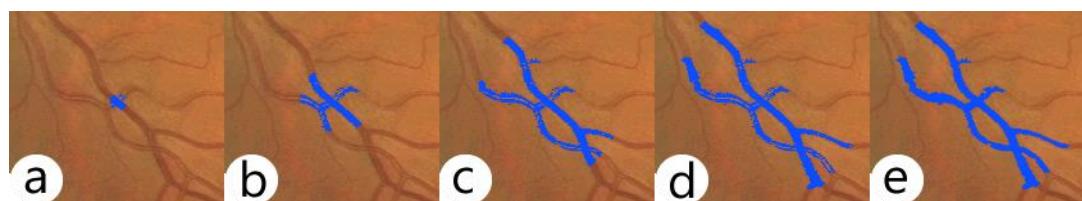


Figura 13: Frames da execução da perfuração.

3.4.2 Canal

A ferramenta de canal cria um caminho de água que é o espaço percorrido por um agente. O jogador determina pontos onde esse agente deverá passar e os pixels cobertos por ele são pintados com água. O tamanho desse agente é variável de acordo com as bordas encontradas por ele. Caso não haja bordas, seu tamanho deve ser limitado a um máximo determinado pelo programador. Esse agente percorre a imagem respeitando as variações de intensidade entre pixels, tentando sempre traçar uma linha reta. Caso não seja possível percorrer este caminho por conta de uma diferença de intensidades superior ao tolerado pelo agente, este altera sua posição para o próximo ponto informado pelo jogador. A diferença entre as intensidades é calculada pela Equação 13. A Figura 14 mostra evolução do desenho da ferramenta canal.



Figura 14: Frames da execução do canal.

3.4.3 Raios X

Esta ferramenta recebeu esse nome por sua animação se assemelhar a uma fotografia com raios x, a imagem é gerada invertendo-se as intensidades dos pixels. O jogador visualiza uma sub-janela quadrada, de dimensão ajustável, com uma parte da imagem tratada, como na Figura 15. A região da sub-janela que estiver em preto será a área pintada com água, caso o jogador clique sobre ela. Este tratamento transforma a sub-janela em uma imagem em tons de cinza e em seguida aplica uma limiarização simples, cujo seu limiar é a intensidade ajustável da ferramenta. Portanto, o jogador pode controlar o tamanho da janela e a intensidade da limiarização. Esta ferramenta permite maior velocidade na segmentação.

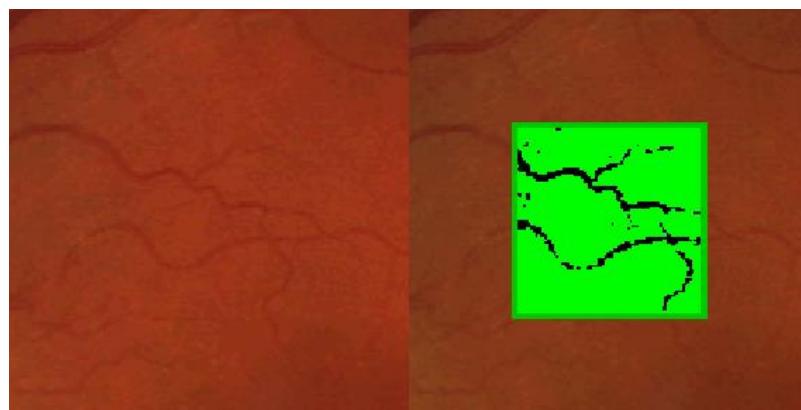


Figura 15: Recorte do planeta com ferramenta de raios x. As duas imagens possuem coloração levemente diferentes por causa da evolução da estação no planeta, mas são imagens adquiridas na mesma partida.

3.4.4 Aterro

A ferramenta mais simples, ela apaga os pixels da imagem de água, analogamente a um aterro. O cursor tem formato circular, onde todos os pixels dentro desta área são substituídos por outros com intensidades alfa zero na imagem de água sobreposta sobre a imagem do planeta.

3.5 Agentes

Durante seu desenvolvimento, o jogo atingiu uma fase onde as segmentações estavam fora de controle, sendo possível pintar o planeta inteiro, o que vai contra os objetivos deste trabalho. Para isto, um método de punição para movimentos errados foi criado. Ele é um monstro que elimina lagos, ou regiões com muito acúmulo de água. Uma vez que o objetivo deste trabalho é identificar os vasos sanguíneos das imagens, não

haverá uma formação que não seja linear. A Figura 16 mostra os *frames* de animação do monstro. Como sua primeira versão foi projetada para dispositivos móveis, não seria possível varrer toda a imagem procurando por lagos, além de realizar toda a matemática de atualização dos outros componentes e finalmente desenhar a cada atualização de tela, que pelo padrão da biblioteca *Processing* é de 60 *frames* por segundo. Limitar essa computação seria imprescindível para que o jogo executasse de forma fluida.



Figura 16: Alguns frames da animação do monstro do jogo.

Os agentes são partículas móveis que realizam operações de verificação nas posições que eles visitam. Existem diferentes tipos de agentes que percorrem o jogo, sendo eles: os agentes de água, de grama, de árvore e os voadores.

Os agentes de água são visíveis ao jogador. Eles nascem após qualquer interação que adicione água ao planeta. Eles percorrem os píxeis que são água, verificando se a quantidade de píxeis Q_w é superior ou igual a quantidade tolerada dentro do campo de visão, de acordo com a Equação 14, onde θ_w é o percentual de tolerância de píxeis dentro do campo de visão de raio $visao_w$, com valor de 20 píxeis:

$$Lago\ Encontrado = \begin{cases} verdadeiro, & Q_w \geq \theta_w \times (\pi \times visao_w^2) \\ falso, & caso contrário \end{cases}. \quad (14)$$

Uma vez encontrado um lago, sua posição é marcada para aparição de um monstro. Todos os píxeis de água com até 60 pontos de distância da posição do monstro são apagados e este agente é eliminado. Este agente é desenhado como um pixel branco e semitransparente sobre a água, como mostrado na Figura 17.



Figura 17: À esquerda, os agentes que percorrem o mapa com água. À direita, aparição do monstro após um movimento indevido.

Os agentes de grama e árvore não são visíveis ao jogador. Eles navegam pseudoaleatoriamente por toda a imagem do planeta em busca de água e grama. O agente de grama, caso visite um pixel que contenha água, sinaliza que naquela posição nascerá grama. O mesmo para o agente de árvore, mas ele procura por um pixel que

Projeto MARTE

contenha grama. Por fim, os agentes voadores podem surgir com as árvores e eles apenas voam pela tela, dando movimento ao planeta que a este ponto se encontra vivo. A Figura 18 ilustra um planeta com segmentação avançada e portanto, vivo.

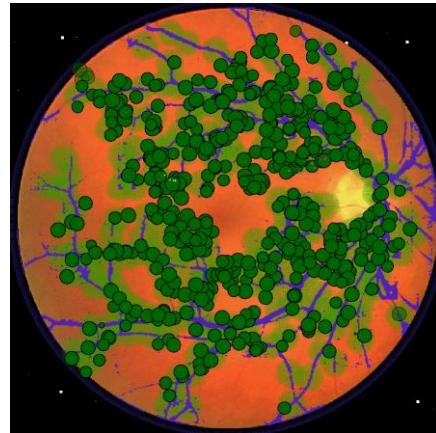


Figura 18: Tela do jogo em uma partida avançada.

3.6 Decisões de Interação

O teclado e o *mouse* são utilizados na interação do jogador. Os cliques indicam onde a ação da ferramenta será realizada e o teclado a configuração do jogo. Anteriormente a versão no computador, a interação nos celulares e *tablets* se dava através de ícones na tela. A Tabela 1 sumariza todos os comandos da última versão do protótipo deste trabalho.

Projeto MARTE

Tabela 1: Comandos do jogo.

Comando	Ferramentas
1	Perfuração
2	Canal
3	Raios-x
0	Aterro
Comando	Modo Perfuração
Z	Menor Precisão
X	Maior Precisão
Comando	Modo Canal
Barra de Espaço	Finaliza Canal
Z	Menor Precisão
X	Maior Precisão
Comando	Modo Raios-X
A	Menor área
S	Maior área
Z	Menor potência
X	Maior potência
Comando	Configuração
Shift + N	Novo jogo
+	Aproxima zoom
-	Afasta zoom
*	Visualização completa do planeta
ESC	Finaliza jogo

4 Resultados e Análises

O jogo digital implementado foi testado com jogadores de diferentes faixas etárias, coletando todos os seus resultados de segmentação. Testes avaliando as reações dos jogadores e questionários também foram realizados durante o desenvolvimento do protótipo. Neste capítulo, os resultados e análises sobre as segmentações e respostas dos jogadores são apresentados.

4.1 Metodologia

A última versão do protótipo deste trabalho foi utilizada para aquisição de segmentações sobre as imagens de retina. Foram avaliadas oito pessoas, com idades variando de oito anos de idade à cinquenta e três anos de idade, para testar o protótipo desenvolvido. Seus dados podem ser encontrados na Tabela 2. Os testes ocorreram tanto no computador utilizado no desenvolvimento quanto nos computadores pessoais dos jogadores. Antes de iniciarem o jogo, a história e as introduções os eram apresentadas oralmente.

Tabela 2: Características dos indivíduos avaliados neste trabalho.

	Jogador 1	Jogador 2	Jogador 3	Jogador 4	Jogador 5	Jogador 6	Jogador 7	Jogador 8
Idade e sexo	8 anos, homem	10 anos, homem	12 anos, homem	16 anos, mulher	18 anos, mulher	50 anos, mulher	53 anos, mulher	22 anos, homem
Familiaridade com Computadores	Pouca	Pouca	Pouca	Muita	Muita	Pouca	Muita	Muita
Gosta de Jogos Eletrônicos	Sim	Sim	Sim	Sim	Não	Sim	Sim	Sim
Frequência que costuma jogar	Duas vezes por semana	Uma vez por semana	Uma vez por semana	Todos os dias	Raramente	Todos os dias	Todos os dias	Raramente

Em um primeiro momento, para todos os jogadores, a história do jogo (presente no Apêndice C deste trabalho) era lida e em seguida, a primeira partida iniciada. O jogador possuía liberdade para permanecer na mesma partida ou não, podendo iniciar um novo jogo quando quisesse. Em um segundo momento, depois de que cada jogador decidisse não mais continuar, o propósito do jogo e deste trabalho eram apresentados. Em seguida, novas partidas eram iniciadas. Essas últimas partidas permitiram avaliar aspectos do jogo como seu apelo. Os resultados serão apresentados na segunda parte deste capítulo.

Para este trabalho, cinco imagens de retinas foram utilizadas. As imagens podem ser encontradas no Apêndice A deste trabalho. Elas poderiam ser apresentadas em qualquer

Resultados e Análises

ordem, portanto, nem todas as imagens foram segmentadas por todos os jogadores. As segmentações obtidas eram, por fim, agrupadas de acordo com as idades dos jogadores e utilizadas no algoritmo STAPLE de combinação de segmentações de imagem.

Como métricas de avaliação dos desempenhos, três taxas foram verificadas. A primeira, o acerto de cada segmentação, determina quantos pixels foram classificados corretamente como sendo ou não vasos sanguíneos. A segunda métrica, a de precisão, indica quantos pixels foram classificados corretamente dentre os pixels classificados como vasos sanguíneos. Finalmente, a taxa de cobertura indica quantos pixels foram classificados corretamente como vasos dentre todos os pixels de vasos, ou seja, qual a quantidade de vasos sanguíneos cobertos de fato pela segmentação realizada.

4.2 Resultados das Segmentações

As imagens segmentadas possuem características diferentes de acordo com a idade do jogador. As imagens segmentadas por jogadores de oito a doze anos possuem menos detalhes e se concentraram sobre os vasos sanguíneos mais aparentes. O nível de detalhe das segmentações aumenta de acordo com a idade do jogador, mesmo com a utilização das mesmas ferramentas de segmentação. A Tabela 3 mostra as médias das taxas de acerto de classificação, de precisão e cobertura sobre as segmentações combinadas com o algoritmo STAPLE por faixa etária:

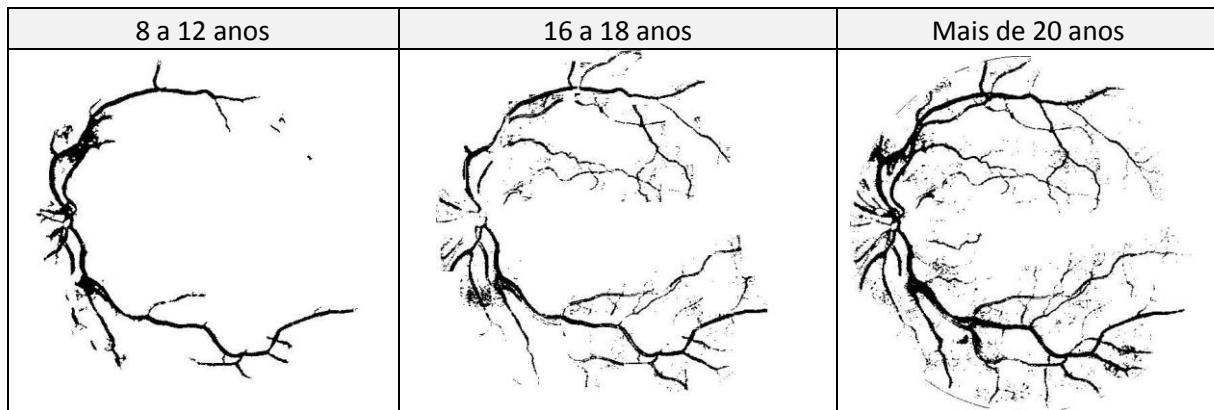
Tabela 3: Comparação entre médias das taxas de acerto, precisão e cobertura por faixa etária.

	8 a 12 anos	16 a 18 anos	Mais de 20 anos
Acerto	84.043%	82.075%	81.829%
Precisão	71.372%	67.646%	72.167%
Cobertura	35.818%	54.239%	62.118%

Os valores da tabela mostram segmentações mais elaborada quando realizada por adultos. As altas taxas de acerto entre os jogadores significam que eles classificaram corretamente os pixels que seriam vasos sanguíneos e os pixels de fundo, que não são vasos, nas imagens de retina. Apesar das crianças possuírem maior taxa de acerto do que os demais nestes resultados, é importante notar a pequena área segmentadas por elas em comparação com os outros através das taxas de cobertura. Os adultos se arriscaram mais, tendo uma taxa de acerto inferior às taxas das outras faixas etárias, porém preocuparam-se em cobrir uma maior quantidade de vasos sanguíneos. A Tabela 4 mostra o resultado das combinações das segmentações para a imagem 2, onde é clara a diferença, entre as três faixas etárias. Não é possível inferir resultados mais elaborados com precisão por apenas oito jogadores estarem sendo avaliados.

Resultados e Análises

Tabela 4: Segmentações por idade.



A Tabela 5 apresenta as médias das taxas quando todas as segmentações são combinadas com o algoritmo STAPLE.

Tabela 5: Resultados para todas as segmentações da imagem 2 combinadas com STAPLE.

Acerto	83.276%
Precisão	76.663%
Cobertura	61.131%

Apesar da melhora da taxa de cobertura da combinação das segmentações, a taxa de acerto verificou leve melhora. A taxa de precisão teve melhora significativa comparada com as segmentações por faixa etária. A Figura 19 é o resultado da combinação de todas as segmentações da imagem 2.

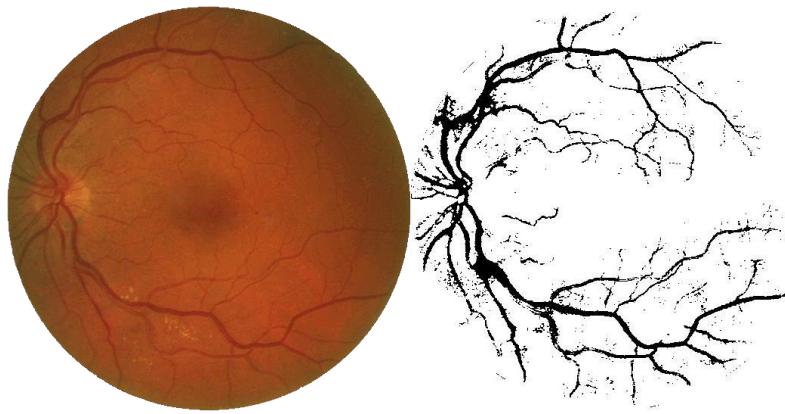


Figura 19: Combinação de todas as segmentações da imagem 2.

O método de combinação de segmentações STAPLE foi fundamental na apresentação destes resultados. A Tabela 6 apresenta uma comparação entre as taxas de

Resultados e Análises

acerto, precisão e cobertura quando utilizada a técnica STAPLE e quando realizada uma média entre as taxas para cada imagem. Quando comparadas, as taxas de acerto mostram-se muito próximas entre o STAPLE e as médias dos resultados individuais. Porém, é importante destacar as fortes taxas de precisão e cobertura alcançadas com a utilização do STAPLE, comparadas com as médias, indicando que uma maior área de vasos foi segmentada de forma mais precisa. Os resultados das segmentações utilizando todas as partidas para cada imagem estão presentes no Apêndice B, enquanto mais taxas são apresentadas no Apêndice D deste trabalho.

Tabela 6: Comparação entre resultados STAPLE e média das taxas de todas as segmentações realizadas.

Imagen	Métrica	STAPLE	Média
0	Acerto	82.229%	83.812%
	Precisão	66.888%	69.384%
	Cobertura	70.983%	42.495%
1	Acerto	82.367%	82.897%
	Precisão	78.591%	73.485%
	Cobertura	64.050%	35.194%
2	Acerto	83.144%	83.116%
	Precisão	79.789%	74.228%
	Cobertura	59.702%	38.469%
3	Acerto	85.312%	84.941%
	Precisão	84.364%	70.415%
	Cobertura	50.740%	25.210%
4	Acerto	84.460%	84.534%
	Precisão	79.309%	69.313%
	Cobertura	49.968%	21.138%

Os resultados das segmentações dos jogadores e do STAPLE podem ser comparados com os resultados obtidos através de técnicas de limiarização realizados por máquina e também combinados com o STAPLE. As técnicas de Niblack, Sauvola e Médias Móveis utilizadas para demonstrar o poder do STAPLE no trabalho de Hugo Leonardo [12], quando comparadas as taxas atingidas por humanos não especialistas destacam-se pela sua superior taxa de acerto, ou seja, a quantidade de pixels classificados corretamente no geral. Porém, as taxas de precisão e cobertura, que lidam exclusivamente com a quantidade de pixels classificados como vasos sanguíneos é superior, no geral. Isso traduz a preocupação do jogador em garantir que suas jogadas permaneçam dentro do espaço delimitado pelo vaso sanguíneo. Vale lembrar que suas jogadas quando segmentam grandes regiões são passíveis de aparição do monstro, o mecanismo de punição do jogo.

Resultados e Análises

Os resultados de segmentações realizadas por máquina e combinadas com o STAPLE podem ser consultadas nos anexos deste trabalho.

4.3 Análise das Ferramentas

As ferramentas do jogo utilizadas na segmentação foram também fundamentais na obtenção dos resultados. A ferramenta de perfuração era a mais interessante visualmente aos jogadores, por causa da animação executada após cada clique. No que se refere a segmentação conseguida, não era sempre eficiente. A perfuração gerava artefatos na segmentação quanto atingia píxeis com intensidades próximas como na ilustrado na Figura 20.



Figura 20: Resultado da ferramenta de perfuração com artefatos.

A perfuração também gerava lagos facilmente, caso o jogador a realizasse sobre um pixel indevido. O uso desta ferramenta forçava a atenção sobre as ações aumentar. Muitos dos lagos gerados pelos vazamentos exemplificados na imagem X eram corrigidos pela ação do monstro no jogo. A Figura 21 mostra o efeito resultante de vários vazamentos conjuntos. Regiões grandes como a da Figura 21 eram candidatas muito favoráveis a aparição de monstros. Com a aparição dos monstros, estes artefatos eram corrigidos.

Resultados e Análises



Figura 21: Muitos vazamentos propiciam a aparição dos monstros.

A segunda ferramenta do jogo, a do canal, foi a menos utilizada. Ela permitia realizar uma segmentação em linha reta da imagem, tolerando mais a diferença entre píxeis. Os jogadores que a utilizaram realizavam conexões entre segmentações separadas. A Figura 22 mostra a segmentação realizada pela ferramenta de canal. Destacada em vermelho, a região criada para conectar as duas outras. Em verde, uma ação recorrente em algumas partidas, o preenchimento de regiões que não são vaso sanguíneo com a ferramenta de canal. Estas regiões não são grandes o suficiente para serem consideradas lagos e portanto, são artefatos da segmentação.



Figura 22: Artefatos da ferramenta de canal.

A ferramenta de Raios X foi a mais utilizada e melhor avaliada dentre as ferramentas de segmentação do jogo. Os jogadores preferiram utilizá-la por conseguirem segmentar mais rapidamente. Os resultados de uso desta ferramenta eram, na maior parte dos casos, segmentações bem definidas. Comumente, artefatos semelhantes a ruídos foram presenciados, como visto na Figura 23.

Resultados e Análises

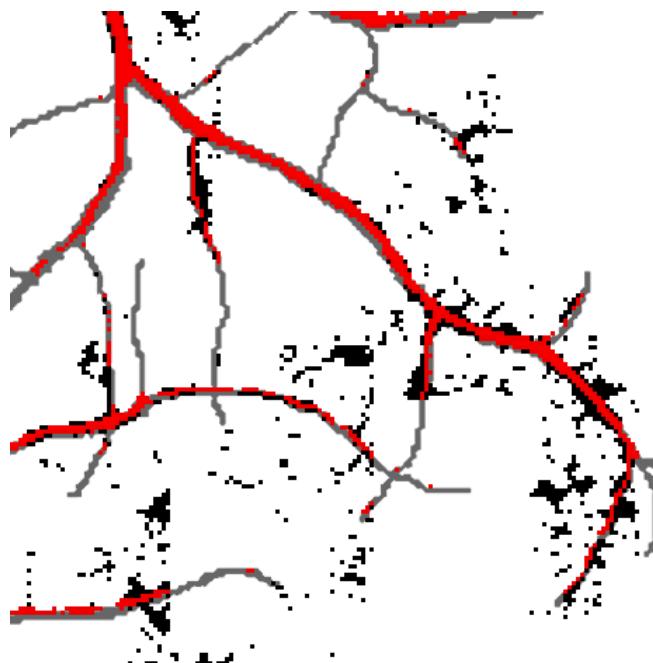


Figura 23: Possível resultado de uma segmentação utilizando a ferramenta de Raios X. Em vermelho, os píxeis classificados corretamente como vaso sanguíneo.

Finalmente, a ferramenta criada para correção manual da segmentação, a de aterro, era pouco utilizada pelos jogadores. Durante o jogo, raramente era lembrada. Seu mau uso acarretou em alguns artefatos gerados pela segmentação dos jogadores. A Figura 24 mostra uma região onde a ferramenta de aterro foi aplicada. Originalmente um vazamento, a região possui marcas da ferramenta mas o erro na segmentação não foi devidamente corrigido.

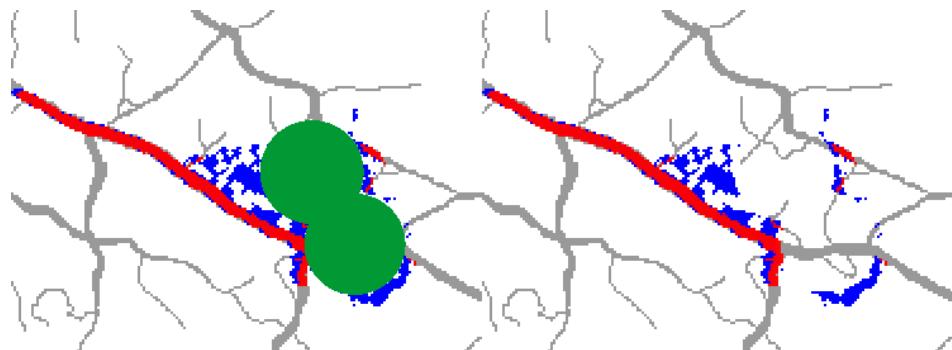


Figura 24: Possível resultado do uso da ferramenta de aterro. Em azul os píxeis errados, em vermelho os píxeis corretos e a área verde é a área de aplicação da ferramenta de aterro.

Resultados e Análises

4.4 Análise do Jogo

Após o fim dos testes com cada jogador, informações sobre o jogo foram coletadas em forma de pesquisa. A primeira impressão que os jogadores tiveram foi de não saberem exatamente o que fazer. As instruções por escrito não foram sugestivas o suficiente. Para envolver os jogadores na experiência, o ideal seria um tempo do jogo dedicado a apresentação da história. Para as crianças, o jogo não foi interessante até as primeiras reações de animação do planeta sobre as segmentações realizadas. Outro elemento que ajudaria bastante na imersão dos jogadores é a presença de efeitos sonoros, que não foram agregados a este trabalho por limitações de tempo. Os jovens e adultos se interessaram rapidamente, as animações da água preenchendo os espaços era na maior parte dos casos apontada como interessante e chamativo. As animações contaram muito para o apelo do jogo, segundo os jogadores.

A quebra de fluidez das ações acarretava em pequenas frustrações do jogador, que com o passar do tempo poderiam desistir do mapa. Seis de oito jogadores questionaram se haveria outro nível no jogo, muitas vezes eles realizaram comparações subjetivas entre as dificuldades de segmentação entre as imagens. Esta reação pode ser explicada pela falta de fim de jogo. Apesar de haver um objetivo definido, o jogador poderia continuar adicionando água ao planeta, uma vez que o objetivo era finalmente subjetivo. Por este motivo, as segmentações realizadas se apresentam muitas vezes incompletas quando comparadas com segmentações da mesma imagem realizadas por outros jogadores. As imagens de retina convenceram apenas as crianças e adolescentes de que aquilo se tratava de uma imagem de um planeta, enquanto os adultos desconfiaram de que aquilo talvez não se tratasse de um planeta de fato.

Todos os jogadores mostraram-se intimidados pela mecânica de punição do jogo: o monstro. As jogadas eram realizadas com muito cuidado para não desencadear a aparição de um monstro e ele desfazer boa parte do trabalho já feito pelo jogador. Apesar da recompensa deste protótipo de jogo ser visual, sem pontuação ou *rankings*, os jogadores buscavam motivos diferentes para avaliar a partida. Entre as crianças, a quantidade de árvores era um fator que indicava que o jogador estava indo bem. Entre os jovens e adultos, a preocupação era no correto preenchimento dos rios do planeta. Não obstante, algumas partidas entre os jovens e adultos eram medidas pela quantidade de área verde que havia crescido no planeta.

Apesar de não ter fim, em um momento o planeta estaria coberto por área verde. Deste modo, era difícil continuar a segmentação e então, o jogador assumia o mapa como concluído. Algumas vezes, áreas na imagem não eram segmentadas, apesar da presença de vasos sanguíneos, pela dificuldade de marcação com as ferramentas disponíveis no jogo.

Resultados e Análises

É importante também notar os diferentes níveis de motivação percebidos nos jogadores mais velhos. Entre os jovens e adultos, quando o real motivo deste trabalho foi apresentado, eles sentiram-se mais motivados em estar contribuindo para um trabalho acadêmico e novas segmentações eram realizadas, com mais atenção. O apelo criado pela representação de planeta foi bem vindo para as crianças. Para os adultos, o jogo deveria ter menos abstrações e deveria estar mais próximo da sua real motivação.

5 Conclusão

Transformar um problema em jogo, processo conhecido como ludificação, é uma solução simples e que utiliza o potencial humano para resolver o problema original. A ludificação pode ser utilizada em qualquer área do conhecimento. Em especial na computação, ela nos permite atribuir o fator subjetivo dos indivíduos na resolução de problemas computacionais, antes apenas aproximados por algoritmos. Portanto, um problema que recebeu ludificação não necessariamente está excluso de receber pré-processamento ou pós-processamento. Este trabalho mostrou como a técnica pode ser eficiente na segmentação de imagens, uma atividade originalmente humana. Hoje a segmentação é bem resolvida por diversos algoritmos, mas a segmentação realizada por humanos continuará superior, uma vez que o homem assiste aquilo que ele deseja retirar de uma imagem.

A abordagem de jogo digital proposta para segmentação de retinas oculares foi implementada e testada com jogadores de diferentes faixas etárias. Os resultados obtidos variaram com as jogadas, mas permitiram que humanos não especialistas realizassem segmentações com resultados satisfatórios depois de combinadas. Foram observados também comportamentos peculiares nos jogadores que podem ser explorados em trabalhos futuros na resolução de problemas mais avançados com ludificação.

A combinação de ludificação com as técnicas já conhecidas de segmentação de imagens podem oferecer ainda melhores resultados. Também, outras abordagens para este mesmo problema podem ser exploradas, focando em uma faixa etária diferente do alvo deste trabalho, como a adulta que apresentou melhores resultados de segmentação.

Finalmente, com a redução do custo dos dispositivos móveis, o potencial humano para a resolução de problemas computacionais coletivamente torna-se cada vez mais tangível. Portanto, esta área de pesquisa tende a estar em evidência no futuro.

6 Bibliografia

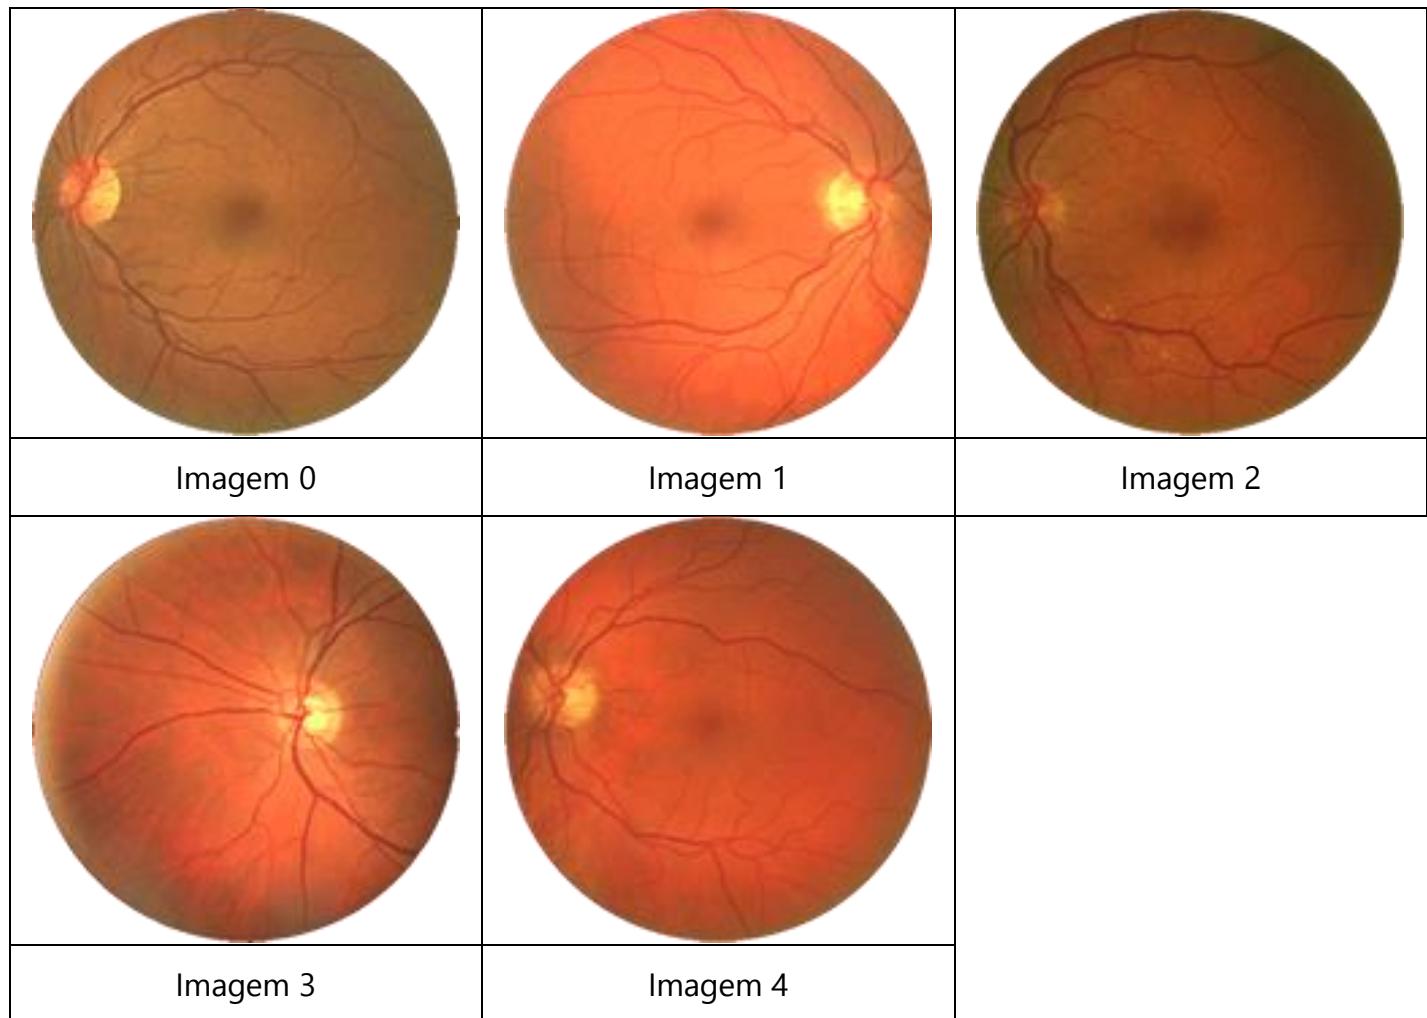
- [1] J. J. Staal, M. D. Abràmoff, M. Niemeijer e B. van Ginneken, "Ridge based vessel segmentation in color images of the retina," *IEEE Transactions on Medical Imaging*, vol. 23, pp. 501-509, 2004.
- [2] M. Niemeijer, J. Staal, B. van Ginneken, M. Loog e M. D. Abràmoff, "Comparative study of retinal vessel segmentation methods on a new publicly available database," *SPIE Medical Imaging*, vol. 5370, pp. 648-656, 2004.
- [3] M. D. Heath, S. Sarkar, T. Sanocki e K. W. Bowyer, "A robust visual method for assessing the relative performance of edge-detection algorithms," *IEEE Transactions of Pattern Analysis and Machine Intelligence*, vol. 19, pp. 1338-1359, 1997.
- [4] J. Radoff, Game On: Energize Your Business with Social Media Games, Illustrated ed., Wiley, 2011, p. 432.
- [5] R. C. Gonzalez e R. E. Woods, Digital Image Processing, 3 ed., Pearson Higher Ed, 2011.
- [6] D. Martin, C. Fowlkes, D. Tal e J. Malik, "A Database of Human Segmented Natural Images and its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics," *Eighth IEEE International Conference on Computer Vision*, vol. 2, pp. 416-423, 2001.
- [7] L. Cinque, C. Guerra e S. Levialdi, "Reply: On the Paper by R. M. Haralick," *CVGIP: Image Understanding*, vol. 60, pp. 250-252, 1994.
- [8] W. Niblack, An introduction to digital image processing, Birkeroed, Dinamarca: Strandberg Publishing Company, 1985.
- [9] J. Schmid, N. Nijdam, S. Han, J. Kim e N. Magnenat-Thalmann, "Interactive Segmentation of Volumetric Medical Images for Collaborative Telemedicine," *Modelling the Physiological Human*, pp. 13-24, 2009.

Bibliografia

- [10] S. Lab, "About EyeWire, A Game to Map the Brain," MIT, 2014. [Online]. Available: <http://blog.eyewire.org/about/>. [Acesso em Outubro 2014].
- [11] S. K. Warfield, K. H. Zou e W. M. Wells, "Simultaneous truth and performance level estimation (STAPLE): an algorithm for the validation of image segmentation," *IEEE Transactions on Medical Imaging*, vol. 23, pp. 903-921, 2004.
- [12] H. M. dos Santos e B. J. T. Fernandes, "Método de Combinação de Segmentações para Extração de Vasos Sanguíneos em Imagens da Retina," Escola Politécnica de Pernambuco, Recife, 2013.
- [13] J. Schell, *The Art of Game Design: a Book of Lenses*, CRC Press, 2008.
- [14] A. Developers, "Get the Android SDK," 2014. [Online]. Available: Disponível em <https://developer.android.com/sdk/index.html?hl=i>. [Acesso em Outubro 2014].
- [15] B. Fry e C. Reas, "Processing.org," 2003. [Online]. Available: Disponível em: <https://processing.org/>. [Acesso em Outubro 2014].

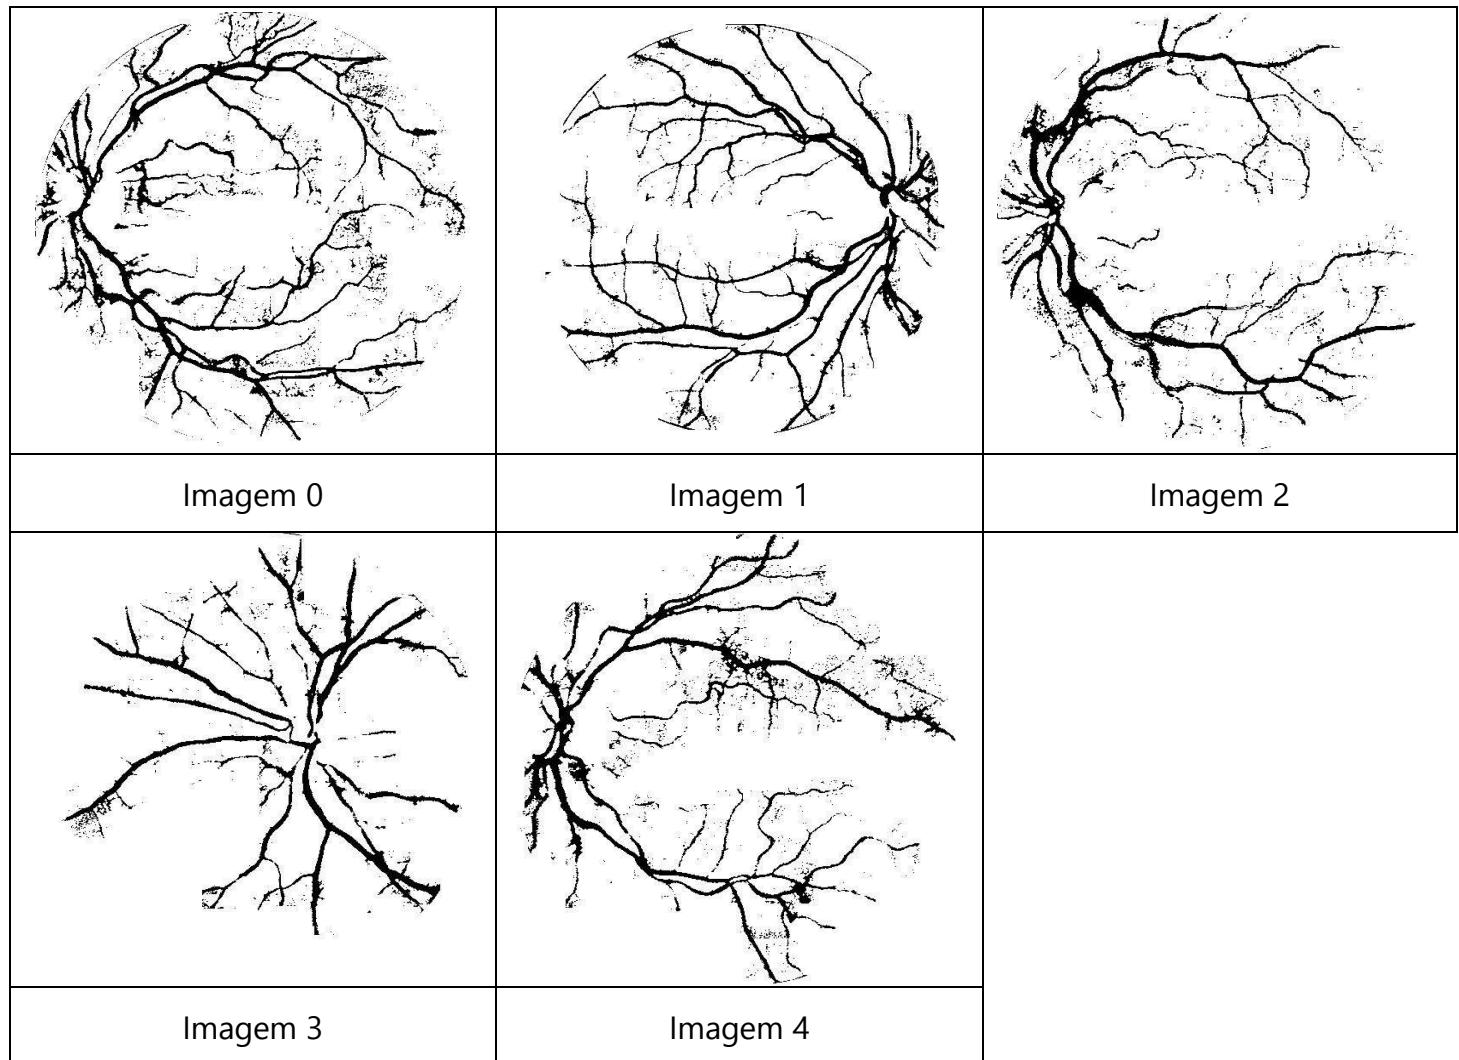
Apêndice A: Imagens de retina utilizadas no jogo

As imagens deste apêndice receberam tratamento preliminar com uma máscara circular para fazê-las semelhantes a planetas.



Apêndice B: Segmentações das Imagens de Retina

As imagens desta seção foram segmentadas utilizando o Projeto MARTE e são referentes as segmentações combinadas de todos os jogadores com o algoritmo STAPLE.



Apêndice C: História do Jogo

"O planeta a seguir possui condições de abrigar vida terrestre, mas ele está muito seco. É sabido que há água em seu subterrâneo. Seu objetivo é inundar os rios deste planeta. Para isto, você pode perfurar o planeta, escavar canais, utilizar raios-x para trazer água à superfície e também aterrkar áreas que não deveriam estar inundadas. Cuidado com seus movimentos, há monstros subterrâneos aguardando seus erros!"

Apêndice D: Resultados das Partidas com algoritmo STAPLE

As tabelas a seguir contabilizam as taxas de acerto, precisão e cobertura para os resultados das segmentações combinadas com o algoritmo STAPLE.

Tabela D1: Resultados separados em três agrupamentos por idade de jogadores.

Imagen	Métrica	8 a 12 anos	Qtd. Segmt.	16 a 18 anos	Qtd. Segmt.	Mais de 20 anos	Qtd. Segmt.
0	Acerto	84.588%		82.981%		76.403%	
	Precisão	69.510%	2	66.759%	3	49.644%	2
	Cobertura	39.208%		59.087%		78.320%	
1	Acerto	82.693%		81.311%		81.836%	
	Precisão	77.153%	9	70.798%	2	75.298%	5
	Cobertura	51.579%		59.346%		63.973%	
2	Acerto	84.608%		84.197%		82.625%	
	Precisão	86.929%	4	84.421%	2	76.384%	6
	Cobertura	34.043%		42.943%		60.367%	
3	Acerto	83.746%		79.991%		86.006%	
	Precisão	62.932%	6	53.420%	2	91.773%	5
	Cobertura	35.759%		56.234%		47.175%	
4	Acerto	84.580%		81.894%		82.273%	
	Precisão	60.336%	5	62.834%	3	67.735%	5
	Cobertura	18.505%		53.586%		60.752%	

Apêndice D: Resultados das Partidas com algoritmo STAPLE

Tabela D2: Resultados quando agrupando partidas realizadas por jogadores de 8 a 18 anos.

Imagen	8 a 18 anos	Qtd. Segmt.
0	Acerto	82.801%
	Precisão	67.074%
	Cobertura	62.716%
1	Acerto	83.334%
	Precisão	83.068%
	Cobertura	53.999%
2	Acerto	84.252%
	Precisão	84.369%
	Cobertura	40.754%
3	Acerto	84.144%
	Precisão	70.136%
	Cobertura	42.521%
4	Acerto	84.225%
	Precisão	72.924%
	Cobertura	39.708%

Tabela D3: Resultados quando agrupando partidas realizadas por jogadores com mais de 16 anos.

Imagen	Mais de 16 anos	Qtd. Segmt.
0	Acerto	82.744%
	Precisão	69.047%
	Cobertura	69.655%
1	Acerto	81.029%
	Precisão	71.624%
	Cobertura	66.535%
2	Acerto	82.525%
	Precisão	76.115%
	Cobertura	61.659%
3	Acerto	84.707%
	Precisão	79.735%
	Cobertura	54.714%
4	Acerto	83.482%
	Precisão	74.038%
	Cobertura	57.464%

Apêndice D: Resultados das Partidas com algoritmo STAPLE

Tabela D4: Taxas de acerto, precisão e cobertura, respectivamente, por jogador organizados por idade. Quando um jogador realizou mais de uma segmentação da mesma imagem, seus resultados foram agrupados com o STAPLE.

Img.	J1	J2	J3	J4	J5	J6	J7	J8
0	85.864%	85.541%	-	84.568%	82.983%	-	79.534%	81.571%
	79.492%	66.036%	-	73.653%	66.708%	-	52.984%	63.697%
	29.044%	19.346%	-	48.505%	58.923%	-	62.692%	70.440%
1	83.164%	83.020%	-	-	84.388%	-	-	81.836%
	79.140%	74.397%	-	-	84.627%	-	-	75.298%
	46.046%	38.063%	-	-	21.940%	-	-	63.973%
2	84.608%	-	-	84.453%	-	84.591%	79.902%	83.670%
	86.929%	-	-	87.204%	-	86.610%	54.509%	82.820%
	34.043%	-	-	42.138%	-	33.857%	44.648%	55.583%
3	84.957%	-	81.854%	-	86.287%	-	85.532%	86.076%
	71.673%	-	42.849%	-	86.434%	-	66.485%	92.389%
	30.481%	-	26.358%	-	13.620%	-	15.396%	45.011%
4	84.580%	-	-	86.203%	85.091%	78.371%	-	84.942%
	60.336%	-	-	93.513%	77.577%	38.395%	-	81.671%
	18.505%	-	-	5.183%	29.208%	35.730%	-	42.468%

Anexo A: Resultados Comparativos do STAPLE

A tabela a seguir apresenta os resultados comparativos das combinações discutidas no trabalho de Hugo Leonardo [12] e os resultados atingidos neste trabalho, para as imagens de retina utilizadas.

Imagen	Métricas	Médias Móveis	Sauvola	Niblack	Médias e Niblack	Niblack e Sauvola	Médias e Sauvola	Médias, Sauvola e Niblack	Projeto MARTE
0	Acerto	88.98%	91.66%	91.11%	91.31%	91.55%	91.67%	91.99%	82.23%
	Precisão	63.59%	89.24%	72.76%	76.42%	86.78%	89.37%	84.42%	66.89%
	Cobertura	37.31%	41.40%	51.52%	48.83%	41.94%	41.43%	47.74%	70.98%
1	Acerto	80.66%	90.19%	90.87%	91.01%	90.26%	90.18%	91.59%	82.37%
	Precisão	35.49%	95.86%	80.82%	84.65%	95.31%	96.06%	84.14%	78.59%
	Cobertura	35.56%	36.11%	51.28%	48.93%	36.86%	35.97%	54.07%	64.05%
2	Acerto	87.67%	90.58%	89.33%	89.48%	90.57%	90.56%	90.58%	83.14%
	Precisão	67.53%	93.32%	70.73%	74.03%	92.68%	93.52%	92.71%	79.79%
	Cobertura	29.72%	38.07%	45.73%	42.83%	38.32%	37.86%	38.41%	59.70%
3	Acerto	86.02%	88.19%	89.83%	90.12%	88.32%	88.27%	88.36%	85.31%
	Precisão	45.15%	72.67%	68.81%	73.86%	73.72%	73.55%	73.89%	84.36%
	Cobertura	22.25%	18.31%	43.44%	40.14%	19.28%	18.80%	19.69%	50.74%
4	Acerto	88.13%	89.95%	90.61%	90.79%	89.97%	89.94%	90.01%	84.46%
	Precisão	65.63%	86.36%	73.89%	78.06%	85.55%	86.74%	85.55%	79.31%
	Cobertura	26.43%	30.80%	47.72%	44.73%	31.42%	30.55%	31.77%	49.97%