



UNIVERSIDADE FEDERAL DO MARANHÃO
UNIVERSIDADE FEDERAL DO PIAUÍ
Doutorado em Ciência da Computação Associação
UFMA/UFPI

Alexandre de Carvalho Araújo

**Segmentação Automática do Pâncreas e Massas
Pancreáticas em Tomografias Computadorizadas
Usando Arquiteturas *Encoder-Decoder***

Orientador: Prof. Dr. João Dallyson Sousa de Almeida
Coorientador: Prof. Dr. Anselmo Cardoso de Paiva

São Luís - MA
Setembro, 2025

Alexandre de Carvalho Araújo

**Segmentação Automática do Pâncreas e Massas
Pancreáticas em Tomografias Computadorizadas
Usando Arquiteturas *Encoder-Decoder***

TESE DO DOUTORADO

Tese apresentada como requisito parcial
para obtenção do título de Doutor em
Ciência da Computação, ao Doutorado
em Ciência da Computação, Associação
UFMA/UFPI.

Orientador: Prof. Dr. João Dallyson Sousa de Almeida
Coorientador: Prof. Dr. Anselmo Cardoso de Paiva

São Luís - MA
Setembro, 2025

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Araújo, Alexandre de Carvalho.

Segmentação automática do pâncreas e massas
pancreáticas em tomografias computadorizadas usando
arquiteturas encoder-decoder / Alexandre de Carvalho
Araújo. - 2025.

120 f.

Coorientador(a) 1: Anselmo Cardoso de Paiva.

Orientador(a): João Dallyson Sousa de Almeida.

Tese (Doutorado) - Programa de Pós-graduação Doutorado
em Ciência da Computação - Associação UFMA/UFPI,
Universidade Federal do Maranhão, São Luís, 2025.

1. Segmentação. 2. Pâncreas. 3. Massas Pancreáticas.
4. Tomografia Computadorizada. 5. Aprendizado Profundo.
I. Almeida, João Dallyson Sousa de. II. Paiva, Anselmo
Cardoso de. III. Título.



Portal do Docente

UNIVERSIDADE FEDERAL DO MARANHÃO
SISTEMA INTEGRADO DE GESTÃO DE ATIVIDADES ACADÊMICAS

EMITIDO EM 24/10/2025 16:47

ATA DE DEFESA DE EXAME DE DEFESA DE TESE DE DOUTORADO

Ata da reunião da Comissão do Exame de Defesa de Tese de Doutorado intitulada "**Segmentação Automática do Pâncreas e Massas Pancreáticas em Tomografias Computadorizadas Usando Arquiteturas Encoder-Decoder**", do PROGRAMA DE PÓS-GRADUAÇÃO DOUTORADO EM CIÊNCIA DA COMPUTAÇÃO - ASSOCIAÇÃO UFMA/UFPI.

Aos vinte e nove dias do mês de Setembro de 2025 às 09:00 horas, reuniu-se em sessão pública a banca examinadora formada pelos professores JOAO DALLYSON SOUSA DE ALMEIDA, Orientador (UFMA), ANTONIO OSEAS DE CARVALHO FILHO, Examinador Interno (UFMA), ARISTOFANES CORREA SILVA, Examinador Interno (UFMA), DEBORA CHRISTINA MUCHALUAT SAADE, Examinador Externo à Instituição (UFF), HERMAN MARTINS GOMES, Examinador Externo à Instituição (UFCG), ANSELMO CARDOSO DE PAIVA, Examinador Co-orientador (UFMA), para, sob a presidência do primeiro, constituírem a comissão para avaliar o Exame de Defesa de Tese de Doutorado do(a) aluno(a) ALEXANDRE DE CARVALHO ARAUJO.

Considerando o trabalho avaliado, as arguições de todos os membros da banca e as respostas dadas pelo candidato, formalizo para fins de registro, por meio deste documento, a decisão da banca de que o candidato pode ser considerado(a): **APROVADO**.

MINUTES OF THE DOCTORAL THESIS DEFENSE

Minutes of the meeting of the Examining Committee for the Doctoral Thesis Defense entitled "Segmentação Automática do Pâncreas e Massas Pancreáticas em Tomografias Computadorizadas Usando Arquiteturas Encoder-Decoder", for the PROGRAMA DE PÓS-GRADUAÇÃO DOUTORADO EM CIÊNCIA DA COMPUTAÇÃO - ASSOCIAÇÃO UFMA/UFPI.

On the twenty-ninth day of September 2025 at 9:00 a.m, the examining committee, composed of the following professors, convened: JOAO DALLYSON SOUSA DE ALMEIDA, Advisor (UFMA); ANTONIO OSEAS DE CARVALHO FILHO, Internal Examiner (UFMA); ARISTOFANES CORREA SILVA, Internal Examiner (UFMA); DEBORA CHRISTINA MUCHALUAT SAADE, External Examiner to the Institution (UFF); HERMAN MARTINS GOMES, External Examiner to the Institution (UFCG); ANSELMO CARDOSO DE PAIVA, Co-Advisor (UFMA); . The meeting was chaired by the first-mentioned professor. The committee was formed to evaluate the Doctoral Thesis Defense of the student ALEXANDRE DE CARVALHO ARAUJO.

Considering the evaluated work, the questions posed by all committee members, and the responses provided by the candidate, I hereby formalize for the record, through this document, the committee's decision that the candidate has: **PASSED**.

ASSINATURAS

ANSELMO CARDOSO DE PAIVA (Co-orientador)
Assinado digitalmente em 29/09/2025

JOAO DALLYSON SOUSA DE ALMEIDA (Presidente)
Assinado digitalmente em 29/09/2025

HERMAN MARTINS GOMES (Externo à Instituição)
Assinado digitalmente em 29/09/2025

DEBORA CHRISTINA MUCHALUAT SAADE (Externo à Instituição)
Assinado digitalmente em 29/09/2025

ARISTOFANES CORREA SILVA (Interno)
Assinado digitalmente em 29/09/2025

ANTONIO OSEAS DE CARVALHO FILHO (Interno)
Assinado digitalmente em 01/10/2025

Alexandre de Carvalho Araújo

Segmentação Automática do Pâncreas e Massas Pancreáticas em Tomografias Computadorizadas Usando Arquiteturas *Encoder-Decoder*

A presente Tese de Doutorado foi avaliada e aprovada por banca examinadora composta pelos seguintes membros:

Prof. Dr. João Dallyson Sousa de Almeida

Orientador

Universidade Federal do Maranhão

Prof. Dr. Anselmo Cardoso de Paiva

Co-orientador

Universidade Federal do Maranhão

Prof. Dr. Aristófanês Corrêa Silva

Examinador Interno

Universidade Federal do Maranhão

Prof. Dr. Antônio Oséas de Carvalho Filho

Examinador Interno

Universidade Federal do Piauí

Profa. Dra. Débora Christina Muchaluat Saade

Examinadora Externa

Universidade Federal Fluminense

Prof. Dr. Herman Martins Gomes

Examinador Externo

Universidade Federal de Campina Grande

Certificamos que esta é a versão original e final da Tese de Doutorado que foi julgada adequada para obtenção do título de Doutor em Ciência da Computação.

Prof. Dr. João Dallyson Sousa de Almeida

Orientador

Prof. Dr. Anselmo Cardoso de Paiva

Coordenador

São Luís - MA, 29 de Setembro de 2025

*À minha família, amigos e a todos
que me deram suporte em minha jornada.*

Agradecimentos

Agradeço à todos da minha família, que contribuíram para que eu me tornasse quem sou hoje. Agradecimentos em especial aos meus pais, Maria do Socorro e José Bernardo, os quais me deram todo o suporte necessário para que eu tivesse a possibilidade de seguir a jornada do doutorado, assim como o apoio e ajuda para que eu conseguisse concluí-la.

À minha namorada, Lorena, pelo apoio emocional, suporte e por todo o amor que me dá.

À família NCA, pelo ambiente de pesquisa, mas também de diversão, que me fez falta durante a pandemia e que foi fator essencial na conclusão desta tese.

A João Dallyson Sousa de Almeida e Anselmo Cardoso de Paiva, pela paciência e orientação sem a qual esse trabalho não seria possível.

Aos meus amigos, cuja companhia me alegra e dá paz de espírito.

Aos professores membros da banca examinadora.

A todos os professores e funcionários do DCCMAPI pela oportunidade, ensinamentos e colaboração.

À CAPES pelo importante apoio financeiro durante o doutorado.

Por fim, agradeço a todos que de alguma maneira moldaram quem eu sou hoje e que não foram ainda contemplados.

"São as perguntas que não sabemos responder que mais nos ensinam. Elas nos ensinam a pensar. Se você dá uma resposta a um homem, tudo o que ele ganha é um fato qualquer. Mas, se você lhe der uma pergunta, ele procurará suas próprias respostas."

(Patrick Rothfuss)

Resumo

O câncer, sendo a segunda principal causa de óbitos em todo o mundo, foi responsável por aproximadamente 10 milhões de mortes no ano de 2020. Comparado a outros tipos de câncer, o câncer pancreático é relativamente raro. O prognóstico para o câncer pancreático é desfavorável, com uma taxa de mortalidade de 98%, uma das piores entre todos os tipos de câncer. O diagnóstico na fase inicial da doença é o principal fator que define o prognóstico. Uma das principais dificuldades do diagnóstico precoce do câncer de pâncreas é a identificação de massas pequenas em exames de imagem, como a ultrassonografia abdominal, a tomografia computadorizada e a ressonância magnética. Os exames de imagem são as principais ferramentas utilizadas para o diagnóstico precoce. Logo, a identificação dessas massas nos estágios iniciais desse tipo de câncer melhora o prognóstico. Tecnologias que suplementem esses exames baseados em imagem são necessárias. Nesta tese, foram desenvolvidos dois métodos, um para segmentação do pâncreas e outro para a segmentação de massas pancreáticas em exames de tomografia computadorizada utilizando Aprendizagem Profunda. O método proposto para segmentação do pâncreas utilizou-se da combinação dos modelos *EfficientNetB7* com *U-Net*, tendo alcançado resultados promissores, com Dice médio de $85,39 \pm 2,39\%$ na base de dados NIH e $85,96 \pm 02,08\%$ na base de dados MSD. Para a segmentação de massas pancreáticas, utilizou-se a combinação de cinco modelos *Encoder-Decoder*: *U-Net*, *FPN* e *LinkNet*, *EDU-Net* e *ETDPU-Net*. Os três primeiros utilizam *EfficientNetB7* como *backbone*, enquanto a *EDU-Net* e *ETDPU-Net* - arquitetura desenvolvida durante esta tese - utilizam convoluções deformáveis e atenção *Squeeze-and-Excitation* para melhorar a extração de características. Esses cinco modelos são combinados em um comitê de votação majoritária para obter resultados superiores aos modelos individuais. O método proposto nesta tese alcançou Dice de $65,28\% \pm 5,57\%$ na base MSD, evidenciando a sua validade e desempenho.

Palavras-chave: Segmentação, Pâncreas, Massas Pancreáticas, Tomografia Computadorizada, Aprendizado profundo.

Abstract

Cancer, the second leading cause of mortality worldwide, accounted for approximately 10 million deaths in 2020. Although relatively rare compared to other malignancies, pancreatic cancer presents one of the poorest prognoses, with a mortality rate of approximately 98%, ranking among the highest across all cancer types. Early-stage detection is the most critical determinant of patient prognosis. However, early diagnosis is particularly challenging due to the difficulty in identifying small lesions in medical imaging modalities such as abdominal ultrasound, computed tomography (CT), and magnetic resonance imaging (MRI). These imaging techniques constitute the primary tools for early detection, and the accurate identification of small pancreatic lesions at early stages significantly improves clinical outcomes. Therefore, there is a pressing need for technologies that can augment and enhance image-based diagnostic workflows. In this work, two deep learning-based methods were developed: one for automatic pancreas segmentation and another for pancreatic mass segmentation in CT scans. The proposed pancreas segmentation approach integrates the EfficientNetB7 backbone within a U-Net architecture, achieving promising results, with a mean Dice similarity coefficient (DSC) of $85.39 \pm 2.39\%$ on the NIH dataset and $85.96 \pm 2.08\%$ on the MSD dataset. For pancreatic mass segmentation, an ensemble of five encoder-decoder architectures was employed: U-Net, FPN, LinkNet, EDU-Net, and ETDPU-Net. The first three utilize EfficientNetB7 as their encoder backbone. The latter two—EDU-Net and ETDPU-Net—were designed as part of this thesis and incorporate deformable convolutions and Squeeze-and-Excitation (SE) attention mechanisms to enhance feature representation. The outputs of all five models are aggregated using a majority voting ensemble strategy to surpass the performance of individual models. The proposed mass segmentation framework achieved a DSC of $65.28\% \pm 5.57\%$ on the MSD dataset, validating the efficacy and robustness of the method.

Keywords: Segmentation, Pancreas, Pancreatic mass, Computer Tomography, Deep Learning.

Lista de ilustrações

Figura 1 – Vista axial de quatro pacientes diferentes e a renderização respectiva do pâncreas e massa pancreática. Em vermelho o contorno e a renderização do pâncreas e em amarelo o contorno e renderização da massa pancreática.	23
Figura 2 – Imagem ilustrativa do pâncreas e estruturas adjacentes	28
Figura 3 – Exemplo de pâncreas com massa. (a) TC do pâncreas com marcação (b) TC do pâncreas sem marcação. Em verde a marcação do pâncreas e em amarelo a marcação da massa.	29
Figura 4 – Ilustração de um tomógrafo, com a vista lateral do tubo de raios-X girando em espiral em torno do paciente.	29
Figura 5 – Arquitetura da rede original <i>U-Net</i>	33
Figura 6 – Arquitetura FPN para segmentação.	35
Figura 7 – Estrutura da arquitetura <i>LinkNet</i> . <i>Conv</i> representa uma convolução; <i>full-conv</i> representa uma convolução completa (LONG; SHELHAMER; DARRELL, 2015); $/2$ representa uma redução de dimensão por um fator de 2 através de uma convolução com <i>stride</i> = 2; $*2$ representa <i>upsampling</i> por um fator de 2.	37
Figura 8 – Estrutura de um <i>Bloco Encoder</i> no <i>Encoder</i> de uma <i>LinkNet</i>	37
Figura 9 – Estrutura de um <i>Bloco Decoder</i> no <i>Decoder</i> de uma <i>LinkNet</i>	38
Figura 10 – Exemplo ilustrativo dos diferentes tipos de escalonamento que compõe o escalonamento composto da arquitetura <i>EfficientNet</i> (a) exemplo de rede base; (b)-(d) escalonamento de apenas uma parte específica, profundidade, largura ou resolução; (e) modelo proposto pela <i>EfficientNet</i>	39
Figura 11 – Bloco MBConv e bloco SE	40
Figura 12 – Exemplo simplificado da saída da YOLO. Neste exemplo, é utilizada uma grade 3×3 e uma única predição de classe por elemento da grade	42
Figura 13 – Visualização da arquitetura YOLO-NAS em sua versão L (<i>Large</i>). A arquitetura é encontrada automaticamente pelo sistema de busca de arquitetura de rede neural AutoNAC.	43
Figura 14 – Exemplo visual da localização das amostragem em convoluções tradicionais e em convoluções deformáveis 3×3 . Os pontos verdes representam uma amostragem tradicional, os pontos azuis representam uma amostragem deformada, baseada no deslocamento representado pelas setas azul claro.	45
Figura 15 – Exemplo de uma convolução deformável 3×3	46

Figura 16 – Estrutura do bloco <i>Squeeze-and-Excitation</i>	46
Figura 17 – Fluxograma do método de segmentação do pâncreas em 2D	64
Figura 18 – Resultado do janelamento de HU com centro 50 e largura 400. Em verde, a marcação do pâncreas e em amarelo, a marcação da massa pancreática.	65
Figura 19 – Representação gráfica da combinação da EfficientNetb7 com U-Net utilizando uma convolução para transformação dos canais de entrada	66
Figura 20 – Exemplo da base MSD. (a) Vista axial, (b) Vista coronal, (c) Vista sagital	68
Figura 21 – Exemplos de cortes da base NIH. A marcação do pâncreas está representada em vermelho	69
Figura 22 – Segmentação do pâncreas em diferentes paciente utilizando o melhor modelo treinado com a EfficientNet+UNet	73
Figura 23 – Fluxograma do método proposto para segmentação de massas pancreáticas.	79
Figura 24 – Fluxograma da etapa de detecção do pâncreas.	80
Figura 25 – U-Net com <i>EfficientNetB7</i> como <i>backbone</i> do <i>Encoder</i> para extração de características	82
Figura 26 – LinkNet com <i>EfficientNetB7</i> como <i>backbone</i> do <i>Encoder</i> para extração de características	82
Figura 27 – FPN com <i>EfficientNetB7</i> como <i>backbone</i> do <i>Encoder</i> para extração de características	83
Figura 28 – Modelo de arquitetura <i>U-Net</i> deformável com <i>Skip Connections</i> SE.	85
Figura 29 – Arquitetura <i>U-Net</i> utilizando blocos De <i>Encoder</i> com Tripla Deformação Paralela (ETDP) e <i>Skip Connections</i> SE.	85
Figura 30 – Processo de votação no comitê.	86
Figura 31 – Processo de votação no comitê.	86
Figura 32 – Exemplos de comparação entre detecção individual e detecção global. Em vermelho a <i>bounding box</i> da detecção e em verde o contorno da marcação da massa pancreática	90
Figura 33 – Exemplos de segmentação para o paciente 18. (A) e (B) apresentam segmentação pelo comitê. (C) e (D) apresentam segmentação individual dos modelos.	93
Figura 34 – Exemplos de segmentação para o paciente 344. (A) - (E) apresentam segmentação pelo comitê. (F) - (J) apresentam segmentação dos modelos individuais.	94

Figura 35 – Exemplos de segmentação para o paciente 106. (A) e (B) representam as duas fatias com massa pancreática desse paciente. (C) apresenta uma fatia desse paciente onde modelos individuais segmentam erroneamente uma área que não tem massa, mas o comitê corrige o erro descartando essas segmentações. (D) Apresenta uma fatia onde o comitê segmenta erroneamente.	95
Figura 36 – Exemplos de casos onde a segmentação correta de modelos individuais é descartada pelo comitê. (A) e (D): Fatia do paciente 37; (B) e (E): Fatia do paciente 45; (C) e (F): Fatia do paciente 55.	96
Figura 37 – Exemplos de segmentação para o paciente 418. (A), (B), (C), (D) e (E) representam as cinco primeiras fatias onde o pâncreas foi detectado para este paciente, que também são as cinco fatias de massa pancreática presente neste paciente.	96
Figura 38 – Exemplos onde a segmentação da EDU-Net ou ETDPU-Net foram melhores do que U-Net com <i>backbone</i> . (A) Somente a ETDPU-Net identifica a massa. (B) Somente a EDU-Net identifica a massa. (C) Ambas EDU-Net e ETDPU-Net identificam a lesão.	97

Lista de tabelas

Tabela 1 – Ranqueamento por Dice de trabalhos relacionados à segmentação do pâncreas na base NIH	58
Tabela 2 – Ranqueamento por Dice de trabalhos relacionados à segmentação do pâncreas na base MSD	58
Tabela 3 – Trabalhos relacionados à segmentação da massa em ordem de Dice decrescente na base de dados Medical Segmentation Decathlon . .	63
Tabela 4 – Resultados de Dice obtidos na comparação entre estratégias na base MSD: (I) estratégia de geração de imagens de três canais a partir de uma camada de convolução; (II) abordagem 2.5D de utilizar os cortes anterior e posterior ao corte alvo para geração de imagem de três canais.	71
Tabela 5 – Resultados obtidos no Experimento 3: Comparação entre redes pré-treinadas na ImageNet. Resultados organizados em ordem crescente de dice na base MSD.	72
Tabela 6 – Comparação do método proposto que combina <i>EfficientNetB7</i> e <i>U-Net</i> para segmentação de pâncreas na base NIH. Dice apresentado em ordem decrescente da média. (-) representa ausência de desvio padrão apresentado.	75
Tabela 7 – Comparação da combinação da <i>EfficientNetB7</i> e <i>U-Net</i> proposta para segmentação de pâncreas na base MSD. Dice apresentado em ordem decrescente da média. (-) representa ausência de desvio padrão apresentado.	76
Tabela 8 – Operações de aumento de dados para o treinamento da detecção do pâncreas	88
Tabela 9 – Resultados das detecções do pâncreas	88
Tabela 10 – Comparação por partição da média da sensibilidade por paciente calculada a partir das detecções individuais e a partir da detecção global	89
Tabela 11 – Operações de aumento de dados para o treinamento da segmentação da massa pancreática	91
Tabela 12 – Comparação entre <i>EfficientNetB0</i> e <i>EfficientNetB7</i> como <i>backbones</i> para segmentação de massa pancreática com modelos <i>U-Net</i> , <i>FPN</i> e <i>LinkNet</i>	91
Tabela 13 – Resultados obtidos para segmentação da massa pancreática a partir da detecção global do pâncreas por paciente. Métricas calculadas por paciente.	92

Tabela 14 – Comparação dos resultados obtidos neste trabalho com trabalhos da literatura para segmentação da massa pancreática	98
Tabela 15 – Resultados obtidos para segmentação da massa a partir da fatia completa. Resultados calculados como média por paciente utilizando todas as fatias dos pacientes.	100
Tabela 16 – Comparação da Sensibilidade para massa por partição calculada a partir das detecções individuais e a partir da detecção global da massa	101
Tabela 17 – Comparação da Sensibilidade para massa por partição calculada a partir da detecção global do pâncreas e a partir da detecção global da massa	101
Tabela 18 – Resultados obtidos para segmentação da massa a partir da detecção da massa pancreática. Resultados calculados como média por paciente utilizando todas as fatias dos pacientes.	102
Tabela 19 – Produção científica relacionada à segmentação do pâncreas e massas pancreáticas.	108

Lista de abreviaturas e siglas

ADP	<i>Adenocarcinoma Pancreático Ductal</i>
ALOT	<i>Active Localization Offset</i>
AP	<i>Aprendizado Profundo</i>
ASM	<i>Active Shape Model</i>
BN	<i>Batch Normalization</i>
CBAM	<i>Convolutional Block Attention Module</i>
CAD	<i>Computer Aided Diagnosis</i>
CNN	<i>Convolutional Neural Network</i>
DSC	<i>Dice Score</i>
ECC	<i>External Contour Cropping</i>
ETDP	<i>Encoder de Tripla Deformação Paralela</i>
FPN	<i>Feature Pyramid Network</i>
HU	<i>Unidade de Hounsfield</i>
IB	<i>Inverse Bottleneck</i>
INCA	<i>Instituto Nacional de Câncer</i>
LBP	<i>Local Binary Pattern</i>
LLE	<i>Local Linear Embedding</i>
MAI	<i>Mixed-scale Attention Integration</i>
MFE	<i>Multi-scale Feature Extraction</i>
MSD	<i>Medical Segmentation Decathlon</i>
NIH	<i>National Institutes of Health</i>
NMS	<i>Non-Maximum Supression</i>

PPM	<i>Prior Propagation Module</i>
RM	<i>Ressonância Magnética</i>
SCM	<i>Shape Context Memory</i>
SE	<i>Squeeze-and-Excitation</i>
SR	<i>Size Ratio</i>
STFFM	<i>Scale-Transferrable Feature Fusion Module</i>
SVCF	<i>Spacial Visual Cues Fusion</i>
TC	<i>Tomografia Computadorizada</i>
YOLO	<i>You Only Look Once</i>

Sumário

1	INTRODUÇÃO	20
1.1	Questões de pesquisa	24
1.2	Objetivos	25
1.3	Contribuições	26
1.4	Organização do Trabalho	26
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Fisiologia e Patologia do Pâncreas	27
2.2	Tomografia Computadorizada	27
2.3	Aprendizado Profundo	30
2.3.1	Redes Neurais Convolucionais	31
2.3.2	Arquiteturas <i>Encoder-Decoder</i>	33
2.3.2.1	<i>U-Net</i>	33
2.3.2.2	<i>Feature Pyramid Network</i>	34
2.3.2.3	<i>LinkNet</i>	36
2.3.3	EfficientNet	38
2.3.4	<i>You Only Look Once (YOLO)</i>	39
2.3.4.1	YOLO-NAS	41
2.3.5	Redes Convolucionais Deformáveis	44
2.3.6	<i>Squeeze-and-Excitation</i>	45
2.4	Comitê de votação	47
2.4.1	Votação por maioria	47
2.4.2	Votação por pluralidade	48
2.4.3	Votação ponderada	49
2.4.4	Votação <i>soft</i>	49
2.5	Métricas de Avaliação	50
2.5.1	Sensibilidade	50
2.5.2	Precisão	51
2.5.3	Coeficiente de Dice-Sørensen	51
2.5.4	Índice de Jaccard	51
2.6	Considerações Finais	52
3	TRABALHOS RELACIONADOS	53
3.1	Segmentação do pâncreas	53
3.2	Segmentação de massa pancreática	59

4	MÉTODO DE SEGMENTAÇÃO DO PÂNCREAS	64
4.0.1	Pré-processamento	64
4.0.2	Segmentação do pâncreas	66
4.1	Resultados e Discussão	67
4.1.1	Bases de dados	67
4.1.1.1	<i>Base Medical Segmentation Decathlon (MSD)</i>	67
4.1.1.2	<i>National Institutes of Health Clinical Center Pancreas Segmentation dataset (NIH)</i>	69
4.1.2	Experimento de comparação entre estratégia 2D e 2.5D	70
4.1.3	Experimento de comparação entre redes pré-treinadas como <i>backbones</i>	71
4.1.3.1	Comparação com a literatura	74
4.2	Limitações da Pesquisa e Método	76
4.3	Considerações finais	77
5	MÉTODO DE SEGMENTAÇÃO DE MASSAS PANCREÁTICAS	79
5.1	Método Proposto	79
5.1.1	Janelamento de HU & Fatiamento	80
5.1.2	Deteção do pâncreas	80
5.1.3	Normalização de valores de píxel	81
5.1.4	Segmentação da massa pancreática.	81
5.1.4.1	Arquiteturas com <i>backbone EfficientNetB7</i>	82
5.1.4.2	Arquiteturas com convoluções deformadas	84
5.1.5	Comitê de votação	84
5.2	Resultados e Discussão	86
5.2.1	Base de Imagens	87
5.2.2	Deteção do pâncreas para redução de escopo	87
5.2.2.1	Deteção fatia a fatia do pâncreas	87
5.2.2.2	Deteção Global baseada no baricentro das detecções individuais	88
5.2.3	Segmentação da massa pancreática	89
5.2.3.1	Comparação com a literatura	97
5.2.4	Análise de impacto	99
5.2.4.1	Segmentação sem etapa de detecção do pâncreas	99
5.2.4.2	Adição de uma etapa de detecção da massa pancreática	100
5.3	Limitações da Pesquisa e Método	103
5.4	Considerações finais	104
6	CONCLUSÃO	105
6.1	Questões de pesquisa	106
6.2	Trabalhos futuros	106
6.3	Impacto ético	107

6.4	Produções Científicas	108
------------	--	------------

	REFERÊNCIAS	109
--	------------------------------	------------