



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Avaliação de Segmentação de glomerulopatias utilizando Modelos de Aprendizagem Profunda

João Viktor de Carvalho Mota

Monografia apresentada como requisito parcial
para conclusão do Curso de Bacharelado em Engenharia da Computação

Orientador
Prof. Dr. Flávio de Barros Vidal

Brasília
2024

Dedicatória

Dedico este trabalho aos meus pais, meus avós, meu irmão e meus amigos.

Agradecimentos

Gostaria de agradecer meus pais, Wagner e Kerre Anne, por sempre me apoiarem e por sempre estarem comigo. Também agradecer meu irmão, Pietro, que sempre me ajudou em todas as minhas dificuldades. Agradecer meus avós que sempre acreditaram em mim. Agradecer meus amigos que também sempre estiveram comigo por todas as dificuldades. Agradecer todos os meus professores da UnB que me ajudaram a formar a pessoa que sou hoje, entre eles meu orientador, Flávio Vidal, que ajudou muito neste processo. Também agradecer o doutorando, George, que ajudou muito na realização deste trabalho. Obrigado de verdade a todos vocês.

Resumo

Este trabalho explora e compara diversos modelos de aprendizagem profunda aplicados à segmentação de imagens histológicas e à classificação de glomerulopatias, com o objetivo de automatizar a segmentação dessas patologias e, assim, fornecer suporte aos patologistas para aumentar a precisão e a reprodutibilidade dos diagnósticos. Foram realizadas duas abordagens de avaliação. Na primeira, uma ampla variedade de arquiteturas foi analisada para avaliar o desempenho geral dos modelos, destacando-se o modelo Unet++ com o codificador RegNet, que apresentou os melhores resultados nas classes de fundo (background) e podócitos não lesionados, bem como na média geral. Na segunda abordagem, ajustes específicos nas estratégias de treinamento foram aplicados para melhorar a segmentação das classes de glomerulopatias. Nessa configuração, o modelo PAN combinado com o codificador RegNet sobressaiu-se para as classes de glomerulopatias, embora isso tenha levado a uma diminuição do F1-Score para as classes de fundo e podócitos não lesionados, resultando em uma média inferior. Esta pesquisa não apenas contribui para o avanço da análise histológica e do diagnóstico assistido por inteligência artificial, mas também oferece insights sobre o desempenho de diferentes modelos de aprendizagem profunda em conjuntos de dados histológicos com glomerulopatias.

Palavras-chave: Redes Neurais Convolucionais, Glomerulopatias, Aprendizagem de Máquina

Abstract

This work explores and compares various deep learning models applied to the segmentation of histological images and the classification of glomerulopathies, aiming to automate the segmentation of these pathologies and thereby provide support to pathologists, enhancing the accuracy and reproducibility of diagnoses. Two evaluation approaches were conducted. In the first approach, a wide range of architectures was analyzed to assess the overall performance of the models, with the Unet++ model featuring the RegNet encoder standing out by achieving the best results in the background and non-lesioned podocyte classes, as well as in the overall average. In the second approach, specific adjustments to training strategies were applied to improve the segmentation of glomerulopathy classes. In this configuration, the PAN model combined with the RegNet encoder excelled in the glomerulopathy classes, although this led to a decrease in the F1-Score for the background and non-lesioned podocyte classes, resulting in a lower overall average. This research not only contributes to the advancement of histological analysis and AI-assisted diagnosis but also provides insights into the performance of different deep learning models on histological datasets with glomerulopathies.

Keywords: Convolutional Neural Networks , Glomerulopathies , Deep Learning

Sumário

1	Introdução	1
1.1	Contextualização	1
1.2	Motivação	2
1.3	Justificativa	2
1.4	Objetivos	3
1.4.1	Objetivo Geral	3
1.4.2	Objetivos Específicos	3
1.5	Organização do Trabalho	4
2	Fundamentação Teórica	5
2.1	Segmentação	5
2.2	Classificação	6
2.3	Redes Neurais Convolucionais	7
2.3.1	Arquiteturas	11
2.3.2	Codificador (<i>Encoder</i>)	18
3	Metodologia Proposta	22
3.1	Preparação do Ambiente e Escolha das Ferramentas	22
3.2	Elaboração da Base de Dados de Imagens	23
3.3	Pré Processamento e Separação do Dataset	23
3.4	Treinamento dos Modelos de Segmentação	25
3.5	Avaliação dos Resultados	26
4	Resultados	28
4.1	Primeiro Treinamento	28
4.2	Segundo Treinamento	34
4.3	Diferenças Entre os Treinamentos	44
5	Conclusões	47
5.1	Trabalhos Futuros	48

Referências	49
Anexo	51
I Resultados Completos	52

Lista de Figuras

2.1	Exemplo das tarefas de classificação, localização, detecção e segmentação. Fonte: Nirmala Murali	7
2.2	Arquitetura de um CNN.	8
2.3	Convolução	9
2.4	Pooling	9
2.5	Exemplo de Arquitetura Codificador-Decodificador CNN.	10
2.6	Arquitetura da Unet. Fonte: Unet	11
2.7	Arquitetura da Unet++. Fonte: Unet++	12
2.8	Arquitetura da MANet. Fonte: MANet	13
2.9	Arquitetura da Linknet. Fonte: Linknet	14
2.10	Arquitetura da FPN. Fonte: FPN	15
2.11	Arquitetura da PSPNet. Fonte: PSPNet	16
2.12	Arquitetura da PAN. Fonte: PAN	16
2.13	Arquitetura da DeepLabV3. Fonte: DeepLabV3	17
2.14	Arquitetura da DeepLabV3+. Fonte: DeepLabV3+	18
3.1	Fluxograma da Metodologia	22
3.2	aumento de dados (<i>Data Augmentation</i>) técnicas	24
4.1	Predição e Referência (<i>Ground Truth</i>) do Modelo Aleatório - Primeiro Trei- namento	33
4.2	Predição e Referência (<i>Ground Truth</i>) do Pior Modelo - Primeiro Treinamento	33
4.3	Predição e Referência (<i>Ground Truth</i>) do Melhor Modelo - Primeiro Trei- namento	34
4.4	Predição e Referência (<i>Ground Truth</i>) do Modelo Aleatório - Segundo Trei- namento	41
4.5	Predição e Referência (<i>Ground Truth</i>) de um dos Piores Modelos 1 - Se- gundo Treinamento	42
4.6	Predição e Referência (<i>Ground Truth</i>) de um dos Piores Modelos 2 - Se- gundo Treinamento	42

4.7	Predição e Referência(<i>Ground Truth</i>) de um dos Melhores Modelos 1 - Segundo Treinamento	43
4.8	Predição e Referência(<i>Ground Truth</i>) de um dos Melhores Modelos 2 - Segundo Treinamento	43

Lista de Tabelas

3.1	Ocorrências de imagens e pixels para cada classe.	23
3.2	Combinações de arquiteturas e encoders utilizados no trabalho.	25
4.1	Modelos que se destacam nos melhores 10 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento . . .	29
4.2	Modelos que se destacam nos melhores 5 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento	30
4.3	Modelos que se destacam nos melhores resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento	30
4.4	Modelos que se destacam nos piores 10 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento	31
4.5	Modelos que se destacam nos piores 5 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento	32
4.6	Modelos que se destacam nos piores resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score.	32
4.7	Modelos que se destacam nos melhores 10 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento . . .	35
4.8	Modelos que se destacam nos melhores 5 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento	36
4.9	Modelos que se destacam nos melhores resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento	37
4.10	Modelos que se destacam nos piores 10 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento	38
4.11	Modelos que se destacam nos piores 5 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento	39
4.12	Modelos que se destacam nos piores resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento	40
4.13	Comparação entre os modelos de treinamento avaliados por Índice de Jaccard (IoU) e F-Score para diferentes classes.	45

Capítulo 1

Introdução

1.1 Contextualização

A análise histológica de tecidos renais desempenha um papel crucial no diagnóstico e tratamento de doenças renais, particularmente as glomerulopatias, que são doenças que afetam os glomérulos, unidades funcionais do rim [1]. A segmentação com alta precisão de glomerulopatias em imagens histológicas é fundamental para identificar padrões patológicos específicos, o que pode orientar decisões terapêuticas e prognósticas [1]. Tradicionalmente, essa segmentação é realizada manualmente por patologistas, um processo que é não só demorado como também sujeito a variações interobservador, potencialmente comprometendo a consistência dos diagnósticos [2].

Com o avanço da tecnologia e o surgimento de modelos de aprendizagem profunda, há um crescente interesse em automatizar a segmentação de imagens histológicas [3]. Modelos de aprendizagem profunda têm mostrado resultados promissores em diversas tarefas de visão computacional devido à sua capacidade de aprender representações complexas diretamente a partir dos dados [4]. No entanto, a eficácia desses modelos na segmentação de glomerulopatias ainda precisa ser avaliada de maneira minuciosa e sistemática. Diferentes arquiteturas de redes neurais convolucionais (CNNs) e suas variantes podem ter desempenhos variados dependendo da natureza dos dados e das características das classes a serem segmentadas [4].

A avaliação comparativa de diferentes modelos de aprendizagem profunda é essencial para identificar as melhores abordagens para a segmentação de glomerulopatias. Esta avaliação não só ajuda a determinar quais modelos oferecem a melhor precisão e robustez, mas também fornece percepções sobre os fatores que influenciam o desempenho, como a escolha do codificador, a estratégia de loss function e o balanceamento de classes. Essas percepções podem orientar futuras pesquisas e desenvolvimentos no campo, contribuindo

para a melhoria contínua das técnicas de segmentação automática e, conseqüentemente, para a qualidade do diagnóstico histopatológico [5].

Além disso, a implementação de modelos eficazes para a segmentação de glomerulopatias pode ter um impacto significativo na prática clínica. Automatizar esse processo permite que os patologistas concentrem-se em tarefas mais complexas e interpretativas, aumentando simultaneamente a precisão e a reprodutibilidade dos diagnósticos [5]. Essa melhoria é especialmente crucial em contextos com recursos limitados, onde a disponibilidade de patologistas especializados é frequentemente restrita. Portanto, a avaliação de modelos de aprendizagem profunda para a segmentação de glomerulopatias não só representa uma contribuição acadêmica significativa, mas também um passo essencial para a transformação digital da patologia renal [6].

1.2 Motivação

A segmentação automática de glomerulopatias em imagens histológicas é uma necessidade na área médica devido a vários fatores críticos. Atualmente, esse processo é realizado manualmente pelos patologistas, uma tarefa exaustiva e sujeita a erros de avaliação visual. Com a diminuição do número de patologistas em todo o mundo, a necessidade de soluções automatizadas se intensifica. De acordo com a Sociedade Brasileira de Patologia Clínica/Medicina Laboratorial (SBPC/ML), a demanda por patologistas está crescendo rapidamente, mas o número de profissionais disponíveis não acompanha essa necessidade [7].

Os erros associados à avaliação visual manual podem levar a diagnósticos imprecisos, impactando negativamente o tratamento e o prognóstico dos pacientes. A automatização da segmentação pode oferecer suporte aos patologistas, permitindo que eles se concentrem em tarefas mais complexas e de interpretação que exigem sua expertise. Isso não apenas melhora a precisão e a reprodutibilidade dos diagnósticos, mas também otimiza o tempo e os recursos disponíveis, especialmente em contextos com recursos limitados.

O projeto PathoSpotter [6], desenvolvido pela Fiocruz Bahia, exemplifica o potencial de integrar modelos de aprendizagem profunda na prática clínica. Este projeto visa a criação de ferramentas avançadas para a análise de imagens histológicas, promovendo uma transformação digital na patologia renal.

1.3 Justificativa

No contexto deste trabalho, dispomos de um conjunto de imagens histológicas já segmentadas e classificadas que podem ser utilizadas para treinar modelos de aprendizagem

profunda. A disponibilidade dessas imagens, combinada com a crescente capacidade dos modelos de aprendizagem profunda de lidar com tarefas complexas de visão computacional, oferece uma oportunidade única para desenvolver soluções automatizadas para a segmentação de glomerulopatias.

Treinando modelos de aprendizagem profunda com essas imagens, buscamos não apenas automatizar a segmentação de glomerulopatias, mas também melhorar significativamente a precisão dos diagnósticos de doenças renais. Essa abordagem tem o potencial de transformar a prática clínica, proporcionando diagnósticos mais rápidos e precisos, o que é crucial para a implementação de tratamentos mais eficazes e para melhorar a qualidade de vida dos pacientes.

Ao avaliar a eficácia de diferentes modelos de aprendizagem profunda para a segmentação de glomerulopatias, este trabalho contribui significativamente para essa iniciativa, buscando soluções que possam ser aplicadas na rotina clínica, melhorando a qualidade do atendimento aos pacientes com doenças renais.

1.4 Objetivos

Este trabalho apresenta um objetivo geral e vários objetivos específicos que contribuem para alcançar o objetivo geral de forma estruturada e eficiente.

1.4.1 Objetivo Geral

Comparar diferentes modelos de aprendizagem profunda na segmentação de glomerulopatias em imagens histológicas e identificar os modelos que oferecem melhor desempenho para essa tarefa.

1.4.2 Objetivos Específicos

Para alcançar o objetivo geral, são definidos os seguintes objetivos específicos:

- Preparar o ambiente de treinamento, incluindo a configuração de hardware e software necessários para a implementação dos modelos de aprendizagem profunda.
- Preparar a base de dados, incluindo a coleta, limpeza e pré-processamento das imagens histológicas para garantir a qualidade e consistência dos dados.
- Separar o conjunto de dados em subconjuntos de treinamento, validação e teste para garantir uma avaliação robusta e imparcial dos modelos.
- Treinar os modelos de segmentação utilizando diferentes arquiteturas de redes neurais convolucionais (CNNs) e suas variantes para identificar a abordagem mais eficaz.

- Avaliar o desempenho dos modelos de segmentação, utilizando métricas específicas de segmentação para determinar a precisão, robustez e reprodutibilidade dos resultados.

1.5 Organização do Trabalho

Este trabalho está organizado em capítulos da seguinte forma:

- **Capítulo 2 - Fundamentação Teórica:** aborda os conceitos e as técnicas fundamentais relacionados ao reconhecimento facial, aprendizado profundo e degradação de imagens.
- **Capítulo 3 - Metodologia:** são apresentados os detalhes da metodologia adotada para realizar a análise quantitativa das degradações em modelos de reconhecimento facial.
- **Capítulo 4 - Resultados:** os resultados obtidos na análise das degradações são apresentados e discutidos neste capítulo.
- **Capítulo 5 - Conclusão:** neste capítulo, são apresentadas as conclusões do trabalho, incluindo as contribuições, as limitações e as sugestões para trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Neste capítulo, será apresentada uma breve fundamentação que compreende o embasamento teórico de um sistema de segmentação e classificação de imagens. Serão abordados conceitos fundamentais, como segmentação, classificação, redes neurais convolucionais (em inglês Convolutional Neural Networks ou CNNs), arquiteturas específicas de redes e os codificadores (*encoders*) utilizados nesse contexto.

2.1 Segmentação

Segmentação no contexto de visão computacional e aprendizado de máquina é o processo de dividir uma imagem digital em regiões ou segmentos distintos, cada um representando um objeto ou uma parte de um objeto [8]. Este processo é utilizado para localizar e extrair objetos de imagens, permitindo a rotulação automática das classes representadas, como mostrado na Figura 2.1. A segmentação é essencial em várias aplicações, incluindo a análise médica, onde é utilizada para identificar estruturas anatômicas específicas em imagens histológicas.

A segmentação pode ser descrita como a atribuição de um rótulo a cada pixel de uma imagem $I(x,y)$, onde x e y são as coordenadas dos pixels, e $L(x,y)$ é o rótulo correspondente. Este processo pode ser modelado como um problema de otimização, onde o objetivo é minimizar uma função de custo que avalia a consistência dos rótulos com base em características dos pixels, como cor, textura, e proximidade espacial. Essa função de custo pode ser definida por:

$$\min_L \sum_{(x,y)} C(L(x,y), I(x,y)) + \lambda \sum_{(x_1,y_1),(x_2,y_2) \in N} S(L(x_1,y_1), L(x_2,y_2)) \quad (2.1)$$

onde $C(L(x,y), I(x,y))$ mede o custo de atribuir o rótulo $L(x,y)$ ao pixel (x,y) da imagem, e $S(L(x_1,y_1), L(x_2,y_2))$ avalia a suavidade entre rótulos adjacentes. N representa o

conjunto de pares de pixels vizinhos e λ é um parâmetro que controla a regularização da suavidade dos rótulos.

Existem diferentes tipos de segmentação, cada uma com suas aplicações e técnicas específicas:

- **Segmentação Semântica:** A segmentação semântica atribui um rótulo a cada pixel da imagem com base na classe do objeto que ele representa. Por exemplo, em uma imagem médica, pode identificar todos os pixels pertencentes a um tumor.
- **Segmentação por Instâncias:** Este tipo de segmentação não só identifica a classe dos objetos, mas também diferencia entre várias instâncias de uma mesma classe. Por exemplo, em uma imagem contendo várias células, a segmentação por instâncias identificará cada célula individualmente.
- **Segmentação Panóptica:** Combina a segmentação semântica e a segmentação por instâncias, fornecendo uma visão completa onde todos os pixels são rotulados e as instâncias são diferenciadas.

Principais aplicações da segmentação incluem:

- **Análise Médica:** Identificação de órgãos, tecidos e anomalias em imagens de raios-X, tomografia computadorizada e ressonância magnética.
- **Visão Computacional:** Detecção de objetos em sistemas de segurança, reconhecimento facial e veículos autônomos.
- **Indústria:** Inspeção de qualidade em linhas de produção, identificação de defeitos em produtos e automação de processos.

2.2 Classificação

Classificação é o processo de rotular o conjunto de pixels como pertencente a uma classe específica [4]. Após a etapa de segmentação, a classificação é empregada para identificar e distinguir os conjuntos de pixels segmentados com base em suas características e atributos. Essa etapa é crucial para a interpretação dos objetos identificados, permitindo a categorização e a análise mais detalhada das regiões segmentadas. Por exemplo, em imagens médicas, a classificação pode ser usada para distinguir entre diferentes tipos de tecidos ou identificar anomalias específicas.

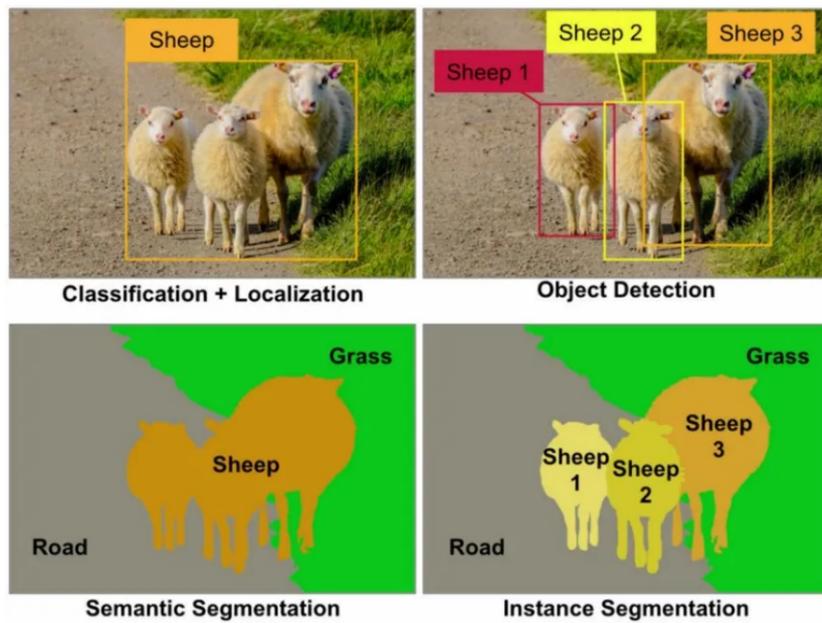


Figura 2.1: Exemplo das tarefas de classificação, localização, detecção e segmentação. Fonte: Nirmala Murali

2.3 Redes Neurais Convolucionais

Rede neural Convolutiva (em inglês Convolutional Neural Networks ou CNNs) [9] é um algoritmo de aprendizado profundo que serve majoritariamente para reconhecimento de imagens. É uma rede neural onde não há ligação completa de todos os neurônios, recebe uma imagem como entrada e atribui pesos a objetos da imagem para conseguir diferenciá-los. As CNNs costumam ser utilizadas em tarefas de classificação, segmentação, detecção e geração de imagens [10, 11, 12].

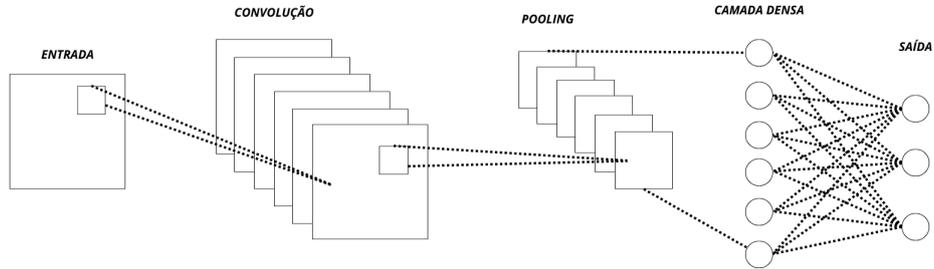


Figura 2.2: Arquitetura de um CNN.

Uma rede neural convolucional é composta de diferentes camadas: camadas convolucionais, camadas de pooling, camadas de ativação e camadas totalmente conectadas como descrito na Figura 2.2. Porém, há diversas arquiteturas diferentes que serão explicadas abaixo alguns exemplos utilizados nesse trabalho.

Camadas Convolucionais costumam ser as primeiras camadas em uma Rede Neural Convolutiva, onde a convolução é aplicada à entrada. Essa convolução envolve passar um filtro sobre a imagem de entrada para extrair características e padrões visuais relevantes, permitindo que a rede aprenda a capturar padrões de forma hierárquica e também reduzir o número de parâmetros comparado a uma rede totalmente conectada. A convolução é uma operação matemática que envolve o produto escalar entre um filtro (ou kernel) K e uma região da imagem de entrada $I(x,y)$. A operação de convolução pode ser expressa como:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i - m, j - n) \cdot K(m, n) \quad (2.2)$$

onde $S(i,j)$ representa o mapa de características resultante, e $I(i-m,j-n)$ é a região da imagem afetada pelo filtro $K(m,n)$.

A convolução está sendo demonstrada na Figura 2.3.

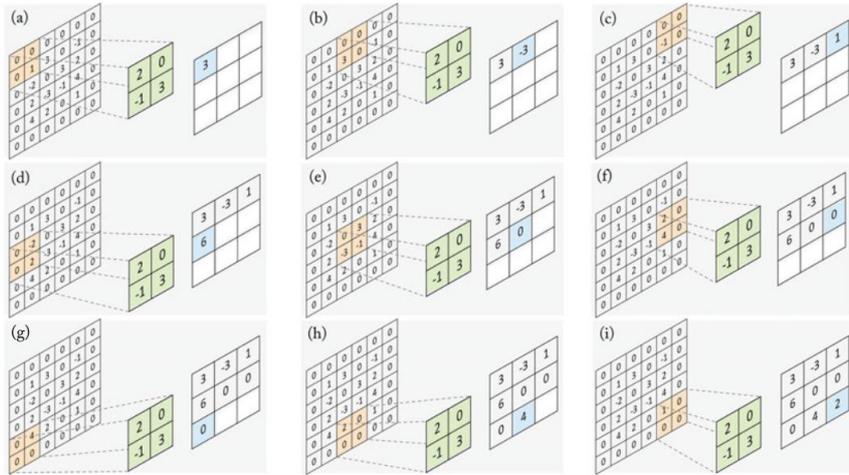


Figura 2.3: Convolução

Camadas de Pooling costumam vir após as camadas convolucionais e servem para reduzir a dimensionalidade espacial da imagem. Isso aumenta a eficiência do processamento ao diminuir o número de parâmetros, mantendo as características mais importantes. A operação mais comum é o Max Pooling, que seleciona o valor máximo em uma região específica do mapa de características, resumindo assim as características em um nível superior de abstração. O Max Pooling pode ser descrito como:

$$P(i, j) = \max\{S(m, n)\} \tag{2.3}$$

onde $P(i,j)$ é o valor máximo dentro da janela $m \times n$ do mapa de características S .

Podemos ver uma representação de um pooling na Figura 2.4.

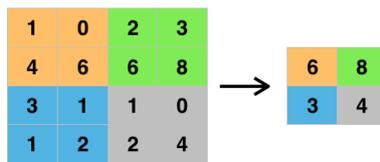


Figura 2.4: Pooling

Camadas de Ativação constituem uma etapa crucial após as camadas de pooling ou convolucionais. Nestas camadas, uma função de ativação é aplicada para introduzir não linearidades na rede. Essas não linearidades são fundamentais para que a rede possa aprender relações complexas entre as características extraídas, ampliando assim sua capacidade de representação. A função de ativação mais comum é a ReLU (Rectified Linear Unit), definida como:

$$f(x) = \max(0, x) \tag{2.4}$$

Sem essas camadas de ativação, a rede se comportaria como uma combinação linear, limitando sua capacidade de modelagem.

Camadas Totalmente Conectadas são geralmente encontradas no final da rede e são responsáveis por combinar as características extraídas das camadas anteriores para realizar a classificação ou segmentação da imagem. Elas recebem como entrada as características aprendidas nas camadas anteriores e produzem uma saída final, representando as classes ou segmentações desejadas. Nestas camadas, cada neurônio está conectado a todos os neurônios da camada anterior, o que permite à rede integrar todas as informações extraídas e tomar uma decisão final. Cada neurônio em uma camada totalmente conectada realiza a seguinte operação:

$$y = f(W \cdot x + b) \quad (2.5)$$

onde W são os pesos, x são as entradas, b é o bias, e f é a função de ativação.

Além dessas camadas, as redes neurais convolucionais podem incluir um Codificador (*Encoder*) e um Decodificador (*Decoder*). O Codificador (*Encoder*) consiste no conjunto das camadas convolucionais e de pooling, cujo objetivo é reduzir a dimensionalidade da imagem e extrair características visuais relevantes. Por outro lado, o Decodificador (*Decoder*) geralmente reconstrói a imagem segmentada a partir das características extraídas pelo Codificador (*Encoder*). Ele é composto por camadas de amostragem superior (*upsampling*) e convolucionais, que visam aumentar a resolução espacial da imagem segmentada. Essa arquitetura de Codificador-Decodificador é comumente empregada em tarefas de segmentação e reconstrução de imagens. Abaixo na Figura 2.5 está um exemplo de uma Arquitetura Codificador-Decodificador [13].

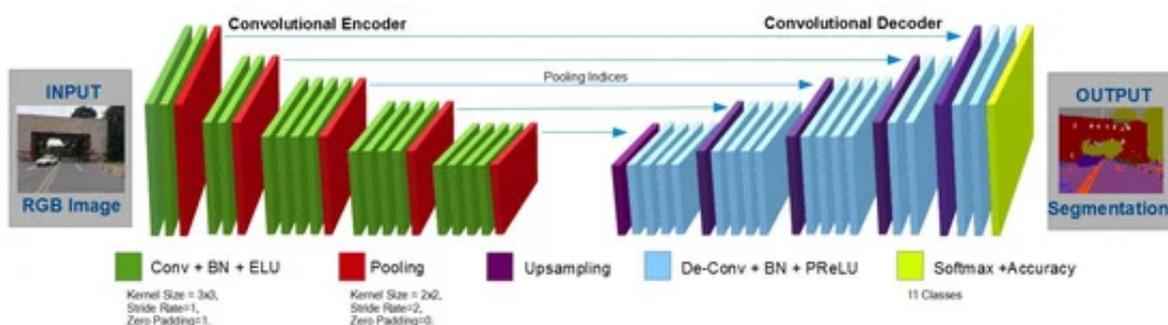


Figura 2.5: Exemplo de Arquitetura Codificador-Decodificador CNN.

A escolha de uma arquitetura e de um codificador para um modelo reflete duas decisões distintas, mas interconectadas, no design de redes neurais. A arquitetura define a estrutura geral do modelo, incluindo como as camadas são organizadas e como os dados fluem através da rede. Ela é responsável por capturar e processar as informações de forma

eficiente, garantindo que o modelo consiga extrair as características relevantes dos dados de entrada.

Por outro lado, o codificador é uma parte específica da arquitetura, muitas vezes usada para reduzir a dimensionalidade dos dados de entrada e representar as informações de maneira mais compacta e informativa. Ele pode ser visto como uma sub-rede dentro da arquitetura maior. Escolher um codificador envolve decidir como essas informações serão representadas antes de serem passadas para as próximas camadas do modelo. Portanto, a escolha de uma arquitetura determina o esqueleto da rede, enquanto a escolha de um codificador afeta diretamente a forma como os dados são processados e compactados dentro dessa estrutura.

2.3.1 Arquiteturas

Nesta seção, serão discutidas algumas das principais arquiteturas de redes neurais convolucionais (em inglês Convolutional Neural Networks ou CNNs) utilizadas para segmentação de imagens. Essas arquiteturas foram desenvolvidas para melhorar a precisão e a eficiência da segmentação em diferentes contextos, especialmente em imagens médicas. Serão abordadas as arquiteturas U-Net, U-Net++, MANet, Linknet, FPN, PSPNet, PAN, DeepLabV3 e DeepLabv3+, destacando suas características principais e inovações.

Unet

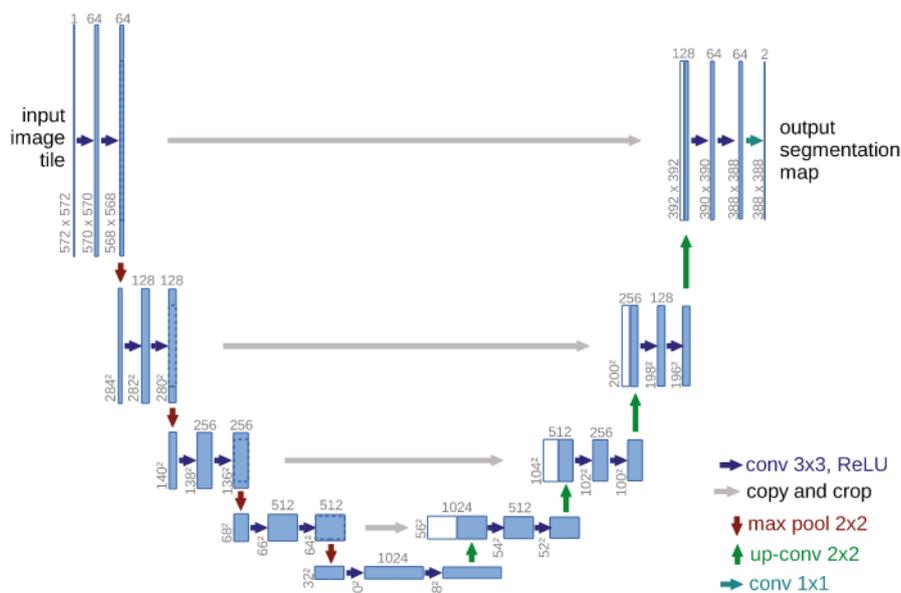


Figura 2.6: Arquitetura da U-Net. Fonte: U-Net

A U-Net [14] se destaca como uma das arquiteturas de redes neurais convolucionais mais populares para segmentação de imagens como pode ser visto na Figura 2.6. Sua estrutura em forma de U, combinando um codificador (*encoder*) que extrai características visuais com um decodificador (*decoder*) que gera a segmentação, a torna ideal para lidar com conjuntos de dados de treinamento pequenos e, ao mesmo tempo, alcançar alta precisão.

Unet++

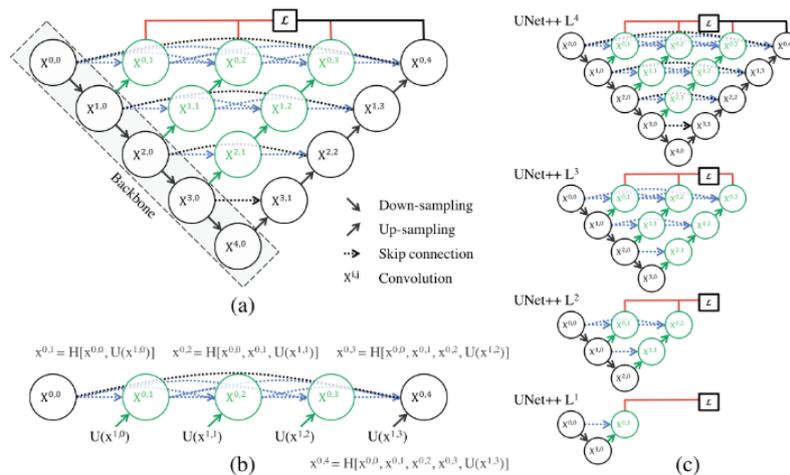


Figura 2.7: Arquitetura da Unet++. Fonte: Unet++

A U-net++ [15] surge como uma evolução da Unet e foi criada baseada em conexões densas e integradas. A limitação central da U-Net original é a dificuldade de capturar detalhes finos de objetos de interesse, especialmente em imagens de alta resolução. A U-Net++ propõe uma solução inovadora: enriquecer gradativamente os mapas de características de alta resolução do codificador (*encoder*) antes da fusão com os mapas do decodificador (*decoder*). É possível ver a arquitetura na Figura 2.7.

Ao contrário da U-Net, que conecta diretamente os mapas, a U-Net++ os processa por meio de blocos convolucionais densos. Essa etapa enriquece os mapas do codificador (*encoder*), tornando-os semanticamente mais próximos dos mapas do decodificador (*decoder*). Com essa redução, o aprendizado da rede se torna mais eficiente, resultando em segmentações mais precisas, principalmente em imagens de alta resolução.

MANet

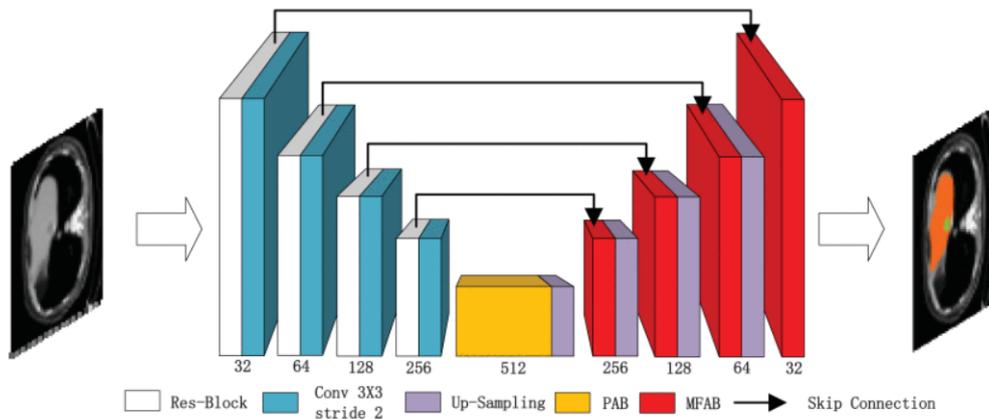


Figura 2.8: Arquitetura da MANet. Fonte: MANet

O MANet (Multi-scale Attention Network) [16] é uma arquitetura de rede neural convolucional desenvolvida para segmentação de imagens, com sua inovação central baseada em um mecanismo de atenção que utiliza a memória para armazenar informações contextuais cruciais para a segmentação como é possível ver na Figura 2.8.

Enquanto muitos modelos convolucionais enfrentam dificuldades na captura de detalhes finos em imagens de alta resolução, o MANet aborda essa questão de forma singular, introduzindo mecanismos de atenção em múltiplas escalas. Essa abordagem permite à rede focalizar diferentes níveis de detalhes na imagem, ajustando-se dinamicamente às características específicas de cada região. Esse foco não só melhora a precisão da segmentação, mas também otimiza o processo de aprendizado da rede.

Linknet

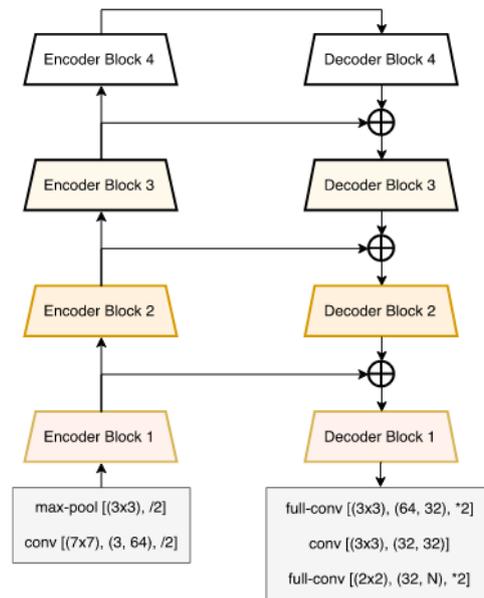


Figura 2.9: Arquitetura da Linknet. Fonte: Linknet

O LinkNet [17] é uma arquitetura de rede neural convolucional que se destaca por sua eficiência e desempenho robusto como é visto na Figura 2.9. Sua principal característica distintiva reside na utilização de conexões de atalho, que promovem uma comunicação eficaz entre diferentes camadas da rede, facilitando a propagação de informações relevantes durante o processo de segmentação.

Além disso, o LinkNet se destaca por sua arquitetura leve e eficiente, o que o torna adequado para aplicações em tempo real e em ambientes com recursos limitados. Ao otimizar a propagação de informações e reduzir a carga computacional, o LinkNet oferece resultados precisos e rápidos em tarefas de segmentação de imagens.

FPN

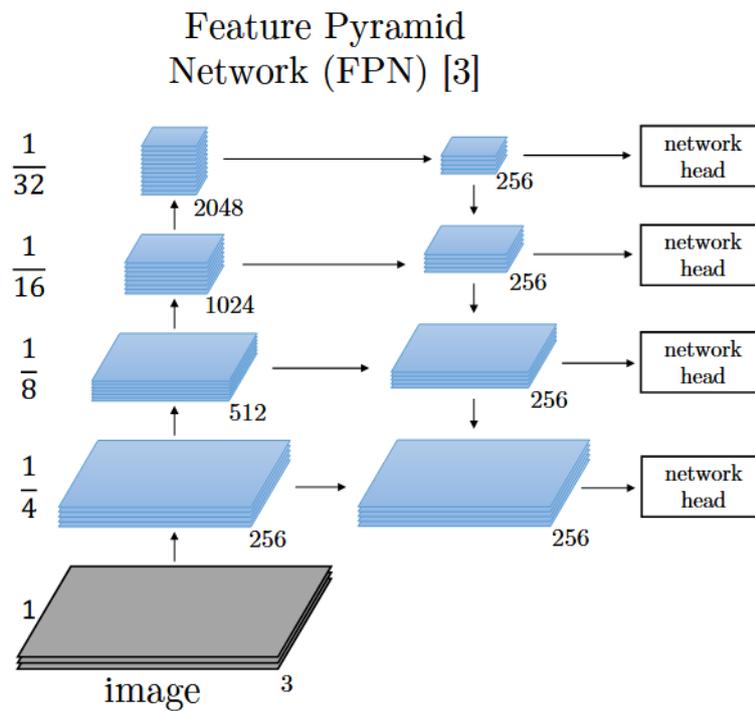


Figura 2.10: Arquitetura da FPN. Fonte: FPN

O FPN (Feature Pyramid Network) é uma arquitetura de CNN em que teve como inovação sua geração de pirâmides de características como mostrado na Figura 2.10. Essas pirâmides permitem a detecção de objetos em diferentes escalas e resoluções, aumentando assim sua capacidade de detecção em diversas partes da imagem.

Uma das principais vantagens do FPN é a utilização de conexões laterais para fundir características de diferentes níveis da pirâmide. Isso permite a combinação de informações detalhadas de baixo nível com informações semânticas mais abstratas de alto nível. O FPN é capaz de detectar objetos com alta precisão e robustez em uma variedade de condições e cenários, tornando-se uma escolha favorável para aplicações de detecção de objetos em imagens.

PSPNet

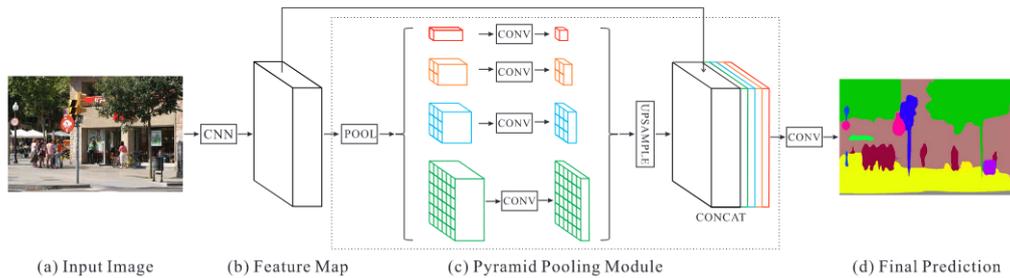


Figura 2.11: Arquitetura da PSPNet. Fonte: PSPNet

O PSPNet (Pyramid Scene Parsing Network) [18] é uma arquitetura de rede neural convolucional com o propósito de segmentar cenas complexas. Sua principal inovação reside na utilização de uma pirâmide de pooling espacial (PSP), que permite à rede capturar informações contextuais em diferentes escalas e resoluções. A Figura 2.11 mostra a arquitetura do PSPNet.

O PSPNet divide a entrada em várias escalas e aplica uma operação de pooling espacial em cada uma delas. Isso permite que a rede obtenha representações contextuais em diferentes níveis de detalhe, melhorando assim sua capacidade de compreender a cena como um todo. Além disso, o PSPNet utiliza uma estrutura de decodificador com camadas atrás para fundir e refinar as características extraídas em cada escala. Essa abordagem permite que a rede capture informações contextuais em várias escalas e as utilize de forma eficaz para segmentar objetos.

PAN

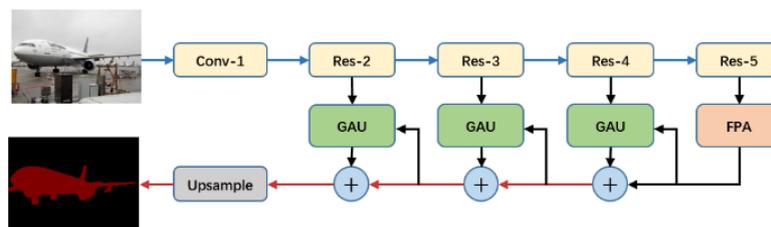


Figura 2.12: Arquitetura da PAN. Fonte: PAN

O PAN (Path Aggregation Network) [19] é uma arquitetura de rede neural convolucional e uma das suas principais inovações é sua abordagem de agregação de caminhos, onde múltiplos caminhos de diferentes profundidades são explorados para capturar informações em várias escalas. Isso permite que a rede capture detalhes finos e características semânticas

em diferentes níveis de resolução, melhorando assim sua capacidade de segmentar objetos em imagens de maneira precisa e robusta. Além disso, o PAN utiliza uma estrutura de decodificador para combinar e refinar as características extraídas de cada caminho de maneira eficaz. Mostra-se na Figura 2.12 a arquitetura do PAN.

DeepLabV3

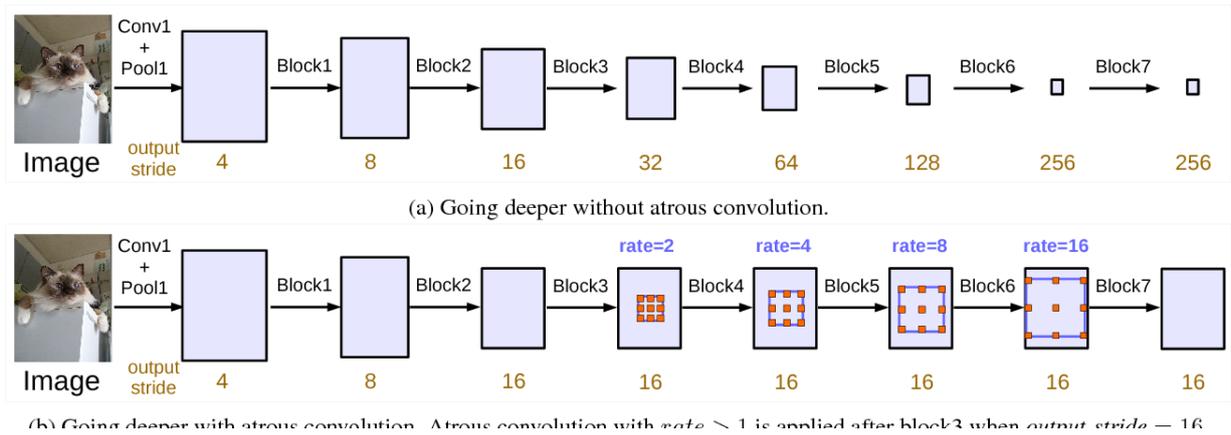


Figura 2.13: Arquitetura da DeepLabV3. Fonte: DeepLabV3

O DeepLabV3 [20] é uma versão avançada da arquitetura DeepLab e sua principal diferença é o uso do codificador (*encoder*)-decodificador (*decoder*) com conexões residuais e o atrous spatial pyramid pooling (ASPP), que permite capturar informações contextuais em várias escalas. É possível ver a arquitetura na Figura 2.13.

Essa arquitetura se destaca pelo uso eficaz de convoluções dilatadas, também conhecidas como convoluções atriais, que ajudam a aumentar o campo receptivo das camadas convolucionais sem aumentar o número de parâmetros. Além do mecanismo ASPP que combina convoluções atriais em diferentes taxas de dilatação para capturar informações contextuais em múltiplas escalas. É uma ótima arquitetura para várias aplicações em visão computacional.

DeepLabV3+

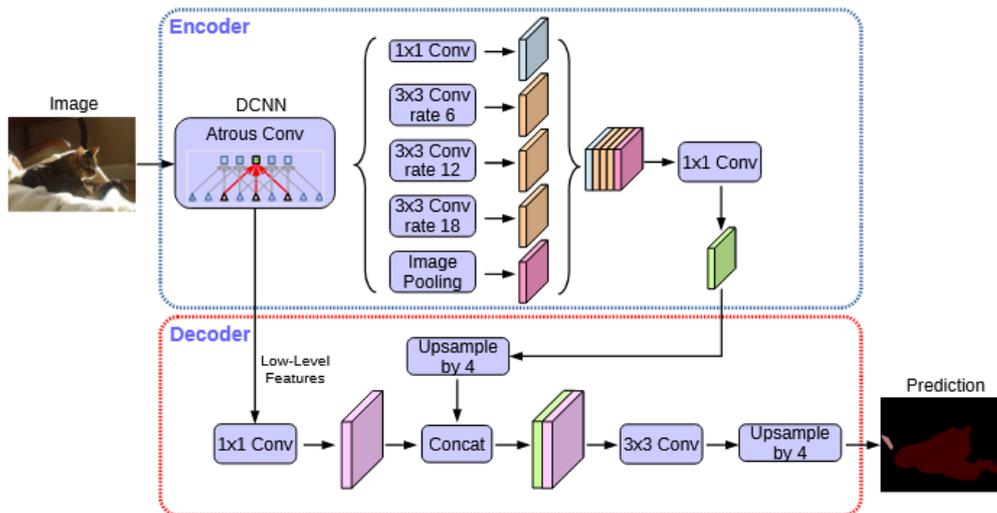


Figura 2.14: Arquitetura da DeepLabV3+. Fonte: DeepLabV3+

O DeepLabV3+ [21] é uma evolução da arquitetura DeepLabV3, com foco na melhoria da precisão da segmentação de imagens. Suas principais diferenças incluem um módulo de decodificação aprimorado para aumentar a resolução da segmentação final, capturando detalhes mais precisos de objetos de interesse. Além disso, o DeepLabV3+ introduz a atrous separable convolution (ASConv), que combina os benefícios das convoluções dilatadas e separáveis, otimizando a eficiência computacional sem comprometer a precisão. Outra diferença é o refinamento de bordas, implementando um módulo específico para refinar as bordas da segmentação, resultando em contornos mais nítidos e precisos. Essas melhorias tornam o DeepLabV3+ uma escolha ainda mais poderosa para aplicações que exigem segmentação semântica de alta qualidade em imagens complexas. A Figura 2.14 mostra a arquitetura do modelo.

2.3.2 Codificador (*Encoder*)

Os codificadores (*encoders*) são componentes fundamentais nas arquiteturas de redes neurais convolucionais para tarefas de segmentação e classificação de imagens. Eles são responsáveis por extrair características relevantes das imagens de entrada, processando-as através de várias camadas convolucionais para capturar diferentes níveis de abstração. Diversas arquiteturas de codificadores (*encoder*) têm sido desenvolvidas ao longo dos anos, cada uma com suas próprias inovações e vantagens. Nesta seção, discutiremos algumas das arquiteturas de codificadores (*encoder*) mais utilizadas, incluindo ResNet, DenseNet,

Inception, EfficientNet, VGG, RegNet(x/y) e Mix Vision Transformer, destacando suas características principais e contribuições para a segmentação de imagens.

ResNet

A ResNet [22] é uma arquitetura de rede neural convolucional completa porém foi utilizada como codificador (*encoder*) nas CNNs mais complexas ditas acima. Suas principais características reside nos blocos residuais, que permitem que informações de ativação passem por atalhos, preservando e transmitindo gradientes mais facilmente durante o treinamento. Essa abordagem ajuda a mitigar o problema de desvanecimento do gradiente, permitindo a construção de redes mais profundas sem comprometer o desempenho. Além disso, a ResNet é altamente modular, facilitando sua adaptação e implementação em diversas tarefas de segmentação de imagens.

Entretanto, ao ser utilizada como codificador (*encoder*), é utilizada apenas os blocos convolucionais da ResNet, incluindo seus blocos residuais. Ao integrar a ResNet como parte do codificador (*encoder*), as CNNs mais complexas podem se beneficiar da profundidade e da eficácia das características extraídas pela ResNet.

DenseNet

A DenseNet, ou Dense Convolutional Network [23], é uma CNN reconhecida por sua abordagem densa e altamente conectada entre as camadas. Ao contrário de arquiteturas tradicionais, onde as camadas são conectadas sequencialmente, o DenseNet emprega conexões densas entre todas as camadas, o que significa que cada camada recebe entradas diretamente de todas as camadas anteriores e passa suas próprias saídas para todas as camadas seguintes. Isso cria um fluxo contínuo de informações ao longo da rede, promovendo o reuso eficiente de características e facilitando o treinamento de redes profundas. Os blocos densamente conectados da DenseNet foi utilizada como codificador (*encoder*) nas CNNs mais complexas acima permitindo que a rede capture uma ampla gama de características em diferentes níveis de abstração.

Inception

A Inception, ou Inception Network [24], é uma família de arquiteturas de rede neural convolucional desenvolvida pelo Google. Ela é conhecida por sua abordagem inovadora na extração de características, usando módulos de convolução paralelos com diferentes tamanhos de filtro para capturar informações em diferentes escalas espaciais. Os módulos de convolução em paralelo da Inception podem ser incorporados ao codificador (*encoder*) de CNNs mais complexas, permitindo que a rede capture características em várias escalas

espaciais. Isso ajuda a melhorar a capacidade da rede de compreender e representar características detalhadas e de contexto das imagens, resultando em segmentações mais precisas e eficazes.

EfficientNet

O EfficientNet [25] é uma arquitetura de rede neural convolucional desenvolvida pelo Google que utiliza um método de escalabilidade que combina diferentes fatores como largura, profundidade e resolução para obter modelos de redes neurais que são eficientes em termos de recursos computacionais. Ao ser utilizada como codificador (*encoder*) em CNNs mais complexas, sua arquitetura permite capturar informações importantes em diferentes escalas e níveis de abstração, enquanto mantém uma carga computacional relativamente baixa.

VGG

VGG (Visual Geometry Group) [26] é uma arquitetura de rede neural convolucional conhecida por sua simplicidade e eficácia. Ela foi desenvolvida pelo Visual Geometry Group da Universidade de Oxford e foi uma das primeiras arquiteturas de CNN a alcançar grande sucesso. É uma arquitetura que possui um alto tamanho e profundidade porém simples de ser criada se comparado com outras arquiteturas mais recentes.

RegNet(x/y)

RegNet [27] é uma família de arquiteturas de rede neural convolucional projetada para otimizar o desempenho e a eficiência de modelos de aprendizado profundo. Ela foi desenvolvida com base em uma abordagem sistemática de design. O "x" e "y" em RegNet(x/y) referem-se a dois parâmetros principais que definem a arquitetura. O parâmetro "x" denota a largura do modelo, controlando o número de canais em cada camada convolucional, enquanto o parâmetro "y" representa a profundidade do modelo, indicando o número de blocos repetidos na arquitetura.

Mix Vision Transformer

O Mix Vision Transformer [28] é uma arquitetura de rede neural nova que combina elementos de Transformers com técnicas de mistura de dados (*mixup*) usadas em CNNs. É uma arquitetura que têm ótimo desempenho com imagens de alta granularidade FGVC - Fine-Grained Visual Categorization. A abordagem dele envolve a divisão da imagem em patches que são tratados como sequências de entrada para o Transformer e também utiliza a convolução em certas partes da arquitetura para capturar características locais de

forma eficiente. Ao integrar esses dois paradigmas, o MViT busca obter o melhor dos dois mundos, combinando a capacidade de representação dos Transformers com a capacidade de extrair características das CNNs.

Capítulo 3

Metodologia Proposta

A metodologia adotada neste trabalho é detalhada pelo fluxograma apresentado na Figura 3.1 abaixo. Cada etapa será detalhada nas seções subsequentes deste capítulo. É importante destacar que o desenvolvimento da metodologia proposta segue uma abordagem sequencial e incremental, onde cada etapa depende da conclusão da anterior para prosseguir.

Primeiramente, é necessário preparar o ambiente de desenvolvimento e escolher as ferramentas apropriadas para a realização do trabalho. Em seguida, a base de dados de imagens é elaborada, seguida pelo pré-processamento e separação do dataset. Posteriormente, os modelos de segmentação são treinados, e por fim, os resultados são avaliados. Este fluxo metodológico garante uma organização clara e eficiente do processo de desenvolvimento.

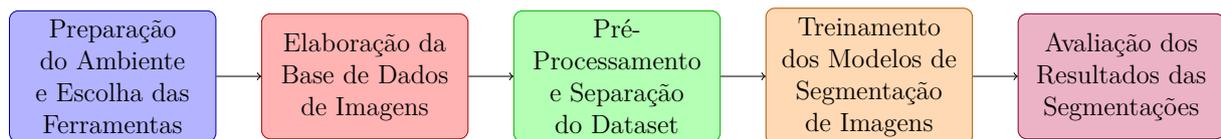


Figura 3.1: Fluxograma da Metodologia

3.1 Preparação do Ambiente e Escolha das Ferramentas

Inicialmente, o projeto foi iniciado com a inclusão de bibliotecas fundamentais, tais como TensorFlow, NumPy, OpenCV (cv2), Albumentations, Matplotlib e scikit-learn. Essas bibliotecas foram principalmente usadas para o processamento e manipulação dos dados antes do treinamento e durante a elaboração da base de dados. Para conduzir os processos

de treinamento, a biblioteca Segmentation Models foi amplamente utilizada. Baseada em PyTorch, essa biblioteca oferece acesso a nove arquiteturas para segmentação multiclasse, juntamente com diversos encoders disponíveis, facilitando consideravelmente o processo de desenvolvimento e experimentação.

3.2 Elaboração da Base de Dados de Imagens

As imagens histológicas e suas anotações foram obtidas pelo Centro de Pesquisa Gonçalo Moniz da Fiocruz na Bahia. Elas foram adquiridas por meio de biópsias renais, nas quais um pequeno fragmento de tecido é retirado do paciente, seccionado transversalmente, corado, montado em uma lâmina e, por fim, ampliado e capturado por uma câmera acoplada ao microscópio. A ferramenta LabelMe foi utilizado por médicos especialistas para a realização da segmentação das imagens. Com isso, foi anotado um total de 1401 imagens.

Nesse conjunto de imagens as classes não estão balanceadas como evidenciado na Tabela 3.1 abaixo. Com isso vai ser preciso fazer algumas mudanças para tentar balancear o conjunto de dados para facilitar o treinamento com o foco nas 3 classes das glomerulopatias (hipertrofia, degeneração, hiperplasia).

Tabela 3.1: Ocorrências de imagens e pixels para cada classe.

Classes	Imagens (% do total)	Pixels (% do total)
Plano de Fundo (<i>Background</i>)	1401 (100,00%)	1,481,987,511 (91,48%)
Podócito sem lesão*	1393 (99,43%)	88,559,958 (5,47%)
Hipertrofia	571 (40,76%)	8,376,553 (0,52%)
Degeneração	612 (43,68%)	12,494,821 (0,77%)
Hiperplasia	493 (35,19%)	28,575,999 (1,76%)

Nota: Podócito sem lesão é a classe onde os podócitos não apresentam nenhuma das três glomerulopatias abordadas neste trabalho, não necessariamente indicando que o podócito é saudável.*

3.3 Pré Processamento e Separação do Dataset

Inicialmente, foi considerado utilizar as proporções clássicas de 70% para treinamento, 20% para teste e 10% para validação. No entanto, para garantir que todas as classes estivessem devidamente representadas em cada subconjunto, foi ajustada a divisão para 75%, 17%, e 8% respectivamente. Essa escolha permitiu que cada classe tivesse um mínimo adequado de imagens em todas as fases do processo, assegurando uma representação mais balanceada no treinamento, validação no teste dos modelos. No conjunto de treinamento foi utilizado a técnica de aumento de dados (*Data Augmentation*) utilizando a biblioteca

alumentations. Essa biblioteca considera um intervalo de valores e para cada imagem gerada é usado todos os pré-processamentos da imagem abaixo ao mesmo tempo porém com valores diferentes. Para deixar o conjunto de dados mais balanceado foi usado o aumento de dados (*Data Augmentation*) para gerar apenas 1 imagem além da original em imagens com apenas plano de fundo (*background*) e/ou podócito sem lesão, enquanto que foi gerado 9 imagens além da original para as imagens com pelo menos uma glomerulopatia. As técnicas usadas estão sendo mostradas na Figura 3.2 abaixo.

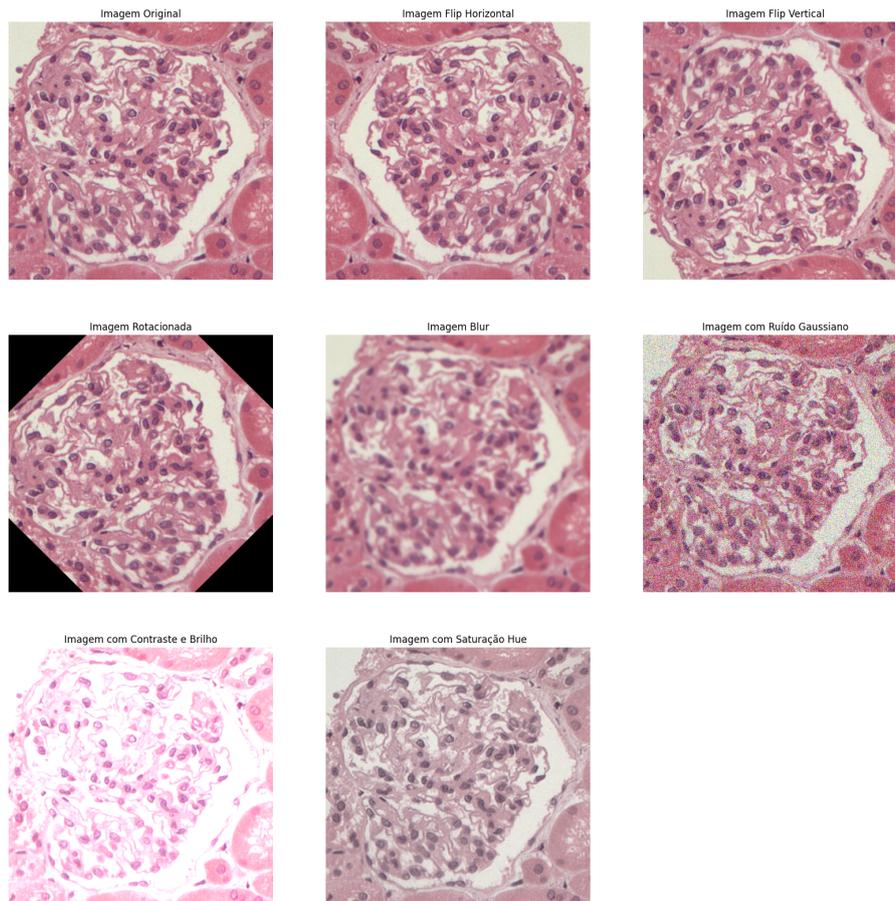


Figura 3.2: aumento de dados (*Data Augmentation*) técnicas

Os intervalos utilizados no pré-processamento para cada uma dessas técnicas foram:

- Flip Horizontal com probabilidade de 50%
- Rotação em um intervalo de -45% a 45% e probabilidade de 50%
- Blur Gaussiano com limite de blur de 0 a 1.0 e probabilidade de 50%
- Ruído Gaussiano com limite de 0 a 5% de 255 e probabilidade de 50%
- Flip Vertical com probabilidade de 50%

- Contraste de luz com limite de luz de 0,2 e limite de contraste de 0,2 e probabilidade de 50%
- Saturação Hue com limite de Hue de 20 e de Saturação de 30 com probabilidade de 50%

3.4 Treinamento dos Modelos de Segmentação

Utilizando a biblioteca Segmentation Models, baseada em PyTorch, foi desenvolvido um código para realizar o treinamento em todas as arquiteturas disponíveis dessa ferramenta. A biblioteca oferece nove arquiteturas e sete encoders, onde cada encoder pode possuir profundidades diferentes. Nem todas as combinações de arquitetura e encoder são compatíveis, mas foi explorado todas as possibilidades viáveis. Além disso, foi realizado treinamentos tanto com quanto sem pesos pré-treinados pelo ImageNet, o que resultou em um total de 370 modelos distintos. Essa abordagem garantiu uma exploração abrangente das metodologias e a aplicação diversificada de técnicas de segmentação.

As nove arquiteturas empregadas foram: U-Net, U-Net++, MANet, LinkNet, FPN, PSPNet, PAN, DeepLabV3 e DeepLabV3+. Quanto aos encoders, utilizamos o ResNet, DenseNet, Inception, EfficientNet, VGG, RegNet (x/y) e Mix Vision Transformer, considerando que cada um possui diferentes profundidades. Vale destacar que nem todos os encoders podem se integrar perfeitamente com todas as arquiteturas. As combinações diferentes que foram treinados será mais detalhado na Tabela 3.2 abaixo:

Tabela 3.2: Combinações de arquiteturas e encoders utilizados no trabalho.

Arquitetura/Encoders	EfficientNet	ResNet	RegNetX	RegNetY	Inception/ResNet	Inception	VGG	XInception	DenseNet	Mix Vision Transformer
U-Net	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
U-Net++	✓	✓	✓	✓	✓	✓	✓	✓		
MANet	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
LinkNet	✓	✓	✓	✓	✓	✓	✓	✓		
FPN	✓	✓	✓	✓	✓					
PSPNet	✓	✓	✓	✓	✓	✓	✓	✓		
PAN	✓	✓	✓	✓						
DeepLabV3	✓	✓	✓	✓						
DeepLabV3+	✓	✓	✓	✓						

- **EfficientNet:** efficient-b0, b1, b2, b3, b4, b5, b6
- **ResNet:** resnet101, resnet50
- **RegNetX:** timm-regnetx064, timm-regnetx080, timm-regnetx120, timm-regnetx320
- **RegNetY:** timm-regnety064, timm-regnety080, timm-regnety120, timm-regnety320
- **Inception/Resnet:** inceptionresnetv2
- **Inception:** inceptionv4

- **VGG:** vgg19
- **XInception:** xception
- **DenseNet:** densenet169, densenet201
- **Mix Vision Transformer:** mitb1, b2, b3, b4, b5

3.5 Avaliação dos Resultados

Para a avaliação dos resultados obtidos, foi utilizada a biblioteca PyTorch, que oferece suporte para uma variedade de métricas de avaliação de modelos de redes neurais convolucionais. Inicialmente, foi calculado o F1 Score utilizando o cálculo da própria biblioteca PyTorch. Este índice proporciona uma medida agregada de precisão e recall para cada classe prevista pelo modelo.

O F1 Score é uma métrica que combina a precisão (precision) e a revocação (recall) em um único valor, proporcionando uma medida balanceada entre esses dois aspectos. A equação para o F1 Score é dada por:

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.1)$$

Onde: - *Precision* (Precisão) é a proporção de verdadeiros positivos (TP) entre os exemplos classificados como positivos:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3.2)$$

- *Recall* (Revocação) é a proporção de verdadeiros positivos entre os exemplos que realmente são positivos:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.3)$$

- *TP* (True Positives) são os verdadeiros positivos, - *FP* (False Positives) são os falsos positivos, e - *FN* (False Negatives) são os falsos negativos.

O Índice de Jaccard, também conhecido como Intersection over Union (IoU), é uma métrica que calcula a similaridade entre dois conjuntos, no caso, entre a segmentação prevista pelo modelo e a segmentação real (verdadeiro). A equação para o IOU é dada por:

$$IOU = \frac{|A \cap B|}{|A \cup B|} \quad (3.4)$$

Onde: - $|A \cap B|$ é o número de pixels na interseção entre o conjunto A (segmentação prevista) e o conjunto B (segmentação real), - $|A \cup B|$ é o número de pixels na união entre o conjunto A e o conjunto B

Além disso, o Índice de Jaccard (IOU) foi calculado de forma clássica, levando em consideração o número de verdadeiros positivos (TP), falsos positivos (FP) e falsos negativos (FN) para cada classe e cada pixel, uma vez que se trata de uma tarefa de segmentação multiclasse. Vale ressaltar que, durante os cálculos do IOU e do F1 Score, foram desconsideradas as instâncias em que uma classe não estava presente tanto na predição quanto no ground truth.

$$\text{IoU}(Y, \hat{Y}) = \frac{TP}{TP + FN + FP} \quad (3.5)$$

Para visualização e comparação dos resultados obtidos, a biblioteca Matplotlib foi empregada, possibilitando a análise das diferenças nos dados e nas imagens geradas pelos modelos de segmentação.

Capítulo 4

Resultados

Neste capítulo, serão apresentados os resultados da segmentação das imagens histológicas e classificação das glomerulopatias. Este trabalho foi dividido em dois treinamentos distintos. No primeiro treinamento, foram exploradas todas as arquiteturas de modelos descritas no capítulo anterior, visando obter uma visão abrangente do desempenho de cada uma. No segundo treinamento, o foco foi direcionado para a melhoria dos resultados do primeiro treinamento, especialmente em relação às classes menos representadas no conjunto de dados. Além disso, serão destacadas as diferenças entre esses dois treinamentos, oferecendo observações sobre o impacto das estratégias adotadas na qualidade dos resultados obtidos.

4.1 Primeiro Treinamento

O primeiro treinamento foi conduzido conforme descrito na Seção 3.4, com algumas considerações adicionais. Neste contexto, optou-se por calcular o perda (*Loss*) ignorando a contribuição do plano de fundo (*background*), visando direcionar o modelo para as classes de interesse. Além disso, o critério de seleção do melhor modelo em cada treinamento baseou-se no Índice de Jaccard (IoU), foi utilizado 35 épocas, um tamanho do lote (*batch size*) de 16 e uma taxa de aprendizado (*learning rate*) de 0.0001. Esses hiperparâmetros foram escolhidos com base no exemplo fornecido pela biblioteca Segmentation Models, com pequenas adaptações realizadas a partir de testes iniciais para melhor adequação ao nosso problema específico.

Na Tabela 4.1 abaixo, são listados os modelos que se destacam nos melhores 10 resultados para cada classe, bem como na média geral, tanto para o Índice de Jaccard (IoU) quanto para o F-Score.

Tabela 4.1: Modelos que se destacam nos melhores 10 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento

Melhores 10 Modelos - TOP10	Frequência
Unet++_timm-regnety_320_imagenet.pth	10
Unet++_timm-regnety_120_imagenet.pth	9
Unet++_timm-regnetx_064_imagenet.pth	6
Unet++_timm-regnety_080_imagenet.pth	6
Unet_mit_b4_imagenet.pth	6
Linknet_timm-regnety_120_imagenet.pth	6
PAN_timm-regnety_120_imagenet.pth	4
Unet++_vgg19_imagenet.pth	4
Unet_timm-regnety_320_imagenet.pth	4
Unet_efficientnet-b6_imagenet.pth	4
Linknet_timm-regnetx_320_imagenet.pth	3
Unet++_efficientnet-b3_imagenet.pth	3
Unet_timm-regnety_120_imagenet.pth	3
Unet_timm-regnety_064_imagenet.pth	2
Unet++_timm-regnetx_320_imagenet.pth	2
Unet++_efficientnet-b6_imagenet.pth	2
Unet_mit_b2_imagenet.pth	2
MAnet_mit_b2_imagenet.pth	2
Unet_mit_b3_imagenet.pth	2
FPN_timm-regnety_120_imagenet.pth	2
Unet++_timm-regnety_064_imagenet.pth	1
MAnet_mit_b5_imagenet.pth	1
Unet_timm-regnetx_320_imagenet.pth	1
Linknet_efficientnet-b4_imagenet.pth	1
Linknet_timm-regnetx_120_imagenet.pth	1
DeepLabv3+_timm-regnety_120_imagenet.pth	1

Observa-se na Tabela 4.1 que os modelos com Unet++ e encoder do RegNet (x/y) se destacam nos melhores 10 resultados. Além disso, os modelos Unet e Linknet, juntamente com os encoders Mix Vision Transformer e EfficientNet, aparecem como secundários. Esses resultados indicam que, em média para todas as classes, o modelo Unet++ e o encoder do RegNet(x/y) contribuem significativamente para a obtenção de bons resultados tanto individualmente quanto na média geral.

Na Tabela 4.2 abaixo, está listado os melhores 5 resultados do primeiro treinamento para cada classe e média geral.

Tabela 4.2: Modelos que se destacam nos melhores 5 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento

Melhores 5 Modelos - TOP5	Frequência
Unet++_timm-regnety_120_imagenet.pth	8
Unet++_timm-regnety_320_imagenet.pth	7
Unet++_timm-regnetx_064_imagenet.pth	6
PAN_timm-regnety_120_imagenet.pth	4
Unet++_timm-regnety_080_imagenet.pth	4
Linknet_timm-regnety_120_imagenet.pth	2
MAnet_mit_b2_imagenet.pth	2
Unet_timm-regnety_064_imagenet.pth	2
Unet++_efficientnet-b6_imagenet.pth	2
Unet++_timm-regnetx_320_imagenet.pth	2
Unet++_vgg19_imagenet.pth	2
MAnet_mit_b5_imagenet.pth	1
Unet_efficientnet-b6_imagenet.pth	1
Unet_mit_b3_imagenet.pth	1
Unet_mit_b4_imagenet.pth	1
Unet_timm-regnety_120_imagenet.pth	1
Unet_timm-regnety_320_imagenet.pth	1
Unet++_efficientnet-b3_imagenet.pth	1

É evidente um predomínio dos modelos Unet++ e Unet quando combinados com os encoders do RegNet(x/y). As configurações com Unet++ se destacam no topo da lista, como também evidenciado na Tabela 4.1 dos 10 melhores resultados.

A seguir, apresenta-se a Tabela 4.3 dos melhores resultados para cada classe, bem como a média geral tanto para o IoU quanto para o Fscore:

Tabela 4.3: Modelos que se destacam nos melhores resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento

Melhor Modelo - TOP 1	Frequência
Unet++_timm-regnety_320_imagenet.pth	6
Unet++_vgg19_imagenet.pth	2
PAN_timm-regnety_120_imagenet.pth	2
Unet++_timm-regnety_120_imagenet.pth	2

O melhor modelo, destacado nesta Tabela 4.3, é o Unet++ com o encoder timm-regnety e pesos pré-treinados do ImageNet, aparecendo com 6 aparições na lista. Este modelo demonstrou uma consistência notável em produzir resultados de alta qualidade e desempenho em várias métricas de avaliação. Além disso, outros modelos que se destacam incluem o Unet++ com o encoder VGG19, o PAN com o encoder timm-regnety

e o Unet++ com os encoders timm-regnety e timm-regnetx, cada um aparecendo duas vezes na lista. Esses resultados destacam a eficácia do modelo Unet++ com o encoder timm-regnety como o mais proeminente e confiável para a tarefa de segmentação de glomerulopatias em imagens histológicas.

Agora, a Tabela 4.4 apresenta os 10 piores resultados deste treinamento para cada classe, bem como para a média geral:

Tabela 4.4: Modelos que se destacam nos piores 10 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento

Piores 10 Modelos - BOTTOM 10	Frequência
PSPNet_resnet101_None.pth	4
PSPNet_efficientnet-b2_None.pth	4
PSPNet_efficientnet-b0_None.pth	4
PSPNet_efficientnet-b4_None.pth	4
PAN_efficientnet-b3_None.pth	4
PSPNet_efficientnet-b3_None.pth	4
FPN_efficientnet-b0_None.pth	4
FPN_timm-regnetx_064_None.pth	4
PSPNet_efficientnet-b1_None.pth	4
DeepLabv3_efficientnet-b3_None.pth	2
DeepLabv3_efficientnet-b0_None.pth	2
DeepLabv3_efficientnet-b1_None.pth	2
DeepLabv3_efficientnet-b4_None.pth	2
FPN_timm-regnety_064_None.pth	2
DeepLabv3_resnet50_None.pth	2
DeepLabv3_efficientnet-b2_None.pth	2
DeepLabv3_efficientnet-b6_None.pth	2
DeepLabv3_resnet101_None.pth	2
PSPNet_timm-regnetx_080_None.pth	2
PAN_efficientnet-b1_None.pth	1
PSPNet_efficientnet-b5_None.pth	1
DeepLabv3_timm-regnetx_080_None.pth	1
DeepLabv3_timm-regnety_064_None.pth	1

Os piores modelos, destacados nesta Tabela 4.4, incluem várias instâncias do PSPNet com diferentes encoders, como resnet,efficientnet, entre outros, cada um aparecendo quatro vezes na lista. Além disso, modelos como PAN com o encoder efficientnet-b3 e FPN com o encoder efficientnet-b0 também aparecem quatro vezes. Outros modelos que se destacam como os piores incluem DeepLabv3 com diferentes encoders e FPN com os encoders timm-regnetx e timm-regnety, cada um aparecendo duas vezes na lista. Esses resultados indicam que, apesar da variedade de modelos e encoders testados, alguns modelos especí-

ficos, como PSPNet e PAN, parecem ter dificuldades consistentes em produzir resultados satisfatórios para a tarefa de segmentação de glomerulopatias em imagens histológicas.

A Tabela 4.5 abaixo mostra os 5 piores modelos desse treinamento:

Tabela 4.5: Modelos que se destacam nos piores 5 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Primeiro Treinamento

Piores 5 Modelos - BOTTOM 5	Frequência
FPN_efficientnet-b0_None.pth	4
PSPNet_efficientnet-b0_None.pth	4
PSPNet_efficientnet-b2_None.pth	4
PSPNet_resnet101_None.pth	4
PSPNet_efficientnet-b4_None.pth	3
DeepLabv3_efficientnet-b0_None.pth	2
DeepLabv3_efficientnet-b1_None.pth	2
DeepLabv3_efficientnet-b3_None.pth	2
DeepLabv3_efficientnet-b4_None.pth	2
DeepLabv3_resnet50_None.pth	2
PSPNet_efficientnet-b3_None.pth	1

Há uma predominância dos modelos DeepLabv3 e PSPNet, ambos utilizando o encoder do EfficientNet. Isso indica que esses modelos específicos tiveram dificuldades em produzir resultados satisfatórios para essa tarefa.

Abaixo é possível ver a Tabela 4.6 do pior modelo desse treinamento.

Tabela 4.6: Modelos que se destacam nos piores resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score.

Pior Modelo - BOTTOM 1	Frequência
PSPNet_resnet101_None.pth	4
DeepLabv3_efficientnet-b1_None.pth	2

O modelo com o desempenho mais fraco, representado pelo modelo PSPNet com encoder resnet101 e sem pesos pré-trinados, apareceu quatro vezes na lista dos piores modelos. Seguindo-o de perto, o modelo DeepLabv3 com encoder efficientnet também teve um desempenho significativamente ruim, aparecendo duas vezes na lista. O número reduzido de ocorrências na Tabela 4.6 se deve aos muitos empates de resultados com valores zero nas classes das glomerulopatias.

A seguir, uma imagem foi selecionada aleatoriamente a partir do conjunto de teste e do subconjunto onde é garantido que todas as classes estejam presentes. Em seguida, foi realizada a predição utilizando três modelos distintos: o melhor modelo, o pior modelo e um modelo escolhido aleatoriamente.

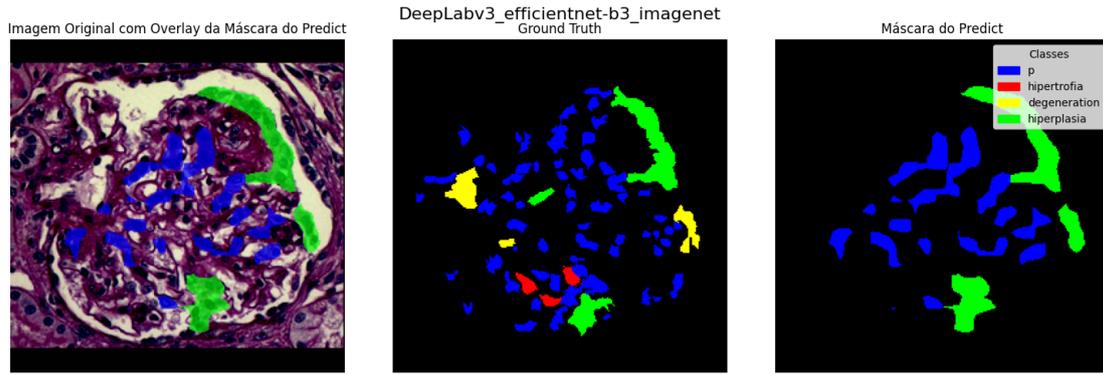


Figura 4.1: Predição e Referência (*Ground Truth*) do Modelo Aleatório - Primeiro Treinamento

Na análise da imagem gerada pelo modelo aleatório mostrada na Figura 4.1, observa-se uma identificação correta da hiperplasia (representada em verde), embora haja pouca precisão na detecção de podócitos não lesionados. O modelo também apresenta uma boa detecção do plano de fundo (*background*). No entanto, não são identificados elementos das outras duas classes, hipertrofia e degeneração.

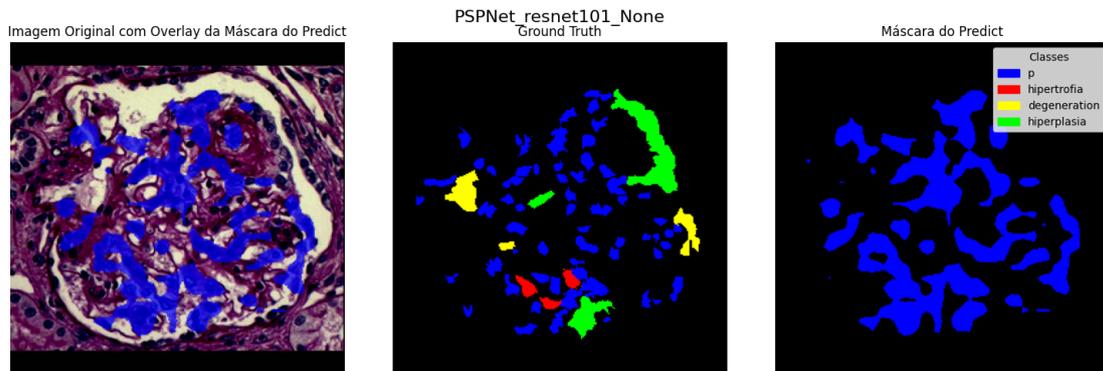


Figura 4.2: Predição e Referência (*Ground Truth*) do Pior Modelo - Primeiro Treinamento

O pior modelo mostrado na Figura 4.2 não obteve acertos para nenhuma das glomerulopatias e gerou regiões extensas para os podócitos saudáveis, resultando em uma predição pouco precisa.

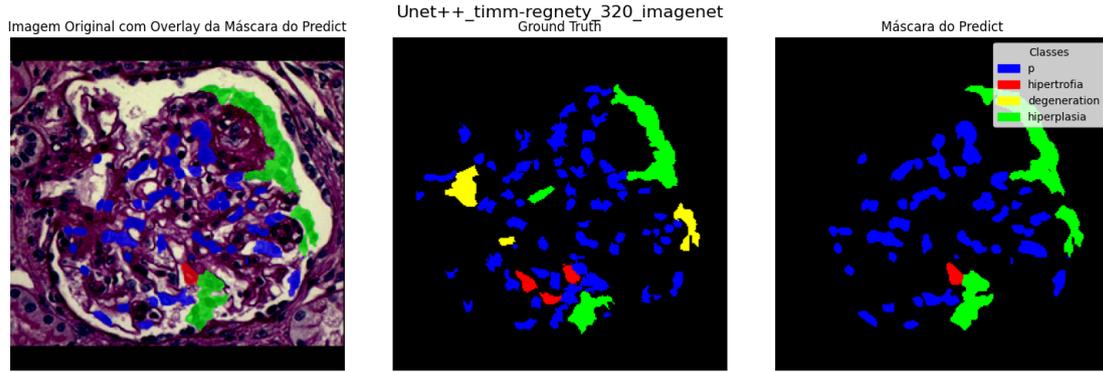


Figura 4.3: Predição e Referência (*Ground Truth*) do Melhor Modelo - Primeiro Treinamento

O melhor modelo mostrado na Figura 4.3 apresentou predições mais precisas para os podócitos não lesionados, acertando também a hiperplasia e a hipertrofia. Entretanto, não houve acerto para a degeneração, havendo uma confusão com a hiperplasia. Por outro lado, a predição do plano de fundo (*background*) foi excelente.

4.2 Segundo Treinamento

No segundo treinamento, também seguimos o mesmo protocolo descrito na seção 3.4, com algumas adaptações. Nesta etapa, implementamos um cálculo de perda (*Loss*) inversamente proporcional à quantidade de pixels que cada classe possui no conjunto de dados e também baseando-se nos resultados obtidos no primeiro treinamento onde as glomerulopatias hipertrofia e degeneração não obtiveram bons resultados. Os valores de perda (*Loss*) foram ajustados para refletir essa proporção: a perda do plano de fundo (*background*) foi mantida em 0, dos podócitos não lesionados em 0.5, da hipertrofia em 2.5, da degeneração em 2.0 e da hiperplasia em 0.7. Além disso, alteramos o critério de seleção do melhor modelo, optando pelo menor perda (*Loss*), em contraste com o primeiro treinamento. Os demais parâmetros permaneceram constantes, com 35 épocas, um tamanho do lote (*batch size*) de 16 e um taxa de aprendizado (*learning rate*) de 0.0001. Esses hiperparâmetros foram escolhidos com base no exemplo fornecido pela biblioteca Segmentation Models, com pequenas adaptações realizadas a partir de testes iniciais para melhor adequação ao nosso problema específico. Na Tabela 4.7 a seguir, estão listados os 10 melhores modelos, juntamente com o número de vezes que cada um apareceu na lista ordenada para cada classe, considerando os métodos de avaliação (IoU e FScore), bem como as médias dos resultados obtidos.

Tabela 4.7: Modelos que se destacam nos melhores 10 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento

Melhores 10 Modelos - TOP 10	Frequência
PAN_timm-regnetx_064_imagenet_lr.pth	6
DeepLabv3+_efficientnet-b2_imagenet_lr.pth	5
Linknet_xception_imagenet_lr.pth	5
Unet++_inceptionv4_imagenet_lr.pth	4
PAN_timm-regnety_120_imagenet_lr.pth	4
FPN_efficientnet-b2_imagenet_lr.pth	4
PAN_timm-regnety_080_imagenet_lr.pth	4
DeepLabv3+_efficientnet-b0_imagenet_lr.pth	4
MAnet_mit_b1_imagenet_lr.pth	4
MAnet_mit_b3_imagenet_lr.pth	4
Linknet_inceptionv4_imagenet_lr.pth	3
PSPNet_timm-regnety_080_imagenet_lr.pth	3
Linknet_vgg19_imagenet_lr.pth	3
DeepLabv3+_timm-regnetx_064_imagenet_lr.pth	3
DeepLabv3+_efficientnet-b6_imagenet_lr.pth	3
Unet_inceptionv4_imagenet_lr.pth	2
Unet_efficientnet-b2_imagenet_lr.pth	2
DeepLabv3+_timm-regnetx_120_imagenet_lr.pth	2
Linknet_timm-regnetx_120_imagenet_lr.pth	2
PAN_resnet101_imagenet_lr.pth	2
Unet++_vgg19_imagenet_lr.pth	2
Unet_mit_b3_imagenet_lr.pth	2
MAnet_vgg19_imagenet_lr.pth	2
Unet_vgg19_imagenet_lr.pth	2
MAnet_mit_b2_imagenet_lr.pth	2
Unet_mit_b5_imagenet_lr.pth	2
Unet_mit_b2_imagenet_lr.pth	2
Unet++_efficientnet-b6_imagenet_lr.pth	2
Unet++_efficientnet-b2_imagenet_lr.pth	2
Unet_efficientnet-b6_imagenet_lr.pth	2
Unet_efficientnet-b3_imagenet_lr.pth	2
Linknet_efficientnet-b2_imagenet_lr.pth	2
Linknet_timm-regnetx_064_imagenet_lr.pth	2
Unet_efficientnet-b0_imagenet_lr.pth	2
Unet++_efficientnet-b1_imagenet_lr.pth	2
Linknet_efficientnet-b4_imagenet_lr.pth	2
DeepLabv3+_efficientnet-b3_imagenet_lr.pth	2
PAN_resnet50_imagenet_lr.pth	2
Unet_efficientnet-b1_imagenet_lr.pth	2
DeepLabv3_timm-regnety_080_imagenet_lr.pth	2
DeepLabv3_efficientnet-b2_imagenet_lr.pth	2
MAnet_efficientnet-b2_imagenet_lr.pth	2
PAN_efficientnet-b5_imagenet_lr.pth	2
Unet_mit_b1_imagenet_lr.pth	1
DeepLabv3+_efficientnet-b5_imagenet_lr.pth	1
PAN_efficientnet-b1_imagenet_lr.pth	1
MAnet_efficientnet-b0_imagenet_lr.pth	1
Unet++_xception_imagenet_lr.pth	1

Primeiramente, é possível observar a presença frequente das arquiteturas PAN, DeepLabv3+ e Linknet. Essas arquiteturas foram combinadas com uma variedade de encoders, incluindo timm-regnetx e efficientnet, demonstrando sua eficácia em diferentes configurações. Além disso, a utilização de pesos pré-treinados no ImageNet parece ser uma prática comum entre os modelos mais bem-sucedidos. Unet++, Unet e MAnet também aparecem com bastante frequência porém com menos aparições.

Abaixo está a Tabela 4.8 com os melhores 5 modelos do segundo treinamento.

Tabela 4.8: Modelos que se destacam nos melhores 5 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento

Melhores 5 Modelos - TOP 5	Frequência
Unet++_inceptionv4_imagenet_lr.pth	4
FPN_efficientnet-b2_imagenet_lr.pth	4
PAN_timm-regnety_080_imagenet_lr.pth	4
Linknet_xception_imagenet_lr.pth	4
PAN_timm-regnetx_064_imagenet_lr.pth	4
DeepLabv3+_efficientnet-b0_imagenet_lr.pth	2
Unet++_vgg19_imagenet_lr.pth	2
PAN_timm-regnety_120_imagenet_lr.pth	2
DeepLabv3+_timm-regnetx_120_imagenet_lr.pth	2
Unet_vgg19_imagenet_lr.pth	2
Linknet_vgg19_imagenet_lr.pth	2
DeepLabv3+_timm-regnetx_064_imagenet_lr.pth	2
Unet_mit_b3_imagenet_lr.pth	2
MAnet_vgg19_imagenet_lr.pth	2
MAnet_mit_b3_imagenet_lr.pth	2
Unet++_efficientnet-b6_imagenet_lr.pth	2
Unet++_efficientnet-b2_imagenet_lr.pth	2
Linknet_timm-regnetx_064_imagenet_lr.pth	2
Unet_efficientnet-b0_imagenet_lr.pth	2
Unet++_efficientnet-b1_imagenet_lr.pth	2
PSPNet_timm-regnety_080_imagenet_lr.pth	2
DeepLabv3+_efficientnet-b2_imagenet_lr.pth	2
DeepLabv3+_timm-regnety_080_imagenet_lr.pth	2
MAnet_mit_b1_imagenet_lr.pth	1
Unet_inceptionv4_imagenet_lr.pth	1
DeepLabv3+_efficientnet-b6_imagenet_lr.pth	1
Linknet_efficientnet-b2_imagenet_lr.pth	1
Linknet_efficientnet-b4_imagenet_lr.pth	1
DeepLabv3+_efficientnet-b3_imagenet_lr.pth	1

Notavelmente, as arquiteturas Unet++ e PAN, combinadas com encoders como inceptionv4, timm-regnety e efficientnet, aparecem com frequência nesse grupo. Isso sugere que essas configurações específicas estão consistentemente entre as mais eficazes para a tarefa de segmentação de glomerulopatias. Além disso, a presença de arquiteturas como FPN e Linknet, juntamente com encoders como efficientnet e vgg19, indica uma variedade de opções que podem oferecer resultados promissores.

A Tabela 4.9 abaixo mostra o melhor modelo para o segundo treinamento em cada classe e também na média geral.

Tabela 4.9: Modelos que se destacam nos melhores resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento

Melhor Modelo - TOP 1	Frequência
PAN_timm-regnety_080_imagenet_lr.pth	3
PAN_timm-regnetx_064_imagenet_lr.pth	2
DeepLabv3+_timm-regnetx_120_imagenet_lr.pth	2
Linknet_timm-regnetx_064_imagenet_lr.pth	2
Unet++_vgg19_imagenet_lr.pth	2
Unet++_inceptionv4_imagenet_lr.pth	1
FPN_efficientnet-b2_imagenet_lr.pth	1
DeepLabv3_timm-regnety_080_imagenet_lr.pth	1

O modelo que se destaca como o melhor, com a maior frequência de aparições entre os resultados de destaque, é o PAN com o encoder timm-regnety e pesos pré-treinados do ImageNet. Este modelo apareceu em três ocasiões na lista dos melhores resultados. Em segundo lugar, temos o PAN com o encoder timm-regnetx, bem como o DeepLabv3+ com o encoder timm-regnetx, e o Linknet com o encoder timm-regnetx, todos com duas aparições cada. Esses resultados destacam a consistência e eficácia do PAN com encoders timm-regnety e timm-regnetx para a tarefa de segmentação de glomerulopatias em imagens histológicas.

Abaixo é possível ver as Tabelas com dez(4.10),cinco(4.11) e com o pior(4.12) modelo desse treinamento. Porém é possível ver que as três Tabelas(4.10, 4.11 e 4.12) são quase iguais, pois ouve muitos empates com resultados iguais a 0 em algumas classes.

Tabela 4.10: Modelos que se destacam nos piores 10 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento

Piores 10 Modelos - BOTTOM 10	Frequência
FPN_timm-regnetx_080_None_lr.pth	6
FPN_timm-regnety_064_None_lr.pth	4
PAN_efficientnet-b3_None_lr.pth	4
PAN_efficientnet-b4_None_lr.pth	4
PSPNet_efficientnet-b1_None_lr.pth	4
PSPNet_efficientnet-b0_None_lr.pth	4
PSPNet_efficientnet-b2_None_lr.pth	4
PSPNet_efficientnet-b5_None_lr.pth	4
FPN_timm-regnetx_120_imagenet_lr.pth	4
FPN_efficientnet-b0_imagenet_lr.pth	4
FPN_timm-regnetx_064_imagenet_lr.pth	4
PSPNet_efficientnet-b5_imagenet_lr.pth	4
Linknet_timm-regnetx_080_imagenet_lr.pth	4
FPN_timm-regnetx_080_imagenet_lr.pth	4
PAN_timm-regnetx_080_None_lr.pth	4
FPN_efficientnet-b5_imagenet_lr.pth	4
PAN_efficientnet-b2_imagenet_lr.pth	4
FPN_efficientnet-b1_imagenet_lr.pth	2
Linknet_inceptionresnetv2_imagenet_lr.pth	2
PSPNet_efficientnet-b2_imagenet_lr.pth	2
FPN_inceptionresnetv2_None_lr.pth	2
PAN_efficientnet-b4_imagenet_lr.pth	2
PAN_efficientnet-b2_None_lr.pth	2
PSPNet_efficientnet-b4_imagenet_lr.pth	2
FPN_resnet50_None_lr.pth	2
PAN_timm-regnetx_120_imagenet_lr.pth	2
FPN_efficientnet-b6_imagenet_lr.pth	2
FPN_timm-regnety_320_imagenet_lr.pth	2
FPN_efficientnet-b5_None_lr.pth	2
PSPNet_inceptionv4_imagenet_lr.pth	2
PSPNet_efficientnet-b3_None_lr.pth	2
PSPNet_timm-regnetx_320_None_lr.pth	2
Linknet_timm-regnety_120_imagenet_lr.pth	2
FPN_timm-regnetx_064_None_lr.pth	2
PSPNet_timm-regnety_064_None_lr.pth	2
PSPNet_timm-regnety_320_None_lr.pth	2
Linknet_efficientnet-b2_imagenet_lr.pth	1

Na lista dos piores modelos, o modelo FPN com encoder timm-regnetx e sem pesos pré-treinados aparece com a maior frequência, sendo observado seis vezes. Em seguida,

há uma série de modelos com quatro ocorrências cada, incluindo FPN com encode timm-regnety, PAN com encoder efficientnet-b3 e PSPNet com encoder efficientnet-b1. Esses resultados sugerem que esses modelos específicos tiveram dificuldades consistentes em realizar a segmentação das glomerulopatias nas imagens histológicas.

Tabela 4.11: Modelos que se destacam nos piores 5 resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento

Piores 5 Modelos - BOTTOM 5	Frequência
FPN_timm-regnetx_080_None_lr.pth	6
FPN_timm-regnety_064_None_lr.pth	4
PAN_efficientnet-b3_None_lr.pth	4
PAN_efficientnet-b4_None_lr.pth	4
PSPNet_efficientnet-b1_None_lr.pth	4
PSPNet_efficientnet-b0_None_lr.pth	4
PSPNet_efficientnet-b2_None_lr.pth	4
PSPNet_efficientnet-b5_None_lr.pth	4
FPN_timm-regnetx_120_imagenet_lr.pth	4
FPN_efficientnet-b0_imagenet_lr.pth	4
FPN_timm-regnetx_064_imagenet_lr.pth	4
PSPNet_efficientnet-b5_imagenet_lr.pth	4
Linknet_timm-regnetx_080_imagenet_lr.pth	4
FPN_timm-regnetx_080_imagenet_lr.pth	4
PAN_timm-regnetx_080_None_lr.pth	2
FPN_efficientnet-b5_imagenet_lr.pth	2
PAN_efficientnet-b2_imagenet_lr.pth	2
FPN_efficientnet-b1_imagenet_lr.pth	2
Linknet_inceptionresnetv2_imagenet_lr.pth	2
PSPNet_efficientnet-b2_imagenet_lr.pth	2
FPN_inceptionresnetv2_None_lr.pth	2
PAN_efficientnet-b4_imagenet_lr.pth	2
PAN_efficientnet-b2_None_lr.pth	2
PSPNet_efficientnet-b4_imagenet_lr.pth	2
FPN_resnet50_None_lr.pth	2
PAN_timm-regnetx_120_imagenet_lr.pth	2
FPN_efficientnet-b6_imagenet_lr.pth	2
FPN_timm-regnety_320_imagenet_lr.pth	2
FPN_efficientnet-b5_None_lr.pth	2
PSPNet_inceptionv4_imagenet_lr.pth	2
PSPNet_efficientnet-b3_None_lr.pth	2
PSPNet_timm-regnetx_320_None_lr.pth	2
FPN_timm-regnetx_064_None_lr.pth	2
PSPNet_timm-regnety_064_None_lr.pth	2
PSPNet_timm-regnety_320_None_lr.pth	2
Linknet_efficientnet-b2_imagenet_lr.pth	1

A única diferença entre essa Tabela 4.11 e a Tabela 4.10 dos 10 piores é que nessa Tabela 4.10 não tem o modelo Linknet com o encoder timm-regnety. As Tabelas 4.11 e 4.10 são extremamente parecidas pois houve muitos empates de resultados.

Tabela 4.12: Modelos que se destacam nos piores resultados para cada classe, avaliados por Índice de Jaccard (IoU) e F-Score. Segundo Treinamento

Pior Modelo - BOTTOM 1	Frequência
FPN_timm-regnetx_080_None_lr.pth	6
FPN_timm-regnety_064_None_lr.pth	2
PAN_efficientnet-b3_None_lr.pth	2
PAN_efficientnet-b4_None_lr.pth	2
PSPNet_efficientnet-b1_None_lr.pth	2
PSPNet_efficientnet-b0_None_lr.pth	2
PSPNet_efficientnet-b2_None_lr.pth	2
PSPNet_efficientnet-b5_None_lr.pth	2
FPN_timm-regnetx_120_imagenet_lr.pth	2
FPN_efficientnet-b0_imagenet_lr.pth	2
FPN_timm-regnetx_064_imagenet_lr.pth	2
PSPNet_efficientnet-b5_imagenet_lr.pth	2
Linknet_timm-regnetx_080_imagenet_lr.pth	2
FPN_timm-regnetx_080_imagenet_lr.pth	2
PAN_timm-regnetx_080_None_lr.pth	2
FPN_efficientnet-b5_imagenet_lr.pth	2
PAN_efficientnet-b2_imagenet_lr.pth	2
FPN_efficientnet-b1_imagenet_lr.pth	2
Linknet_inceptionresnetv2_imagenet_lr.pth	2
PSPNet_efficientnet-b2_imagenet_lr.pth	2
FPN_inceptionresnetv2_None_lr.pth	2
PAN_efficientnet-b4_imagenet_lr.pth	2
PAN_efficientnet-b2_None_lr.pth	2
PSPNet_efficientnet-b4_imagenet_lr.pth	2
FPN_resnet50_None_lr.pth	2
PAN_timm-regnetx_120_imagenet_lr.pth	2
FPN_efficientnet-b6_imagenet_lr.pth	2
FPN_timm-regnety_320_imagenet_lr.pth	2
FPN_efficientnet-b5_None_lr.pth	2
PSPNet_inceptionv4_imagenet_lr.pth	2
PSPNet_efficientnet-b3_None_lr.pth	2
PSPNet_timm-regnetx_320_None_lr.pth	2
FPN_timm-regnetx_064_None_lr.pth	2
PSPNet_timm-regnety_064_None_lr.pth	2
PSPNet_timm-regnety_320_None_lr.pth	2
Linknet_efficientnet-b2_imagenet_lr.pth	1

O pior modelo, considerando a quantidade de aparições, é o FPN com encoder timm-regnetx e sem pesos pré-treinados, com um total de 6 ocorrências. Isso sugere que esse modelo teve o desempenho mais fraco em relação aos demais na tarefa de segmentação das

glomerulopatias nas imagens histológicas. A diferença dessa Tabela 4.12 com as de cima são no número de ocorrências de alguns modelos, porém além disso ela continua igual. Isso mostra que houve muitos empates com resultados baixos. Ao analisar os números dos resultados mais desfavoráveis no apêndice, é evidente que vários desses modelos provavelmente enfrentaram algum tipo de problema durante o processo de treinamento, resultando em um desempenho inadequado. A vasta quantidade de modelos sendo treinados torna difícil identificar esses problemas durante o próprio treinamento, sendo necessário avaliar todos os resultados posteriormente para detectá-los.

Aqui estão as previsões de alguns modelos em uma imagem que foi selecionada aleatoriamente a partir do conjunto de teste e do subconjunto onde é garantido que todas as classes estejam presentes. Selecionamos cinco modelos para avaliação: um modelo escolhido aleatoriamente, um dos piores modelos, outro dos piores modelos, mas com resultados não repetidos conforme indicado na Tabela 4.12 dos piores modelos, e dois dos melhores modelos selecionados de maneira distinta, uma vez que escolher apenas um modelo como o melhor é uma tarefa desafiadora.

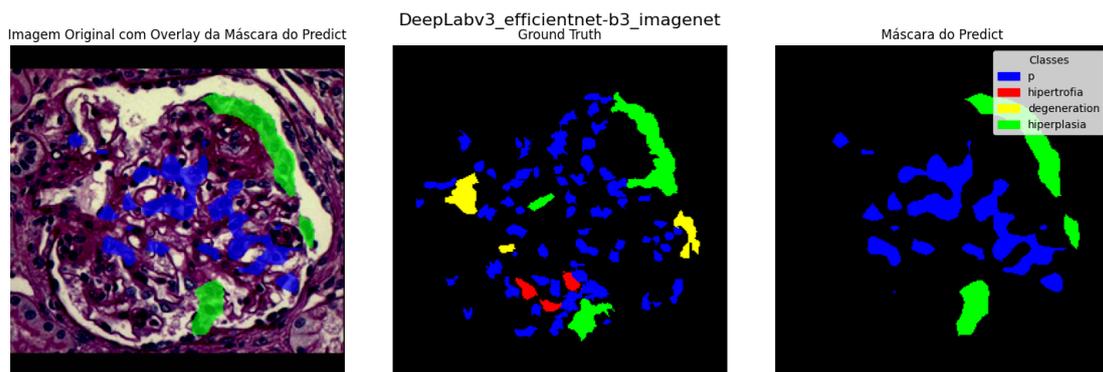


Figura 4.4: Predição e Referência (*Ground Truth*) do Modelo Aleatório - Segundo Treinamento

Na análise da imagem gerada pelo modelo aleatório, observa-se uma identificação boa da hiperplasia (representada em verde), embora haja pouca precisão na detecção de podócitos não lesionados. É possível ver também que as outras glomerulopatias foram detectadas como plano de fundo (*background*) com 1 exceção.

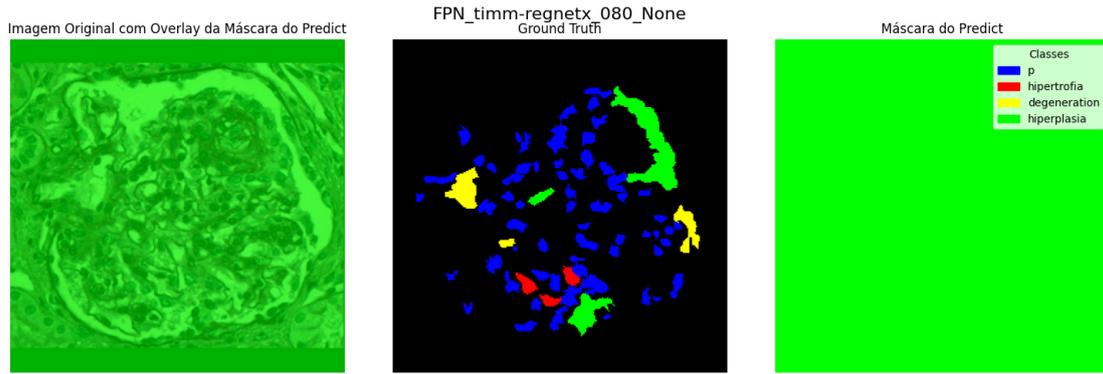


Figura 4.5: Predição e Referência (*Ground Truth*) de um dos Piores Modelos 1 - Segundo Treinamento

Esse modelo foi considerado o pior modelo porém pode-se dizer que houve alguma falha na hora do treinamento pelo resultado bem próximo de 0 em todas as classes. Podemos ver que a predição mostrada na Figura 4.5 tentou dizer que toda a imagem é hiperplasia, tendo assim um péssimo resultado.

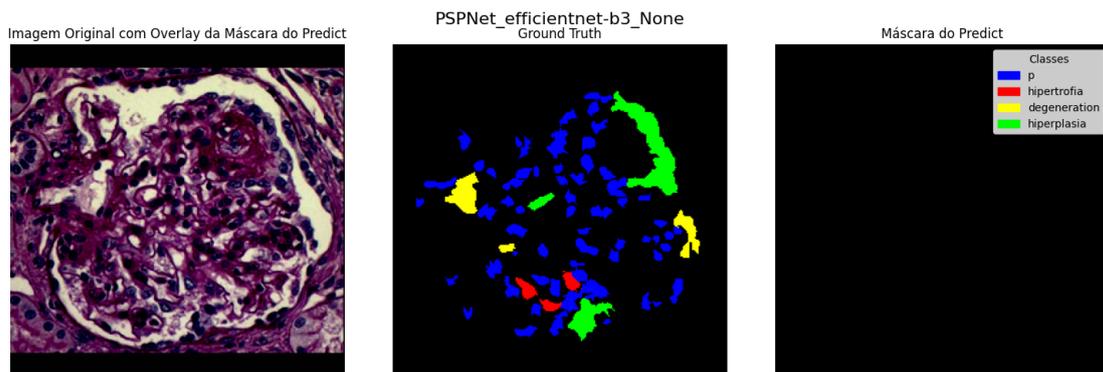


Figura 4.6: Predição e Referência (*Ground Truth*) de um dos Piores Modelos 2 - Segundo Treinamento

Esse modelo foi um dos piores modelos também porém com alguns resultados diferentes de 0, podemos ver que o modelo prediz que toda a imagem é composta por 'plano de fundo (*background*)' como pode-se ver na Figura 4.6. Como a maior parte da imagem é composta por 'plano de fundo (*background*)', o resultado é um pouco maior que o outro pior modelo porém continua sendo um péssimo resultado.

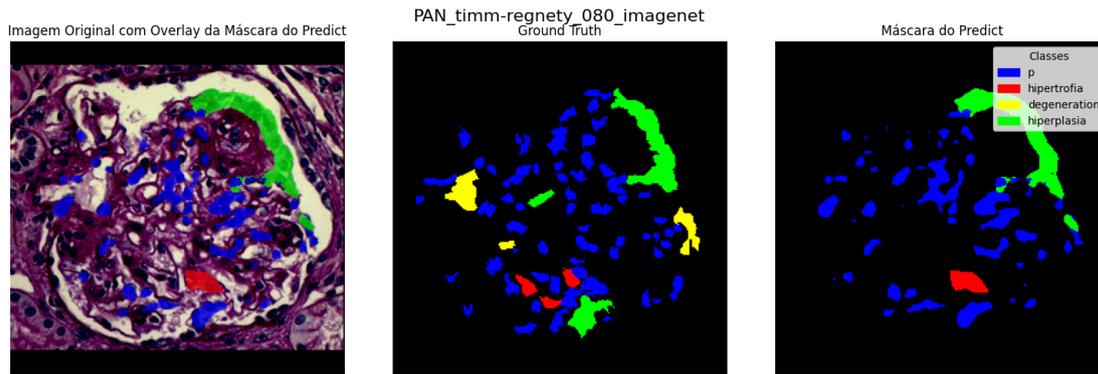


Figura 4.7: Predição e Referência (*Ground Truth*) de um dos Melhores Modelos 1 - Segundo Treinamento

Este modelo se destaca como um dos melhores, sendo o mais frequente no TOP 1. No entanto, fica empatado com outros modelos como o mais frequente no TOP 5 e terceiro mais frequente no TOP 10, revelando sua eficácia em algumas categorias em comparação com outros modelos, mas não tão eficiente em outras. Na análise das previsões mostrada na Figura 4.7, observamos sua precisão em identificar podócitos não lesionados e hiperplasia, além de acertar parcialmente na hipertrofia. Embora tenha obtido resultados satisfatórios, não conseguiu prever a degeneração e apresentou confusão em algumas classes.

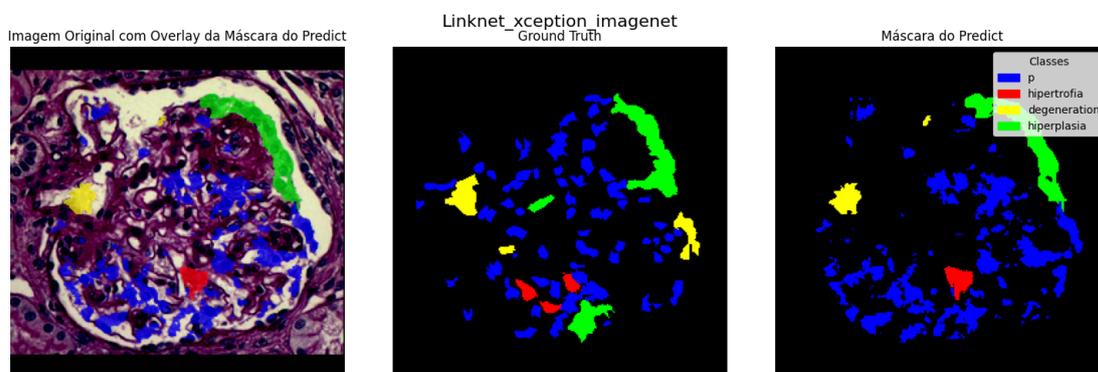


Figura 4.8: Predição e Referência (*Ground Truth*) de um dos Melhores Modelos 2 - Segundo Treinamento

Este modelo também se destaca como um dos melhores, sendo o segundo mais frequente no TOP 1 e TOP 10, e empatado com outros modelos como o mais frequente no TOP 5. Além disso, é notável por ter valores distintos de zero para todas as classes, ao contrário de outros modelos considerados os melhores do treinamento. Na análise das previsões mostrada na Figura 4.8, observamos sua precisão em identificar podócitos não lesionados e hiperplasia, além de prever tanto degeneração quanto hiperplasia, abran-

gendo todas as classes presentes na imagem original. No entanto, errou ao prever uma das degenerações e também ao identificar uma degeneração inexistente, além de ter cometido erros na predição de uma hiperplasia e duas hipertrofias. Apesar dessas falhas, continua sendo um dos melhores modelos, principalmente por ser capaz de prever todas as classes, o que é incomum entre a maioria dos modelos treinados.

4.3 Diferenças Entre os Treinamentos

Nesta seção, faremos uma análise comparativa entre os dois modelos de treinamento. Primeiramente, o segundo modelo de treinamento demonstrou ser mais eficaz na segmentação de glomerulopatias, destacando-se nas classes de hipertrofia e degeneração, onde apresentou melhor desempenho em comparação ao primeiro modelo. Por outro lado, o primeiro modelo teve um desempenho superior nas outras classes, como plano de fundo e podócitos não lesionados. Isso sugere que esses modelos podem ser complementares, cada um servindo a propósitos específicos dentro do contexto de segmentação histológica.

Quando analisamos as arquiteturas utilizadas, a Unet++ destacou-se em ambos os treinamentos, demonstrando uma robustez e versatilidade notáveis em tarefas de segmentação complexas, o que a torna uma escolha sólida para uma variedade de cenários. A Unet e a MANet também figuraram consistentemente entre os melhores modelos em ambos os treinamentos, corroborando sua eficácia. Por outro lado, a DeepLabv3+ teve um desempenho mais expressivo no segundo modelo de treinamento, enquanto a DeepLabv3 apresentou resultados insatisfatórios no primeiro treinamento, evidenciando possíveis diferenças na capacidade de generalização entre as variantes.

As arquiteturas FPN e PSPNet obtiveram resultados insatisfatórios em ambos os treinamentos, sugerindo que essas abordagens podem não ser as mais adequadas para este tipo específico de segmentação histológica. O Linknet apresentou um comportamento ambíguo: figurou entre os melhores modelos em ambos os treinamentos, mas também foi um dos piores no segundo treinamento, o que indica uma variabilidade de desempenho dependendo do encoder. O PAN, quando combinado com o encoder RegNet Y, destacou-se entre os melhores modelos em ambos os treinamentos, porém, com outros encoders, teve um desempenho inferior, sugerindo uma dependência da arquitetura do encoder para alcançar bons resultados.

No que tange aos encoders, RegNetX e RegNetY aparecem frequentemente entre os melhores modelos em ambos os treinamentos, evidenciando sua eficácia na extração de características relevantes para segmentação. O Mix Vision Transformer mostrou-se promissor, embora tenha figurado entre os piores modelos com certa frequência no segundo treinamento, o que pode estar relacionado à complexidade da arquitetura e à capacidade

de generalização. O encoder VGG apareceu com menos frequência, mas esteve entre os melhores em ambos os treinamentos, possivelmente devido à sua simplicidade e eficiência na extração de características hierárquicas.

Por outro lado, ResNet não apareceu frequentemente entre os melhores modelos e figurou entre os piores no primeiro treinamento, o que pode indicar que essa arquitetura não se adequa tão bem a este problema específico de segmentação. O EfficientNet mostrou uma alta variabilidade de desempenho, aparecendo tanto entre os melhores quanto entre os piores modelos em ambos os treinamentos. Essa variabilidade pode ser atribuída à sua flexibilidade, como descrito na Tabela 3.2, onde é mencionado que o EfficientNet pode ser combinado com todas as arquiteturas possíveis e possui sete profundidades diferentes.

O Inception mostrou-se intermediário no primeiro modelo de treinamento, não aparecendo entre os melhores ou piores, mas destacou-se entre os melhores no segundo modelo, enquanto apareceu menos frequentemente entre os piores. Por fim, DenseNet não apareceu de forma significativa entre os melhores ou piores modelos em ambos os treinamentos, mostrando um desempenho intermediário, sem grandes destaques positivos ou negativos.

É importante ressaltar que o sucesso de uma abordagem de segmentação histológica depende não só da arquitetura escolhida, mas também da combinação eficaz entre arquitetura e encoder. As especificidades dos melhores e piores modelos de cada treinamento já foram detalhadas na seção anterior, o que reforça a importância de escolher cuidadosamente essas combinações para alcançar os melhores resultados.

Abaixo, é apresentado a Tabela 4.13 que mostra a quantidade de modelos nos quais houve melhoria ou piora do primeiro modelo para o segundo. Além disso, incluímos a média das melhorias ou pioras dos resultados, assim como a média ajustada, na qual desconsideramos os valores zerados, uma vez que houve muitos deles, especialmente entre as classes de hipertrofia e degeneração.

Tabela 4.13: Comparação entre os modelos de treinamento avaliados por Índice de Jaccard (IoU) e F-Score para diferentes classes.

	Média		Plano de Fundo		Podócito*		hipertrofia		degeneration		hiperplasia	
	IOU	F1	IOU	F1	IOU	F1	IOU	F1	IOU	F1	IOU	F1
Piorou	364	364	354	354	364	362	3	3	1	1	322	322
Melhorou	1	1	11	10	1	3	36	36	28	28	13	13
Média	-0.056	-0.066	-0.107	-0.099	-0.074	-0.101	0.002	0.004	0.001	0.002	-0.105	-0.138
Média*	-0.056	-0.066	-0.107	-0.099	-0.074	-0.101	0.023	0.035	0.015	0.024	-0.114	-0.150

Nota*: A Classe Podócito é a classe que representam os podócitos que não apresentam nenhuma das três glomerulopatias abordadas neste trabalho, não necessariamente indicando que o podócito é saudável.

A análise da Tabela 4.13 revela padrões distintos de desempenho entre os dois modelos de treinamento, destacando as categorias "Piorou" e "Melhorou", bem como a média e as classes específicas. Notavelmente, nos segmentos de plano de fundo (*background*),

podócito não lesionado e hiperplasia, observa-se que os modelos do primeiro treinamento predominantemente superaram os do segundo. Por outro lado, nas categorias de hipertrofia e degeneração, o segundo modelo de treinamento demonstrou um desempenho superior, apesar da prevalência de valores zerados nessas classes.

Ao considerarmos as médias de melhoria, fica evidente que o primeiro modelo exibiu um desempenho significativamente melhor do que o segundo, com uma diferença de aproximadamente 0.1 nas classes de plano de fundo (*background*), podócito não lesionado e hiperplasia. Esta disparidade é substancial, destacando a eficácia do primeiro modelo nessas áreas. Por outro lado, nas classes de hipertrofia e degeneração, o segundo modelo superou o primeiro em torno de 0.035 e 0.025, respectivamente, em termos de F1. Embora essas diferenças também sejam notáveis, é importante ressaltar que os objetivos específicos desses treinamentos são segmentar as glomerulopatias.

Em suma, a análise do desempenho dos modelos de treinamento para segmentação de imagens histológicas de glomerulopatias revela a complexidade dessa tarefa. Enquanto melhorias na diferenciação das glomerulopatias podem resultar em uma degradação dos resultados em categorias como plano de fundo (*background*) e podócito saudável, o segundo modelo demonstrou ser mais eficaz em determinados contextos. Essas percepções destacam os desafios inerentes à otimização do desempenho dos modelos em tarefas de segmentação complexas como essa.

Capítulo 5

Conclusões

Este trabalho realizou a segmentação de imagens histológicas e a classificação de glomerulopatias, utilizando dois treinamentos distintos de modelos. No primeiro treinamento, uma ampla gama de arquiteturas foi explorada para avaliar o desempenho de cada modelo. No segundo treinamento, o foco foi em melhorar os resultados das classes menos representadas, ajustando as estratégias de treinamento baseadas nas observações do primeiro experimento.

No primeiro treinamento, a abordagem de calcular o perda (*Loss*) ignorando o background se mostrou eficaz em direcionar o modelo para as classes de interesse. O modelo Unet++ com encoder RegNet (x/y) destacou-se, aparecendo frequentemente entre os melhores resultados. Em contrapartida, modelos como PSPNet e PAN enfrentaram dificuldades, apresentando um desempenho ruim.

No segundo treinamento, o cálculo do perda (*Loss*) foi ajustado de acordo com a representação de cada classe no conjunto de dados. O modelo PAN com encoder timm-regnety, pré-treinado no ImageNet, obteve os melhores resultados, demonstrando consistência e eficácia. No entanto, alguns modelos continuaram a apresentar problemas de desempenho, particularmente o FPN com encoder timm-regnetx.

Comparando os dois treinamentos, observamos que o primeiro modelo teve um desempenho superior nas classes de background, podócitos não lesionados e hiperplasia, enquanto o segundo modelo foi mais eficaz nas classes de hipertrofia e degeneração. Isso demonstra a complexidade de otimizar o desempenho dos modelos para todas as classes de interesse simultaneamente.

Em síntese, a tarefa de segmentação de glomerulopatias em imagens histológicas é complexa e exige um equilíbrio delicado entre o desempenho nas várias classes de interesse. Embora o segundo treinamento tenha proporcionado melhorias significativas em classes específicas, o primeiro modelo se destacou por manter um desempenho mais equilibrado de maneira geral sendo assim modelos de treinamento complementares. Esse trabalho

contribui para o entendimento dos desafios e estratégias eficazes na segmentação de glomerulopatias, oferecendo uma base sólida para futuras pesquisas que busquem refinar ainda mais essas técnicas.

5.1 Trabalhos Futuros

A ampliação do conjunto de dados com mais imagens de cada classe poderia ajudar a equilibrar a representação das classes, reduzindo o impacto das classes menos representadas. A inclusão de mais exemplos diversificados garantiria que os modelos fossem treinados com uma variedade maior de padrões, melhorando sua capacidade de generalização e precisão.

Explorar arquiteturas de modelos mais avançadas ou híbridas, combinando as vantagens de diferentes encoders e decoders, pode levar a melhorias significativas. Novas arquiteturas podem ser capazes de capturar características mais complexas das imagens histológicas, resultando em uma segmentação mais precisa e robusta.

Realizar uma busca mais abrangente de hiperparâmetros, incluindo o ajuste fino de taxa de aprendizado (*learning rate*), tamanho do lote (*batch size*) e número de épocas, pode otimizar ainda mais o desempenho dos modelos. Pequenas variações nesses parâmetros podem ter um impacto considerável na qualidade dos resultados, permitindo uma adaptação mais precisa ao conjunto de dados específico.

Essas melhorias futuras têm o potencial de aumentar significativamente a precisão e a confiabilidade dos modelos de segmentação de glomerulopatias, contribuindo para avanços na análise histológica e no diagnóstico médico assistido por inteligência artificial. Com essas abordagens, espera-se obter resultados mais robustos e aplicáveis na prática clínica, beneficiando tanto a pesquisa quanto o tratamento de doenças renais.

Referências

- [1] Glasscock, Richard J: *Precision medicine for the treatment of glomerulonephritis: a bold goal but not yet a transformative achievement*. Clinical Kidney Journal, 15(4):657–662, dezembro 2021, ISSN 2048-8505. <https://doi.org/10.1093/ckj/sfab270>. 1
- [2] McGrath, Hari, Peichao Li, Reuben Dorent, Robert Bradford, Shakeel Saeed, Sotirios Bisdas, Sebastien Ourselin, Jonathan Shapey e Tom Vercauteren: *Manual segmentation versus semi-automated segmentation for quantifying vestibular schwannoma volume on mri*. International Journal of Computer Assisted Radiology and Surgery, 15, julho 2020. 1
- [3] Razzak, Muhammad, Saeeda Naz e Ahmad Zaib: *Deep learning for medical image processing: Overview, challenges and future*. abril 2017. 1
- [4] Krizhevsky, Alex, Ilya Sutskever e Geoffrey E Hinton: *Imagenet classification with deep convolutional neural networks*. Em Pereira, F., C.J. Burges, L. Bottou e K.Q. Weinberger (editores): *Advances in Neural Information Processing Systems*, volume 25. Curran Associates, Inc., 2012. https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf. 1, 6
- [5] Gurcan, Metin N., Laura E. Boucheron, Ali Can, Anant Madabhushi, Nasir M. Rajpoot e Bulent Yener: *Histopathological image analysis: A review*. IEEE Reviews in Biomedical Engineering, 2:147–171, 2009. 2
- [6] pathospotter. <https://pathospotter.bahia.fiocruz.br/>. 2
- [7] Patologia Clínica/Medicina Laboratorial, Sociedade Brasileira de: *Sbpc/ml mostra que patologistas clínicos são cada vez mais essenciais e contam as ações para seduzir estudantes de medicina e colegas de outras especialidades*. <https://www.sbpc.org.br/pt/noticias-e-eventos/noticias/1047-sbpc-ml-mostra-que-patologistas-clinicos-sao-cada-vez-mais-essenciais-e-cont> 2
- [8] Mahmoud, Amira, El Sayed El-Rabaie, Taha Taha, Adel El-Fishawy, O. Zahran e Fathi Abd El-Samie: *Medical image segmentation techniques, a literature review, and some novel trends*. Menoufia Journal of Electronic Engineering Research, 27:23–58, julho 2018. 5

- [9] Yamashita, Rikiya, Mizuho Nishio, Richard Do e Kaori Togashi: *Convolutional neural networks: an overview and application in radiology*. Insights into Imaging, 9, junho 2018. 7
- [10] Salas, Joaquin, Genevieve Patterson e Flavio de Barros Vidal: *A systematic mapping of artificial intelligence solutions for sustainability challenges in latin america and the caribbean*. IEEE Latin America Transactions, 20(11):2312–2329, 2022. 7
- [11] Rosa, Michel Junio Ferreira, Jefferson Chaves Gomes, Flávio de Barros Vidal, Marcus Vinicius Lamar, Carla Koike e Aleteia Araujo: *Faciem - microservice-based application for face recognition in mobile devices*. Em *2022 17th Iberian Conference on Information Systems and Technologies (CISTI)*, páginas 1–7, 2022. 7
- [12] Carvalho, Leonardo Rebouças de, Felipe LS Mendes, Jefferson Chaves, Marcos C Lima, Flavio Elias Gomes de Deus, Aletéia PF Araújo e Flavio de Barros Vidal: *Deep-vacuity: A proposal of a machine learning platform based on high-performance computing architecture for insights on government of brazil official gazettes*. Em *WEBIST*, páginas 136–143, 2022. 7
- [13] Yasrab, Robail: *Ecruc: An encoder-decoder based convolution neural network (cnn) for road-scene understanding*. Journal of Imaging, 4(10), 2018, ISSN 2313-433X. <https://www.mdpi.com/2313-433X/4/10/116>. 10
- [14] Ronneberger, Olaf, Philipp Fischer e Thomas Brox: *U-net: Convolutional networks for biomedical image segmentation*, 2015. 12
- [15] Zhou, Zongwei, Md Mahfuzur Rahman Siddiquee, Nima Tajbakhsh e Jianming Liang: *Unet++: A nested u-net architecture for medical image segmentation*, 2018. 12
- [16] Fan, Tongle, Guanglei Wang, Yan Li e Hongrui Wang: *Ma-net: A multi-scale attention network for liver and tumor segmentation*. IEEE Access, 8:179656–179665, 2020. 13
- [17] Chaurasia, Abhishek e Eugenio Culurciello: *Linknet: Exploiting encoder representations for efficient semantic segmentation*. Em *2017 IEEE Visual Communications and Image Processing (VCIP)*. IEEE, dezembro 2017. <http://dx.doi.org/10.1109/VCIP.2017.8305148>. 14
- [18] Zhao, Hengshuang, Jianping Shi, Xiaojuan Qi, Xiaogang Wang e Jiaya Jia: *Pyramid scene parsing network*, 2017. 16
- [19] Li, Hanchao, Pengfei Xiong, Jie An e Lingxue Wang: *Pyramid attention network for semantic segmentation*, 2018. 16
- [20] Chen, Liang Chieh, George Papandreou, Florian Schroff e Hartwig Adam: *Rethinking atrous convolution for semantic image segmentation*, 2017. 17
- [21] Chen, Liang Chieh, Yukun Zhu, George Papandreou, Florian Schroff e Hartwig Adam: *Encoder-decoder with atrous separable convolution for semantic image segmentation*, 2018. 18

- [22] He, Kaiming, Xiangyu Zhang, Shaoqing Ren e Jian Sun: *Deep residual learning for image recognition*, 2015. 19
- [23] Huang, Gao, Zhuang Liu, Laurens van der Maaten e Kilian Q. Weinberger: *Densely connected convolutional networks*, 2018. 19
- [24] Szegedy, Christian, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke e Andrew Rabinovich: *Going deeper with convolutions*, 2014. 19
- [25] Tan, Mingxing e Quoc V. Le: *Efficientnet: Rethinking model scaling for convolutional neural networks*, 2020. 20
- [26] Simonyan, Karen e Andrew Zisserman: *Very deep convolutional networks for large-scale image recognition*, 2015. 20
- [27] Radosavovic, Ilija, Raj Prateek Kosaraju, Ross Girshick, Kaiming He e Piotr Dollár: *Designing network design spaces*, 2020. 20
- [28] Yu, Xiaohan, Jun Wang, Yang Zhao e Yongsheng Gao: *Mix-vit: Mixing attentive vision transformer for ultra-fine-grained visual categorization*. *Pattern Recognition*, 135:109131, 2023, ISSN 0031-3203. <https://www.sciencedirect.com/science/article/pii/S0031320322006112>. 20

Anexo I

Resultados Completos

Anexo dos resultados

Arquitetura	MÉDIA		background		p		hipertrofia		degeneration		hiperplasia	
	IOU	F1	IOU	F1	IOU	F1	IOU	F1	IOU	F1	IOU	F1
DeepLabv3_efficientnet-b0_imagenet.pth	0.2534	0.2963	0.9171	0.9565	0.2135	0.3378	0	0	0	0	0.1362	0.187
DeepLabv3_efficientnet-b0_None.pth	0.2292	0.2672	0.8938	0.9435	0.1467	0.2411	0	0	0	0	0.1055	0.1513
DeepLabv3_efficientnet-b1_imagenet.pth	0.2573	0.3009	0.918	0.957	0.2244	0.3535	0	0	0	0	0.1439	0.1942
DeepLabv3_efficientnet-b1_None.pth	0.2262	0.2638	0.8898	0.9412	0.1394	0.2299	0	0	0	0	0.1018	0.1478
DeepLabv3_efficientnet-b2_imagenet.pth	0.2595	0.3029	0.9235	0.96	0.2233	0.3513	0	0	0	0	0.1509	0.2034
DeepLabv3_efficientnet-b2_None.pth	0.236	0.2748	0.9032	0.9488	0.164	0.2681	0	0	0	0	0.1126	0.1572
DeepLabv3_efficientnet-b3_imagenet.pth	0.2595	0.3028	0.9236	0.96	0.2275	0.3566	0	0	0	0	0.1466	0.1971
DeepLabv3_efficientnet-b3_None.pth	0.2309	0.268	0.902	0.9482	0.148	0.2436	0	0	0	0	0.1042	0.148
DeepLabv3_efficientnet-b4_imagenet.pth	0.2592	0.302	0.9245	0.9605	0.2263	0.3546	0	0	0	0	0.1452	0.1951
DeepLabv3_efficientnet-b4_None.pth	0.2356	0.2742	0.9067	0.9508	0.1613	0.2638	0	0	0	0	0.11	0.1563
DeepLabv3_efficientnet-b5_imagenet.pth	0.2615	0.3047	0.9259	0.9613	0.2301	0.3597	0	0	0	0	0.1516	0.2025
DeepLabv3_efficientnet-b5_None.pth	0.2462	0.2874	0.9124	0.9539	0.1882	0.3026	0	0	0	0	0.1304	0.1807
DeepLabv3_efficientnet-b6_imagenet.pth	0.2641	0.3078	0.9263	0.9615	0.2412	0.3744	0	0	0	0	0.1529	0.203
DeepLabv3_efficientnet-b6_None.pth	0.2462	0.2862	0.9172	0.9565	0.1804	0.2917	0	0	0	0	0.1334	0.1829
DeepLabv3_resnet101_imagenet.pth	0.2572	0.2988	0.9258	0.9612	0.2071	0.3286	0	0	0	0	0.1533	0.2044
DeepLabv3_resnet101_None.pth	0.2412	0.2793	0.9165	0.9561	0.1633	0.2671	0	0	0	0	0.1261	0.1735
DeepLabv3_resnet50_imagenet.pth	0.2587	0.3026	0.9182	0.9571	0.2251	0.3535	0	0	0	0	0.15	0.2026
DeepLabv3_resnet50_None.pth	0.2375	0.2753	0.9094	0.9522	0.1571	0.2566	0	0	0	0	0.1208	0.1678
DeepLabv3_timm-regnetx_064_imagenet.pth	0.2645	0.3076	0.9285	0.9627	0.2394	0.3701	0	0	0	0	0.1547	0.2052
DeepLabv3_timm-regnetx_064_None.pth	0.2461	0.2871	0.9146	0.9551	0.1818	0.2938	0	0	0	0	0.1342	0.1868
DeepLabv3_timm-regnetx_080_imagenet.pth	0.2584	0.3007	0.924	0.9602	0.2198	0.345	0	0	0	0	0.148	0.1981
DeepLabv3_timm-regnetx_080_None.pth	0.2447	0.2851	0.9145	0.9551	0.1806	0.293	0	0	0	0	0.1283	0.1775
DeepLabv3_timm-regnetx_120_imagenet.pth	0.2664	0.3097	0.9297	0.9633	0.247	0.3801	0	0	0	0	0.1553	0.2049
DeepLabv3_timm-regnetx_120_None.pth	0.2489	0.2898	0.9202	0.9582	0.1921	0.3096	0	0	0	0	0.1323	0.1814
DeepLabv3_timm-regnetx_320_imagenet.pth	0.2699	0.3135	0.9301	0.9635	0.2553	0.3903	0	0	0	0	0.1639	0.2137
DeepLabv3_timm-regnetx_320_None.pth	0.2488	0.2922	0.9071	0.951	0.2058	0.3285	0	0	0	0	0.1313	0.1815
DeepLabv3_timm-regnety_064_imagenet.pth	0.2662	0.3101	0.9287	0.9628	0.2439	0.3771	0	0	0	0	0.1585	0.2107
DeepLabv3_timm-regnety_064_None.pth	0.244	0.2834	0.9159	0.9558	0.1806	0.2918	0	0	0	0	0.1237	0.1696
DeepLabv3_timm-regnety_080_imagenet.pth	0.2676	0.3112	0.9294	0.9632	0.2516	0.3866	0	0	0	0	0.1568	0.2065
DeepLabv3_timm-regnety_080_None.pth	0.2428	0.2831	0.9101	0.9525	0.184	0.2962	0	0	0	0	0.1198	0.1667
DeepLabv3_timm-regnety_120_imagenet.pth	0.2691	0.3128	0.929	0.9629	0.2505	0.385	0	0	0	0	0.1657	0.2161
DeepLabv3_timm-regnety_120_None.pth	0.2478	0.2895	0.9154	0.9555	0.1968	0.3161	0	0	0	0	0.1268	0.1758
DeepLabv3_timm-regnety_320_imagenet.pth	0.2719	0.3155	0.9321	0.9646	0.2667	0.4042	0	0	0	0	0.1605	0.2089
DeepLabv3_timm-regnety_320_None.pth	0.2549	0.2965	0.9233	0.9598	0.2129	0.337	0	0	0	0	0.1382	0.1854
DeepLabv3+_efficientnet-b0_imagenet.pth	0.2607	0.3042	0.9215	0.9588	0.2369	0.3663	0	0	0	0	0.145	0.1958
DeepLabv3+_efficientnet-b0_None.pth	0.2466	0.2873	0.9154	0.9555	0.2073	0.3267	0	0	0	0	0.1102	0.1545
DeepLabv3+_efficientnet-b1_imagenet.pth	0.2685	0.313	0.9276	0.9622	0.2542	0.3897	0	0	0	0	0.1605	0.213
DeepLabv3+_efficientnet-b1_None.pth	0.2234	0.2577	0.9005	0.9472	0.2167	0.3411	0	0	0	0	0	0
DeepLabv3+_efficientnet-b2_imagenet.pth	0.2638	0.3082	0.9199	0.958	0.2479	0.3812	0	0	0	0	0.1511	0.202
DeepLabv3+_efficientnet-b2_None.pth	0.254	0.2957	0.9204	0.9582	0.2222	0.3471	0	0	0	0	0.1273	0.1734
DeepLabv3+_efficientnet-b3_imagenet.pth	0.2682	0.3119	0.9291	0.963	0.2569	0.3911	0	0	0	0	0.155	0.2054
DeepLabv3+_efficientnet-b3_None.pth	0.2539	0.2957	0.9184	0.9572	0.221	0.3438	0	0	0	0	0.1303	0.1774
DeepLabv3+_efficientnet-b4_imagenet.pth	0.2712	0.3153	0.9319	0.9645	0.265	0.4018	0	0	0	0	0.1591	0.2101
DeepLabv3+_efficientnet-b4_None.pth	0.258	0.3002	0.9236	0.96	0.2259	0.3514	0	0	0	0	0.1403	0.1895
DeepLabv3+_efficientnet-b5_imagenet.pth	0.2737	0.3178	0.9328	0.965	0.2816	0.4222	0	0	0	0	0.1539	0.2017
DeepLabv3+_efficientnet-b5_None.pth	0.2613	0.3044	0.9216	0.9589	0.2497	0.3814	0	0	0	0	0.1354	0.1818
DeepLabv3+_efficientnet-b6_imagenet.pth	0.2757	0.3203	0.9338	0.9655	0.2834	0.4241	0	0	0	0	0.1612	0.2119
DeepLabv3+_efficientnet-b6_None.pth	0.2361	0.2725	0.9118	0.9535	0.2689	0.4092	0	0	0	0	0	0
DeepLabv3+_resnet101_imagenet.pth	0.2653	0.3078	0.9287	0.9628	0.2411	0.3713	0	0	0	0	0.1564	0.2047
DeepLabv3+_resnet101_None.pth	0.2541	0.2976	0.9121	0.9537	0.2268	0.3527	0	0	0	0	0.1314	0.1817
DeepLabv3+_resnet50_imagenet.pth	0.2667	0.3094	0.9296	0.9633	0.2425	0.373	0	0	0	0	0.1616	0.211
DeepLabv3+_timm-regnetx_064_imagenet.pth	0.271	0.3139	0.9344	0.9659	0.262	0.3962	0	0	0	0	0.1587	0.2072
DeepLabv3+_timm-regnetx_064_None.pth	0.2499	0.2927	0.9119	0.9536	0.224	0.3513	0	0	0	0	0.1135	0.1586
DeepLabv3+_timm-regnetx_080_imagenet.pth	0.2661	0.3083	0.9319	0.9645	0.2395	0.3686	0	0	0	0	0.159	0.2085
DeepLabv3+_timm-regnetx_080_None.pth	0.2491	0.2906	0.9164	0.9561	0.2175	0.3421	0	0	0	0	0.1117	0.1549
DeepLabv3+_timm-regnetx_120_imagenet.pth	0.2712	0.3147	0.932	0.9645	0.2607	0.3951	0	0	0	0	0.1631	0.2139
DeepLabv3+_timm-regnetx_120_None.pth	0.2521	0.2941	0.9178	0.9568	0.2181	0.3419	0	0	0	0	0.1246	0.1719
DeepLabv3+_timm-regnetx_320_imagenet.pth	0.2726	0.3162	0.9327	0.9649	0.2754	0.414	0	0	0	0	0.1548	0.2019
DeepLabv3+_timm-regnetx_320_None.pth	0.2551	0.2989	0.9146	0.9551	0.2412	0.3737	0	0	0	0	0.12	0.166
DeepLabv3+_timm-regnety_064_imagenet.pth	0.2687	0.3117	0.9317	0.9644	0.2524	0.3849	0	0	0	0	0.1592	0.2092
DeepLabv3+_timm-regnety_064_None.pth	0.2527	0.2959	0.9135	0.9545	0.2335	0.3624	0	0	0	0	0.1166	0.1626
DeepLabv3+_timm-regnety_080_imagenet.pth	0.2729	0.3163	0.9328	0.965	0.2676	0.4035	0	0	0	0	0.1643	0.2132
DeepLabv3+_timm-regnety_080_None.pth	0.2503	0.2925	0.9109	0.953	0.2185	0.342	0	0	0	0	0.1219	0.1677
DeepLabv3+_timm-regnety_120_imagenet.pth	0.2738	0.3174	0.9338	0.9656	0.2654	0.401	0	0	0	0	0.1696	0.2204
DeepLabv3+_timm-regnety_120_None.pth	0.2598	0.3027	0.9236	0.96	0.2419	0.3736	0	0	0	0	0.1336	0.18
DeepLabv3+_timm-regnety_320_imagenet.pth	0.2754	0.3185	0.9357	0.9665	0.2769	0.4136	0	0	0	0	0.1644	0.2125

DeepLabv3+_timm-regnety_320_None.pth	0.2598	0.3036	0.9196	0.9578	0.2498	0.3847	0	0	0	0	0.1295	0.1757
FPN_efficientnet-b0_imagenet.pth	0.2638	0.3067	0.9255	0.961	0.2407	0.369	0	0	0	0	0.1527	0.2036
FPN_efficientnet-b0_None.pth	0.2165	0.2517	0.8818	0.9367	0.2005	0.3216	0	0	0	0	0	0
FPN_efficientnet-b1_imagenet.pth	0.2668	0.3111	0.9236	0.96	0.2553	0.3894	0	0	0	0	0.1549	0.206
FPN_efficientnet-b1_None.pth	0.2531	0.2944	0.921	0.9586	0.2121	0.3333	0	0	0	0	0.1322	0.1802
FPN_efficientnet-b2_imagenet.pth	0.2683	0.3128	0.9268	0.9617	0.2591	0.3963	0	0	0	0	0.1554	0.2058
FPN_efficientnet-b2_None.pth	0.2496	0.2898	0.9196	0.9578	0.2082	0.3273	0	0	0	0	0.12	0.164
FPN_efficientnet-b3_imagenet.pth	0.2703	0.3144	0.9298	0.9634	0.2602	0.3962	0	0	0	0	0.1614	0.2123
FPN_efficientnet-b3_None.pth	0.2219	0.2571	0.8927	0.9428	0.2169	0.3427	0	0	0	0	0	0
FPN_efficientnet-b4_imagenet.pth	0.2754	0.3208	0.9324	0.9648	0.2789	0.4219	0	0	0	0	0.1659	0.2173
FPN_efficientnet-b4_None.pth	0.2541	0.2955	0.9205	0.9583	0.2087	0.3287	0	0	0	0	0.1413	0.1903
FPN_efficientnet-b5_imagenet.pth	0.2359	0.2724	0.9107	0.9529	0.2688	0.409	0	0	0	0	0	0
FPN_efficientnet-b5_None.pth	0.2564	0.2976	0.9243	0.9604	0.2166	0.3387	0	0	0	0	0.1412	0.1892
FPN_efficientnet-b6_imagenet.pth	0.2753	0.3199	0.9338	0.9655	0.2832	0.4244	0	0	0	0	0.1595	0.2093
FPN_efficientnet-b6_None.pth	0.2602	0.3021	0.9262	0.9614	0.2335	0.3622	0	0	0	0	0.1416	0.1869
FPN_inceptionresnetv2_imagenet.pth	0.2635	0.3052	0.9287	0.9628	0.2394	0.3661	0	0	0	0	0.1493	0.1971
FPN_inceptionresnetv2_None.pth	0.256	0.2979	0.9209	0.9585	0.2232	0.3488	0	0	0	0	0.1358	0.1822
FPN_resnet101_imagenet.pth	0.2287	0.2639	0.9054	0.95	0.2383	0.3694	0	0	0	0	0	0
FPN_resnet101_None.pth	0.2535	0.2943	0.924	0.9602	0.2013	0.32	0	0	0	0	0.142	0.1911
FPN_resnet50_imagenet.pth	0.2691	0.3122	0.932	0.9646	0.2502	0.3835	0	0	0	0	0.1632	0.2131
FPN_resnet50_None.pth	0.25	0.2899	0.9228	0.9596	0.2015	0.3194	0	0	0	0	0.1257	0.1704
FPN_timm-regnetx_064_imagenet.pth	0.2338	0.27	0.9089	0.9519	0.2601	0.3979	0	0	0	0	0	0
FPN_timm-regnetx_064_None.pth	0.2175	0.2528	0.8837	0.9378	0.2037	0.3262	0	0	0	0	0	0
FPN_timm-regnetx_080_imagenet.pth	0.2324	0.2682	0.9092	0.9521	0.2529	0.3889	0	0	0	0	0	0
FPN_timm-regnetx_080_None.pth	0.2393	0.2786	0.9082	0.9516	0.188	0.299	0	0	0	0	0.1001	0.1426
FPN_timm-regnetx_120_imagenet.pth	0.2723	0.3161	0.933	0.9651	0.2728	0.4101	0	0	0	0	0.1558	0.205
FPN_timm-regnetx_120_None.pth	0.2443	0.2864	0.9053	0.95	0.2077	0.329	0	0	0	0	0.1085	0.1532
FPN_timm-regnetx_320_imagenet.pth	0.2728	0.3158	0.9342	0.9657	0.2731	0.409	0	0	0	0	0.1566	0.2044
FPN_timm-regnetx_320_None.pth	0.2501	0.2917	0.9162	0.956	0.2161	0.34	0	0	0	0	0.1181	0.1627
FPN_timm-regnety_064_imagenet.pth	0.275	0.319	0.9341	0.9657	0.2772	0.4155	0	0	0	0	0.1639	0.214
FPN_timm-regnety_064_None.pth	0.22	0.2554	0.8884	0.9405	0.2115	0.3366	0	0	0	0	0	0
FPN_timm-regnety_080_imagenet.pth	0.2756	0.3199	0.9336	0.9654	0.2851	0.4272	0	0	0	0	0.1595	0.207
FPN_timm-regnety_080_None.pth	0.2495	0.291	0.9166	0.9562	0.21	0.3329	0	0	0	0	0.1211	0.1662
FPN_timm-regnety_120_imagenet.pth	0.2771	0.3206	0.9346	0.966	0.2797	0.4162	0	0	0	0	0.171	0.2207
FPN_timm-regnety_120_None.pth	0.2542	0.2976	0.9143	0.9549	0.2319	0.3627	0	0	0	0	0.1249	0.1705
FPN_timm-regnety_320_imagenet.pth	0.2407	0.2764	0.919	0.9574	0.2845	0.4246	0	0	0	0	0	0
FPN_timm-regnety_320_None.pth	0.2636	0.3064	0.93	0.9635	0.2422	0.3735	0	0	0	0	0.1457	0.1952
Linknet_efficientnet-b0_imagenet.pth	0.2327	0.2684	0.9095	0.9522	0.2539	0.3898	0	0	0	0	0	0
Linknet_efficientnet-b0_None.pth	0.248	0.288	0.9164	0.9561	0.1971	0.31	0	0	0	0	0.1265	0.1739
Linknet_efficientnet-b1_imagenet.pth	0.2364	0.272	0.9142	0.9548	0.2676	0.4052	0	0	0	0	0	0
Linknet_efficientnet-b1_None.pth	0.2252	0.2595	0.9042	0.9493	0.2217	0.348	0	0	0	0	0	0
Linknet_efficientnet-b2_imagenet.pth	0.2666	0.3097	0.9285	0.9627	0.2499	0.3806	0	0	0	0	0.1544	0.2052
Linknet_efficientnet-b2_None.pth	0.227	0.2613	0.907	0.9509	0.2278	0.3558	0	0	0	0	0	0
Linknet_efficientnet-b3_imagenet.pth	0.2376	0.274	0.9142	0.9548	0.274	0.4152	0	0	0	0	0	0
Linknet_efficientnet-b3_None.pth	0.2264	0.2608	0.905	0.9498	0.2272	0.3543	0	0	0	0	0	0
Linknet_efficientnet-b4_imagenet.pth	0.2751	0.3198	0.9323	0.9647	0.2748	0.4131	0	0	0	0	0.1684	0.2211
Linknet_efficientnet-b4_None.pth	0.2268	0.2615	0.9047	0.9496	0.2293	0.3578	0	0	0	0	0	0
Linknet_efficientnet-b5_imagenet.pth	0.2408	0.2766	0.9196	0.9577	0.2846	0.4254	0	0	0	0	0	0
Linknet_efficientnet-b5_None.pth	0.2651	0.3079	0.9271	0.9619	0.2493	0.382	0	0	0	0	0.1493	0.1956
Linknet_efficientnet-b6_imagenet.pth	0.2769	0.3211	0.9347	0.966	0.285	0.4244	0	0	0	0	0.1648	0.2151
Linknet_efficientnet-b6_None.pth	0.2665	0.3099	0.9281	0.9624	0.2537	0.3874	0	0	0	0	0.1506	0.1994
Linknet_inceptionresnetv2_imagenet.pth	0.2684	0.3109	0.9312	0.9641	0.2643	0.3978	0	0	0	0	0.1463	0.1925
Linknet_inceptionresnetv2_None.pth	0.2679	0.3108	0.9306	0.9638	0.2543	0.3884	0	0	0	0	0.1545	0.202
Linknet_inceptionv4_imagenet.pth	0.2711	0.315	0.9321	0.9646	0.2766	0.417	0	0	0	0	0.1468	0.1936
Linknet_inceptionv4_None.pth	0.2697	0.3128	0.9319	0.9644	0.2623	0.3979	0	0	0	0	0.1541	0.2015
Linknet_resnet101_imagenet.pth	0.2698	0.3127	0.9315	0.9643	0.2584	0.3921	0	0	0	0	0.1589	0.2071
Linknet_resnet101_None.pth	0.2624	0.3045	0.9276	0.9622	0.2452	0.3758	0	0	0	0	0.1392	0.1845
Linknet_resnet50_imagenet.pth	0.2727	0.3162	0.9333	0.9652	0.2674	0.4026	0	0	0	0	0.1627	0.2132
Linknet_resnet50_None.pth	0.258	0.3002	0.9247	0.9606	0.2284	0.3561	0	0	0	0	0.137	0.1842
Linknet_timm-regnetx_064_imagenet.pth	0.273	0.3167	0.9329	0.965	0.2799	0.4183	0	0	0	0	0.1524	0.2002
Linknet_timm-regnetx_064_None.pth	0.2248	0.2608	0.8953	0.9444	0.2288	0.3597	0	0	0	0	0	0
Linknet_timm-regnetx_080_imagenet.pth	0.2713	0.3149	0.9314	0.9642	0.2649	0.3996	0	0	0	0	0.1604	0.2108
Linknet_timm-regnetx_080_None.pth	0.2502	0.2917	0.9185	0.9573	0.2053	0.3246	0	0	0	0	0.1273	0.1765
Linknet_timm-regnetx_120_imagenet.pth	0.2789	0.3235	0.9329	0.965	0.2926	0.432	0	0	0	0	0.1691	0.2206
Linknet_timm-regnetx_120_None.pth	0.2577	0.3011	0.9206	0.9584	0.2377	0.369	0	0	0	0	0.1302	0.1783
Linknet_timm-regnetx_320_imagenet.pth	0.2821	0.3262	0.9374	0.9674	0.3029	0.4458	0	0	0	0	0.1701	0.2178
Linknet_timm-regnetx_320_None.pth	0.2617	0.3052	0.925	0.9608	0.2491	0.3822	0	0	0	0	0.1343	0.1828
Linknet_timm-regnety_064_imagenet.pth	0.2795	0.3234	0.9364	0.9669	0.2919	0.4319	0	0	0	0	0.1693	0.2184
Linknet_timm-regnety_064_None.pth	0.2301	0.2662	0.9036	0.949	0.2471	0.3822	0	0	0	0	0	0
Linknet_timm-regnety_080_imagenet.pth	0.28	0.3238	0.937	0.9672	0.2978	0.439	0	0	0	0	0.1655	0.2128
Linknet_timm-regnety_080_None.pth	0.228	0.2645	0.8975	0.9456	0.2424	0.3768	0	0	0	0	0	0
Linknet_timm-regnety_120_imagenet.pth	0.2827	0.3271	0.9377	0.9676	0.3104	0.4547	0	0	0	0	0.1655	0.2129
Linknet_timm-regnety_120_None.pth	0.2606	0.303	0.9251	0.9608	0.2384	0.3662	0	0	0	0	0.1394	0.1877
Linknet_timm-regnety_320_imagenet.pth	0.2776	0.3222	0.9304	0.9637	0.2951	0.437	0	0	0	0	0.1625	0.2102
Linknet_timm-regnety_320_None.pth	0.2652	0.3097	0.9216	0.9589	0.2648	0.4029	0	0	0	0	0.1395	0.1868
Linknet_vgg19_imagenet.pth	0.2795	0.3243	0.9341	0.9657	0.3008	0.4435	0	0	0	0	0.1624	0.2122
Linknet_vgg19_None.pth	0.2723	0.3166	0.93	0.9635	0.2735	0.4102	0	0	0	0	0.1582	0.2096
Linknet_xception_imagenet.pth	0.2682	0.3119	0.9304	0.9637	0.2542	0.3884	0	0	0	0	0.1565	0.2075
Linknet_xception_None.pth	0.2256	0.262	0.8941	0.9437	0.234	0.3661	0	0	0	0	0	0
MAnet_densenet169_imagenet.pth	0.2767	0.3211	0.934	0.9656	0.2907	0.4322	0	0	0	0	0.1586	0.2077
MAnet_densenet169_None.pth	0.2359	0.272	0.912	0.9536	0.2673	0.4066	0	0	0	0	0	0
MAnet_densenet201_imagenet.pth	0.276	0.3203	0.9313	0.9642	0.29	0.4323	0	0	0	0	0.1584	0.2049
MAnet_densenet201_None.pth	0.2661	0.3095	0.9281	0.9624	0.2569	0.3889	0	0	0	0	0.1455	0.1962
MAnet_efficientnet-b0_imagenet.pth	0.2681	0.313	0.923	0.9597	0.2666	0.4049	0	0	0	0	0.1509	0.2005
MAnet_efficientnet-b0_None.pth	0.2612	0.3042	0.9252	0.9609	0.2478	0.3794	0	0	0	0	0.1331	0.1807
MAnet_efficientnet-b1_imagenet.pth	0.274	0.3187	0.9303	0.9636	0.2795	0.4193	0	0	0	0	0.1603	0.2103
MAnet_efficientnet-b1_None.pth	0.2656	0.3097	0.9279	0.9623	0.259	0.395	0	0	0	0	0.1413	0.1911
MAnet_efficientnet-b2_imagenet.pth	0.2743	0.3184	0.9319	0.9645	0.2853	0.4263	0	0	0	0	0.1542	0.201
MAnet_efficientnet-b2_None.pth	0.2644	0.3081	0.9239	0.9602	0.256	0.3899	0	0	0	0	0.1421	0.1905
MAnet_efficientnet-b3_imagenet.pth	0.236	0.2723	0.9106	0.9528	0.2695	0.4086	0	0	0	0	0	0
MAnet_efficientnet-b3_None.pth	0.2666	0.3107	0.9244	0.9605	0.268	0.406	0	0	0	0	0.1407	0.1869
MAnet_efficientnet-b4_imagenet.pth	0.2787	0.3233	0.9348	0.9661	0.2918	0.4337	0	0	0	0	0.1669	0.2168
MAnet_efficientnet-b4_None.pth	0.2659	0.3107	0.9245	0.9605	0.2693	0.4072	0	0	0	0	0.1359	0.1857
MAnet_efficientnet-b5_imagenet.pth	0.2791	0.3235	0.9345	0.9659	0.2907	0.4314	0	0	0	0	0.1703	0.2202
MAnet_efficientnet-b5_None.pth	0.271	0.3153	0.9296	0.9633	0.2762	0.4157	0	0	0	0	0.1491	0.1978
MAnet_efficient												

MAnet_mit_b4_None.pth	0.2678	0.3113	0.9296	0.9632	0.2561	0.3904	0	0	0	0	0.1533	0.2029
MAnet_mit_b5_imagenet.pth	0.2813	0.3257	0.9353	0.9663	0.2991	0.4422	0	0	0	0	0.1722	0.2199
MAnet_mit_b5_None.pth	0.266	0.3098	0.9259	0.9612	0.257	0.3917	0	0	0	0	0.1472	0.1961
MAnet_resnet101_imagenet.pth	0.2732	0.3174	0.9314	0.9642	0.2806	0.4195	0	0	0	0	0.1539	0.2033
MAnet_resnet101_None.pth	0.2651	0.3093	0.9267	0.9617	0.2526	0.3871	0	0	0	0	0.1462	0.1975
MAnet_resnet50_imagenet.pth	0.2707	0.3141	0.9292	0.963	0.279	0.4174	0	0	0	0	0.1456	0.1899
MAnet_resnet50_None.pth	0.2679	0.3129	0.9245	0.9605	0.2627	0.3993	0	0	0	0	0.1525	0.2047
MAnet_timm-regnetx_064_imagenet.pth	0.2737	0.3177	0.9303	0.9636	0.2893	0.43	0	0	0	0	0.1489	0.1949
MAnet_timm-regnetx_064_None.pth	0.2604	0.3042	0.9215	0.9589	0.2491	0.3826	0	0	0	0	0.1313	0.1794
MAnet_timm-regnetx_080_imagenet.pth	0.2734	0.317	0.932	0.9645	0.2733	0.4097	0	0	0	0	0.1617	0.211
MAnet_timm-regnetx_080_None.pth	0.2564	0.3001	0.9178	0.9568	0.2361	0.3651	0	0	0	0	0.1282	0.1783
MAnet_timm-regnetx_120_imagenet.pth	0.2743	0.3184	0.9316	0.9643	0.2854	0.4251	0	0	0	0	0.1544	0.2028
MAnet_timm-regnetx_120_None.pth	0.2626	0.3059	0.9251	0.9608	0.251	0.3834	0	0	0	0	0.1369	0.1855
MAnet_timm-regnetx_320_imagenet.pth	0.2784	0.3229	0.9357	0.9665	0.2966	0.4389	0	0	0	0	0.1598	0.2088
MAnet_timm-regnetx_320_None.pth	0.2619	0.3054	0.9237	0.9601	0.2476	0.3795	0	0	0	0	0.1381	0.1874
MAnet_timm-regnety_064_imagenet.pth	0.2792	0.3245	0.9315	0.9643	0.2967	0.441	0	0	0	0	0.168	0.217
MAnet_timm-regnety_064_None.pth	0.258	0.3022	0.9155	0.9556	0.2432	0.3751	0	0	0	0	0.1314	0.1804
MAnet_timm-regnety_080_imagenet.pth	0.281	0.3246	0.9367	0.967	0.2992	0.4401	0	0	0	0	0.1693	0.2157
MAnet_timm-regnety_080_None.pth	0.2558	0.2989	0.9182	0.957	0.2407	0.372	0	0	0	0	0.1201	0.1654
MAnet_timm-regnety_120_imagenet.pth	0.277	0.3221	0.9291	0.9629	0.2972	0.4408	0	0	0	0	0.1585	0.2066
MAnet_timm-regnety_120_None.pth	0.2616	0.3051	0.9239	0.9602	0.2546	0.3883	0	0	0	0	0.1294	0.177
MAnet_timm-regnety_320_imagenet.pth	0.2781	0.3227	0.9333	0.9653	0.3014	0.4447	0	0	0	0	0.1559	0.2037
MAnet_timm-regnety_320_None.pth	0.259	0.3031	0.9196	0.9578	0.2539	0.3903	0	0	0	0	0.1218	0.1673
MAnet_vgg19_imagenet.pth	0.2787	0.3231	0.9337	0.9654	0.3014	0.4421	0	0	0	0	0.1584	0.2079
MAnet_vgg19_None.pth	0.2751	0.3201	0.9321	0.9646	0.2895	0.4317	0	0	0	0	0.1539	0.2041
MAnet_xception_imagenet.pth	0.2726	0.3154	0.9346	0.9659	0.2753	0.4117	0	0	0	0	0.1531	0.1996
MAnet_xception_None.pth	0.2656	0.3101	0.924	0.9602	0.2696	0.4082	0	0	0	0	0.1343	0.1823
PAN_efficientnet-b0_imagenet.pth	0.2621	0.3059	0.9241	0.9603	0.2438	0.376	0	0	0	0	0.1423	0.1931
PAN_efficientnet-b0_None.pth	0.244	0.2828	0.9193	0.9577	0.1831	0.2933	0	0	0	0	0.1177	0.1628
PAN_efficientnet-b1_imagenet.pth	0.2666	0.3109	0.9271	0.9619	0.2526	0.3878	0	0	0	0	0.1533	0.205
PAN_efficientnet-b1_None.pth	0.2209	0.2546	0.8983	0.946	0.2062	0.3269	0	0	0	0	0	0
PAN_efficientnet-b2_imagenet.pth	0.2684	0.3125	0.9296	0.9633	0.2562	0.3922	0	0	0	0	0.156	0.207
PAN_efficientnet-b2_None.pth	0.2482	0.2885	0.9192	0.9576	0.199	0.3156	0	0	0	0	0.1229	0.1694
PAN_efficientnet-b3_imagenet.pth	0.2699	0.3147	0.9297	0.9633	0.2595	0.3971	0	0	0	0	0.1602	0.2131
PAN_efficientnet-b3_None.pth	0.2179	0.253	0.8866	0.9394	0.2031	0.3256	0	0	0	0	0	0
PAN_efficientnet-b4_imagenet.pth	0.2713	0.3166	0.9307	0.9639	0.2679	0.4088	0	0	0	0	0.1581	0.2104
PAN_efficientnet-b4_None.pth	0.2263	0.2618	0.9002	0.9471	0.2315	0.3619	0	0	0	0	0	0
PAN_efficientnet-b5_imagenet.pth	0.2721	0.3166	0.9325	0.9648	0.2713	0.4109	0	0	0	0	0.1567	0.2071
PAN_efficientnet-b5_None.pth	0.2272	0.2638	0.8962	0.9449	0.2396	0.3742	0	0	0	0	0	0
PAN_efficientnet-b6_imagenet.pth	0.2732	0.3175	0.9335	0.9653	0.2663	0.4032	0	0	0	0	0.1662	0.2188
PAN_efficientnet-b6_None.pth	0.2305	0.2666	0.9055	0.9501	0.2469	0.383	0	0	0	0	0	0
PAN_resnet101_imagenet.pth	0.2621	0.3043	0.9293	0.9631	0.227	0.3532	0	0	0	0	0.1544	0.2052
PAN_resnet101_None.pth	0.2472	0.2876	0.9129	0.9541	0.1991	0.3128	0	0	0	0	0.1241	0.1709
PAN_resnet50_imagenet.pth	0.2312	0.2671	0.9076	0.9512	0.2483	0.3841	0	0	0	0	0	0
PAN_resnet50_None.pth	0.2494	0.2912	0.914	0.9548	0.2037	0.3225	0	0	0	0	0.1292	0.1789
PAN_timm-regnetx_064_imagenet.pth	0.271	0.3148	0.932	0.9645	0.2611	0.398	0	0	0	0	0.1618	0.2113
PAN_timm-regnetx_064_None.pth	0.2402	0.2798	0.9109	0.953	0.1906	0.3028	0	0	0	0	0.0996	0.1431
PAN_timm-regnetx_080_imagenet.pth	0.2666	0.3096	0.9313	0.9642	0.2423	0.3732	0	0	0	0	0.1592	0.2108
PAN_timm-regnetx_080_None.pth	0.2421	0.2807	0.9177	0.9567	0.1836	0.2921	0	0	0	0	0.1091	0.1546
PAN_timm-regnetx_120_imagenet.pth	0.2721	0.3162	0.9323	0.9647	0.2704	0.4091	0	0	0	0	0.1576	0.2073
PAN_timm-regnetx_120_None.pth	0.2475	0.2882	0.9157	0.9557	0.2049	0.3241	0	0	0	0	0.1168	0.1611
PAN_timm-regnetx_320_imagenet.pth	0.2695	0.3131	0.9301	0.9635	0.2659	0.4017	0	0	0	0	0.1514	0.2003
PAN_timm-regnetx_320_None.pth	0.2492	0.2907	0.9172	0.9565	0.2066	0.3274	0	0	0	0	0.1222	0.1695
PAN_timm-regnety_064_imagenet.pth	0.2739	0.3183	0.9329	0.965	0.2721	0.4109	0	0	0	0	0.1645	0.2155
PAN_timm-regnety_064_None.pth	0.2392	0.2814	0.8928	0.9429	0.1961	0.3117	0	0	0	0	0.107	0.1522
PAN_timm-regnety_080_imagenet.pth	0.2733	0.3174	0.934	0.9657	0.273	0.4123	0	0	0	0	0.1596	0.2089
PAN_timm-regnety_080_None.pth	0.2468	0.2886	0.9097	0.9523	0.2064	0.3257	0	0	0	0	0.1177	0.165
PAN_timm-regnety_120_imagenet.pth	0.2842	0.3329	0.9361	0.9668	0.2761	0.4162	0	0	0.043	0.0654	0.1659	0.2161
PAN_timm-regnety_120_None.pth	0.2529	0.2965	0.9115	0.9534	0.2246	0.3519	0	0	0	0	0.1284	0.1771
PSPNet_efficientnet-b0_imagenet.pth	0.2497	0.2935	0.91	0.9525	0.2116	0.337	0	0	0	0	0.127	0.1782
PSPNet_efficientnet-b0_None.pth	0.2156	0.2513	0.8786	0.9348	0.1993	0.3217	0	0	0	0	0	0
PSPNet_efficientnet-b1_imagenet.pth	0.2579	0.3036	0.9134	0.9544	0.2375	0.3726	0	0	0	0	0.1386	0.1911
PSPNet_efficientnet-b1_None.pth	0.2173	0.2528	0.8844	0.9382	0.2022	0.3257	0	0	0	0	0	0
PSPNet_efficientnet-b2_imagenet.pth	0.2243	0.2614	0.8908	0.9419	0.2305	0.3653	0	0	0	0	0	0
PSPNet_efficientnet-b2_None.pth	0.2155	0.2519	0.876	0.9335	0.2014	0.326	0	0	0	0	0	0
PSPNet_efficientnet-b3_imagenet.pth	0.2569	0.3021	0.9138	0.9547	0.2338	0.3675	0	0	0	0	0.1368	0.1884
PSPNet_efficientnet-b3_None.pth	0.2172	0.2525	0.8852	0.9387	0.2009	0.3238	0	0	0	0	0	0
PSPNet_efficientnet-b4_imagenet.pth	0.2267	0.2633	0.8975	0.9456	0.2362	0.3711	0	0	0	0	0	0
PSPNet_efficientnet-b4_None.pth	0.2166	0.2526	0.8803	0.9359	0.2029	0.3272	0	0	0	0	0	0
PSPNet_efficientnet-b5_imagenet.pth	0.2641	0.3083	0.9242	0.9604	0.2465	0.3807	0	0	0	0	0.15	0.2003
PSPNet_efficientnet-b5_None.pth	0.2196	0.255	0.8907	0.9418	0.2073	0.3332	0	0	0	0	0	0
PSPNet_efficientnet-b6_imagenet.pth	0.2293	0.2664	0.9001	0.9471	0.2463	0.3847	0	0	0	0	0	0
PSPNet_efficientnet-b6_None.pth	0.2541	0.2966	0.9196	0.9578	0.208	0.331	0	0	0	0	0.1428	0.1941
PSPNet_inceptionresnetv2_imagenet.pth	0.255	0.2968	0.9225	0.9594	0.2054	0.3268	0	0	0	0	0.1473	0.1978
PSPNet_inceptionresnetv2_None.pth	0.253	0.2943	0.9222	0.9592	0.2025	0.324	0	0	0	0	0.1402	0.1884
PSPNet_inceptionv4_imagenet.pth	0.2557	0.2977	0.9239	0.9602	0.2147	0.3392	0	0	0	0	0.1399	0.1891
PSPNet_inceptionv4_None.pth	0.2516	0.2941	0.917	0.9564	0.2105	0.3344	0	0	0	0	0.1306	0.1798
PSPNet_resnet101_imagenet.pth	0.2543	0.2959	0.923	0.9597	0.2098	0.3308	0	0	0	0	0.1386	0.189
PSPNet_resnet101_None.pth	0.2134	0.2497	0.8717	0.931	0.1955	0.3176	0	0	0	0	0	0
PSPNet_resnet50_imagenet.pth	0.2587	0.3023	0.9212	0.9587	0.2293	0.3594	0	0	0	0	0.1433	0.1936
PSPNet_resnet50_None.pth	0.2487	0.2908	0.9136	0.9545	0.2018	0.3223	0	0	0	0	0.128	0.1774
PSPNet_timm-regnetx_064_imagenet.pth	0.2612	0.3044	0.9255	0.961	0.233	0.3628	0	0	0	0	0.1475	0.198
PSPNet_timm-regnetx_064_None.pth	0.2414	0.2824	0.9081	0.9515	0.1843	0.2978	0	0	0	0	0.1148	0.1624
PSPNet_timm-regnetx_080_imagenet.pth	0.2566	0.2992	0.9242	0.9603	0.2232	0.3506	0	0	0	0	0.1355	0.1849
PSPNet_timm-regnetx_080_None.pth	0.2404	0.2809	0.9065	0.9507	0.1795	0.292	0	0	0	0	0.1159	0.1618
PSPNet_timm-regnetx_120_imagenet.pth	0.2637	0.308	0.9256	0.9611	0.2452	0.3797	0	0	0	0	0.1477	0.199
PSPNet_timm-regnetx_120_None.pth	0.2406	0.2824	0.9017	0.9479	0.1892	0.3062	0	0	0	0	0.1121	0.1577
PSPNet_timm-regnetx_320_imagenet.pth	0.2659	0.3091	0.9296	0.9633	0.2478	0.3815	0	0	0	0	0.1521	0.201
PSPNet_timm-regnetx_320_None.pth	0.2467	0.2879	0.9165	0.9562	0.1943	0.3134	0	0	0	0	0.1226	0.1701
PSPNet_timm-regnety_064_imagenet.pth	0.2631	0.3066	0.928	0.9624	0.2421	0.3758	0	0	0	0	0.1454	0.195
PSPNet_timm-regnety_064_None.pth	0.2469	0.2879	0.9161	0.9559	0.1948	0.3114	0	0	0	0	0.1234	0.172
PSPNet_timm-regnety_080_imagenet.pth	0.2675	0.3126	0.9279	0.9624	0.2563	0.3948	0	0	0	0	0.1533	0.206
PSPNet_timm-regnety_080_None.pth	0.2499	0.2908	0.921	0.9586	0.1964	0.314	0	0	0	0	0.1321	0.1816
PSPNet_timm-regnety_120_imagenet.pth	0.266	0.3094	0.9306	0.9638	0.2468	0.3804	0	0	0	0	0.1526	0.2026
PSPNet_timm-regnety_120_None.pth	0.2495	0.291</										

Unet_efficientnet-b1_imagenet.pth	0.2743	0.3189	0.9307	0.9638	0.2836	0.4241	0	0	0	0	0.1572	0.2067
Unet_efficientnet-b1_None.pth	0.2606	0.3042	0.9207	0.9584	0.255	0.3893	0	0	0	0	0.1271	0.173
Unet_efficientnet-b2_imagenet.pth	0.2735	0.3177	0.9325	0.9648	0.2849	0.4256	0	0	0	0	0.15	0.1983
Unet_efficientnet-b2_None.pth	0.2613	0.3036	0.9266	0.9616	0.2439	0.3737	0	0	0	0	0.136	0.1829
Unet_efficientnet-b3_imagenet.pth	0.2762	0.3208	0.932	0.9645	0.2858	0.4268	0	0	0	0	0.1633	0.2126
Unet_efficientnet-b3_None.pth	0.2657	0.3093	0.9275	0.9621	0.2624	0.3976	0	0	0	0	0.1386	0.1867
Unet_efficientnet-b4_imagenet.pth	0.2784	0.3231	0.9347	0.966	0.2898	0.4316	0	0	0	0	0.1675	0.2179
Unet_efficientnet-b4_None.pth	0.2707	0.3145	0.9299	0.9634	0.2724	0.4096	0	0	0	0	0.1514	0.1993
Unet_efficientnet-b5_imagenet.pth	0.2762	0.3202	0.9359	0.9667	0.2899	0.4305	0	0	0	0	0.155	0.204
Unet_efficientnet-b5_None.pth	0.2702	0.314	0.9303	0.9636	0.2721	0.4112	0	0	0	0	0.1485	0.1951
Unet_efficientnet-b6_imagenet.pth	0.2806	0.325	0.9375	0.9675	0.2945	0.4357	0	0	0	0	0.1708	0.2216
Unet_efficientnet-b6_None.pth	0.2703	0.3137	0.93	0.9635	0.2723	0.4105	0	0	0	0	0.1491	0.1946
Unet_inceptionresnetv2_imagenet.pth	0.2695	0.3119	0.933	0.9651	0.2714	0.4069	0	0	0	0	0.1429	0.1873
Unet_inceptionresnetv2_None.pth	0.2694	0.3131	0.9312	0.9641	0.2601	0.3955	0	0	0	0	0.1556	0.2061
Unet_inceptionv4_imagenet.pth	0.2716	0.3149	0.9334	0.9653	0.2775	0.4157	0	0	0	0	0.147	0.1933
Unet_inceptionv4_None.pth	0.2723	0.3172	0.9277	0.9622	0.2786	0.4187	0	0	0	0	0.1552	0.2052
Unet_mit_b1_imagenet.pth	0.2788	0.3234	0.935	0.9662	0.2929	0.4346	0	0	0	0	0.1661	0.2161
Unet_mit_b1_None.pth	0.2625	0.3071	0.9198	0.9579	0.2519	0.3868	0	0	0	0	0.141	0.1908
Unet_mit_b2_imagenet.pth	0.2807	0.325	0.9368	0.9671	0.3042	0.4483	0	0	0	0	0.1624	0.2096
Unet_mit_b2_None.pth	0.2642	0.3073	0.9237	0.9601	0.2484	0.3806	0	0	0	0	0.1489	0.1958
Unet_mit_b3_imagenet.pth	0.2797	0.3238	0.9364	0.9669	0.29	0.4303	0	0	0	0	0.1721	0.2217
Unet_mit_b3_None.pth	0.283	0.3275	0.9376	0.9675	0.3079	0.453	0	0	0	0	0.1694	0.2171
Unet_mit_b4_imagenet.pth	0.264	0.3076	0.9227	0.9595	0.2629	0.4008	0	0	0	0	0.1344	0.1777
Unet_mit_b4_None.pth	0.2745	0.3189	0.9304	0.9637	0.2841	0.4245	0	0	0	0	0.1582	0.2063
Unet_mit_b5_imagenet.pth	0.2686	0.3124	0.9285	0.9627	0.26	0.3958	0	0	0	0	0.1543	0.2033
Unet_mit_b5_None.pth	0.2725	0.316	0.9345	0.9659	0.2646	0.3994	0	0	0	0	0.1635	0.2146
Unet_resnet101_imagenet.pth	0.2653	0.3092	0.9237	0.9601	0.2594	0.3946	0	0	0	0	0.1436	0.1914
Unet_resnet101_None.pth	0.2741	0.3179	0.9322	0.9647	0.2765	0.4137	0	0	0	0	0.1617	0.2112
Unet_resnet50_imagenet.pth	0.2616	0.3056	0.9207	0.9584	0.2505	0.3841	0	0	0	0	0.1369	0.1854
Unet_resnet50_None.pth	0.2775	0.3211	0.936	0.9667	0.2912	0.4313	0	0	0	0	0.1601	0.2073
Unet_timm-regnetx_064_imagenet.pth	0.2546	0.2966	0.9229	0.9597	0.2319	0.3616	0	0	0	0	0.1182	0.1616
Unet_timm-regnetx_064_None.pth	0.273	0.3162	0.934	0.9656	0.2696	0.4042	0	0	0	0	0.1615	0.2113
Unet_timm-regnetx_080_imagenet.pth	0.2486	0.29	0.917	0.9564	0.2147	0.3364	0	0	0	0	0.1114	0.1573
Unet_timm-regnetx_080_None.pth	0.2774	0.3211	0.9364	0.9669	0.2888	0.4278	0	0	0	0	0.1618	0.2107
Unet_timm-regnetx_120_imagenet.pth	0.2548	0.2965	0.9248	0.9607	0.2418	0.3737	0	0	0	0	0.1076	0.148
Unet_timm-regnetx_120_None.pth	0.2813	0.3255	0.9354	0.9663	0.3003	0.4429	0	0	0	0	0.1709	0.2182
Unet_timm-regnetx_320_imagenet.pth	0.2603	0.3035	0.9258	0.9612	0.2494	0.3821	0	0	0	0	0.1264	0.1741
Unet_timm-regnetx_320_None.pth	0.2798	0.3235	0.938	0.9677	0.2938	0.4331	0	0	0	0	0.1671	0.2167
Unet_timm-regnety_064_imagenet.pth	0.2572	0.3006	0.9207	0.9584	0.238	0.3684	0	0	0	0	0.1275	0.176
Unet_timm-regnety_064_None.pth	0.281	0.3251	0.936	0.9667	0.2981	0.4393	0	0	0	0	0.1706	0.2196
Unet_timm-regnety_080_imagenet.pth	0.2593	0.302	0.9259	0.9613	0.2349	0.3634	0	0	0	0	0.136	0.1856
Unet_timm-regnety_080_None.pth	0.282	0.3257	0.9378	0.9677	0.3	0.4409	0	0	0	0	0.1722	0.22
Unet_timm-regnety_120_imagenet.pth	0.2615	0.3039	0.9294	0.9631	0.2461	0.379	0	0	0	0	0.1319	0.1776
Unet_timm-regnety_120_None.pth	0.2828	0.3272	0.9364	0.9669	0.3083	0.4513	0	0	0	0	0.1696	0.2178
Unet_timm-regnety_320_imagenet.pth	0.2612	0.3056	0.9204	0.9583	0.2599	0.3983	0	0	0	0	0.1258	0.1713
Unet_timm-regnety_320_None.pth	0.2766	0.3224	0.9267	0.9617	0.2967	0.4418	0	0	0	0	0.1596	0.2086
Unet_vgg19_imagenet.pth	0.2767	0.3216	0.931	0.964	0.2919	0.4349	0	0	0	0	0.1605	0.2093
Unet_vgg19_None.pth	0.2737	0.3177	0.9336	0.9654	0.2814	0.4216	0	0	0	0	0.1533	0.2015
Unet_xception_imagenet.pth	0.2618	0.3048	0.9242	0.9604	0.2533	0.3854	0	0	0	0	0.1314	0.1781
Unet_xception_None.pth	0.2736	0.3186	0.9277	0.9622	0.2783	0.4176	0	0	0	0	0.1619	0.2132
Unet++_efficientnet-b0_imagenet.pth	0.2638	0.3069	0.9257	0.9611	0.2705	0.4077	0	0	0	0	0.123	0.1655
Unet++_efficientnet-b0_None.pth	0.2771	0.3216	0.9351	0.9662	0.2921	0.4337	0	0	0	0	0.1582	0.2083
Unet++_efficientnet-b1_imagenet.pth	0.2646	0.3074	0.9284	0.9626	0.2659	0.4014	0	0	0	0	0.1289	0.173
Unet++_efficientnet-b1_None.pth	0.2777	0.3226	0.9333	0.9652	0.2963	0.4383	0	0	0	0	0.159	0.2096
Unet++_efficientnet-b2_imagenet.pth	0.2677	0.3109	0.9297	0.9633	0.2655	0.3998	0	0	0	0	0.143	0.1912
Unet++_efficientnet-b2_None.pth	0.2814	0.3263	0.9358	0.9666	0.3002	0.4429	0	0	0	0	0.1709	0.2221
Unet++_efficientnet-b3_imagenet.pth	0.2709	0.316	0.9251	0.9608	0.2843	0.4262	0	0	0	0	0.1453	0.1928
Unet++_efficientnet-b3_None.pth	0.2788	0.3242	0.9316	0.9643	0.3002	0.4451	0	0	0	0	0.162	0.2115
Unet++_efficientnet-b4_imagenet.pth	0.2696	0.3139	0.927	0.9618	0.2782	0.4171	0	0	0	0	0.1426	0.1904
Unet++_efficientnet-b4_None.pth	0.2802	0.3248	0.9352	0.9663	0.2983	0.4407	0	0	0	0	0.1674	0.2171
Unet++_efficientnet-b5_imagenet.pth	0.2725	0.3161	0.9334	0.9653	0.2759	0.4133	0	0	0	0	0.1531	0.2018
Unet++_efficientnet-b5_None.pth	0.2815	0.3262	0.9361	0.9667	0.312	0.4565	0	0	0	0	0.1593	0.2076
Unet++_efficientnet-b6_imagenet.pth	0.2746	0.3193	0.932	0.9645	0.2925	0.4356	0	0	0	0	0.1486	0.1961
Unet++_efficientnet-b6_None.pth	0.273	0.3155	0.9326	0.9649	0.2741	0.4086	0	0	0	0	0.1583	0.2039
Unet++_inceptionresnetv2_imagenet.pth	0.2686	0.3138	0.9192	0.9576	0.2741	0.4147	0	0	0	0	0.1497	0.1969
Unet++_inceptionresnetv2_None.pth	0.2748	0.3193	0.9321	0.9646	0.2947	0.4378	0	0	0	0	0.1475	0.1941
Unet++_inceptionv4_imagenet.pth	0.2758	0.3201	0.9337	0.9655	0.2844	0.4247	0	0	0	0	0.1609	0.2102
Unet++_inceptionv4_None.pth	0.2762	0.3201	0.9334	0.9653	0.285	0.4246	0	0	0	0	0.1625	0.2104
Unet++_resnet101_imagenet.pth	0.2658	0.3099	0.9266	0.9616	0.2689	0.4065	0	0	0	0	0.1337	0.1815
Unet++_resnet101_None.pth	0.2764	0.3203	0.9335	0.9653	0.2926	0.4334	0	0	0	0	0.1559	0.2027
Unet++_resnet50_imagenet.pth	0.2691	0.3126	0.9287	0.9628	0.2752	0.4131	0	0	0	0	0.1416	0.1874
Unet++_resnet50_None.pth	0.2956	0.3453	0.9395	0.9686	0.2958	0.4374	0.076	0.1069	0	0	0.1666	0.2138
Unet++_timm-regnetx_064_imagenet.pth	0.2602	0.3027	0.9276	0.9622	0.247	0.3794	0	0	0	0	0.1265	0.1722
Unet++_timm-regnetx_064_None.pth	0.2783	0.322	0.9359	0.9666	0.2859	0.4235	0	0	0	0	0.1695	0.2201
Unet++_timm-regnetx_080_imagenet.pth	0.2563	0.2979	0.9249	0.9607	0.2517	0.3856	0	0	0	0	0.1049	0.1433
Unet++_timm-regnetx_080_None.pth	0.2781	0.3215	0.9368	0.9671	0.2901	0.4293	0	0	0	0	0.1633	0.2111
Unet++_timm-regnetx_120_imagenet.pth	0.2339	0.2699	0.9101	0.9526	0.2594	0.397	0	0	0	0	0	0
Unet++_timm-regnetx_120_None.pth	0.279	0.3222	0.9382	0.9679	0.2948	0.4348	0	0	0	0	0.1622	0.2085
Unet++_timm-regnetx_320_imagenet.pth	0.2635	0.3068	0.9278	0.9623	0.2601	0.3951	0	0	0	0	0.1293	0.1768
Unet++_timm-regnetx_320_None.pth	0.2818	0.3261	0.9364	0.9669	0.3027	0.4456	0	0	0	0	0.1698	0.2179
Unet++_timm-regnety_064_imagenet.pth	0.2648	0.3093	0.9247	0.9606	0.269	0.4084	0	0	0	0	0.1301	0.1773
Unet++_timm-regnety_064_None.pth	0.284	0.3289	0.9378	0.9676	0.3125	0.4579	0	0	0	0	0.1699	0.2189
Unet++_timm-regnety_080_imagenet.pth	0.2588	0.3025	0.9178	0.9569	0.2551	0.3918	0	0	0	0	0.1209	0.164
Unet++_timm-regnety_080_None.pth	0.297	0.3454	0.9416	0.9697	0.3039	0.4453	0.0624	0.0861	0	0	0.177	0.226
Unet++_timm-regnety_120_imagenet.pth	0.2616	0.3041	0.9272	0.9619	0.2547	0.3884	0	0	0	0	0.1262	0.1701
Unet++_timm-regnety_120_None.pth	0.3003	0.3497	0.9429	0.9704	0.307	0.4479	0.0797	0.1093	0	0	0.1721	0.2207
Unet++_timm-regnety_320_imagenet.pth	0.2687	0.3119	0.9311	0.964	0.279	0.4187	0	0	0	0	0.1334	0.1768
Unet++_timm-regnety_320_None.pth	0.2829	0.328	0.9356	0.9665	0.3134	0.4595	0	0	0	0	0.1655	0.2137
Unet++_vgg19_imagenet.pth	0.2732	0.3183	0.9288	0.9628	0.2965	0.4413	0	0	0	0	0.1405	0.1876
Unet++_vgg19_None.pth	0.2745	0.3185	0.9337	0.9654	0.2874	0.4282	0	0	0	0	0.1516	0.1986
Unet++_xception_imagenet.pth	0.2689	0.3123	0.9315	0.9643	0.275	0.4143	0	0	0	0	0.1383	0.1829
Unet++_xception_None.pth												

MODELOS	MÉDIA		_background_		p		hipertrofia		degeneration		hiperplasia	
	IOU	F1	IOU	F1</								

Linknet_inceptionresnetv2_None.pth	0.2232	0.2581	0.8981	0.9459	0.2181	0.3445	0	0	0	0	0	0	0	0
Linknet_inceptionv4_imagenet.pth	0.2521	0.2938	0.9241	0.9603	0.2258	0.3551	0	0	0	0	0	0	0.1105	0.1536
Linknet_inceptionv4_None.pth	0.2312	0.2663	0.9125	0.9539	0.2435	0.3775	0	0	0	0	0	0	0	0
Linknet_resnet101_imagenet.pth	0.052	0.0893	0.1255	0.2193	0.0851	0.1519	0	0	0.0066	0.0127	0.0426	0.0626	0	0
Linknet_resnet101_None.pth	0.2156	0.2468	0.8985	0.9461	0.1795	0.2878	0	0	0	0	0	0	0	0
Linknet_resnet50_imagenet.pth	0.2194	0.2529	0.8925	0.9426	0.2048	0.3217	0	0	0	0	0	0	0	0
Linknet_resnet50_None.pth	0.2153	0.2495	0.8827	0.9369	0.1936	0.3107	0	0	0	0	0	0	0	0
Linknet_timm-regnetx_064_imagenet.pth	0.2378	0.2779	0.91	0.9526	0.2268	0.3517	0	0	0.0522	0.0853	0	0	0	0
Linknet_timm-regnetx_064_None.pth	0.2107	0.2411	0.8961	0.9445	0.1573	0.2608	0	0	0	0	0	0	0	0
Linknet_timm-regnetx_080_imagenet.pth	0.0095	0.0179	0	0	0.0474	0.0894	0	0	0	0	0	0	0	0
Linknet_timm-regnetx_080_None.pth	0.1962	0.2274	0.854	0.9198	0.1271	0.2171	0	0	0	0	0	0	0	0
Linknet_timm-regnetx_120_imagenet.pth	0.2339	0.2675	0.9245	0.9603	0.2451	0.3772	0	0	0	0	0	0	0	0
Linknet_timm-regnetx_120_None.pth	0.211	0.2454	0.8723	0.9307	0.1829	0.2963	0	0	0	0	0	0	0	0
Linknet_timm-regnetx_320_imagenet.pth	0.2294	0.2625	0.916	0.9558	0.2309	0.3568	0	0	0	0	0	0	0	0
Linknet_timm-regnetx_320_None.pth	0.2177	0.2515	0.893	0.943	0.1955	0.3146	0	0	0	0	0	0	0	0
Linknet_timm-regnety_064_imagenet.pth	0.2298	0.2624	0.9221	0.9591	0.2267	0.3529	0	0	0	0	0	0	0	0
Linknet_timm-regnety_064_None.pth	0.2146	0.2478	0.8886	0.9406	0.1845	0.2984	0	0	0	0	0	0	0	0
Linknet_timm-regnety_080_imagenet.pth	0.2306	0.2648	0.9122	0.9537	0.2409	0.3705	0	0	0	0	0	0	0	0
Linknet_timm-regnety_080_None.pth	0.2151	0.2477	0.8946	0.944	0.1812	0.2945	0	0	0	0	0	0	0	0
Linknet_timm-regnety_120_imagenet.pth	0.0784	0.1139	0.3236	0.4467	0.0438	0.0786	0	0	0	0	0.0245	0.0444	0	0
Linknet_timm-regnety_120_None.pth	0.2087	0.2404	0.8821	0.9365	0.1614	0.2654	0	0	0	0	0	0	0	0
Linknet_timm-regnety_320_imagenet.pth	0.2367	0.2711	0.9221	0.9591	0.2614	0.3963	0	0	0	0	0	0	0	0
Linknet_timm-regnety_320_None.pth	0.2204	0.254	0.898	0.9459	0.2039	0.3241	0	0	0	0	0	0	0	0
Linknet_vgg19_imagenet.pth	0.2403	0.275	0.9258	0.9611	0.2758	0.4137	0	0	0	0	0	0	0	0
Linknet_vgg19_None.pth	0.2179	0.2533	0.8828	0.9373	0.2065	0.3291	0	0	0	0	0	0	0	0
Linknet_xception_imagenet.pth	0.2503	0.2949	0.9128	0.9541	0.1768	0.289	0.0441	0.0646	0.0272	0.0427	0.0908	0.124	0	0
Linknet_xception_None.pth	0.2185	0.2504	0.9019	0.948	0.1904	0.304	0	0	0	0	0	0	0	0
MAnet_densenet169_imagenet.pth	0.2314	0.2645	0.9209	0.9585	0.2362	0.3639	0	0	0	0	0	0	0	0
MAnet_densenet169_None.pth	0.2249	0.2576	0.9095	0.9522	0.215	0.3357	0	0	0	0	0	0	0	0
MAnet_densenet201_imagenet.pth	0.2366	0.2726	0.9169	0.9563	0.2663	0.4065	0	0	0	0	0	0	0	0
MAnet_densenet201_None.pth	0.2162	0.2466	0.9081	0.9515	0.173	0.2816	0	0	0	0	0	0	0	0
MAnet_efficientnet-b0_imagenet.pth	0.2001	0.2462	0.7692	0.8636	0.1372	0.2317	0.0378	0.0569	0	0	0.0565	0.079	0	0
MAnet_efficientnet-b0_None.pth	0.2182	0.2514	0.8968	0.9452	0.1942	0.312	0	0	0	0	0	0	0	0
MAnet_efficientnet-b1_imagenet.pth	0.2166	0.2477	0.9041	0.9492	0.1789	0.289	0	0	0	0	0	0	0	0
MAnet_efficientnet-b2_imagenet.pth	0.2407	0.2836	0.8857	0.9387	0.192	0.3043	0	0	0	0	0.1257	0.1752	0	0
MAnet_efficientnet-b2_None.pth	0.2194	0.2507	0.9073	0.951	0.1898	0.3024	0	0	0	0	0	0	0	0
MAnet_efficientnet-b3_imagenet.pth	0.2159	0.2472	0.8934	0.943	0.0998	0.1648	0.0321	0.0477	0	0	0.0541	0.0803	0	0
MAnet_efficientnet-b3_None.pth	0.2217	0.2553	0.8972	0.9453	0.2112	0.331	0	0	0	0	0	0	0	0
MAnet_efficientnet-b4_imagenet.pth	0.2281	0.2694	0.8755	0.9323	0.1626	0.2673	0.0245	0.0368	0	0	0.0779	0.1104	0	0
MAnet_efficientnet-b4_None.pth	0.2216	0.2541	0.9035	0.9487	0.2044	0.3217	0	0	0	0	0	0	0	0
MAnet_efficientnet-b5_imagenet.pth	0.2105	0.2411	0.8673	0.9254	0.1112	0.1762	0	0	0	0	0.0739	0.1039	0	0
MAnet_efficientnet-b5_None.pth	0.2238	0.2555	0.9117	0.9534	0.2073	0.3239	0	0	0	0	0	0	0	0
MAnet_efficientnet-b6_imagenet.pth	0.23	0.2733	0.8566	0.9211	0.2071	0.3259	0	0	0	0	0.0865	0.1196	0	0
MAnet_efficientnet-b6_None.pth	0.2256	0.2605	0.8992	0.9463	0.2291	0.3561	0	0	0	0	0	0	0	0
MAnet_inceptionresnetv2_imagenet.pth	0.2346	0.2686	0.9194	0.9577	0.2535	0.3852	0	0	0	0	0	0	0	0
MAnet_inceptionresnetv2_None.pth	0.2338	0.2688	0.915	0.9553	0.2542	0.3888	0	0	0	0	0	0	0	0
MAnet_inceptionv4_imagenet.pth	0.251	0.2927	0.9186	0.9573	0.2341	0.3611	0	0	0	0	0.1025	0.1449	0	0
MAnet_inceptionv4_None.pth	0.2271	0.2592	0.9173	0.9564	0.2182	0.3397	0	0	0	0	0	0	0	0
MAnet_mit_b1_imagenet.pth	0.2412	0.2768	0.9251	0.9607	0.2811	0.4235	0	0	0	0	0	0	0	0
MAnet_mit_b1_None.pth	0.2259	0.2611	0.9008	0.9474	0.2286	0.3583	0	0	0	0	0	0	0	0
MAnet_mit_b2_imagenet.pth	0.241	0.2776	0.9183	0.957	0.2866	0.4312	0	0	0	0	0	0	0	0
MAnet_mit_b2_None.pth	0.2274	0.2613	0.9107	0.9529	0.2265	0.3537	0	0	0	0	0	0	0	0
MAnet_mit_b3_imagenet.pth	0.2435	0.2794	0.9245	0.9603	0.2929	0.4364	0	0	0	0	0	0	0	0
MAnet_mit_b3_None.pth	0.2292	0.2629	0.9127	0.954	0.2331	0.3602	0	0	0	0	0	0	0	0
MAnet_mit_b4_imagenet.pth	0.2483	0.2895	0.9179	0.9569	0.2239	0.3541	0	0	0	0	0.0999	0.1367	0	0
MAnet_mit_b4_None.pth	0.2239	0.2555	0.9158	0.9557	0.2037	0.322	0	0	0	0	0	0	0	0
MAnet_mit_b5_imagenet.pth	0.2459	0.2869	0.9152	0.9554	0.2174	0.3436	0	0	0	0	0.0971	0.1357	0	0
MAnet_mit_b5_None.pth	0.2229	0.2546	0.9128	0.9541	0.2017	0.3188	0	0	0	0	0	0	0	0
MAnet_resnet101_imagenet.pth	0.2228	0.2571	0.8964	0.9448	0.1777	0.3408	0	0	0	0	0	0	0	0
MAnet_resnet101_None.pth	0.2154	0.2447	0.9068	0.9507	0.1703	0.2728	0	0	0	0	0	0	0	0
MAnet_resnet50_imagenet.pth	0.2231	0.2596	0.8845	0.9381	0.2311	0.3597	0	0	0	0	0	0	0	0
MAnet_resnet50_None.pth	0.2216	0.2536	0.9086	0.9517	0.1992	0.3163	0	0	0	0	0	0	0	0
MAnet_timm-regnetx_064_imagenet.pth	0.2347	0.269	0.9191	0.9575	0.2544	0.3877	0	0	0	0	0	0	0	0
MAnet_timm-regnetx_064_None.pth	0.2172	0.2498	0.8963	0.9449	0.1895	0.3043	0	0	0	0	0	0	0	0
MAnet_timm-regnetx_080_imagenet.pth	0.2293	0.2618	0.9152	0.9554	0.2311	0.3538	0	0	0	0	0	0	0	0
MAnet_timm-regnetx_080_None.pth	0.2127	0.2447	0.8913	0.9419	0.1724	0.2817	0	0	0	0	0	0	0	0
MAnet_timm-regnetx_120_imagenet.pth	0.2209	0.2512	0.9117	0.9534	0.1926	0.3025	0	0	0	0	0	0	0	0
MAnet_timm-regnetx_120_None.pth	0.2188	0.251	0.9039	0.9491	0.1902	0.3059	0	0	0	0	0	0	0	0
MAnet_timm-regnetx_320_imagenet.pth	0.2243	0.2583	0.9041	0.9493	0.2176	0.3423	0	0	0	0	0	0	0	0
MAnet_timm-regnetx_320_None.pth	0.2216	0.2544	0.9069	0.9508	0.2012	0.3212	0	0	0	0	0	0	0	0
MAnet_timm-regnety_064_imagenet.pth	0.2231	0.2558	0.9035	0.9489	0.2122	0.3301	0	0	0	0	0	0	0	0
MAnet_timm-regnety_064_None.pth	0.2102	0.2396	0.8993	0.9465	0.1515	0.2516	0	0	0	0	0	0	0	0
MAnet_timm-regnety_080_imagenet.pth	0.2334	0.2683	0.9122	0.9537	0.2549	0.3875	0	0	0	0	0	0	0	0
MAnet_timm-regnety_080_None.pth	0.2165	0.2496	0.892	0.9425	0.1904	0.3055	0	0	0	0	0	0	0	0
MAnet_timm-regnety_120_imagenet.pth	0.229	0.2629	0.9116	0.9534	0.2335	0.3614	0	0	0	0	0	0	0	0
MAnet_timm-regnety_120_None.pth	0.2142	0.2468	0.8913	0.942	0.1797	0.2922	0	0	0	0	0	0	0	0
MAnet_timm-regnety_320_imagenet.pth	0.2272	0.259	0.9195	0.9577	0.2167	0.3373	0	0	0	0	0	0	0	0
MAnet_timm-regnety_320_None.pth	0.2136	0.247	0.8856	0.9389	0.1825	0.2962	0	0	0	0	0	0	0	0
MAnet_vgg19_imagenet.pth	0.2427	0.2786	0.9222	0.9591	0.2913	0.4338	0	0	0	0	0	0	0	0
MAnet_vgg19_None.pth	0.2314	0.2647	0.9208	0.9584	0.2361	0.3649	0	0	0	0	0	0	0	0
MAnet_xception_imagenet.pth	0.241	0.2821	0.8998	0.9466	0.2115	0.3318	0	0	0	0	0.0938	0.1323	0	0
MAnet_xception_None.pth	0.227	0.2604	0.912	0.9536	0.2233	0.3483	0	0	0	0	0	0	0	0
PAN_efficientnet-b0_imagenet.pth	0.243	0.2844	0.9059	0.9502	0.1946	0.3131	0	0	0	0	0.1146	0.1588	0	0
PAN_efficientnet-b0_None.pth	0.2073	0.2387	0.8806	0.9359	0.156	0.2578	0	0	0	0	0	0	0	0
PAN_efficientnet-b1_imagenet.pth	0.2329	0.2698	0.909	0.952	0.1407	0.232	0.0387	0.0573	0	0	0.0761	0.1079	0	0
PAN_efficientnet-b1_None.pth	0.2054	0.2382	0.8699	0.9297	0.1569	0.2615	0	0	0	0	0	0	0	0
PAN_efficientnet-b2_imagenet.pth	0.0327	0.0494	0	0	0.047	0.0886	0	0	0	0	0.1163	0.1586	0	0
PAN_efficientnet-b2_None.pth	0.0228	0.041	0	0	0.0882	0.159	0	0	0.0026	0.0051	0.0233	0.0407	0	0
PAN_efficientnet-b3_imagenet.pth	0.2358	0.2756	0.8964	0.9449	0.1872	0.2985	0	0	0	0	0.0954	0.1344	0	0
PAN_efficientnet-b3_None.pth	0.0095	0.0179	0	0	0.0474	0.0894	0	0	0	0	0	0	0	0

PAN_timm-regnetx_320_None.pth	0.2098	0.2456	0.8634	0.9261	0.1855	0.3021	0	0	0	0	0	0	0	0	0	0	0	0	0
PAN_timm-regnety_064_imagenet.pth	0.251	0.2922	0.9197	0.9579	0.2186	0.3432	0	0	0	0	0	0	0	0	0	0	0	0.1166	0.16
PAN_timm-regnety_064_None.pth	0.2065	0.2399	0.8687	0.9291	0.1638	0.2702	0	0	0	0	0	0	0	0	0	0	0	0	0
PAN_timm-regnety_080_imagenet.pth	0.2568	0.3033	0.909	0.9519	0.2137	0.3391	0.0522	0.0751	0	0	0	0	0	0	0	0	0	0.1092	0.1506
PAN_timm-regnety_080_None.pth	0.2084	0.2411	0.8774	0.9341	0.1644	0.2714	0	0	0	0	0	0	0	0	0	0	0	0	0
PAN_timm-regnety_120_imagenet.pth	0.2593	0.3031	0.9201	0.9581	0.2486	0.3852	0	0	0	0	0	0	0	0	0	0	0	0.1278	0.1724
PAN_timm-regnety_120_None.pth	0.2082	0.2377	0.8911	0.9419	0.1498	0.2466	0	0	0	0	0	0	0	0	0	0	0	0	0
PAN_timm-regnety_320_imagenet.pth	0.2323	0.2668	0.9181	0.957	0.2434	0.3772	0	0	0	0	0	0	0	0	0	0	0	0	0
PAN_timm-regnety_320_None.pth	0.2166	0.2479	0.9042	0.9493	0.1787	0.2902	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b0_imagenet.pth	0.1977	0.2205	0.8919	0.9422	0.0965	0.1604	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b0_None.pth	0.0095	0.0179	0	0	0.0474	0.0894	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b1_imagenet.pth	0.0095	0.0179	0	0	0.0474	0.0894	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b2_imagenet.pth	0.0116	0.0213	0	0	0.0473	0.0892	0	0	0.0105	0.0172	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b2_None.pth	0.0095	0.0179	0	0	0.0474	0.0894	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b3_imagenet.pth	0.2037	0.2275	0.9046	0.9495	0.1141	0.1882	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b3_None.pth	0.1836	0.1914	0.9179	0.9568	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b4_imagenet.pth	0.0236	0.041	0	0	0.0988	0.1695	0	0	0	0	0	0	0	0	0	0	0	0.0191	0.0356
PSPNet_efficientnet-b4_None.pth	0.2051	0.2392	0.8616	0.9247	0.1639	0.2714	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b5_imagenet.pth	0.0095	0.0179	0	0	0.0474	0.0894	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b5_None.pth	0.0095	0.0179	0	0	0.0474	0.0894	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_efficientnet-b6_imagenet.pth	0.2214	0.2521	0.9051	0.9498	0.1494	0.2399	0	0	0	0	0	0	0	0	0	0	0	0.0525	0.0706
PSPNet_efficientnet-b6_None.pth	0.2119	0.244	0.89	0.9414	0.1697	0.2784	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_inceptionresnetv2_imagenet.pth	0.2372	0.2764	0.9113	0.9533	0.1794	0.2944	0	0	0	0	0	0	0	0	0	0	0	0.0952	0.1342
PSPNet_inceptionresnetv2_None.pth	0.2065	0.2353	0.8933	0.9431	0.1394	0.2333	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_inceptionv4_imagenet.pth	0.0549	0.0872	0	0	0.181	0.2985	0	0	0.0062	0.0121	0	0	0	0	0	0	0	0.0874	0.1256
PSPNet_inceptionv4_None.pth	0.2131	0.2443	0.8987	0.9462	0.1671	0.2755	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_resnet101_imagenet.pth	0.2123	0.2406	0.9086	0.9517	0.1527	0.2511	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_resnet101_None.pth	0.2084	0.2377	0.8952	0.9443	0.1466	0.2444	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_resnet50_imagenet.pth	0.2327	0.2691	0.9133	0.9543	0.1614	0.2636	0	0	0	0	0	0	0	0	0	0	0	0.089	0.1278
PSPNet_resnet50_None.pth	0.2072	0.2387	0.8824	0.937	0.1535	0.2565	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnetx_064_imagenet.pth	0.2379	0.2756	0.9186	0.9573	0.1771	0.2869	0	0	0	0	0	0	0	0	0	0	0	0.0938	0.1337
PSPNet_timm-regnetx_064_None.pth	0.2017	0.2282	0.8929	0.9429	0.1158	0.1981	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnetx_080_imagenet.pth	0.2327	0.2684	0.9172	0.9565	0.1773	0.2852	0	0	0	0	0	0	0	0	0	0	0	0.0689	0.1002
PSPNet_timm-regnetx_080_None.pth	0.2024	0.2282	0.8976	0.9456	0.1145	0.1954	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnetx_120_imagenet.pth	0.2304	0.2681	0.9011	0.9475	0.1938	0.3126	0	0	0	0	0	0	0	0	0	0	0	0.0571	0.0804
PSPNet_timm-regnetx_120_None.pth	0.2011	0.2276	0.892	0.9424	0.1136	0.1957	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnetx_320_imagenet.pth	0.2263	0.2594	0.9129	0.9541	0.2186	0.3426	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnetx_320_None.pth	0.1836	0.1914	0.9179	0.9568	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnety_064_imagenet.pth	0.2481	0.2906	0.9115	0.9534	0.211	0.3373	0	0	0	0	0	0	0	0	0	0	0	0.1178	0.1622
PSPNet_timm-regnety_064_None.pth	0.1836	0.1914	0.9179	0.9568	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnety_080_imagenet.pth	0.2517	0.2944	0.9159	0.9558	0.2135	0.3403	0	0	0	0	0	0	0	0	0	0	0	0.1288	0.1758
PSPNet_timm-regnety_080_None.pth	0.2015	0.2243	0.9054	0.9499	0.1022	0.1715	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnety_120_imagenet.pth	0.2391	0.2769	0.9168	0.9562	0.1821	0.2955	0	0	0	0	0	0	0	0	0	0	0	0.0965	0.1326
PSPNet_timm-regnety_120_None.pth	0.2079	0.2392	0.8838	0.9379	0.1557	0.2581	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnety_320_imagenet.pth	0.227	0.26	0.9157	0.9556	0.2191	0.3446	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_timm-regnety_320_None.pth	0.1836	0.1914	0.9179	0.9568	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_vgg19_imagenet.pth	0.2281	0.2625	0.9134	0.9544	0.2272	0.3579	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_vgg19_None.pth	0.2126	0.2432	0.8958	0.9447	0.1672	0.2714	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_xception_imagenet.pth	0.2134	0.2468	0.8863	0.9392	0.181	0.2949	0	0	0	0	0	0	0	0	0	0	0	0	0
PSPNet_xception_None.pth	0.2107	0.2428	0.8885	0.9405	0.1649	0.2735	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_densenet169_imagenet.pth	0.2352	0.2707	0.9155	0.9556	0.2606	0.3981	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_densenet169_None.pth	0.2116	0.245	0.8812	0.9363	0.1766	0.2885	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_densenet201_imagenet.pth	0.233	0.2685	0.9117	0.9534	0.2533	0.3893	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_densenet201_None.pth	0.2108	0.2389	0.9003	0.947	0.1538	0.2475	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_efficientnet-b0_imagenet.pth	0.2401	0.2842	0.8892	0.9408	0.1589	0.2633	0.0322	0.0472	0.0266	0.0404	0	0	0	0	0	0	0	0.0935	0.1292
Unet_efficientnet-b0_None.pth	0.2138	0.2444	0.903	0.9484	0.1251	0.2116	0	0	0	0	0	0	0	0	0	0	0	0.0408	0.0623
Unet_efficientnet-b1_imagenet.pth	0.2294	0.2754	0.8501	0.9172	0.147	0.245	0.0368	0.0529	0.023	0.0351	0	0	0	0	0	0	0	0.0901	0.1271
Unet_efficientnet-b1_None.pth	0.2051	0.2276	0.9083	0.9515	0.1173	0.1863	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_efficientnet-b2_imagenet.pth	0.2541	0.2971	0.9116	0.9534	0.2413	0.374	0	0	0	0	0	0	0	0	0	0	0	0.1174	0.1582
Unet_efficientnet-b2_None.pth	0.2166	0.2465	0.9115	0.9533	0.1717	0.2791	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_efficientnet-b3_imagenet.pth	0.2301	0.2641	0.9089	0.9518	0.149	0.2392	0.0394	0.0581	0	0	0	0	0	0	0	0	0	0.053	0.0713
Unet_efficientnet-b4_imagenet.pth	0.2382	0.2772	0.9058	0.9501	0.1679	0.2728	0.0336	0.0474	0	0	0	0	0	0	0	0	0	0.0838	0.1155
Unet_efficientnet-b4_None.pth	0.2195	0.2522	0.9023	0.9482	0.1951	0.313	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_efficientnet-b5_imagenet.pth	0.2259	0.2571	0.9088	0.9518	0.1448	0.226	0	0	0	0	0	0	0	0	0	0	0	0.0758	0.1076
Unet_efficientnet-b5_None.pth	0.2247	0.2597	0.8999	0.9468	0.2238	0.3518	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_efficientnet-b6_imagenet.pth	0.2339	0.2715	0.9002	0.9466	0.1714	0.2722	0.0398	0.059	0	0	0	0	0	0	0	0	0	0.0582	0.0799
Unet_efficientnet-b6_None.pth	0.2151	0.2497	0.8773	0.9331	0.1984	0.3155	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_inceptionresnetv2_imagenet.pth	0.2425	0.2857	0.8935	0.9429	0.2221	0.3481	0	0	0	0	0	0	0	0	0	0	0	0.0971	0.1373
Unet_inceptionresnetv2_None.pth	0.2298	0.2632	0.9155	0.9555	0.2336	0.3604	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_inceptionv4_imagenet.pth	0.256	0.2989	0.918	0.9569	0.2517	0.3884	0	0	0	0	0	0	0	0	0	0	0	0.1105	0.149
Unet_inceptionv4_None.pth	0.2297	0.2638	0.9132	0.9542	0.2356	0.3648	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_mit_b1_imagenet.pth	0.2396	0.2753	0.9224	0.9593	0.2754	0.4172	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_mit_b1_None.pth	0.2242	0.2586	0.9025	0.9484	0.2184	0.3445	0	0	0	0	0	0	0	0	0	0	0	0	0
Unet_mit_b2_imagenet.pth	0.2386	0.2754	0.9128	0.9541	0.28	0.4228	0	0	0	0									

Unet++_efficientnet-b1_imagenet.pth	0.2448	0.2875	0.9092	0.952	0.1851	0.2962	0.0218	0.0342	0.0252	0.0389	0.0828	0.1162
Unet++_efficientnet-b1_None.pth	0.2212	0.2537	0.9047	0.9495	0.2013	0.3188	0	0	0	0	0	0
Unet++_efficientnet-b2_imagenet.pth	0.2472	0.292	0.8985	0.9458	0.1969	0.3157	0.0408	0.0602	0	0	0.0999	0.1381
Unet++_efficientnet-b2_None.pth	0.2269	0.2599	0.9134	0.9544	0.2212	0.3451	0	0	0	0	0	0
Unet++_efficientnet-b3_imagenet.pth	0.2171	0.2445	0.9116	0.9533	0.1084	0.1765	0.0242	0.0367	0	0	0.0414	0.0558
Unet++_efficientnet-b4_imagenet.pth	0.226	0.2551	0.9205	0.9582	0.1356	0.2189	0.0241	0.0328	0	0	0.0499	0.0658
Unet++_efficientnet-b4_None.pth	0.2235	0.2558	0.9097	0.9524	0.2076	0.3268	0	0	0	0	0	0
Unet++_efficientnet-b5_imagenet.pth	0.2188	0.2513	0.8816	0.9335	0.1166	0.1863	0.034	0.0485	0	0	0.0617	0.0883
Unet++_efficientnet-b5_None.pth	0.2256	0.2574	0.9142	0.9548	0.2135	0.332	0	0	0	0	0	0
Unet++_efficientnet-b6_imagenet.pth	0.2362	0.2759	0.8883	0.9401	0.1845	0.2886	0.0423	0.0607	0	0	0.0657	0.0901
Unet++_efficientnet-b6_None.pth	0.2245	0.2563	0.9131	0.9542	0.2095	0.3272	0	0	0	0	0	0
Unet++_inceptionresnetv2_imagenet.pth	0.2512	0.2921	0.923	0.9596	0.2327	0.3578	0	0	0	0	0.1004	0.1429
Unet++_inceptionresnetv2_None.pth	0.2305	0.2651	0.9111	0.9531	0.2415	0.3725	0	0	0	0	0	0
Unet++_inceptionv4_imagenet.pth	0.2607	0.3031	0.9262	0.9614	0.2594	0.3953	0	0	0	0	0.1178	0.1588
Unet++_inceptionv4_None.pth	0.2345	0.2695	0.9158	0.9557	0.2568	0.3917	0	0	0	0	0	0
Unet++_resnet101_imagenet.pth	0.2191	0.2494	0.901	0.9442	0.1926	0.299	0	0	0	0	0.002	0.0037
Unet++_resnet101_None.pth	0.2139	0.2462	0.8882	0.9402	0.1811	0.2908	0	0	0	0	0	0
Unet++_resnet50_imagenet.pth	0.2316	0.2649	0.9175	0.9566	0.2407	0.3678	0	0	0	0	0	0
Unet++_resnet50_None.pth	0.2207	0.2531	0.9019	0.948	0.2015	0.3175	0	0	0	0	0	0
Unet++_timm-regnetx_064_imagenet.pth	0.2336	0.268	0.9149	0.9552	0.2529	0.3848	0	0	0	0	0	0
Unet++_timm-regnetx_064_None.pth	0.2141	0.2466	0.8907	0.9416	0.1795	0.2915	0	0	0	0	0	0
Unet++_timm-regnetx_080_imagenet.pth	0.2106	0.2331	0.9177	0.9567	0.1355	0.209	0	0	0	0	0	0
Unet++_timm-regnetx_080_None.pth	0.2009	0.2388	0.8252	0.9021	0.1793	0.2919	0	0	0	0	0	0
Unet++_timm-regnetx_120_imagenet.pth	0.238	0.2726	0.9201	0.958	0.2698	0.405	0	0	0	0	0	0
Unet++_timm-regnetx_120_None.pth	0.2157	0.2476	0.8968	0.9451	0.1815	0.2931	0	0	0	0	0	0
Unet++_timm-regnetx_320_imagenet.pth	0.2362	0.2706	0.9211	0.9586	0.26	0.3945	0	0	0	0	0	0
Unet++_timm-regnetx_320_None.pth	0.2233	0.2558	0.9097	0.9523	0.2069	0.3268	0	0	0	0	0	0
Unet++_timm-regnety_064_imagenet.pth	0.2337	0.2672	0.919	0.9574	0.2493	0.3788	0	0	0	0	0	0
Unet++_timm-regnety_064_None.pth	0.2075	0.2423	0.8626	0.9253	0.1747	0.2863	0	0	0	0	0	0
Unet++_timm-regnety_080_imagenet.pth	0.2346	0.2702	0.9108	0.953	0.2621	0.398	0	0	0	0	0	0
Unet++_timm-regnety_080_None.pth	0.2141	0.244	0.9053	0.9499	0.1653	0.2701	0	0	0	0	0	0
Unet++_timm-regnety_120_imagenet.pth	0.2368	0.2713	0.9205	0.9583	0.2635	0.3983	0	0	0	0	0	0
Unet++_timm-regnety_120_None.pth	0.2065	0.2376	0.8818	0.9366	0.1508	0.2512	0	0	0	0	0	0
Unet++_timm-regnety_320_imagenet.pth	0.2356	0.2683	0.9234	0.9598	0.2546	0.3819	0	0	0	0	0	0
Unet++_timm-regnety_320_None.pth	0.2095	0.2348	0.912	0.9536	0.1354	0.2206	0	0	0	0	0	0
Unet++_vgg19_imagenet.pth	0.2436	0.2797	0.9225	0.9593	0.2956	0.4395	0	0	0	0	0	0
Unet++_vgg19_None.pth	0.2244	0.2537	0.922	0.959	0.2001	0.3094	0	0	0	0	0	0
Unet++_xception_imagenet.pth	0.243	0.2796	0.9234	0.9598	0.1733	0.2718	0	0	0	0	0.1183	0.1662
Unet++_xception_None.pth	0.2206	0.255	0.8928	0.9429	0.2102	0.3324	0	0	0	0	0	0