

基于人工智能的乳腺癌诊断

Breast Cancer Diagnosis Based on Artificial
Intelligence with Mammography

刘逸博

2019/5/21

目录

- 课题的研究背景和意义
- 乳腺钼靶影像及其数字处理任务
- 基于人工智能的乳腺癌诊断综述
- 基于Unet+CNN的实验
- 基于Mask R-CNN的实验

课题的研究背景和意义

- 乳腺癌发病率高、有增长趋势、危害性大
- 没有预防手段，早期检测需求大

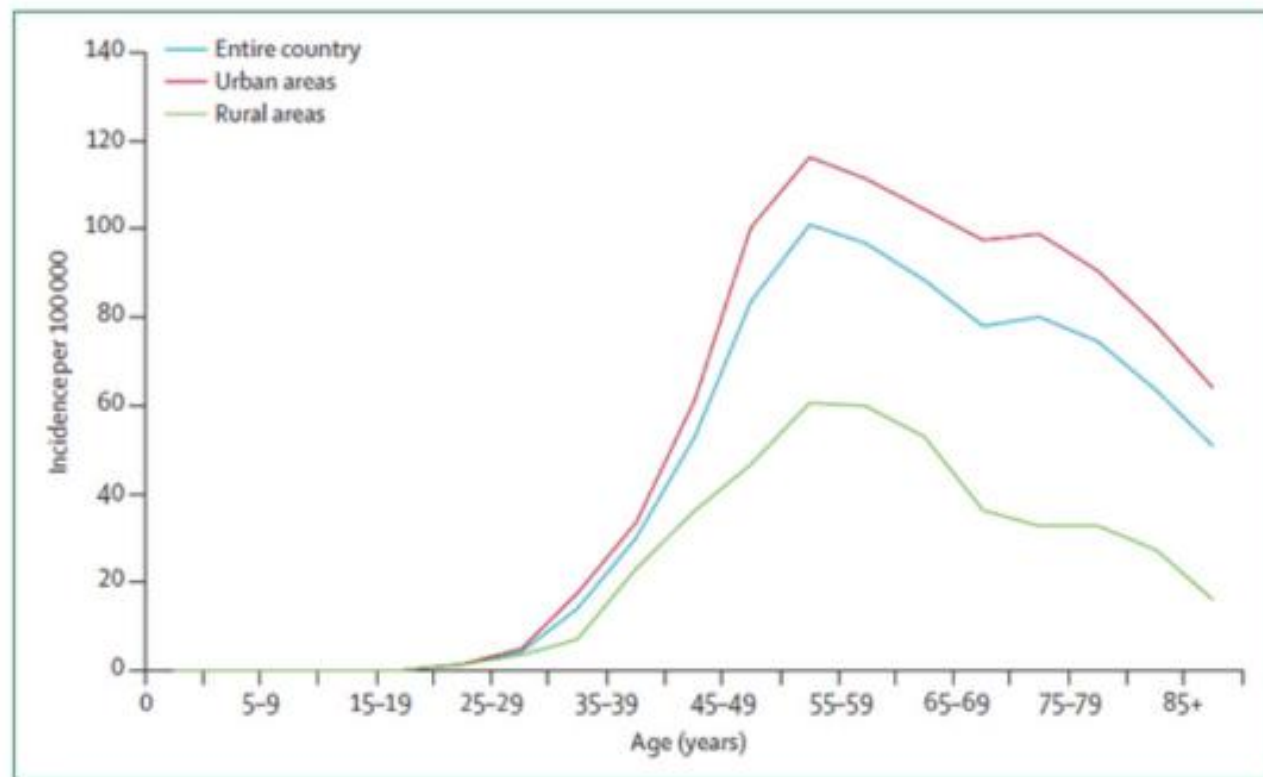




图 1-1 乳腺癌不同年龄段和不同地区发病率

□ 乳腺钼靶影像及其数字处理任务

乳腺钼靶摄片示例



不同体态的摄片



数据集中对应的
肿块标记

病理分析

可能出现的异常类型：

- 肿块（主要研究对象）
- 钙化
- 结构紊乱




图 2-2 病灶分类示例

（从左到右三幅图分别为恶性肿块、良性钙化、恶性钙化）

任务描述

- 肿块检测
- 肿块良恶性判断
- 肿块边缘分割




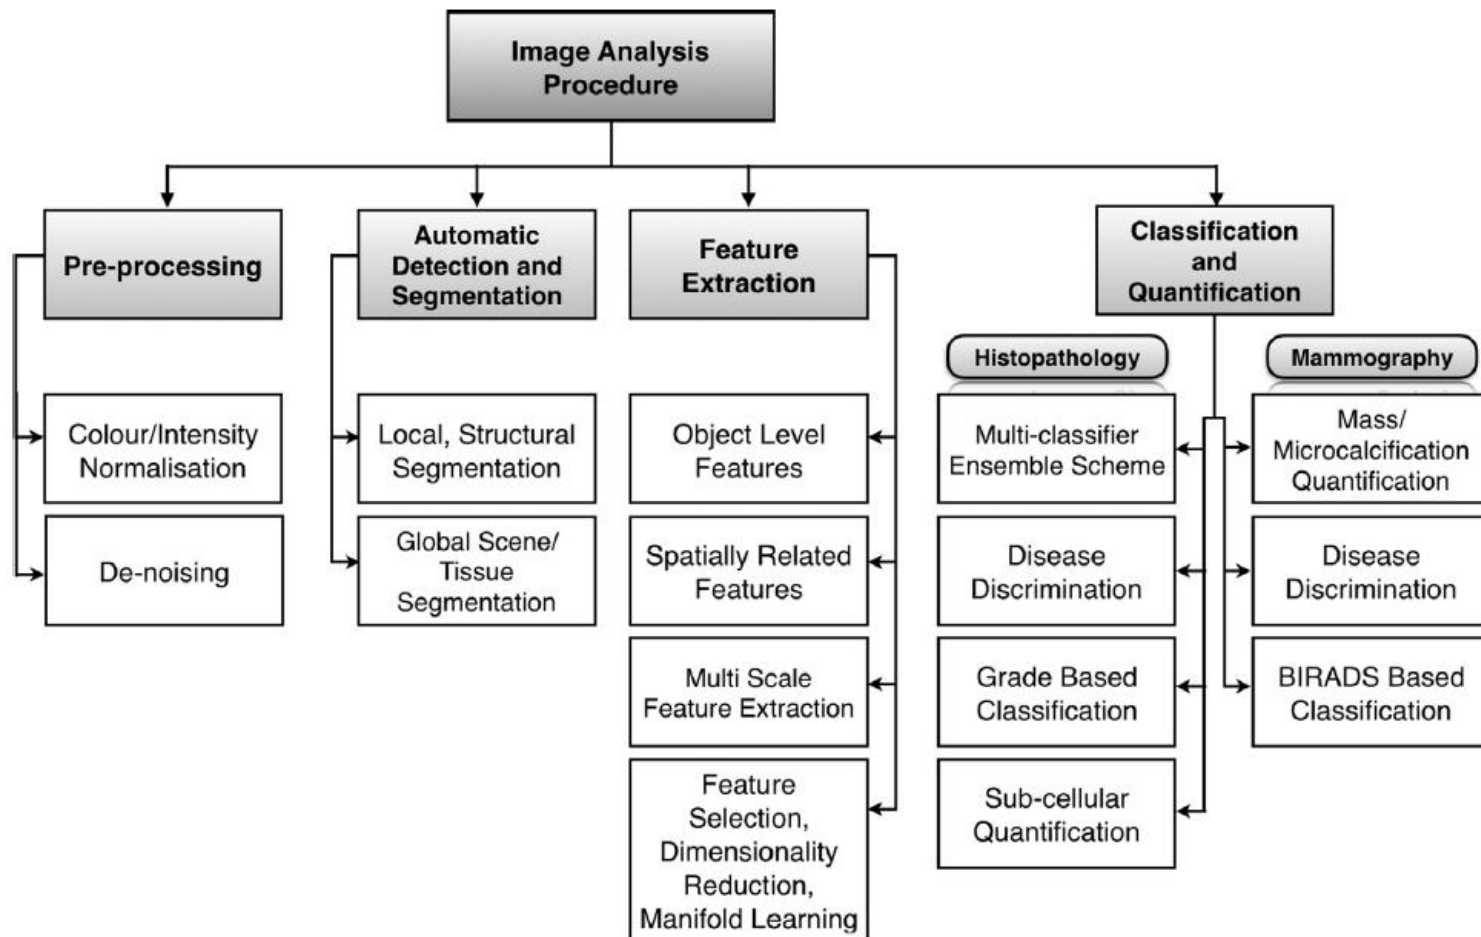
图 2-3 肿块/钙化检测结果示例[3]

传统计算机辅助诊断

- 过程

- 缺点

- 人工提取特征
- 不能适应差异较大的数据集



□基于人工智能的乳腺癌诊断综述

卷积神经网络

网络结构

- 输入层
- 卷积层
 - 卷积滤波器，池化，激活
- Dropout正则化层
- 全连接层





Fig. 3. A typical Convolutional Neural Network architecture.

计算机视觉任务概述


- 图像分类
- 目标检测
- 语义分割
- 实例分割




(a) Image classification



(b) Object localization



(c) Semantic segmentation



(d) Instance segmentation

- 图像分类

 - 卷积层+池化层+全连接层+softmax

- 目标定位

 - 一个分支图像分类;

 - 一个分支判断目标位置, 是回归任务, 输出四个数字标记包围盒位置(例: 中心点横纵坐标、包围盒长宽)

- 目标检测

 - 相比目标定位, 目标种类和个数更多

 - 思路1: 基于候选区域。将整幅图划分为许多候选区, 每个候选区包含一个目标, 对每个候选区进行“目标定位”

 - 思路2: 直接回归。

- 语义分割

 - 逐像素分类。

- 实例分割

 - 在目标检测基础上添加语义分割

目标检测和实例分割

- RCNN
- Fast RCNN
- Faster RCNN
- Mask RCNN

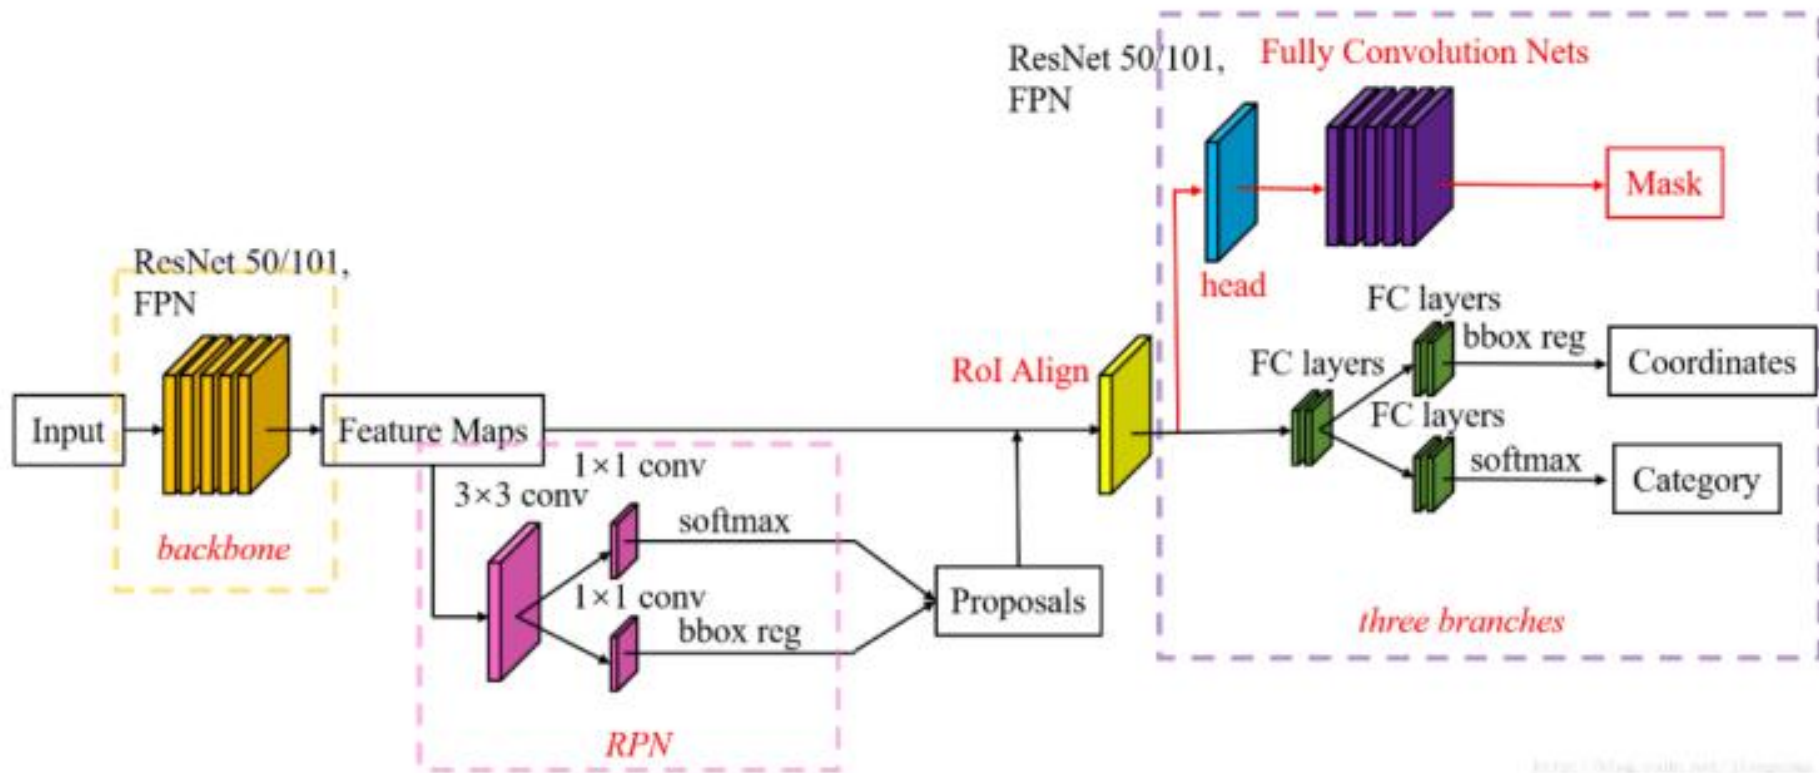


图 3-8 Mask R-CNN 框架结构

R-CNN

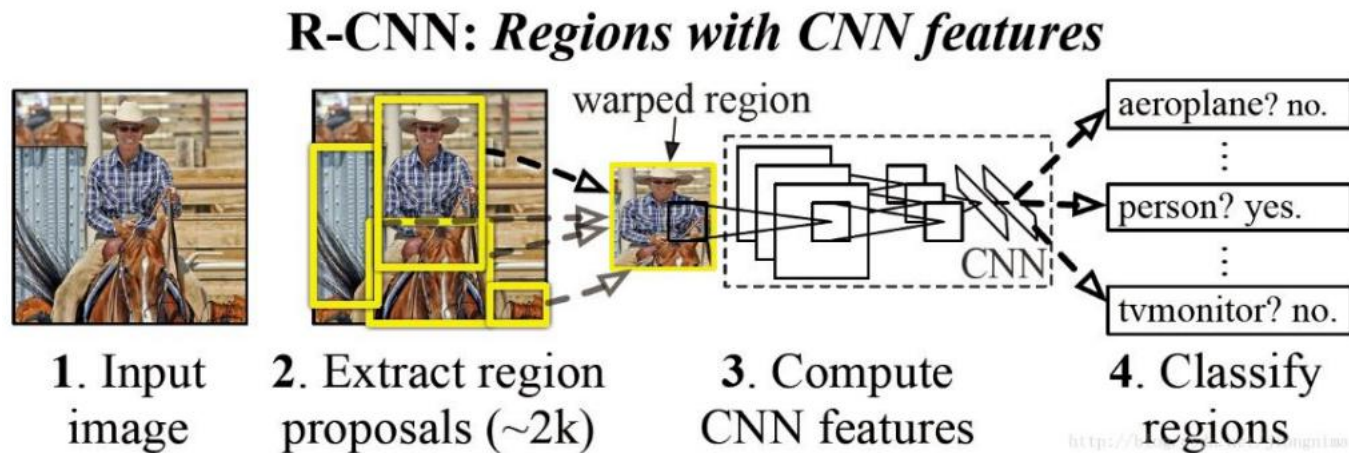


图 3-2 R-CNN 框架结构

1. 提取候选框: selective search
2. 对**每个**候选框进行特征提取
3. SVM分类

耗时
串行式CNN, 耗时
三个模块分别训练

Fast R-CNN

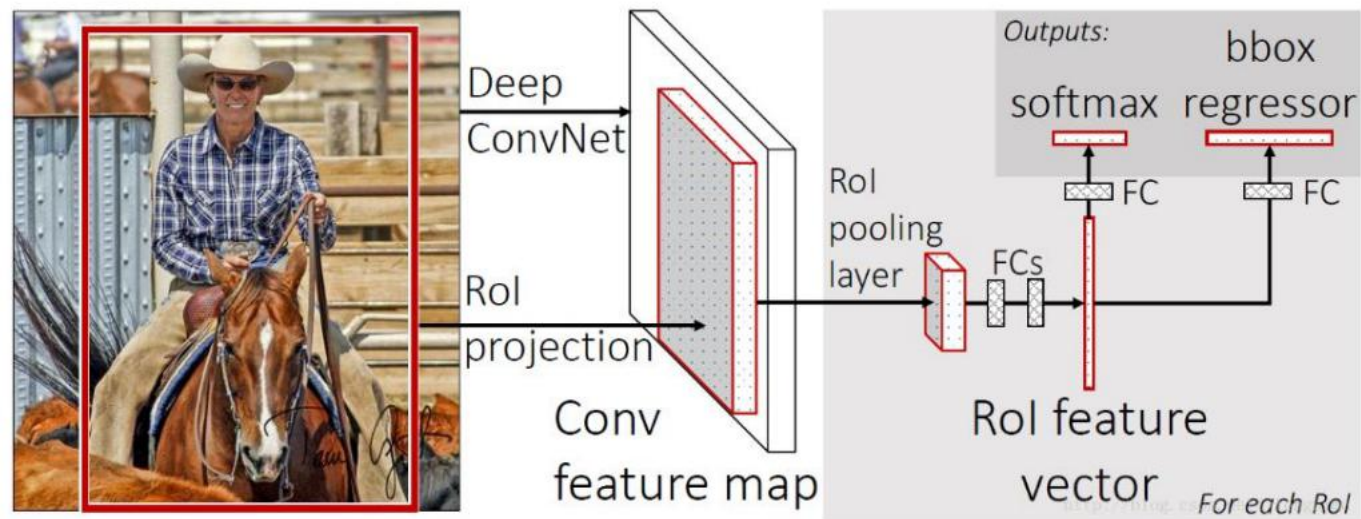


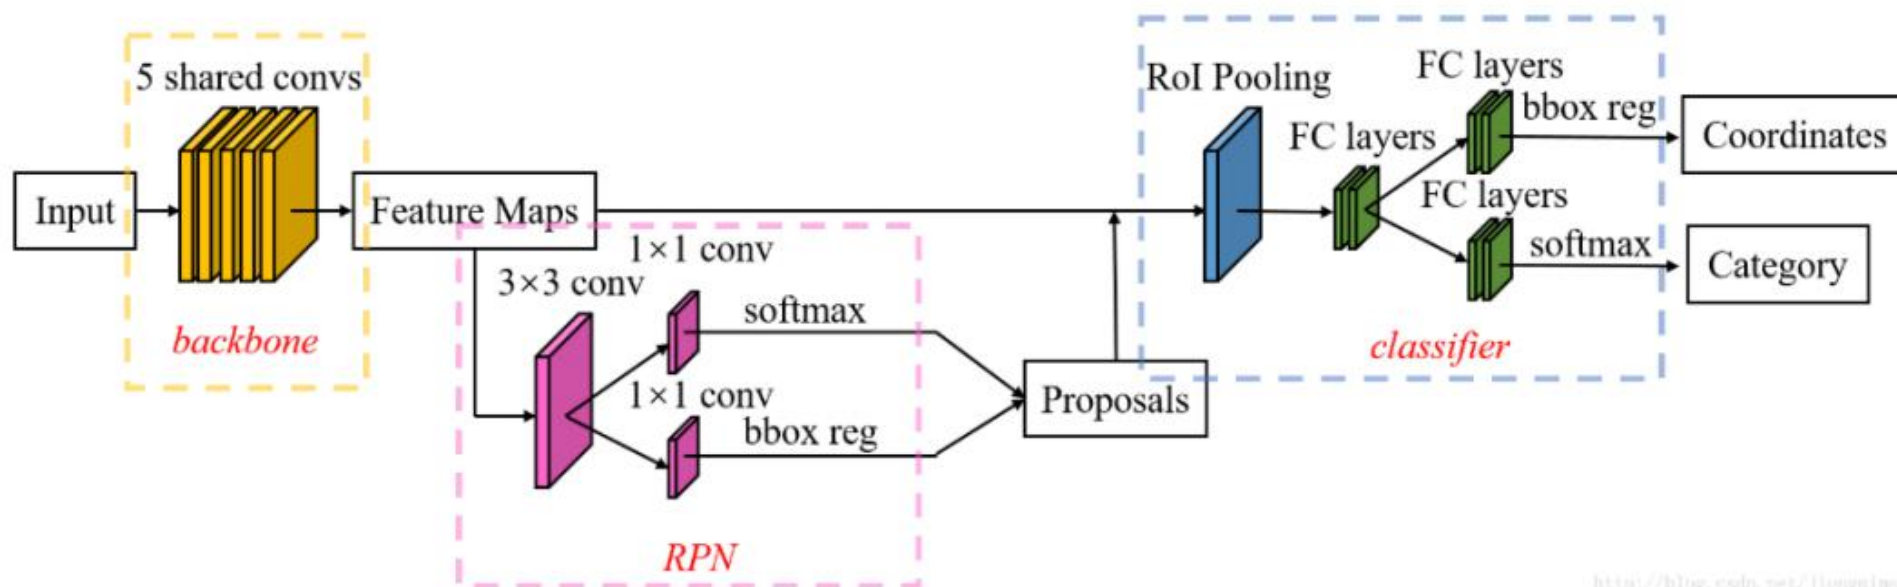
图 3-3 Fast R-CNN 框架结构

- 1. 提取候选框: selective search
- 2. 全图特征提取
- 3. 候选框特征对齐, RoI Pooling Layer, 对每个候选框在共享特征图上提取相应特征
- 4. 全卷积网络代替SVM进行分类和修正

并行CNN

提特征、分类网络同时训练

Faster RCNN



- 1.全图提特征网络 (backbone)
- 2.区域生成网络 (RPN)
- 3.特征选取 (RoI Pooling Layer)
- 4.分类和回归

代替了selective search 提速

对比selective search和RPN




图 3-7 Anchor 示意图


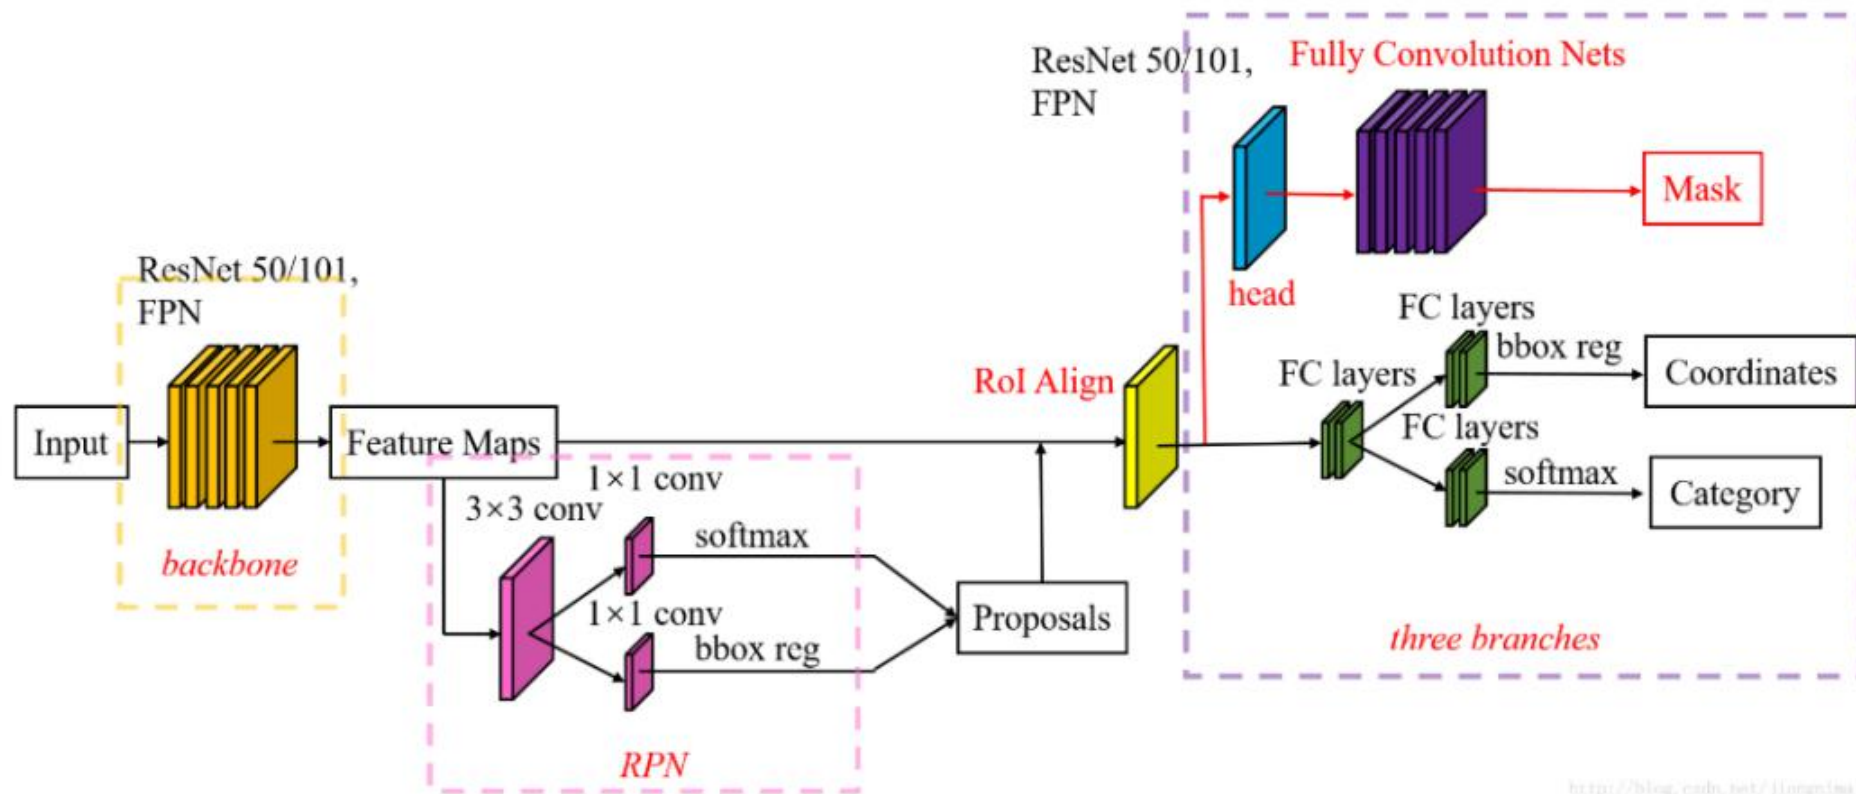


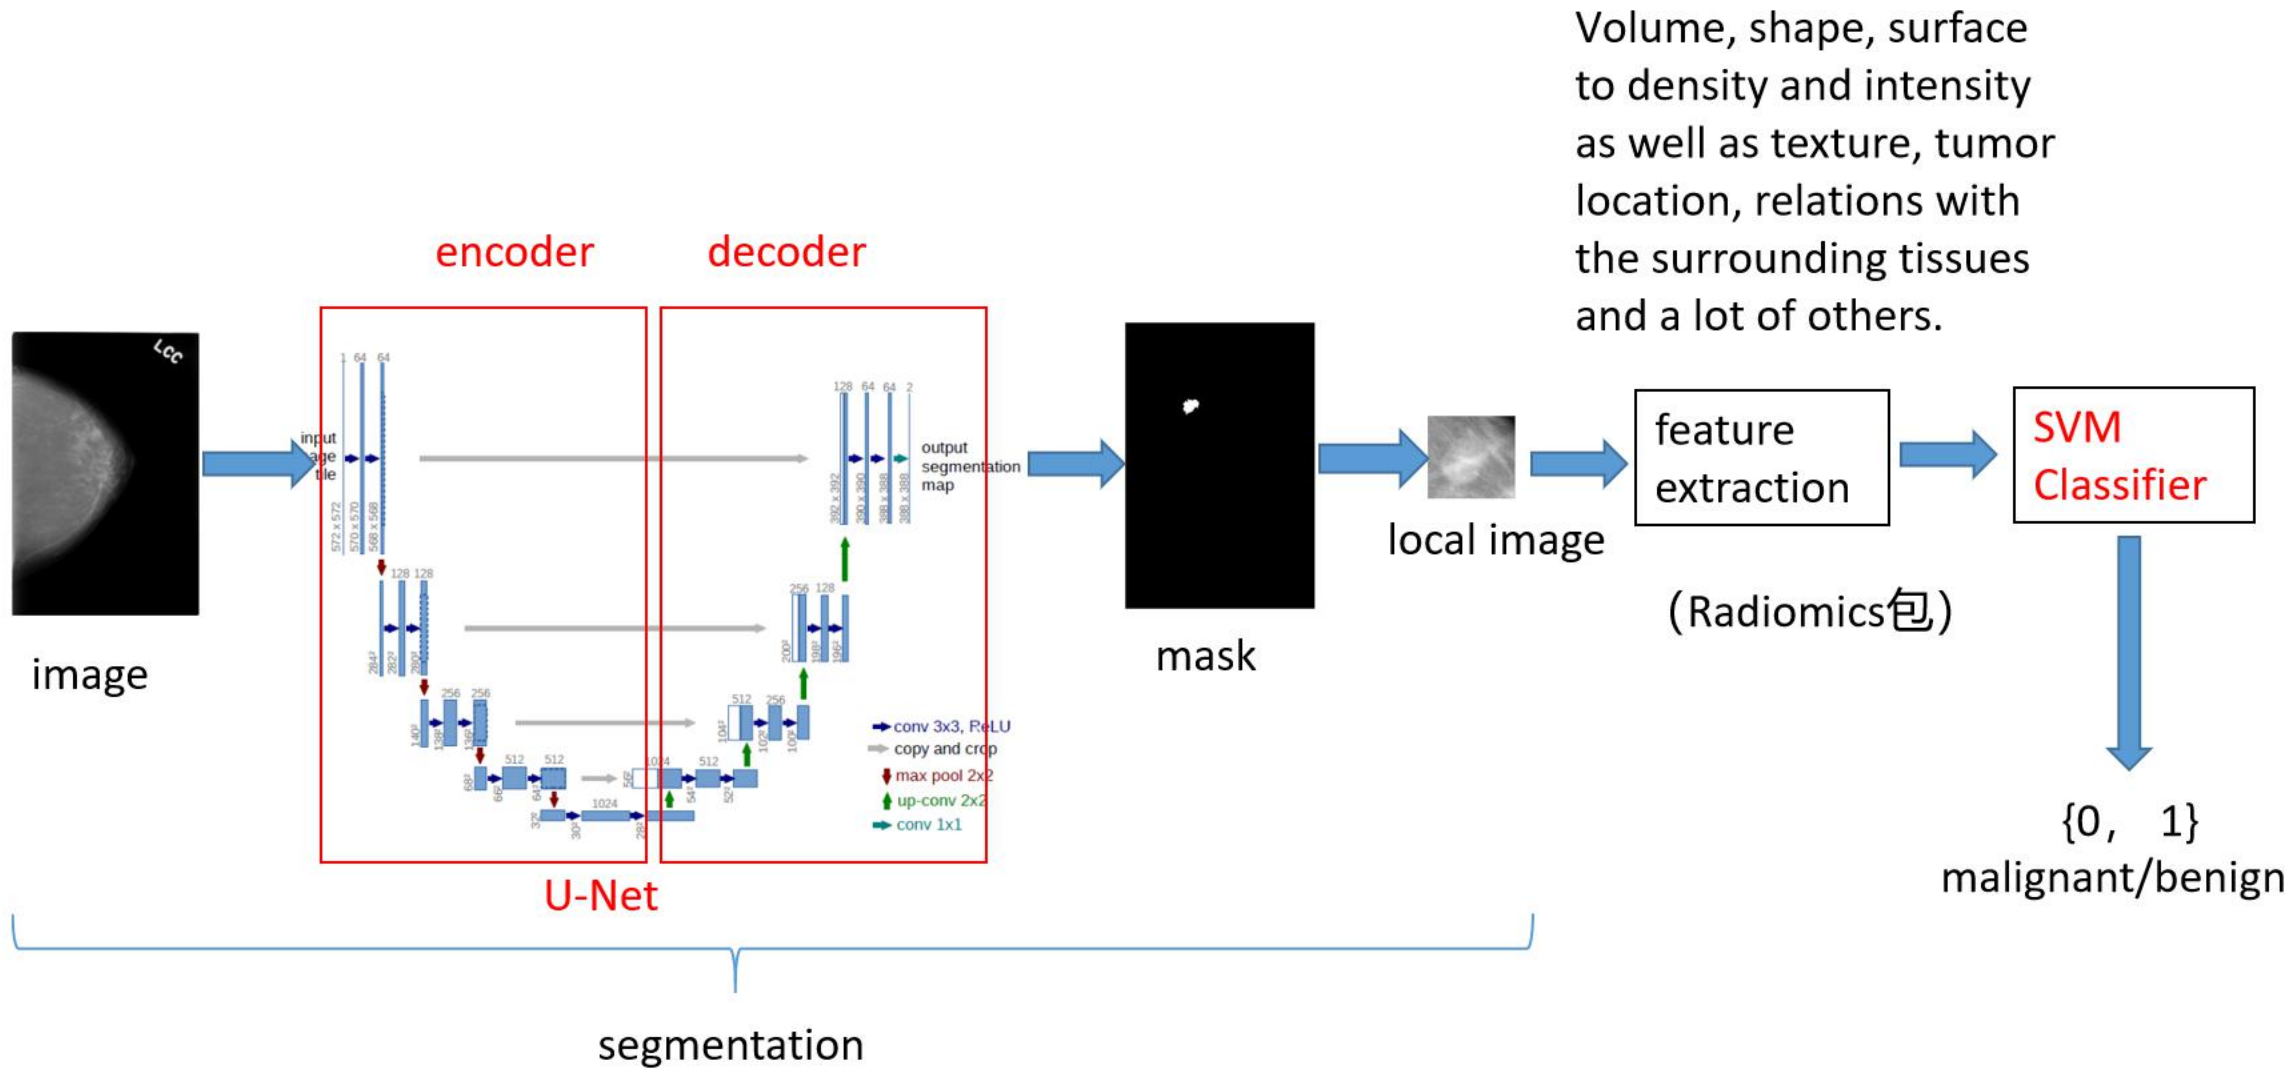
图 3-5 RPN 结构

Mask RCNN



- 添加Mask分支
- RoI Pooling 改成 RoI Align, 取整改为插值, 更好的对齐

□基于Unet+CNN的实验



Volume, shape, surface to density and intensity as well as texture, tumor location, relations with the surrounding tissues and a lot of others.

{0, 1}
malignant/benign

实验结果




图 5-8 UNet 测试检测准确结果

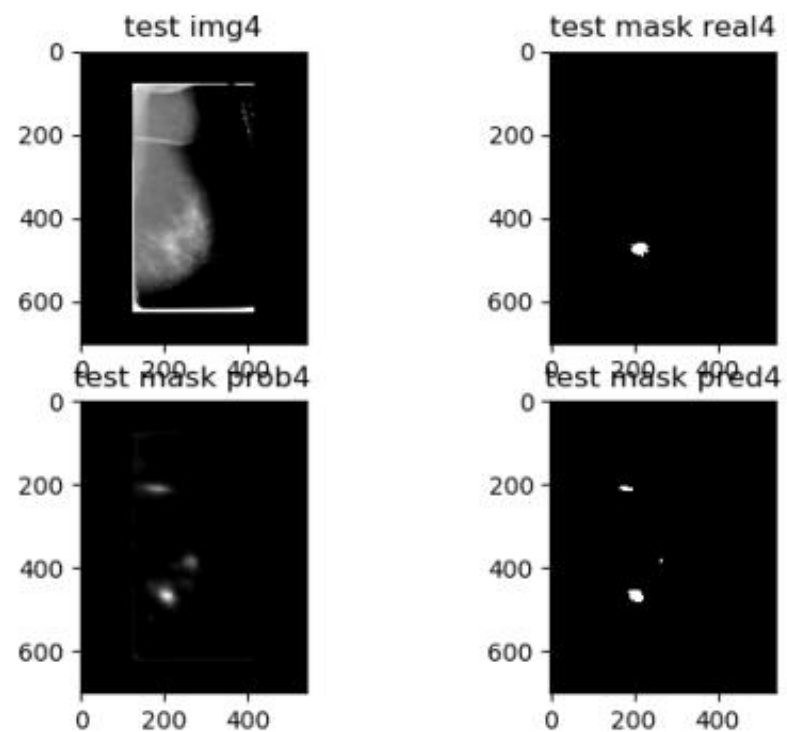


图 5-9 UNet 测试假阳性结果

结果分析

- 数据质量：掩膜上标注的肿块边界呈毛刺状，不平滑。
- Unet适用于对于单个物体的分割，而不适用于多个目标和小目标的分类。
- Unet分割+SVM分类的两步的模型结构，分割结果对分类影响较大。

□基于Mask RCNN的实验

系统概述




图 4-1 乳腺癌诊断系统流程图

- 损失函数

$$L = L_{cls} + L_{box} + L_{mask}$$

- 数据集

DDSM 训练集1231 测试集361

- 数据预处理

- 多张掩膜图像的合并
- 归一化
- 数据增量

评价指标

- 肿块检测敏感度

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

不同于一般的目标检测指标准确率，医学上更介意假阴性而不介意假阳性，即认为宁可“误诊”也不要“漏诊”

- 肿块分类混淆矩阵

$$\text{Confusion matrix} = \begin{bmatrix} \text{TP} & \text{FP} \\ \text{FN} & \text{TN} \end{bmatrix}$$

- 肿块分割Dice系数

$$\text{Dice} = \frac{2|X \cap Y|}{|X| + |Y|}$$

| | | <u>True class</u> | |
|---------------------------|----------|-------------------|-----------------|
| | | p | n |
| <u>Hypothesized class</u> | Y | True Positives | False Positives |
| | N | False Negatives | True Negatives |



□ 实验过程及结果分析

输入数据




图 5-1 原始的输入原图和掩膜




图 5-2 经过归一化的原图和掩膜






图 5-3 经过数据增强的原图

RPN生成的目标候选框



肿块检测和分类结果

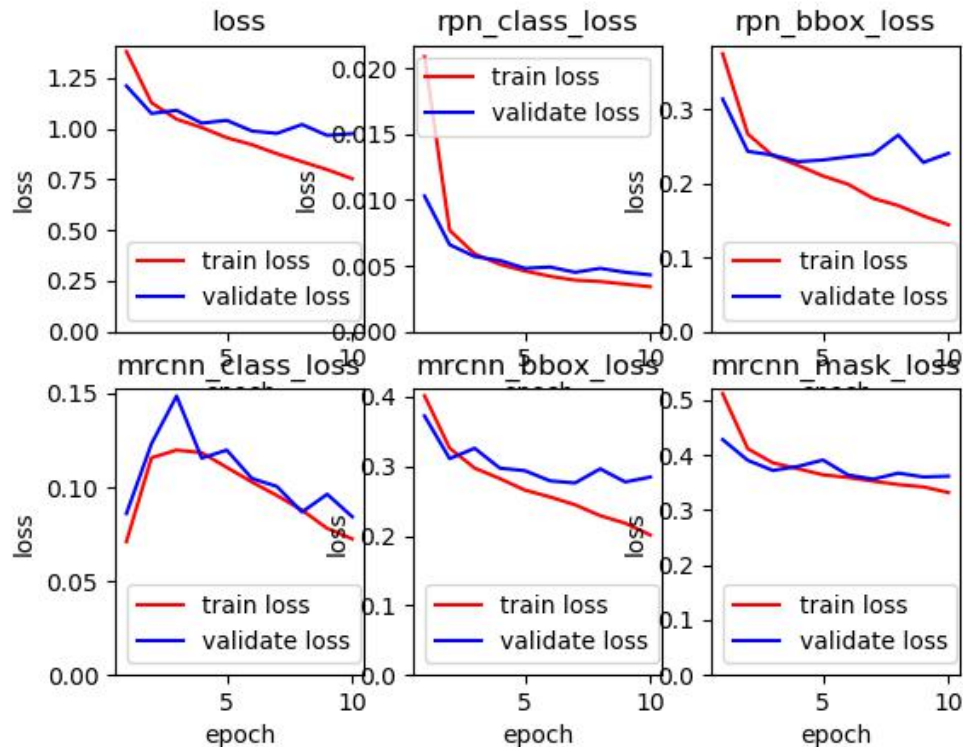


肿块分割结果



模型评价

- 训练损失



- 测试结果

| 评价指标 | 测试结果 |
|--------------|----------------------------------|
| 肿块检测敏感度 | 0.7 |
| 肿块掩膜 Dice 系数 | 0.81 |
| 肿块分类混淆矩阵 | TP=95 FP=66 TN=23 FN=72 |

模型改进

- 提高输入数据质量

掩膜上标注的肿块边界呈毛刺状，这将导致训练的效果降低。改进的办法是使用高斯滤波器对输入掩膜进行预处理，使mask边界更平滑

- 提高模型灵敏度

本实验采取了降低置信度阈值的措施，即更多的感兴趣区域可以被认为是目标区域

□ 谢谢