






Detección de anomalías en imágenes, estudio del problema y aplicación de la librería Anomalib

Autor: Pablo Ferrer González

Tutores: Emilio Soria Olivas y Joan Vila Francés



Trabajo de Final de Grado

Motivación

- Grandes avances debido a la aparición de las redes neuronales convolucionales.
- La detección de anomalías en imágenes es un problema específico en aprendizaje automático.
- El problema presenta desafíos que requieren de modelos específicos.
- Se está trabajando en:
 - Marco teórico
 - Conjuntos de datos
 - Modelos

Objetivos

- Delimitar los principales **retos**.
- Establecer un **marco teórico** introductorio.
- Identificar las **bases comunes** de los modelos más avanzados.
- Valorar las **métricas** relevantes.
- Estudiar los modelos en un conjunto de datos que permita **comparabilidad**.
- Explorar las **técnicas de mejora** de modelos más comunes.
- Comprobar su **viabilidad** en un caso real mediante simulación.

01.

Introducción

Tipos de aprendizaje y aplicaciones de detección de anomalías.

02.

Estado del arte

Retos, evolución de las técnicas y estudio de modelos.

03.

Las métricas y los datos

Estudio de las métricas relevantes y características del conjunto de datos MVTec-AD.

04.

Resultados y mejoras

Evaluación de los modelos y técnicas para mejorar los resultados.

05.

Un caso real

Aplicación de un modelo simulando un escenario realista.

06.

Consideraciones finales

Enumeración de conclusiones.



1. Introducción

Tipos de aprendizaje y aplicaciones de detección de anomalías.

Tipos de aprendizaje

● Supervisado

entrenado en un conjunto de datos etiquetados

● No supervisado

entrenado en un conjunto de datos no etiquetados

● Semi-supervisado

entrenado en un conjunto de datos parcialmente etiquetados

- **Label propagation**

etiqueta en base a sus similitudes locales y la estructura global de los datos.

- **Active Learning**

selecciona las más informativas para ser etiquetadas por un humano.

- **Weak supervision**

etiqueta utilizando información de una o más fuentes y reglas heurísticas.


- **Transfer Learning**

utiliza un modelo ya entrenado en una tarea similar para etiquetar casos no etiquetados.

Aplicaciones

Imágenes

Otros datos





2.Estado del arte



Retos, evolución de las técnicas
y estudio de modelos.



Retos



Retos



1.

Desbalanceado

La efectividad de los modelos está limitada por la cantidad y distribución de los datos

2.

Anotación

Es más fácil conseguir muestras de casos no defectuosos.

3.

Complejidad

Es imposible especificar los distintos tipos de anomalías esperadas incluso para un único problema.

4.

Delicadeza


Los modelos son especialmente sensibles a la presencia del ruido.



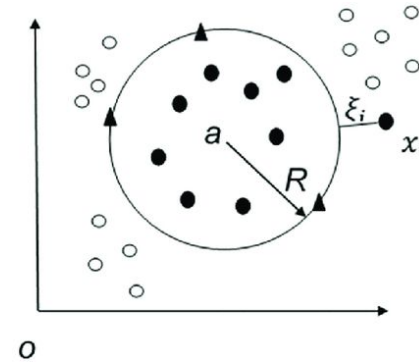
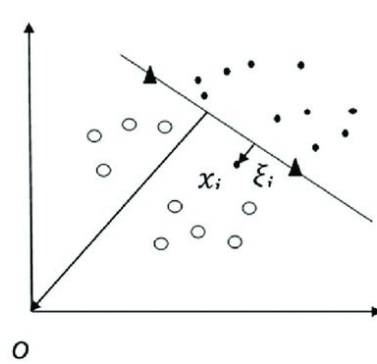
Evolución



Cluster models




OCSVM y SVDD



EXAMPLES

Tree models




Receta de la revolución del Deep Learning en 2012



Big Data: ImageNet

+



Deep Convolutional Neural Network

+



Backprop on GPU

=




Learned Weights



Modelos de Anomalia




CNN

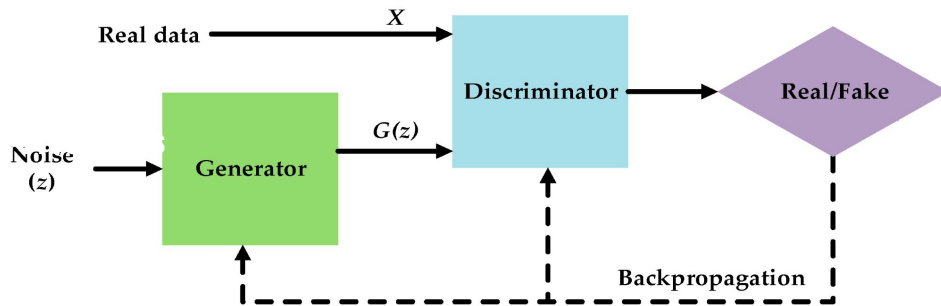


Anomalib

Autoencoder



GAN

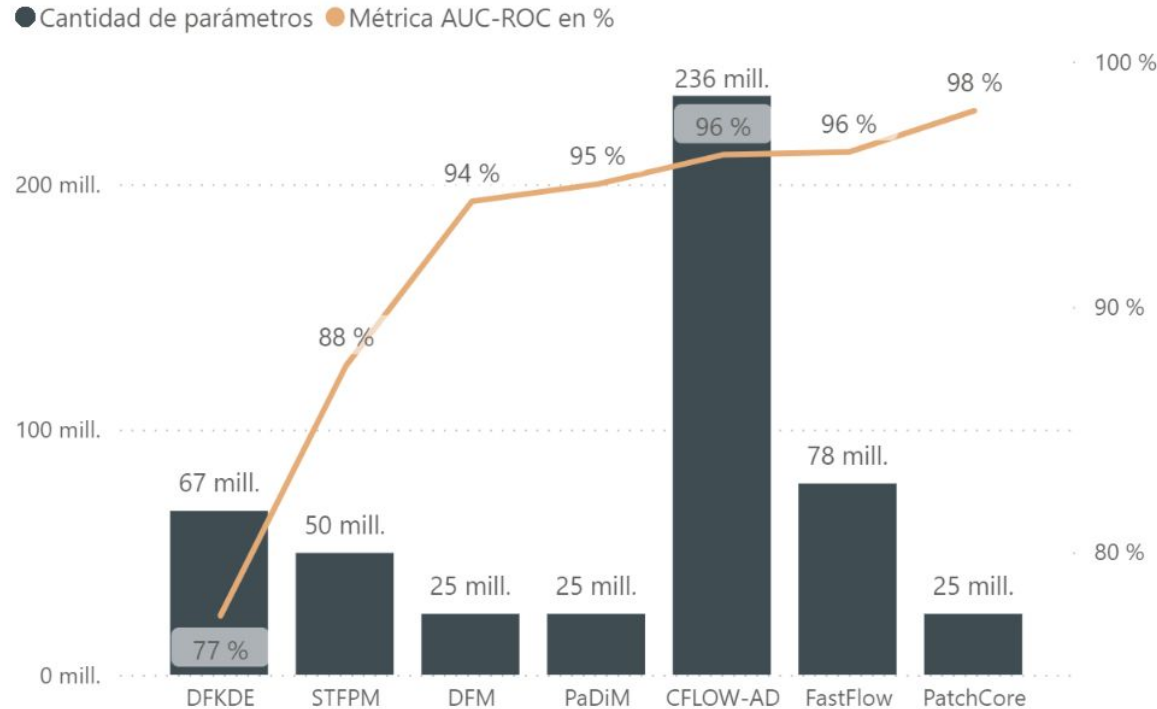


Aspectos comunes

- Los algoritmos utilizan una red neuronal **pre-entrenada** para extraer y procesar las características de una imagen.
- Dividen la imagen en **parches** y procesan cada uno de ellos por separado, valiéndose de técnicas para la representación de sus características.
- Se utilizan técnicas de **reducción de la dimensionalidad y submuestreo** en el proceso.
- Se establece algún **método para evaluar** la probabilidad de anomalía tanto a nivel de cada píxel individual como de la imagen en sí misma.

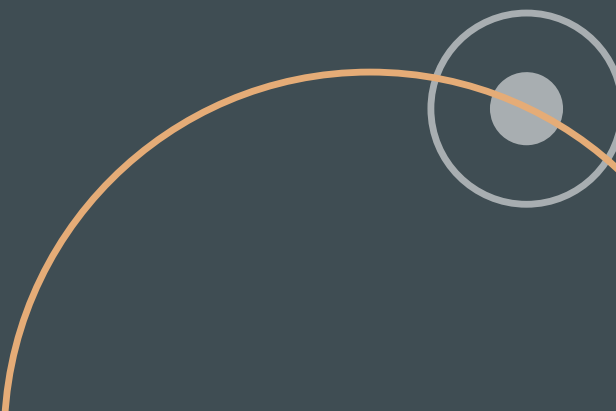
Diferencias

- **Patchcore**: greedy coresnet.
- **Fastflow**: flujo normalizador 2D.
- **Padim**: concatenación aleatoria de capas.
- **Cflow-Ad**: flujo normalizador.
- **STFPM**: red profesor-estudiante.
- **DFM**: gaussian mixture models.
- **DFKDE**: reducción mediante PCA





3. Las métricas y los datos



Estudio de las métricas
relevantes y características del
conjunto de datos MVTec-AD.



Métricas relevantes



Métricas relevantes

		Predicción	
		Positivos	Negativos
Observación	Positivos	Verdaderos Positivos (VP)	Falsos Negativos (FN)
	Negativos	Falsos Positivos (FP)	Verdaderos Negativos (VN)

- True Positive Rate
- False Positive Rate
- Positive Predictive Value

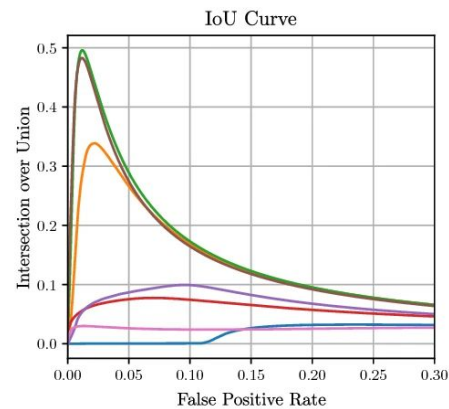
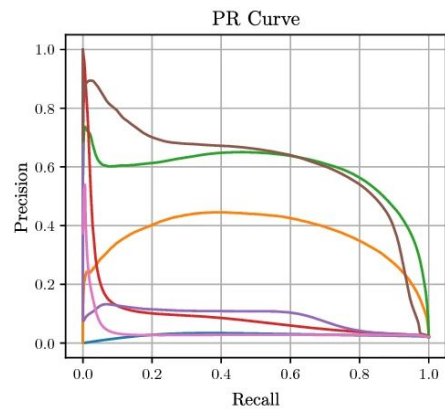
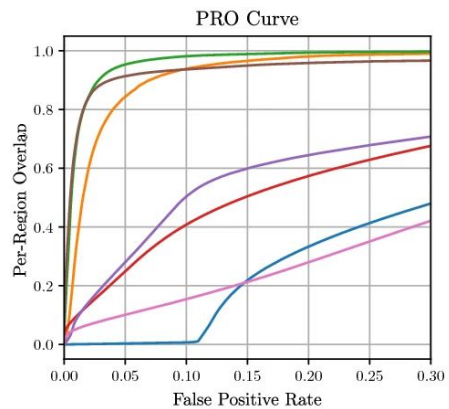
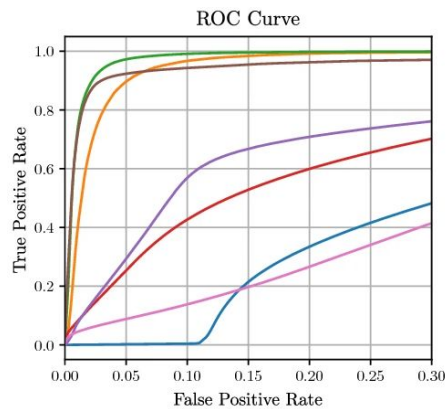
● $\text{IoU} = \frac{|P \cap G|}{|P \cup G|} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}}$.

● $F1 \text{ Score} = \frac{2}{\frac{1}{\text{TPR}} + \frac{1}{\text{PRC}}}$

● $\text{PRO} = \frac{1}{N} \sum_i \sum_k \frac{|P_i \cap C_{i,k}|}{|C_{i,k}|}$,

Métricas relevantes

Combinando métricas



f-AnoGAN Feature Dictionary Student Teacher ℓ_2 -Autoencoder SSIM-Autoencoder Texture Inspection Variation Model

Métricas relevantes

Necesidad de un umbral para la inferencia

- **Umbral máximo-píxel:** selecciona como umbral la puntuación de anomalía máxima que se haya dado durante la fase de entrenamiento.
- **Umbral p-Cuantil:** dada la distribución de todas las puntuaciones de anomalía establece la proporción de píxeles que se clasifican como anómalos.
- **Umbral k-sigma:** calcula la media y desviación típica de todas las puntuaciones de los píxeles durante la fase de inferencia y establece el umbral como $t = \mu + k\sigma$
- **Umbral máxima-área:** añade la condición de un valor de área mínima que han de superar los píxeles vecinos clasificados como anómalos.

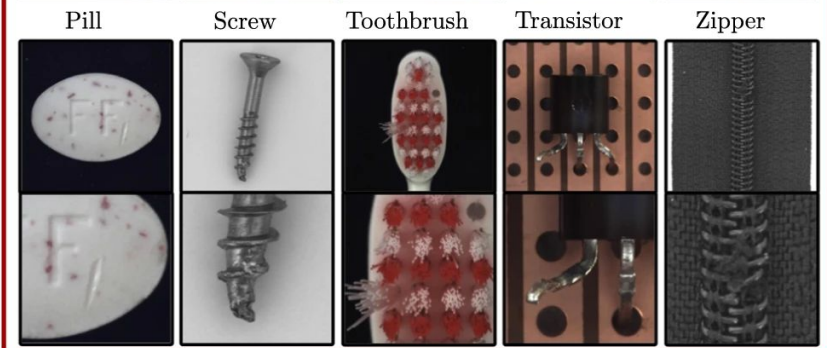
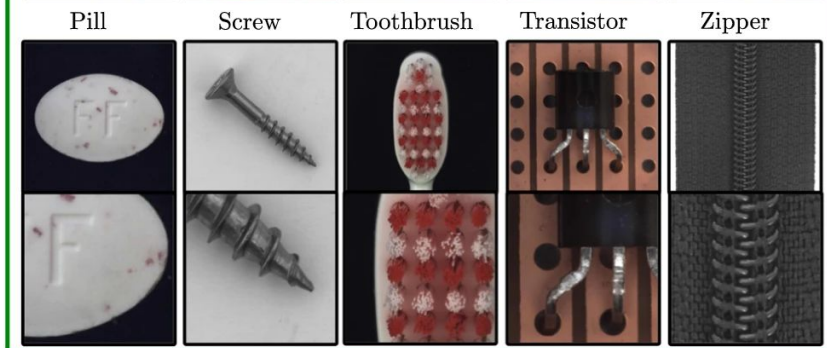
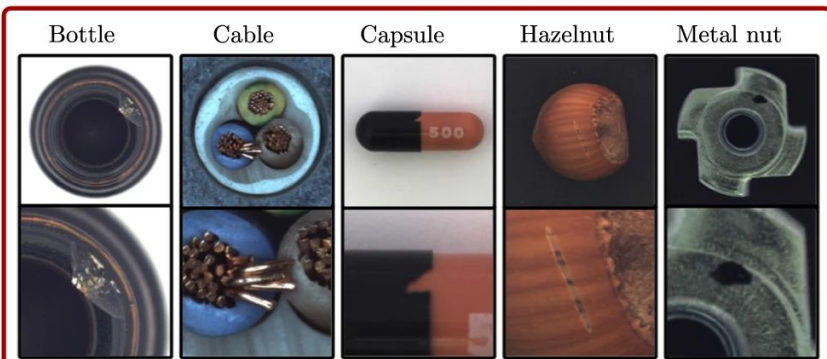
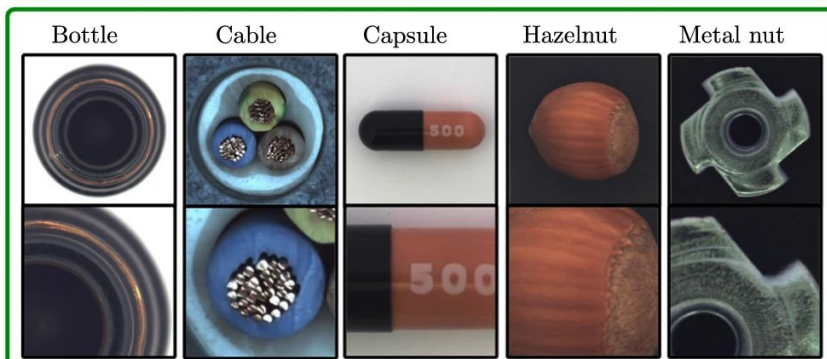




El conjunto de datos MVTec-AD




MVTec-AD

- Intenta simular escenarios reales en el sector de la producción.
- Imágenes de alta calidad con poco ruido y distorsión.
- 10 categorías de objetos (botellas, transistores, pastillas, etc) y 5 categorías de texturas (tejidos, materiales, etc)
- Cada categoría presenta distintos tipos de anomalías
- 5354 imágenes de 900x900 pixeles utilizando con tres canales RGB
- Las imágenes anómalas son aproximadamente el 20 % y un 2.7 % de los píxeles totales son anómalos.




Conjunto de entrenamiento




- Train set: 242 ✓
- Test set: 31 ✓ 84 ✗
- 5 tipos
- 1.5 regiones


Conjunto de test



Tipos de anomalía

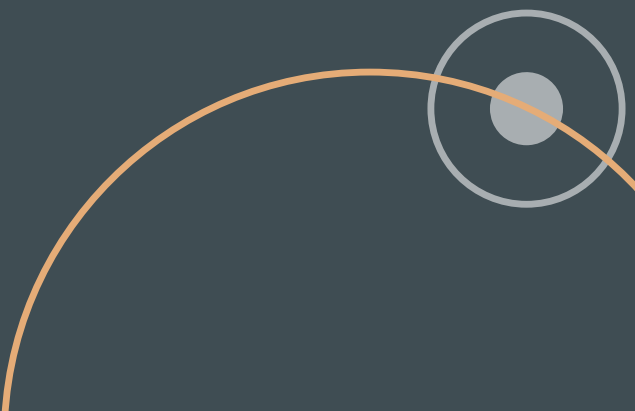


Regiones anómalas





4. Resultados y mejoras



Evaluación de los modelos y técnicas para mejorar los resultados.



Resultados



Resultados

Modelo	AUC-ROC
CBLOF	0.7598
LOF	0.7419
XGBOD	0.7417
XGB	0.7432
CatB	0.8081

Media: 0.7589

Modelo	AUC-ROC
CFlow	0.9620
DFM	0.9430
DFKDE	0.7740
FastFlow	0.8968
PatchCore	0.9800
PaDiM	0.9500
STFPM	0.8081

Media: 0.9117

Datos: MVTec-AD
Categorías: todas

Nota: no se ha ponderado por tamaño del grupo en el cálculo de la media.



Data Augmentation




Data Augmentation


- Técnica que consiste en generar nuevas imágenes a partir de las existentes mediante la aplicación de transformaciones.
- Puede mejorar la capacidad de generalizar a datos desconocidos y a prevenir el sobreajuste.

- Al aplicar la técnica debemos evitar distorsiones o alteraciones significativas en los datos originales.
- Nosotros hemos aplicado:
 - Inversión horizontal y vertical
 - Cambio de iluminación
 - Rotación

Normales sin DA



Anómalas sin DA



Ambas tras DA



Data Augmentation

Datos: naranjas
Categorías: naranjas
Modelo: PaDiM

	ResNet-18	ResNet-50
No augmentation	0.63	0.59
Si augmentation	0.61	0.72

(Métrica AUC-PR)



Transfer Learning



Transfer Learning

Datos: MVTec-AD
Categorías: todas

- Consiste en utilizar una red neuronal ya entrenada en una tarea específica para resolver una nueva tarea relacionada.
- Se consigue reducir la cantidad de datos y la complejidad computacional necesarios para resolver la nueva tarea.

Modelo	ResNet-18	ResNet-50	Cambio %
DFM	0.936	0.943	0.75
DFKDE	0.762	0.774	1.55
PatchCore	0.973	0.980	0.71
PaDiM	0.891	0.950	6.21
STFPM	0.893	0.876	-1.94

(Métrica AUC-ROC)



Ajuste de hiperparámetros



Ajuste de hiperparámetros

- Los hiperparámetros son parámetros que no son aprendidos directamente a partir de los datos, sino fijados previamente.
- El ajuste hiperparametros se realiza mediante un proceso de prueba y error, evaluándose diferentes combinaciones de valores.
- Puede mejorar la capacidad de generalizar a datos desconocidos y a prevenir el sobreajuste.

Datos: MVTec-AD
Categorías: todas
Modelo: DFM

	Pooling 2x2	Pooling 4x4	Pooling 6x6
Modelado Gaussiano	0.7057	0.6932	0.6919
Reconstruc ción PCA	0.9074	0.8956	0.8871

(Métrica AUC-PR)

5. Un caso real

Aplicación de un modelo
simulando un escenario
realista.

Introducción



Finalidad

Detectar naranjas anómalas a tiempo real



Proceso

Simular una cadena de producción de naranjas



Gestión





De componentes implicados (sensores, modelo, comunicación)



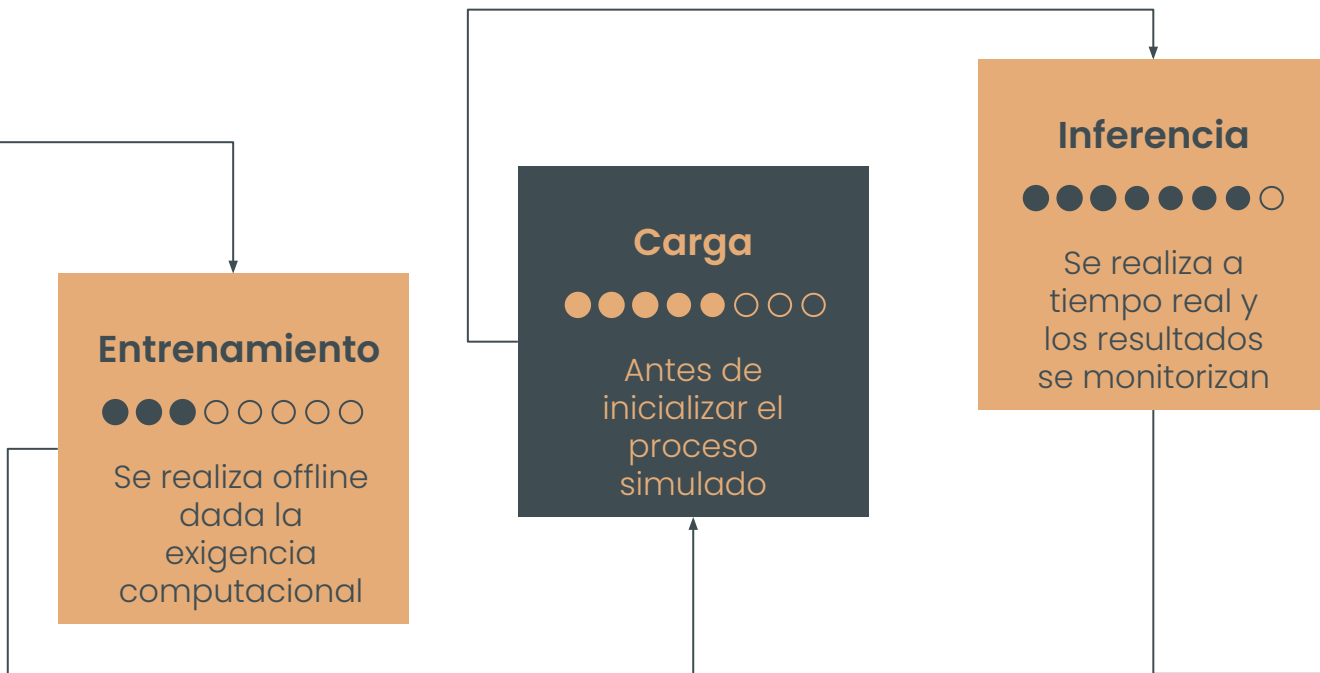
Modelo

ResNet-50 y PaDiM, con data augmentation.

Recursos Físicos

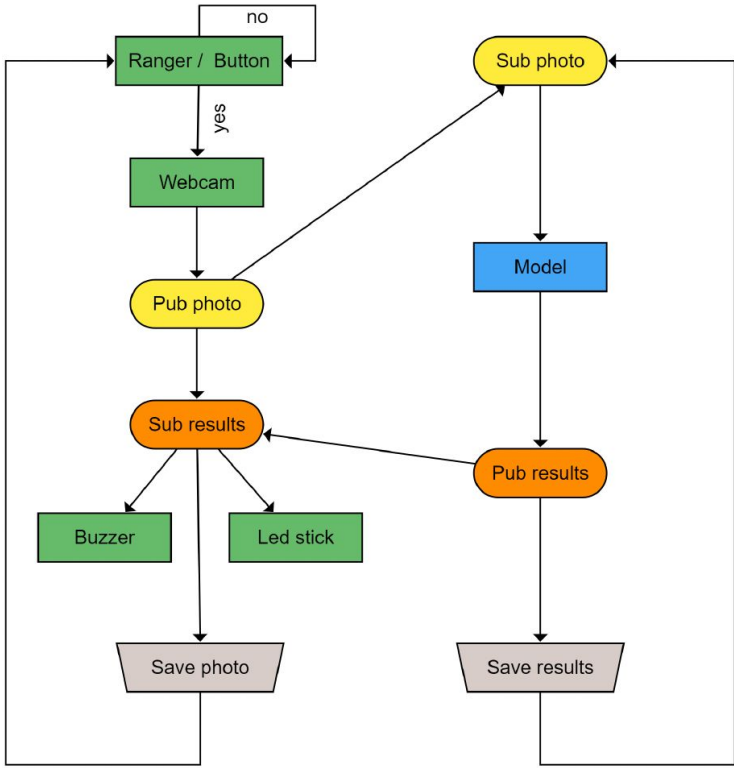


Puesta a punto




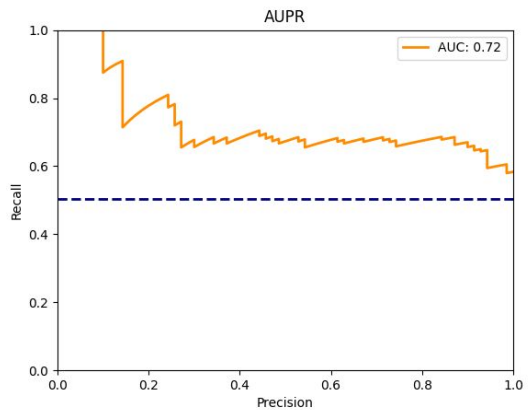
PYNQ-Z2

Server






Resultados




Image



Anomaly map




Predicted masks




Image



Anomaly map



Predicted masks





6. Consideraciones finales



Conclusiones.

Conclusiones

- Se establece un **marco teórico básico sobre los retos y modelos**, que sirve de punto de partida para el estudio del problema.
 - Por ejemplo: el encaje de los modelos OCSVM, SVDD, CNNs, Autoencoders...
- Los modelos de Anomalib, pese a ser muy distintos suelen presentar **aspectos comunes** como el uso de una red preentrenada, la división de la imagen en parches, la reducción de la dimensionalidad y el submuestreo
- Respecto a las **métricas relevantes**, hemos visto las ventajas de la curva PR, o las métricas PRO y F1 score.
- Hemos comprobado que la cantidad y calidad de los datos en el conjunto **MVTec-AD** permite evaluar y comparar modelos.
- Tanto Data Augmentation, como Transfer Learning y ajuste de hiperparámetros presentan **mejoras** lo suficientemente significativas como para ser tenidas en cuenta.
- En cuanto a la **viabilidad**, es posible con la versión actual de Anomalib y la parte de inferencia en el modelo tarda aproximadamente un segundo.



DetECCIÓN DE ANOMALÍAS EN IMÁGENES, ESTUDIO DEL PROBLEMA Y APLICACIÓN DE LA LIBRERÍA ANOMALIB

Autor: Pablo Ferrer González
Tutores: Emilio Soria Olivas y Joan Vila Francés