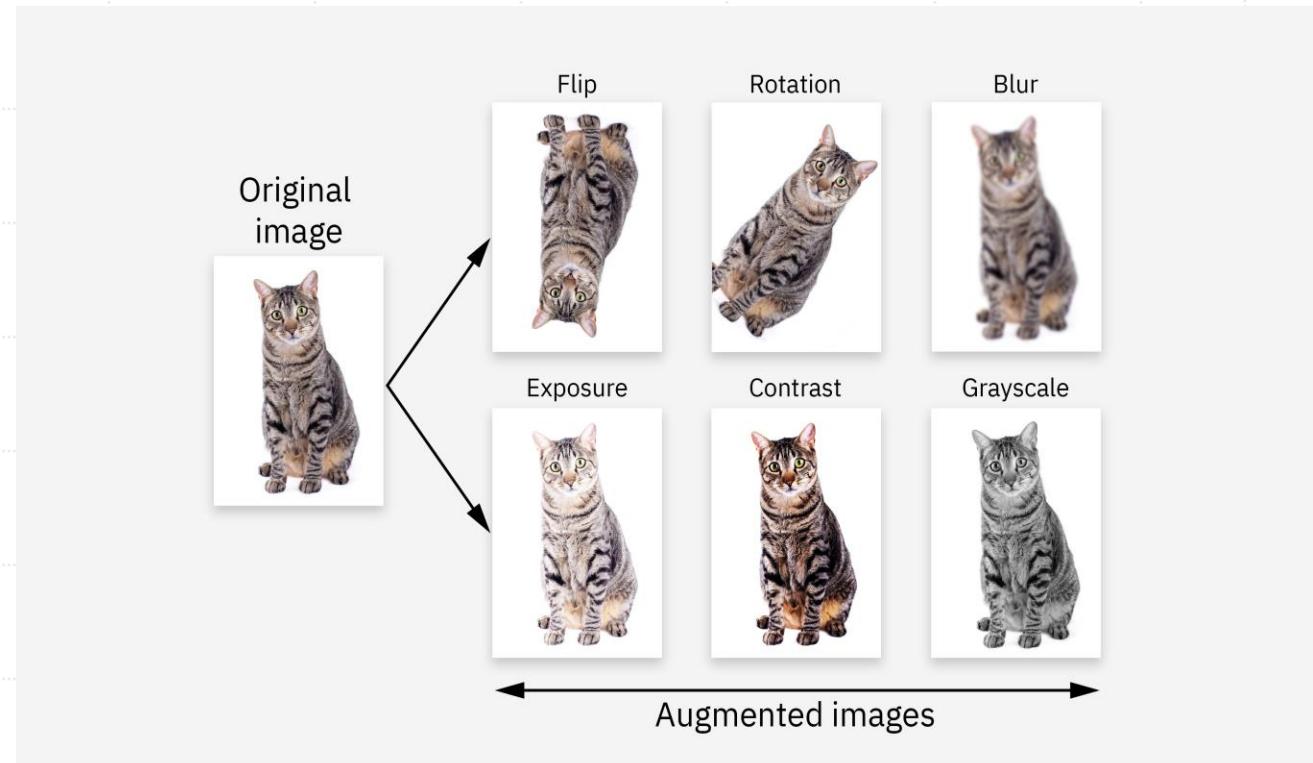


Data Augmentation

- Técnica para mejorar los resultados y prevenir overfitting
- Expandir el dataset creando versiones modificadas de las imágenes
- Transformaciones sobre las imágenes:
 - shift, flip, rotation, brightness, zoom, etc





¿Por qué necesitamos data augmentation?

- Entrenar redes profundas requiere muchos datos reales
- A menudo nuestros datasets son limitados o sesgados
- Sin variación, el modelo puede *memorizar* (overfit)
- En producción nos topamos con ruido, iluminación variable, posiciones diferentes, etc.
- ¿Cómo enseñamos al modelo a “esperar lo inesperado”?
→ augmentation

Augmentation vs Datos sintéticos

Característica	Data Augmentation	Datos Sintéticos
Partir de datos reales	Si	No (o parcialmente)
Modificación local (transformaciones)	Si	Creacion desde cero
Control semántico	Alto	Puede fallar en realismo
Coste/complejidad	Bajo-moderado	alto
Ejemplos típicos	Flips, rotaciones, ruido	Imágenes generadas por GANs, simuladores

Herramientas



Albumentations



IA Explicable

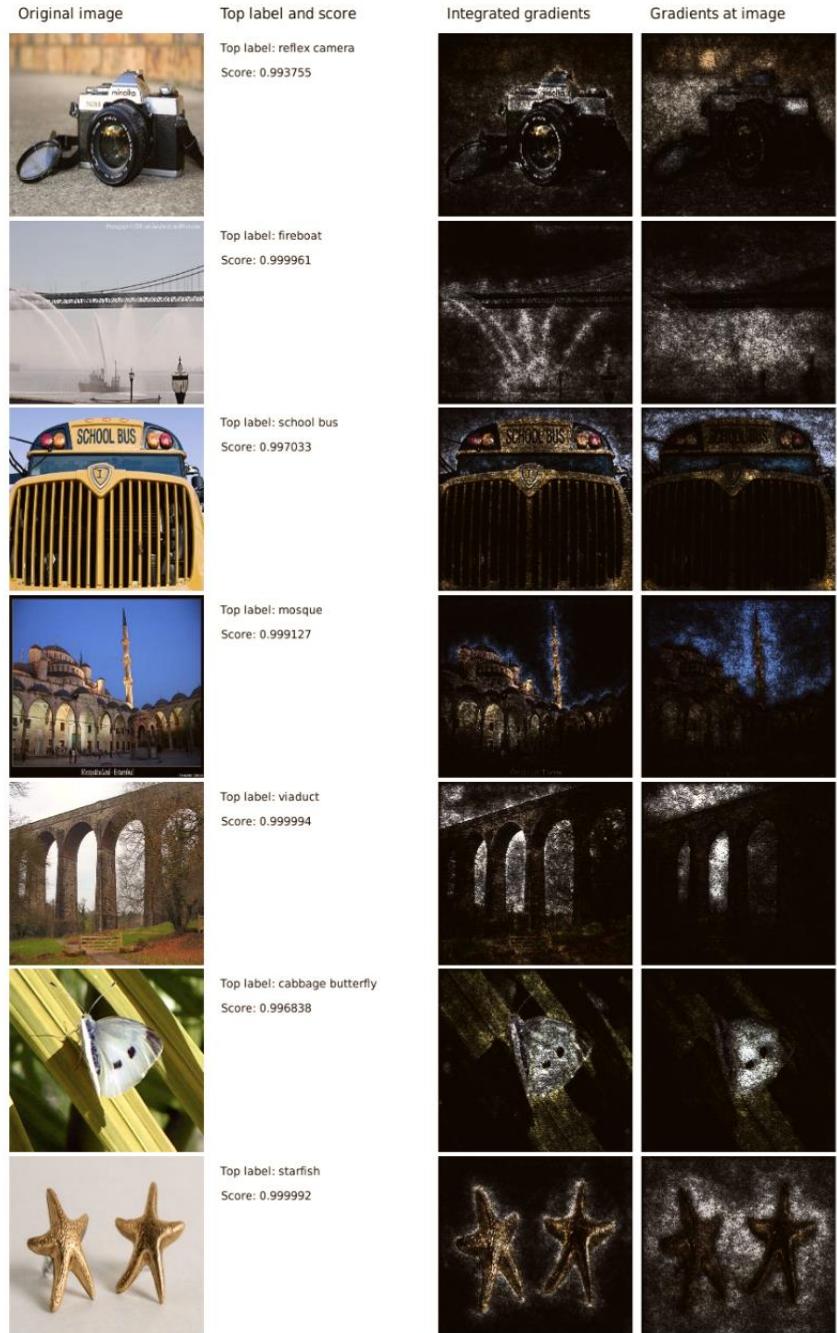
- Complejidad en los modelos (“caja negra”)
- Muchas veces es desconocido que es lo que aprenden las redes y como toman decisiones
- Interpretabilidad

IA Explicable - Objetivo

- 
- Incrementar la transparencia
 - Mejorar el entendimiento
 - Debug (entender casos mal clasificados)

IA Explicable: Integrated gradients

- Que pixeles incrementan mas la salida para la clase correcta
- Puntaje de importancia



IA Explicable: GradCAM

- Inspecciona las activaciones de la ultima capa convolucional antes de la clasificación

