


L U M B R E



Clasificación de imágenes

Grado: 7

Materia: Visión por Computadora · Inteligencia Artificial

11/10/2026

Antes de empezar

Clasificar una imagen —decir si hay un gato o un perro— es la tarea estrella de la visión. Montarla de principio a fin exige preparar datos, elegir y entrenar una red, y evaluarla con honestidad sobre imágenes no vistas.

QUÉ APRENDERÁS

- Entrenar y evaluar de extremo a extremo un clasificador de imágenes, preparando datos, eligiendo arquitectura y midiendo su rendimiento.

Clasificación de imágenes

De píxeles a etiquetas

Un clasificador de imágenes aprende a mirar: recibe píxeles y devuelve una etiqueta. El reto no es solo la red, sino el ciclo completo de datos, entrenamiento y evaluación rigurosa.

VIDEO

Entrenar una CNN con imágenes

Vídeo en español que construye de principio a fin un clasificador de imágenes con una red convolucional.



Escanea para verlo en Lumbre

<https://www.youtube.com/watch?v=1Yue10kxTCU>

El flujo de extremo a extremo

- Recolectar y etiquetar imágenes de cada clase.
- Preprocesar y dividir en entrenamiento, validación y prueba.
- Entrenar una red, afinar con validación y reportar en prueba.

Preparar los datos

Redimensionar al tamaño de entrada, normalizar los valores de píxeles y repartir equilibradamente las clases. Unas etiquetas ruidosas o un desbalance importante hunden el modelo antes de empezar.

Aumento de datos


Generar variantes —giros, voltes, recortes, color— ensancha el conjunto y enseña invariancia. Es la regularización más eficaz en visión, sobre todo con pocas imágenes.

Elegir la arquitectura

Hoy rara vez se diseña desde cero: se parte de una CNN reconocida (ResNet, EfficientNet) y se adapta. El equilibrio entre tamaño, velocidad y precisión guía la elección.

Entrenar el clasificador

Se reemplaza la cabecera por el número de clases propias y se entrena, a menudo con ajuste fino si hay pocos datos. La pérdida de entropía cruzada penaliza los errores de mayor confianza.



El clasificador aprende a mapear píxeles a etiquetas; el reto es todo el ciclo, no solo la red.

Evitar fugas de datos

Que imágenes muy similares no caigan a la vez en entrenamiento y prueba. Sin esta precaución, la métrica engaña: el modelo parece bueno solo porque vio casi lo mismo.

Evaluar con métricas

La exactitud engaña con clases desbalanceadas; conviene precisión, exhaustividad y la matriz de confusión. Ver qué clases se confunden revela los fallos reales.

Interpretar los errores

Revisar las imágenes mal clasificadas suele enseñar más que un número: fallos sistemáticos, etiquetas erróneas o casos límite se detectan mirando.

Desplegar con cuidado

El mundo real trae imágenes peor iluminadas y de otra cámara que las de laboratorio. Validar en condiciones reales y monitorizar el derrame de rendimiento es parte del trabajo.

Errores frecuentes

- Medir solo con la exactitud en clases desbalanceadas y creer que un modelo inútil funciona.
- Permitir fugas de datos repartiendo imágenes casi idénticas entre entrenamiento y prueba.
- Saltarse el aumento de datos y sobreajustar cuando el conjunto de entrenamiento es pequeño.

Ejemplo resuelto: evaluar con honestidad

Tu clasificador marca una exactitud altísima pero sospechas. Lo evalúas con rigor:

1. Separas entrenamiento y prueba cuidando que no se solapen casos similares.
2. Revisas el balance de clases antes de confiar en la exactitud global.
3. Calculas precisión y exhaustividad por clase con su matriz de confusión.
4. Miras las imágenes mal clasificadas para detectar patrones de fallo.
5. Validas en datos reales antes de dar el modelo por bueno.

¿Para qué sirve en la realidad?

Clasificar imágenes alimenta desde lectoras de documentos hasta control de calidad industrial; montarlo bien de extremo a extremo separa una demo que funciona en clase

de un producto fiable en producción.

1. En una tarea de clasificación con clases muy desbalanceadas, la exactitud global puede ser engañosa porque:

- ☐ siempre predice la clase minoritaria
- ☐ un modelo que predice siempre la clase mayoritaria logra alta exactitud sin servir
- ☐ mide solo el tiempo de inferencia
- ☐ depende del número de canales

2. Incluir el mismo identificador de paciente en entrenamiento y prueba puede inflar artificialmente la métrica del clasificador.

- ☐ Verdadero
- ☐ Falso

ACTIVIDAD INTERACTIVA DISPONIBLE EN LUMBRE

3. Clasificación



4. Ordena las etapas de un proyecto de clasificación de imágenes:

Elementos:

- recolectar, etiquetar y dividir los datos
- entrenar la red con aumento y pérdida adecuados
- afinar con validación y medir en prueba
- servir y monitorizar en condiciones reales

Datos	. . .
Entrenar	. . .
Validar	. . .
Desplegar	. . .

Análisis de imágenes https://en.wikipedia.org/wiki/Image_analysis Tareas y métodos del análisis de imágenes digitales.

5. Une cada etapa del proyecto con su propósito.

5.	generar variantes de las imágenes	-----
5.	repartir casos similares en conjuntos distintos	-----
5.	medir aciertos por clase	-----
5.	penalizar los errores más confiados	-----

Opciones: aumento de datos · evitar fugas · matriz de confusion · entropia cruzada

De píxeles a etiquetas

Clasificación de imágenes

Datos

etiquetar

dividir conjuntos

Entrenar

arquitectura base

aumento y pérdida

Evaluar

confusion por clase

evitar fugas

Servir

condiciones reales

monitorizar

El mapa mental interactivo es interactivo en la versión online.



Matriz de confusión https://en.wikipedia.org/wiki/Confusion_matrix Cómo leer precisión y exhaustividad más allá de la exactitud global.

6. Tu clasificador alcanza 99 % en validación pero falla mucho con usuarios reales. ¿Qué dos causas —una de datos y otra de evaluación— investigarías primero?

Referencia curricular

Grado:	7
Materia:	Visión por Computadora · Inteligencia Artificial

Versión interactiva completa (con actividades, videos y autoevaluación):



<https://univ.lumbre.lat/object/cdia-vcp-002-clasificacion-de-imagenes>

Material educativo generado desde Lumbre · lumbre.lat