

L U M B R E



Regularización en profundidad (dropout)

Grado: 7

Materia: Redes Neuronales Artificiales · Inteligencia Artificial

11/10/2026

Antes de empezar

Una red profunda con suficientes parámetros puede memorizar hasta el ruido. La regularización es el freno que la obliga a apoyarse en señal robusta: apagar neuronas al azar, castigar pesos grandes y saber cuándo detenerse.

QUÉ APRENDERÁS

- Controlar el sobreajuste de redes profundas con dropout, penalización de pesos y parada temprana, entendiendo el efecto de cada uno sobre la generalización.

Regularización en profundidad

Aprender sin apoyarse en una sola neurona

Dropout entrena muchas subredes a la vez al apagar neuronas al azar en cada paso: obliga a la red a no confiar en ninguna unidad concreta. Es regularización disfrazada de olvido controlado.

VIDEO

¿Qué es el dropout y por qué mejora el entrenamiento?

Vídeo en español que explica cómo apagar neuronas al azar regulariza una red profunda.



Escanea para verlo en Lumbre

<https://www.youtube.com/watch?v=GZ4aj67g4Ck>

El sobreajuste profundo

Con millones de parámetros, la red tiene capacidad de sobra para memorizar el entrenamiento y flaquear en datos nuevos. Cuanto más expresiva, más hace falta contenerla para que generalice.


Dropout

- Apaga aleatoriamente neuronas en cada paso del entrenamiento.

- Evita que unidades específicas dominen y fomenta representaciones redundantes y robustas.
- En inferencia se usan todas, escalando adecuadamente las activaciones.

Como ensemble implícito

Al variar qué subred se entrena en cada paso, dropout imita un promedio de muchas redes. Ese ensemble de bolsillo reduce varianza y desanima la coadaptación de neuronas.



En cada paso de entrenamiento dropout desactiva neuronas al azar para que la red no dependa de ninguna concreta.

Penalización de pesos

Weight decay añade a la pérdida una pena por pesos grandes, empujando hacia modelos más simples y suaves. Es la regularización l2 clásica, hoy a menudo integrada en el propio optimizador.

Parada temprana

Monitorizar la pérdida de validación y detenerse cuando deja de mejorar corta el entrenamiento antes de que la red memorice ruido. Es barato y eficaz, aunque sensible

al momento elegido.

Aumento de datos

Generar variantes de las entradas —giros, recortes, ruido— ensancha el conjunto sin etiquetar más. Obliga a la red a ser invariante a transformaciones irrelevantes y suele batir a otras regularizaciones.

Combinar frenos

Dropout, weight decay, aumento y parada temprana se suman y a veces se solapan. Usarlos todos a tope puede infra-ajustar; se gradúan según la brecha entre entrenamiento y validación.

Errores frecuentes

- Mantener dropout activo en inferencia, cuando ahí se usan todas las neuronas con el escalado adecuado.
- Aplicar todos los frenos a tope a la vez y caer en infraajuste, con la red incapaz de aprender siquiera el entrenamiento.
- Regularizar sin mirar la brecha entre entrenamiento y validación, ajustando el freno a ciegas.

Ejemplo resuelto: cerrar la brecha entre entrenamiento y validación

La red marca error casi nulo en entrenamiento pero se estanca en validación: sobreajuste típico. Combinamos frenos:

1. Diagnosticar la brecha entre la métrica de entrenamiento y la de validación.
2. Añadir dropout en las capas densas para impedir que confíe en neuronas concretas.
3. Sumar weight decay para penalizar pesos grandes y modelos demasiado complejos.
4. Ampliar datos con aumento si hay margen para generar variantes.
5. Detener por parada temprana justo cuando la validación deja de mejorar.

¿Para qué sirve en la realidad?

Un modelo que memoriza es inútil en producción; la regularización es lo que convierte capacidad bruta en generalización, y se gradúa observando la brecha entre entrenar y validar.

1. El dropout reduce el sobreajuste principalmente porque:

- ☐ añade más parámetros a la red
- ☐ apaga neuronas al azar, impidiendo confiar en unidades concretas
- ☐ eleva la tasa de aprendizaje
- ☐ reduce el tamaño del lote a uno

2. Durante la inferencia, el dropout se mantiene activo apagando neuronas al azar igual que en entrenamiento.

- ☐ Verdadero
- ☐ Falso

ACTIVIDAD INTERACTIVA DISPONIBLE EN LUMBRE

3. Regularización**4. Ordena la decisión ante una red que sobreajusta:****Elementos:**

- comprobar la brecha entre entrenamiento y validación
- aplicar dropout y weight decay
- añadir aumento de datos si hay margen
- detener el entrenamiento por validación

Diagnosticar	. . .
Frenar	. . .
Ampliar	. . .
Parar	. . .

Regularización [https://en.wikipedia.org/wiki/Regularization_\(mathematics\)](https://en.wikipedia.org/wiki/Regularization_(mathematics)) Familias de técnicas que penalizan la complejidad para mejorar la generalización.

5. Une cada técnica con su efecto.

5.	apaga neuronas al azar durante el entrenamiento	-----
5.	penaliza pesos grandes empujando a modelos simples	-----
5.	corta el entrenamiento cuando la validación empeora	-----
5.	crea variantes de las entradas para ensanchar los datos	-----

Opciones: dropout · weight decay · early stopping · aumento

Aprender sin apoyarse en una sola neurona

Regularización profunda

Dropout

apaga neuronas

ensemble implícito

Weight decay

penaliza tamaño

modelos suaves

Parada temprana

vigila validación

corta a tiempo

Aumento

más variantes

invariancia

El mapa mental interactivo es interactivo en la versión online.



Dropout [https://en.wikipedia.org/wiki/Dropout_\(neural_networks\)](https://en.wikipedia.org/wiki/Dropout_(neural_networks)) El mecanismo de apagar neuronas al azar y su efecto regularizador.

6. Tu red llega a casi cero de error en entrenamiento pero estancada en validación. ¿Qué combinarías para cerrar esa brecha, y qué señal te diría que ya estás regularizando de más?

Referencia curricular

Grado:	7
Materia:	Redes Neuronales Artificiales · Inteligencia Artificial

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



<https://univ.lumbre.lat/object/cdia-redn-007-regularizacion-en-profundidad-dropout>

Material educativo generado desde Lumbre · lumbre.lat