

# Introducción a la regularización en aprendizaje profundo

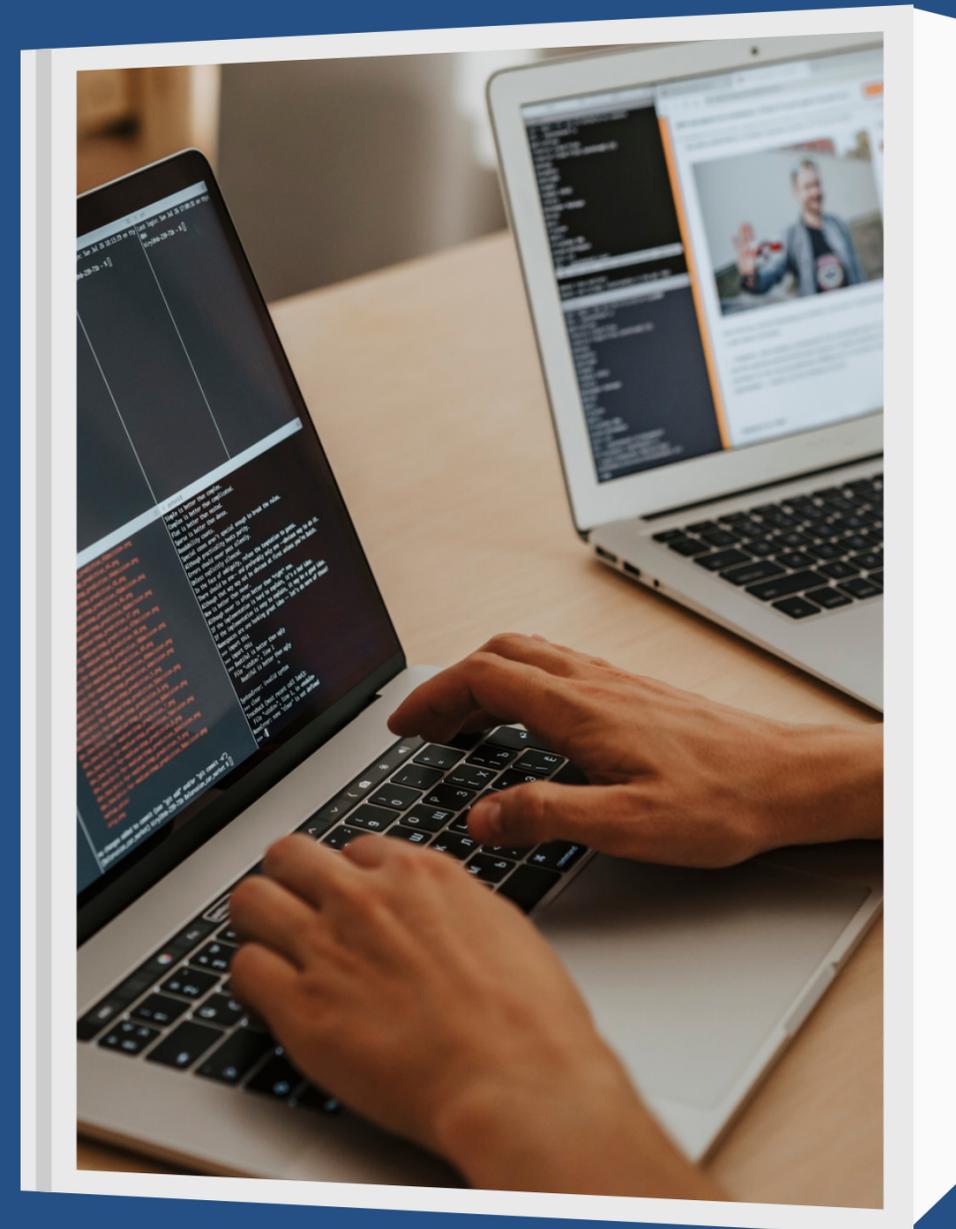
La regularización es una técnica crucial en el aprendizaje profundo que busca prevenir el sobreajuste o la tendencia de un modelo a ajustarse demasiado a los datos de entrenamiento, lo que puede llevar a un rendimiento deficiente en datos nuevos. En modelos complejos, como las **redes neuronales profundas**, existe el riesgo de que el modelo se vuelva muy específico para los datos de entrenamiento, provocando que:

Capture patrones irrelevantes o ruido

Pierda capacidad de generalización

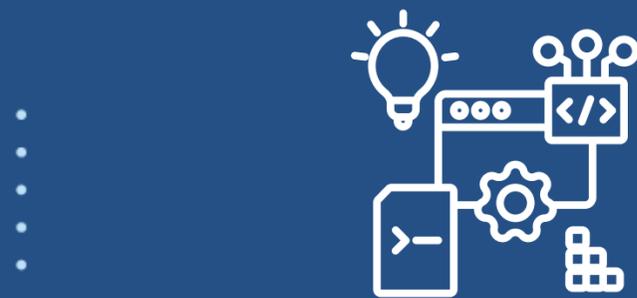


La regularización introduce términos adicionales en la función de pérdida del modelo que penalizan los pesos excesivamente grandes o complejos. Estos términos de penalización ayudan a controlar la complejidad del modelo, evitando que los pesos se disparen y contribuyan al sobreajuste.

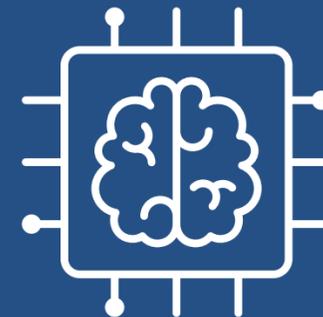




La importancia de la regularización radica en mejorar la capacidad de generalización del modelo, lo que significa que el modelo será capaz de realizar predicciones precisas en nuevos datos no vistos durante el entrenamiento. Al incorporar técnicas de regularización, los modelos de aprendizaje profundo pueden volverse más robustos y efectivos en una variedad de situaciones, incluso cuando los datos son ruidosos o limitados. Estas técnicas pueden ser:



**La penalización de normas**



**Regularización**

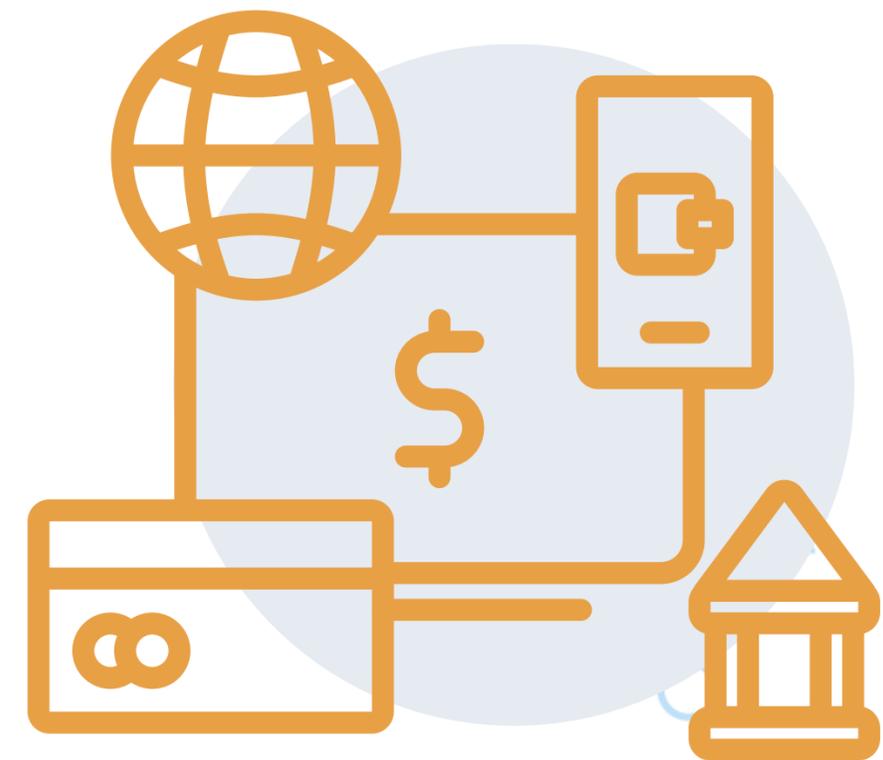


**Dropout**

# Desafíos asociados al sobreajuste y la necesidad de técnicas de regularización

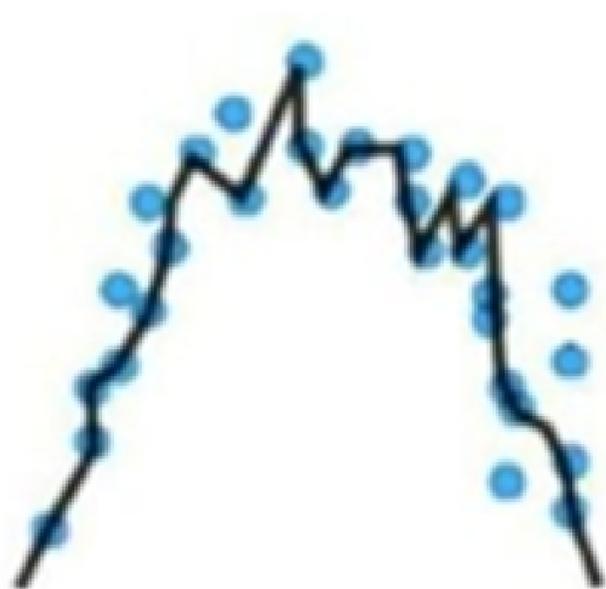
El sobreajuste (overfitting) en redes neuronales es un desafío común que surge cuando el modelo se ajusta demasiado a los datos de entrenamiento, capturando incluso el ruido o la variabilidad aleatoria en lugar de aprender patrones generales. Este fenómeno puede resultar en un rendimiento deficiente en datos nuevos y no vistos durante el entrenamiento.

El sobreajuste (overfitting) puede ser en **regresión**, en **clasificación** y en **deep learning**.

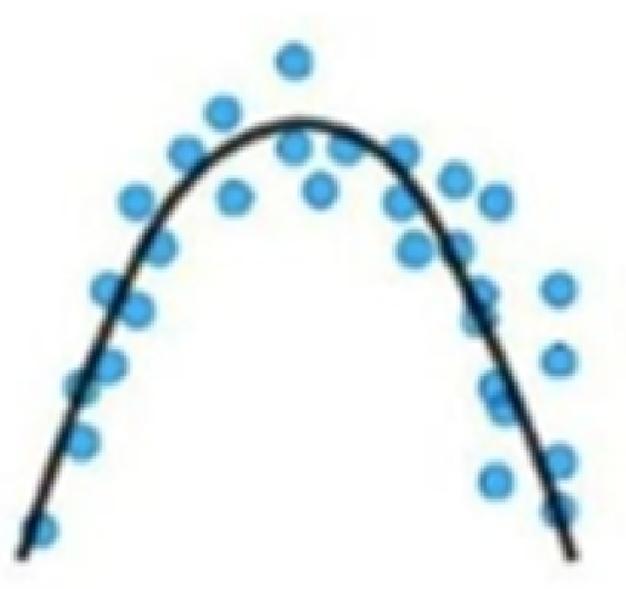


## Overfitting en regresión

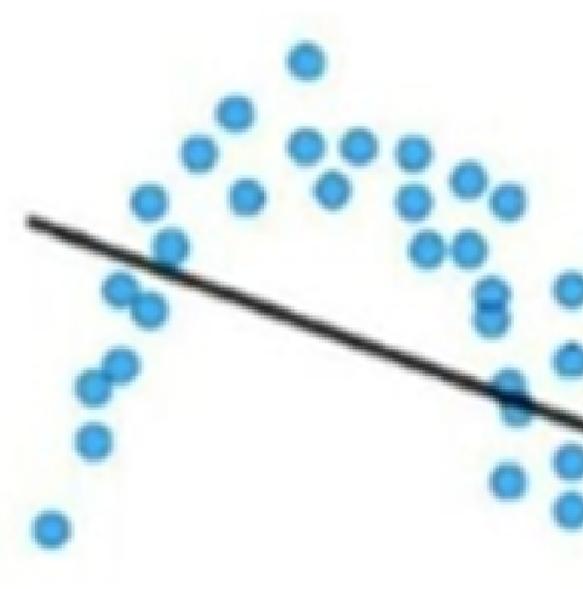
Over-fitting



Optimal-fitting

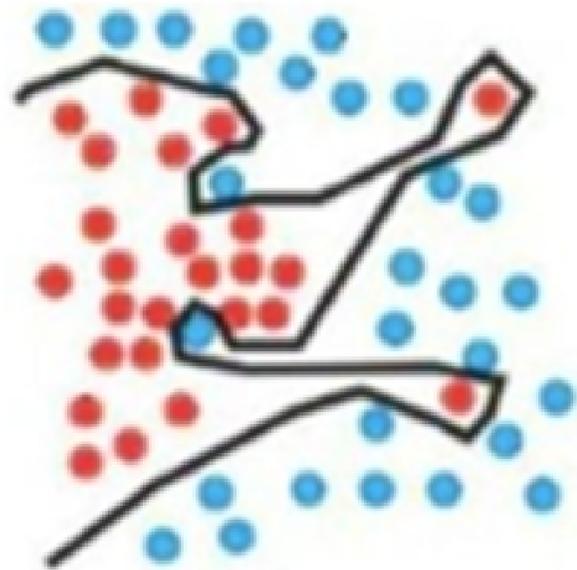


Under-fitting

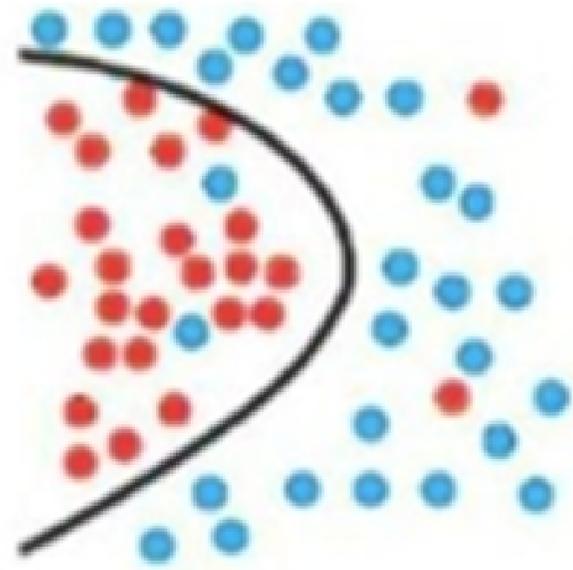


## Overfitting en clasificación

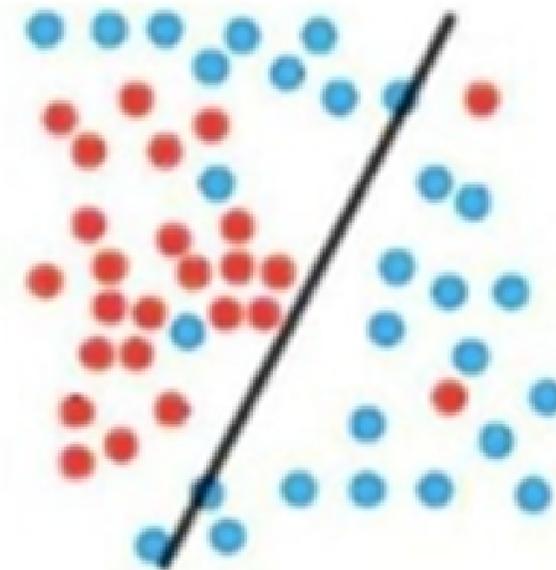
Over-fitting



Optimal-fitting

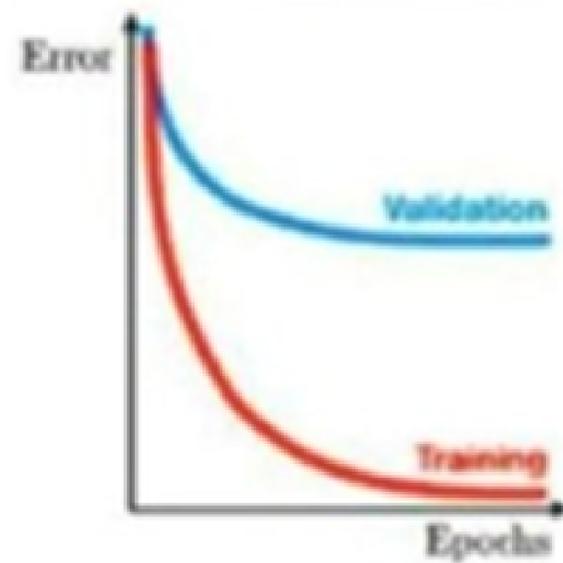


Under-fitting

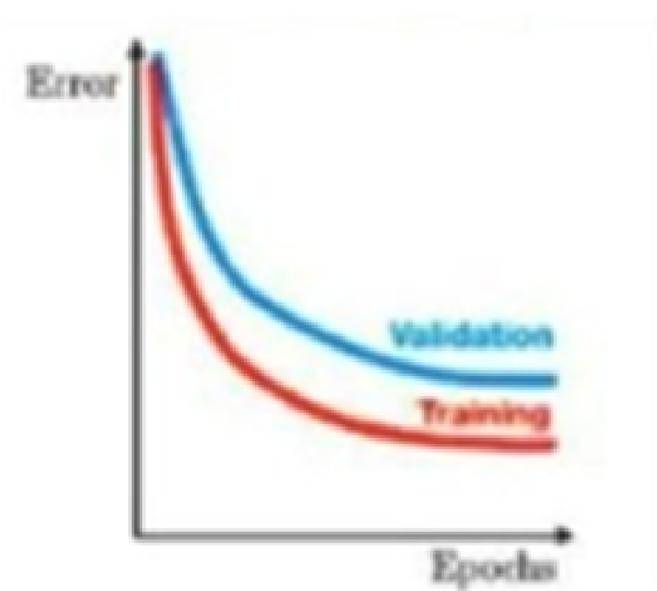


## Overfitting en deep learning

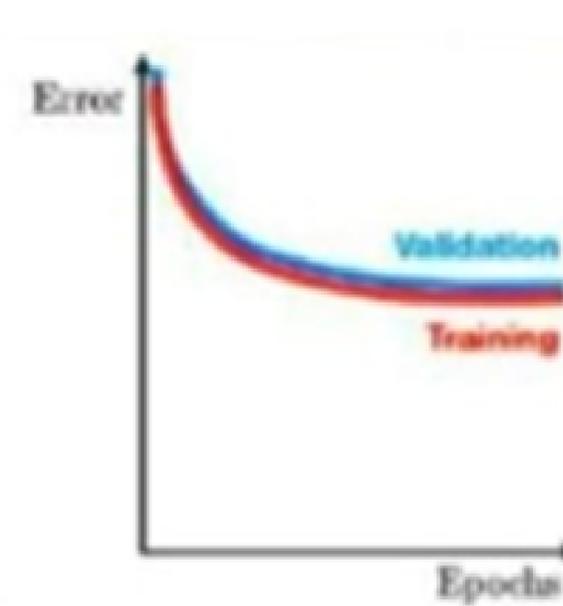
Over-fitting



Optimal-fitting



Under-fitting





Los desafíos asociados al sobreajuste incluyen:

<b>Captura de ruido</b>	<b>Alta varianza</b>	<b>Limitación de la generalización</b>
<p>Las redes neuronales pueden aprender no solo patrones significativos en los datos, sino también el ruido o la variabilidad no deseada. Esto lleva a un modelo que no generaliza bien a nuevos datos.</p>	<p>Un modelo sobreajustado tiende a tener una alta varianza, lo que significa que es muy sensible a pequeñas variaciones en los datos de entrenamiento.</p>	<p>El sobreajuste limita la capacidad del modelo para generalizar a datos no vistos. En lugar de aprender características útiles, el modelo memoriza los datos de entrenamiento.</p>



Para abordar estos desafíos, se utilizan técnicas de regularización. Estas técnicas introducen restricciones en el modelo durante el entrenamiento para evitar que los pesos se vuelvan excesivamente grandes o que el modelo se vuelva demasiado complejo. Al hacerlo, se fomenta una representación más general y útil de los datos, mejorando así la capacidad de generalización del modelo.

Estas estrategias ayudan a controlar la complejidad del modelo y a mitigar los efectos del sobreajuste.

