

# Actividad 3

Ejercicio práctico implementar una red neuronal para clasificación utilizando Keras

# Ejercicio práctico implementar una red neuronal para clasificación utilizando Keras

Pasos a seguir:

- Importación de bibliotecas

Importamos las bibliotecas necesarias. `keras` es la API de alto nivel para construir y entrenar modelos de redes neuronales. `make_classification` es una función de scikit-learn para generar un conjunto de datos de clasificación sintético y `train_test_split` es una función para dividir los datos en conjuntos de entrenamiento y prueba.

```
import keras
from sklearn.datasets import make_classification
from sklearn.model_selection import train_test_split
```

- Generamos un conjunto de datos de clasificación sintético utilizando `make_classification` de scikit-learn.

Creamos un conjunto de datos de clasificación sintética con 100 muestras, 5 características y 2 clases.

# Ejercicio práctico implementar una red neuronal para clasificación utilizando Keras

- Dividimos los datos en conjuntos de entrenamiento y prueba con `train_test_split`.

Dividimos los datos en conjuntos de entrenamiento y prueba. Aquí, el 20% de los datos se reservan para el conjunto de pruebas.

- Convertimos las etiquetas a codificación one-hot utilizando `to_categorical` de Keras.

Convertimos las etiquetas a codificación one-hot utilizando `to_categorical` de Keras. Esto convierte las etiquetas de clases en vectores binarios donde la posición de la clase activa es 1 y todas las demás son 0.

- Creamos un modelo secuencial de Keras con una capa oculta de 10 neuronas y activación ReLU, y una capa de salida con 2 neuronas (una para cada clase) y activación softmax.

Creamos una instancia de un modelo secuencial de Keras.

Añadimos una capa oculta con 10 neuronas y activación ReLU.

Añadimos una capa de salida con 2 neuronas (una para cada clase) y activación softmax.

# Ejercicio práctico implementar una red neuronal para clasificación utilizando Keras

- Compilamos el modelo utilizando el optimizador 'adam' y la función de pérdida 'categorical\_crossentropy'.

Compilamos el modelo utilizando el optimizador Adam, la función de pérdida de entropía cruzada categórica y métricas de precisión.

- Entrenamos el modelo durante 10 épocas en lotes de tamaño 32, utilizando los datos de entrenamiento y validación.

Entrenamos el modelo durante 10 épocas con un tamaño de lote de 32. Utilizamos los conjuntos de validación durante el entrenamiento para monitorear el rendimiento del modelo.



# Ejercicio práctico implementar una red neuronal para clasificación utilizando Keras

- Evaluamos el modelo en el conjunto de prueba y mostramos la pérdida y la precisión obtenidas.

Evaluamos el modelo en el conjunto de prueba y obtenemos la pérdida y la precisión.

Este es un ejercicio básico de cómo implementar una red neuronal para clasificación utilizando Keras. Se pueden ajustar muchos otros parámetros y arquitecturas de red para adaptarse a las necesidades específicas del problema.



Generación de datos de clasificación sintéticos:

```
# Generar un conjunto de datos de clasificación sintético
X, y = make_classification(n_samples=100, n_features=5,
n_classes=2)
```

División de los datos:

```
# Dividir los datos en conjuntos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.2)
```

Codificación one-hot de las etiquetas:

```
# Convertir las etiquetas a codificación one-hot
y_train_categorical = keras.utils.to_categorical(y_train)
y_test_categorical = keras.utils.to_categorical(y_test)
```





Creación del modelo:

```
# Crear una instancia de un modelo secuencial de Keras
model = keras.models.Sequential()
```

Añadir capas al modelo:

```
# Añadir una capa oculta con 10 neuronas y activación ReLU
model.add(keras.layers.Dense(10,
input_shape=(X_train.shape[1],), activation='relu'))
# Añadir una capa de salida con 2 neuronas (una para cada
clase) y activación softmax
model.add(keras.layers.Dense(2, activation='softmax'))
```





Compilación del modelo:

```
# Compilar el modelo
model.compile(optimizer='adam',
              loss='categorical_crossentropy', metrics=['accuracy'])
```

Entrenamiento del modelo:

```
# Entrenar el modelo
model.fit(X_train, y_train_categorical, epochs=10,
         batch_size=32, validation_data=(X_test, y_test_categorical))
```

Evaluación del modelo:



```
# Evaluar el modelo en el conjunto de prueba
loss, accuracy = model.evaluate(X_test, y_test_categorical)
```



Impresión de resultados:

```
print("Pérdida en el conjunto de prueba:", loss)
print("Precisión en el conjunto de prueba:", accuracy)
```

Al ejecutar el código se espera más o menos lo siguiente, pero cada que se ejecute se van a obtener valores un poco diferentes.



```
Epoch 1/10
3/3 [=====] - 1s 79ms/step - loss: 0.5500 - accuracy: 0.7500 - val_loss: 0.4971 - val_accuracy: 0.8500
Epoch 2/10
3/3 [=====] - 0s 12ms/step - loss: 0.5365 - accuracy: 0.7625 - val_loss: 0.4826 - val_accuracy: 0.8500
Epoch 3/10
3/3 [=====] - 0s 12ms/step - loss: 0.5239 - accuracy: 0.7625 - val_loss: 0.4706 - val_accuracy: 0.8500
Epoch 4/10
3/3 [=====] - 0s 13ms/step - loss: 0.5113 - accuracy: 0.7750 - val_loss: 0.4577 - val_accuracy: 0.8500
Epoch 5/10
3/3 [=====] - 0s 12ms/step - loss: 0.4999 - accuracy: 0.7750 - val_loss: 0.4465 - val_accuracy: 0.8500
Epoch 6/10
3/3 [=====] - 0s 12ms/step - loss: 0.4888 - accuracy: 0.7875 - val_loss: 0.4364 - val_accuracy: 0.8500
Epoch 7/10
3/3 [=====] - 0s 11ms/step - loss: 0.4779 - accuracy: 0.8000 - val_loss: 0.4270 - val_accuracy: 0.8500
Epoch 8/10
3/3 [=====] - 0s 12ms/step - loss: 0.4679 - accuracy: 0.8000 - val_loss: 0.4182 - val_accuracy: 0.8500
Epoch 9/10
3/3 [=====] - 0s 12ms/step - loss: 0.4581 - accuracy: 0.8000 - val_loss: 0.4101 - val_accuracy: 0.8500
Epoch 10/10
3/3 [=====] - 0s 12ms/step - loss: 0.4486 - accuracy: 0.8125 - val_loss: 0.4029 - val_accuracy: 0.8500
1/1 [=====] - 0s 18ms/step - loss: 0.4029 - accuracy: 0.8500
Pérdida en el conjunto de prueba: 0.40287724137306213
Precisión en el conjunto de prueba: 0.8500000238418579
```



En este punto se puede pedir a los estudiantes que realicen algún cambio en el código para ver qué efecto tiene.

## Dentro de los cambio se puede plantear:

- Incrementa el número de épocas
- Cambia el tamaño del batch
- Cambia la funcion de activacion
- Añadir más neuronas a las capas existentes.
- Añadir más capas





**TIC**

▶ TALENTO  
**TECH**

**AZ** | PROYECTOS  
EDUCATIVOS

