
Clase 103 — Keras Functional API y Subclassing

Parte: 2 — Deep Learning · Fuente: Géron, cap. 10 § Building Complex Models Using the Functional API y § Building Dynamic Models Using the Subclassing API. Duración estimada: 70 min.

Clase 103 — Keras Functional API y Subclassing

Parte: 2 — Deep Learning · Fuente: Géron, cap. 10 § Building Complex Models Using the Functional API y § Building Dynamic Models Using the Subclassing API. Duración estimada: 70 min.

Objetivo

Construir modelos con topologías no lineales —skip connections, multi-input, multi-output, capas compartidas— usando la Functional API (estilo "grafo de capas"), y modelos con flujo de control dinámico (loops, ifs) usando Subclassing (estilo `class MyModel(Model)` con `call()`). Saber elegir entre las tres APIs según el caso.

Resultados de aprendizaje

Al finalizar, el estudiante podrá:

- Construir un modelo Wide & Deep (clásico de Cheng et al. 2016) con Functional API.
- Construir un modelo multi-output con dos Dense finales y dos losses.
- Implementar un MyResBlock con Subclassing que tiene una skip connection.
- Reconocer el trade-off: Sequential (simple) → Functional (la mayoría de los casos) → Subclassing (cuando hace falta control dinámico).
- Convertir un modelo Functional en JSON / cargar con `model_from_json` (útil para serialización separada de pesos).

Temas

- Functional API: `x = layer(prev_x)`; al final `Model(inputs=[...], outputs=[...])`.
- Multi-input / multi-output: pasar listas o dicts a `inputs=` / `outputs=`.
- Capas compartidas (siamese networks): aplicar la misma instancia de capa a dos entradas distintas.
- Subclassing: heredar de `keras.Model`, definir `__init__` (capas) y `call(self, inputs, training=False)`.
- Cuándo subclassing: control de flujo dinámico, modelos imperativos estilo PyTorch.

Definiciones y características

- Functional API: cada capa se llama como función `output = LayerInstance()(input)`; permite cualquier DAG. Visualizable con `keras.utils.plot_model`.
- Subclassing: Model custom donde `call()` define el forward pass arbitrariamente. Más flexible pero más difícil de serializar y debuggear.
- Skip connection: `y = Add()(x, F(x))` — clave en ResNet (clase 115).
- Capa compartida: `shared = Dense(32)`; `a = shared(x1)`; `b = shared(x2)`. Misma matriz de pesos en ambos.
- `call(self, inputs, training=False)`: el flag `training` distingue forward de entrenamiento (con dropout activo) vs inferencia.

Dataset / recursos

- California Housing para Wide & Deep.
- Librerías: tensorflow, keras.

Ejercicios

1. Wide & Deep: implementá el modelo de Cheng et al. con Functional API — input → wide path (directo a salida) + deep path (Dense × 2 → salida) → Add() → output.
2. Multi-output: predecir simultáneamente precio (regresión) Y rango de precio (clasificación 3 clases) sobre California Housing. Compilar con dict de losses.
3. Capa compartida (siamese): dos imágenes de entrada → mismo encoder Dense(64) aplicado a ambas → concatenar embeddings → clasificación "same/different".
4. ResBlock con Subclassing: implementá una clase ResBlock(Layer) con dos Dense y skip connection. Usala en un modelo Sequential.
5. plot_model: graficá el modelo Wide & Deep con keras.utils.plot_model(model, show_shapes=True). Identificá visualmente las dos rutas.

Homework verificable

Implementar un modelo multi-output en California Housing:

1. Predecir median_house_value (regresión, loss MSE).
2. Predecir expensive (binario: above/below mediana, loss BCE).
3. Compartir las 2 primeras capas Dense (representación común) y luego ramificar.
4. Compilar con loss=[mse, bce], loss_weights=[0.7, 0.3].
5. Entrenar y reportar MAE + accuracy.

Criterio de aceptación: el modelo entrena sin errores, MAE razonable (< \$50k), accuracy ≥ 0.85; plot_model muestra la rama compartida + dos heads.

Errores comunes

| Síntoma / mensaje | Causa y cómo arreglar |
|--|---|
| ValueError: A merge layer should be called | Add()(x, y) en vez de Add()([x, y]). Fix: |
| Subclass call() no respeta training y drop | Fix: aceptar training=False como argumento |
| model.save() falla en subclass | Subclassing requiere implementar get_config |
| Multi-output con loss='mse' (un solo str) | Aplica MSE a las dos salidas. Fix: pasar l |
| Capa creada dentro de call() en cada forward | Crea pesos nuevos cada vez → no aprende. F |

Preguntas frecuentes

¿Funcional o Subclassing?

Funcional por default. Es más fácil de serializar, visualizar y debuggear. Subclassing solo si necesitás control de flujo dinámico (loops, ifs sobre el input — raro en práctica salvo RNN custom).

¿Puedo mezclar Sequential dentro de Funcional?

Sí. inner = Sequential([Dense(64), Dense(32)]); out = inner(x) — Sequential es un Layer válido.

¿Functional es más lento que Sequential?

No, mismo grafo por debajo.

¿Cuándo necesito multi-input?

Cuando tenés modalidades distintas (imagen + metadatos del usuario, texto + features numéricas). Cada modalidad tiene su input y su encoder; al final se concatenan.

¿Add() o Concatenate()?

Add() para skip connections (preserva dimensión). Concatenate() para fusión de modalidades (suma dimensiones).

Referencias

- Géron, cap. 10 — The Functional API y The Subclassing API.
- Cheng et al. (2016), Wide & Deep Learning for Recommender Systems, DLRS.
- Keras — The Functional API.
- Keras — Making new layers and models via subclassing.

Siguiente clase

Clase 104 — Callbacks, TensorBoard, guardar/restaurar modelos

Apéndice: notebook (primer bloque)

Primera celda ejecutable del notebook de la clase.

```
# Imports y configuración inicial
```

Archivos complementarios

- notebook.ipynb