

Modelo Light CNN-9 para reconocimiento de emociones

Entrenamiento, Evaluación y Ejecución

Dr. Hugo Arnoldo Mitre Hernández

CIMAT Zacatecas

Marzo 2026

Dataset de expresiones faciales

Para el entrenamiento del modelo se utilizó el conjunto de datos **Radboud Faces Database (RaFD)**.

Este dataset contiene imágenes de rostros humanos con diferentes expresiones emocionales capturadas en condiciones controladas de iluminación y posición.

Las clases consideradas en este estudio fueron:

- enojado
- feliz
- miedo
- neutral
- sorpresa
- triste

Las imágenes originales tienen una resolución aproximada de 681×1024 píxeles.

Cada carpeta del dataset corresponde a una clase emocional utilizada para el entrenamiento supervisado del modelo.

Preprocesamiento de las imágenes

Antes del entrenamiento del modelo se aplicaron varias transformaciones para estandarizar las entradas de la red neuronal.

- Redimensionamiento de las imágenes a 128×128 píxeles
- Conversión a escala de grises
- Normalización de intensidades en el rango $[0, 1]$

Además, se aplicaron técnicas de *data augmentation* para mejorar la capacidad de generalización del modelo:

- rotación aleatoria
- zoom aleatorio
- volteo horizontal

Estas transformaciones permiten generar variaciones de las imágenes durante el entrenamiento y reducir el riesgo de sobreajuste.

Modelo LightCNN-9

El modelo utilizado es LightCNN-9, una arquitectura convolucional diseñada para tareas de análisis facial.

La red emplea una función especial denominada *Max Feature Map (MFM)* definida como:

$$MFM(x_1, x_2) = \max(x_1, x_2)$$

Esta operación selecciona el mapa de características más informativo entre dos filtros convolucionales.

La arquitectura del modelo incluye:

- capas convolucionales con activación MFM
- operaciones de *max pooling*
- capas densas finales
- capa *softmax* para clasificación en seis clases

El entrenamiento se realiza mediante la función de pérdida *cross entropy* y el optimizador Adam.

Evaluación del modelo

El rendimiento del modelo se evaluó utilizando métricas estándar de clasificación multiclase.

- Accuracy
- F1-score
- Matriz de confusión

La métrica de exactitud se define como:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

El F1-score combina precisión y recall:

$$F1 = 2 \cdot \frac{precision \cdot recall}{precision + recall}$$

La matriz de confusión permite analizar el desempeño del modelo en cada una de las clases emocionales.

Archivo 1: train_lightcnn_rafd.py – Configuración

```
1 import tensorflow as tf                # Biblioteca de aprendizaje profundo
2 from tensorflow.keras import layers, models # Capas y modelos de Keras
3 import pathlib                          # Manejo de rutas de archivos
4
5 # CONFIGURACION: Tamano de imagen y lotes
6 img_size = (128, 128)                 # Redimensionamos a 128x128 pixeles
7 batch_size = 32                       # Procesamos 32 imagenes a la vez
```

¿Qué hace? Importa las herramientas necesarias y define el tamaño de las imágenes (128×128 píxeles en escala de grises) y cuántas imágenes procesar por lote (32).

Listing 1: Normalización y aumento de datos

```
1 # Normalizacion: convierte pixeles de [0,255] a [0,1]
2 normalization_layer = layers.Rescaling(1./255)
3 train_ds = train_ds.map(lambda x, y: (normalization_layer(x), y))
4
5 # Aumento de datos: crea variaciones artificiales
6 data_augmentation = tf.keras.Sequential([
7     layers.RandomFlip("horizontal"),      # Voltea horizontalmente
8     layers.RandomRotation(0.05),          # Rota +-5%
9     layers.RandomZoom(0.1)                # Zoom +-10%
10 ])
```

¿Qué hace? Normalización: divide cada pixel por 255 para tener valores entre 0 y 1.

Aumento de datos: genera versiones ligeramente modificadas de las imágenes para que el modelo aprenda mejor.

Listing 2: Max Feature Map: la innovacion de LightCNN

```
1 class MFM(layers.Layer):
2     def __init__(self, filters, kernel_size, ...):
3         # Crea el doble de filtros (ej: 48 -> 96)
4         self.conv = layers.Conv2D(filters*2, kernel_size, ...)
5
6     def call(self, x):
7         x = self.conv(x)                # Aplica convolucion
8         x1, x2 = tf.split(x, 2, -1)    # Divide en 2 mitades
9         return tf.maximum(x1, x2)      # Toma el maximo
```

¿Qué hace? MFM es la clave de LightCNN. En lugar de usar ReLU, crea el doble de filtros, los divide en 2 y toma el máximo. Esto reduce parámetros y mejora la selección de características.

Archivo 1: train_lightcnn_rafd.py – Arquitectura Completa

Listing 3: Construcción de la red neuronal

```
1 inputs = layers.Input(shape=(128,128,1)) # Entrada: imagen 128x128 gris
2
3 x = data_augmentation(inputs) # Paso 1: Aumento de datos
4
5 # Paso 2: Bloques convolucionales con MFM y pooling
6 x = MFM(48, 5)(x); x = layers.MaxPool2D(2)(x) # 128->64
7 x = MFM(96, 3)(x); x = layers.MaxPool2D(2)(x) # 64->32
8 x = MFM(192, 3)(x); x = layers.MaxPool2D(2)(x) # 32->16
9 x = MFM(128, 3)(x); x = layers.MaxPool2D(2)(x) # 16->8
10
11 x = layers.Flatten()(x) # Paso 3: Aplana a vector
12 x = MFMDense(256)(x) # Paso 4: Capa densa con MFM
13 x = layers.Dropout(0.5)(x) # Paso 5: Apaga 50% neuronas (evita sobreajuste)
14 outputs = layers.Dense(6, activation="softmax")(x) # Paso 6: 6 clases de salida
```

¿Qué hace? Construye la red: 4 bloques convolucionales que reducen la imagen de 128→8 píxeles, luego capas densas para clasificar en 6 emociones.

Archivo 1: train_lightcnn_rafd.py – Entrenamiento y Guardado

Listing 4: Compilacion, entrenamiento y guardado

```
1 # Configura como aprender
2 model.compile(
3     optimizer="adam",                # Algoritmo de optimizacion
4     loss="sparse_categorical_crossentropy", # Funcion de error
5     metrics=["accuracy"]             # Metrica: precision
6 )
7
8 # Entrena por 25 epocas (pasa 25 veces por todos los datos)
9 history = model.fit(train_ds, epochs=25)
10
11 # Guarda el modelo entrenado para usarlo despues
12 model.save("lightcnn9_rafd.h5")
```

¿Qué hace? **Compile**: configura el cómo aprender (Adam ajusta pesos, crossentropy mide error). **Fit**: entrena 25 épocas. **Save**: guarda el modelo en disco.

1. ¿Qué es Softmax?

Problema: La red neuronal devuelve 6 números (logits), pero necesitamos **probabilidades** que sumen 1.

Fórmula Softmax:

$$\sigma(z_i) = \frac{e^{z_i}}{e^{z_1} + e^{z_2} + e^{z_3} + e^{z_4} + e^{z_5} + e^{z_6}}$$

Ejemplo visual:

	Entrada	→	Cálculo	→	Salida	
Enojado	0.5		$e^{0,5} = 1,65$		0.09	(9 %)
Feliz	2.0		$e^{2,0} = 7,39$		0.50	(50 %)
Miedo	-1.0		$e^{-1,0} = 0,37$		0.02	(2 %)
Neutral	0.0		$e^{0,0} = 1,00$		0.07	(7 %)
Sorpresa	1.0		$e^{1,0} = 2,72$		0.18	(18 %)
Triste	-0.5		$e^{-0,5} = 0,61$		0.04	(4 %)
Suma					1.00	(100 %)

La clase con mayor logit (Feliz = 2.0) obtiene la mayor probabilidad (50 %).

2. Propiedades de Softmax

Características:

- 1 **Normalización:** Todas las probabilidades suman exactamente 1.
- 2 **Positividad:** Todas las salidas son > 0 (gracias a e^x).
- 3 **Amplificación:** Diferencias pequeñas en logits $\rightarrow$ grandes diferencias en probabilidades.
- 4 **Diferenciable:** Se puede derivar para entrenar con gradient descent.

Decisión final:

Clase predicha = $\arg \max(p_1, p_2, p_3, p_4, p_5, p_6)$

Es decir: el índice con mayor probabilidad.

Comparación: Logits vs Probabilidades

Emoción	Logit	Prob.
Enojado	0.5	9 %
Feliz	2.0	50 %
Miedo	-1.0	2 %
Neutral	0.0	7 %
Sorpresa	1.0	18 %
Triste	-0.5	4 %

Observación: Feliz tiene solo 2x el logit de Sorpresa (2.0 vs 1.0), pero 2.8x la probabilidad (50 % vs 18 %).

Softmax “exagera” las diferencias.

Listing 5: Importaciones y definicion de capas

```
1 import tensorflow as tf
2 import numpy as np
3 import pathlib
4 import matplotlib.pyplot as plt
5 from sklearn.metrics import confusion_matrix, classification_report, ...
6
7 # DEFINIR CAPAS PERSONALIZADAS (mismas que en entrenamiento)
8 class MFM(tf.keras.layers.Layer): ... # Igual que antes
9 class MFMDense(tf.keras.layers.Layer): ... # Igual que antes
```

¿Qué hace? Importa herramientas para evaluar. **Importante:** debe redefinir las capas MFM porque al cargar el modelo guardado, TensorFlow necesita saber qué son.

Archivo 2: evaluate_lightcnn.py – Carga del Modelo

Listing 6: Carga del modelo entrenado

```
1 # Diccionario con las capas personalizadas
2 custom_objects = {'MFM': MFM, 'MFMDense': MFMDense}
3
4 # Carga el modelo usando las capas definidas
5 with tf.keras.utils.custom_object_scope(custom_objects):
6     model = tf.keras.models.load_model("lightcnn9_rafd.h5", compile=False)
7
8 print("Modelo cargado exitosamente")
```

¿Qué hace? Carga el archivo .h5 guardado. El custom_object_scope le dice a TensorFlow usa estas definiciones de MFM y MFMDense cuando encuentres esas capas en el archivo".

Archivo 2: evaluate_lightcnn.py – Predicciones

Listing 7: Obtener predicciones del modelo

```
1 y_true = []      # Lista para guardar etiquetas reales
2 y_pred = []      # Lista para guardar predicciones del modelo
3
4 # Itera por todos los lotes del dataset
5 for images, labels in test_ds:
6     preds = model.predict(images, verbose=0) # Predice probabilidades
7     preds = np.argmax(preds, axis=1)         # Toma la clase con mayor prob.
8
9     y_pred.extend(preds)                    # Guarda predicciones
10    y_true.extend(labels.numpy())           # Guarda etiquetas reales
11
12 y_true = np.array(y_true) # Convierte a arrays de NumPy
13 y_pred = np.array(y_pred)
```

¿Qué hace? Pasa todas las imágenes por el modelo, obtiene predicciones (6 números = probabilidades por clase), toma el índice del máximo (la clase predicha), y guarda tanto predicciones como valores reales para comparar.

Listing 8: Calculo de metricas de rendimiento

```
1 # Precision global: aciertos / total
2 acc = accuracy_score(y_true, y_pred)
3 print(f"Accuracy: {acc:.4f}") # Ej: 0.8534 = 85.34%
4
5 # F1-score: balance entre precision y recall
6 f1 = f1_score(y_true, y_pred, average="weighted")
7 print(f"F1-score: {f1:.4f}")
8
9 # Reporte detallado por clase
10 print(classification_report(y_true, y_pred, target_names=class_names))
11 # Muestra: precision, recall, f1-score para cada emocion
```

¿Qué hace? Calcula métricas: **Accuracy** (% de aciertos totales), **F1-score** (balance entre precisión y sensibilidad), y **reporte por clase** (cómo le fue a cada emoción individualmente).

Archivo 2: evaluate_lightcnn.py – Matriz de Confusión

Listing 9: Matriz de confusion y visualizacion

```
1 # Crea matriz: filas=real, columnas=prediccion
2 cm = confusion_matrix(y_true, y_pred)
3
4 # Visualizacion con matplotlib
5 plt.figure(figsize=(10, 8))
6 plt.imshow(cm, interpolation="nearest", cmap=plt.cm.Blues)
7 plt.title("Confusion Matrix")
8 plt.colorbar()
9 plt.xticks(tick_marks, class_names, rotation=45)
10 plt.yticks(tick_marks, class_names)
11
12 # Escribe el numero en cada celda
13 for i in range(len(class_names)):
14     for j in range(len(class_names)):
15         plt.text(j, i, cm[i,j], ha="center", va="center")
16
17 plt.savefig('confusion_matrix.png') # Guarda imagen
18 plt.show()                          # Muestra en pantalla
```

Archivo 3: realtime_emotion.py – Configuración

Listing 10: Importaciones y definicion de capas (igual que antes)

```
1 import cv2                                # OpenCV: vision por computadora
2 import tensorflow as tf
3 import numpy as np
4
5 # DEFINIR CAPAS PERSONALIZADAS (MFM y MFMDense)
6 class MFM(tf.keras.layers.Layer): ...
7 class MFMDense(tf.keras.layers.Layer): ...
8
9 # Cargar modelo entrenado
10 custom_objects = {'MFM': MFM, 'MFMDense': MFMDense}
11 with tf.keras.utils.custom_object_scope(custom_objects):
12     model = tf.keras.models.load_model("lightcnn9_rafd.h5", compile=False)
13
14 class_names = ["enojado", "feliz", "miedo", "neutral", "sorpresa", "triste"]
```

¿Qué hace? Importa OpenCV (cv2) para acceder a la cámara. Carga el mismo modelo entrenado. Define los nombres de las 6 emociones para mostrarlas en pantalla.

Listing 11: Inicializacion del detector de rostros

```
1 # Carga el clasificador Haar Cascade (incluido en OpenCV)
2 face_cascade = cv2.CascadeClassifier(
3     cv2.data.haarcascades + "haarcascade_frontalface_default.xml"
4 )
5
6 # Abre la camara (0 = camara por defecto)
7 cap = cv2.VideoCapture(0)
8
9 print("Presiona 'q' para salir")
```

¿Qué hace? Carga un detector de rostros pre-entrenado (Haar Cascade) que viene con OpenCV. Abre la cámara web. El archivo .xml contiene patrones para detectar rostros frontales.

Listing 12: Captura y procesamiento de video

```
1 while True:
2     ret, frame = cap.read()           # Lee un frame de la camara
3     if not ret:
4         break
5
6     gray = cv2.cvtColor(frame, cv2.COLOR_BGR2GRAY) # Convierte a grises
7
8     # Detecta rostros en la imagen
9     faces = face_cascade.detectMultiScale(
10         gray,
11         scaleFactor=1.3,      # Reduccion de escala entre busquedas
12         minNeighbors=5        # Minimo de vecinos para confirmar rostro
13     )
```

¿Qué hace? Bucle infinito que: 1) Captura frame de la cámara, 2) Convierte a escala de grises (el modelo fue entrenado así), 3) Busca rostros con el detector Haar.

Listing 13: Procesamiento de cada rostro detectado

```
1 for (x, y, w, h) in faces:                # Para cada rostro encontrado
2     face = gray[y:y+h, x:x+w]             # Recorta la region del rostro
3
4     face = cv2.resize(face, (128, 128))    # Redimensiona a 128x128
5     face = face / 255.0                    # Normaliza a [0,1]
6     face = np.reshape(face, (1, 128, 128, 1)) # Formato: (batch, h, w, canales)
7
8     prediction = model.predict(face, verbose=0) # Predice emocion
9     emotion_index = np.argmax(prediction)      # Clase con mayor prob.
10    emotion = class_names[emotion_index]       # Nombre de la emocion
11    confidence = np.max(prediction)            # Probabilidad (0-1)
```

¿Qué hace? Para cada rostro: recorta, prepara igual que en entrenamiento (128×128 , normalizado), predice con el modelo, obtiene la emoción y su confianza.

Archivo 3: realtime_emotion.py – Visualización

Listing 14: Dibujar resultados en pantalla

```
1  # Crea etiqueta: "feliz (0.92)"
2  label = f"{emotion} ({confidence:.2f})"
3
4  # Dibuja rectangulo verde alrededor del rostro
5  cv2.rectangle(frame, (x, y), (x+w, y+h), (0, 255, 0), 2)
6
7  # Escribe la emocion arriba del rectangulo
8  cv2.putText(frame, label, (x, y-10),
9              cv2.FONT_HERSHEY_SIMPLEX,      # Tipo de letra
10             0.9,                            # Tamaño
11             (0, 255, 0),                    # Color verde (BGR)
12             2)                              # Grosor
13
14  cv2.imshow("Emotion Recognition", frame)  # Muestra en ventana
15
16  if cv2.waitKey(1) & 0xFF == ord("q"):    # Si presionas 'q', sale
17      break
```

¿Qué hace? Dibuja un rectángulo verde alrededor del rostro y muestra la emoción predicha

Listing 15: Liberar recursos al terminar

```
1 cap.release()           # Libera la camara (apaga)
2 cv2.destroyAllWindows() # Cierra todas las ventanas de OpenCV
```

¿Qué hace? Libera la cámara para que otros programas puedan usarla y cierra las ventanas. **Importante:** si no se hace, la cámara queda "bloqueada" hasta reiniciar.

Resumen: Flujo Completo del Sistema

Orden	Archivo	Función
1	<code>train_lightcnn_rafd.py</code>	Entrena el modelo con imágenes etiquetadas. Crea <code>lightcnn9_rafd.h5</code>
2	<code>evaluate_lightcnn.py</code>	Evalúa qué tan bueno es el modelo. Genera métricas y matriz de confusión
3	<code>realtime_emotion.py</code>	Usa el modelo en vivo con la cámara web

Dependencias: Los 3 archivos necesitan las mismas definiciones de MFM y MFMDense para que el modelo funcione correctamente.

Gracias