

# Clasificación de rostros con aprendizaje hebbiano para bases de datos pequeñas

Fernando Aguilar-Canto, Alberto Espinosa-Juárez,  
Juan Eduardo Luján-García, Hiram Calvo

Instituto Politécnico Nacional,  
Centro de Investigación en Computación,  
México

{faguilarc2021, aespinosaj2021, jlujang2020,  
hcalvo}@cic.ipn.mx

**Resumen.** El aprendizaje hebbiano es un paradigma biológicamente plausible de optimización paramétrica en Redes Neuronales Artificiales. En años recientes, varias reglas hebbianas han sido incluidas en arquitecturas de Aprendizaje Profundo. No obstante, estas implementaciones están principalmente enfocadas en demostrar el potencial del aprendizaje hebbiano, y poca investigación se ha desarrollado en problemas específicos, como la clasificación de rostros. En este artículo, los autores presentan una aplicación del aprendizaje hebbiano en clasificación de rostros utilizando tanto una base de datos pública como privada. Asimismo, las reglas de aprendizaje hebbiano implementadas fueron la regla de Hebb Simple, la regla de Oja y la regla BCM. En general, el algoritmo de kNN mostró mejores resultados comparativos para esta tarea, mientras que las reglas de aprendizaje hebbiano fueron particularmente sensibles al desbalance de los datos. Para mitigar el problema, los autores introdujeron reglas de Hebb escaladas, las cuales lograron mejores resultados en comparación de las versiones no escaladas, teniendo un desempeño cercano al de optimizadores basados en el gradiente como el algoritmo de Adam.

**Palabras clave:** Aprendizaje hebbiano, clasificación de rostros, redes neuronales artificiales.

## Face Classification with Hebbian Learning for Small Datasets

**Abstract.** Hebbian learning is a biologically plausible paradigm for parametric optimization in Artificial Neural Networks. In recent years, several Hebbian-based rules have been integrated into Deep Learning architectures. However, most of these implementations have primarily focused on demonstrating the potential of Hebbian Learning, with limited research conducted on specific problems, such as face classification. This paper presents an application of Hebbian Learning in face classification, utilizing both a public and a private dataset. The authors implemented three Hebbian learning rules: the Basic Hebb rule, the Oja rule, and the BCM rule. Although the kNN algorithm

yielded better comparative results for this task, the Hebbian-based rules exhibited sensitivity to imbalanced data. To address this issue, the authors introduced Scaled-Hebbian learning rules, which achieved improved results compared to the non-scaled versions. These rules performed at a similar level to gradient-based optimizers, such as the Adam algorithm.

**Keywords:** Hebbian learning, face classification, artificial neural networks.

## 1. Introducción

El aprendizaje hebbiano es un mecanismo de aprendizaje biológicamente plausible a nivel neuronal que modela los fenómenos de plasticidad sináptica (cambios en las fuerzas de conexión de las neuronas<sup>1</sup>) conocidos como Potenciación a Largo Plazo (Long-Term Potentiation, LTP) y Depresión a Largo Plazo (Long-Term Depression, LTD) [10, 29]. La plasticidad sináptica, en forma de LTP y LTD, proporciona las bases de numerosos modelos de aprendizaje y memoria, así como el desarrollo de los mapas corticales en el cerebro [1].

En el contexto de computación, el aprendizaje hebbiano está conformada de una familia de reglas de aprendizaje inspiradas en la neuroplasticidad, en donde el cambio de los pesos sinápticos incrementa proporcionalmente a los valores de las actividades (medidas en tasa de disparo o potenciales de acción) de las neuronas presinápticas y postsinápticas [5].

En su versión general, una regla de aprendizaje hebbiana está dada por el cambio de los pesos  $\Delta_w = H(x, y, w, h)$ , donde  $H$  es una función que modela dicho cambio,  $x$  es el valor de actividad de la neurona presináptica,  $y$  la actividad de la neurona postsináptica,  $w$  es el peso entre ambas neuronas y  $h$  es el “tercer factor” mediado por neuromoduladores [21]. El aprendizaje hebbiano ha sido empleado en el contexto del aprendizaje profundo (Deep Learning), en particular con el uso de redes neuronales convolucionales (Convolutional Neural Networks, ConvNets) [5, 22, 3, 27].

La clasificación de rostros es el proceso de clasificar caras en diferentes categorías [34], que pueden pertenecer a personas individuales (como este trabajo), género [17], etnicidad [12] u otras clases. En el contexto de aprendizaje de máquina, muchos clasificadores de rostros utilizan ConvNets, debido a que son robustos a transformaciones de imágenes [26], y como consecuencia, en general han sido efectivas en tareas relacionadas con imágenes [20].

Aunque la clasificación de rostros es un tópico principal en aprendizaje profundo, se ha implementado escasamente con aprendizaje hebbiano (véanse los Trabajos relacionados en la Sección 2). En este trabajo, se hace una implementación de clasificación de rostros utilizando aprendizaje hebbiano con modelos pre-entrenados. La intención de este trabajo es doble: por un lado expandir los límites del aprendizaje hebbiano profundo (tradicionalmente aplicado en bases de datos como MNIST o CIFAR) y evaluar el desempeño del mismo en contextos diferentes.

<sup>1</sup> Es equivalente al ajuste paramétrico de pesos en redes artificiales

De igual forma, nos hemos centrado en bases de datos pequeñas, debido a que la disponibilidad de datos para ciertos fines comerciales muchas veces se restringe a este tipo de problemáticas. Un ejemplo práctico donde este problema aparece, es en la clasificación de rostros de personas pertenecientes a un grupo pequeño, por ejemplo, los estudiantes de un aula o miembros de una junta directiva, con el fin de registrar asistencia de forma automática.

Adicionalmente, es ampliamente conveniente que el sistema aprenda en tiempo real (online) porque eso puede permitir que los usuarios ingresen únicamente las caras y las etiquetas (por voz) de las personas a clasificar, sin tener que utilizar un proceso de entrenamiento que puede demandar supervisión experta. Dado que las reglas hebbianas realizan aprendizaje en tiempo real [3], son candidatas ideales para este tipo de tareas.

Este trabajo se estructura de la siguiente manera: en la sección 2 presentamos los trabajos relacionados con el nuestro; en la sección 3 presentamos a la arquitectura para su evaluación; en la sección 4 mostramos los resultados y una comparación con otras técnicas, así como algunas observaciones relevantes; en la sección 5 recabamos una discusión sobre las observaciones alcanzadas; y finalmente las conclusiones se presentan en la sección 6.

## **2. Trabajos relacionados**

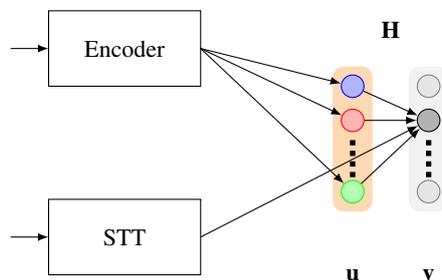
El aprendizaje hebbiano profundo puede definirse como el conjunto de técnicas que utilizan tanto redes neuronales profundas como arquitectura, así como algunas reglas de aprendizaje hebbiano, ya sea en toda la arquitectura o parcialmente.

En el caso particular de la Clasificación de rostros, que es el problema presentado en este artículo, se han utilizado diferentes técnicas con redes neuronales, destacando las ConvNets [8, 12, 17, 33] y el hardware neuromórfico [34].

A pesar de la existencia de implementaciones en cómputo neuromórfico (donde se suele utilizar la regla de Hebb) para el problema de clasificación de rostros, existen pocos trabajos sobre aprendizaje hebbiano en este tópico y un caso similar se observa en el similar problema de reconocimiento de rostros (face recognition). Para el caso de clasificación de ciertas categorías de rostros, en [16] se utiliza un método de detección de coincidencia con redes pulsantes y la regla de Plasticidad Dependiente del Tiempo del Impulso (Spike-Timing Dependent Plasticity) [28].

En cuanto a la detección de rostros, se tienen más trabajos relacionados. En [24] se aplica a la Regla de Oja para implementar una versión del modelo jerárquico de la visión extendido a la Corteza Infratemporal [31], permitiendo reconocer si dos caras son idénticas con invariancia a rotaciones.

Previo al surgimiento del aprendizaje profundo, se exploraron ideas para la clasificación de rostros como en [11], con el uso del Algoritmo Hebbiano Generalizado. Por otro lado, en [6], se implementa el Aprendizaje Hebbiano Competitivo y una red atractiva para obtener una clasificación de rostros robusta e invariante a la pose.



**Fig. 1.** Representación del esquema de [3] donde el vector  $\mathbf{u}$  representa la salida del codificador visual (generalmente una red convolucional o transformador visual),  $\mathbf{v}$  representa a la codificación one-hot de las etiquetas,  $\mathbf{H}$  representa la matriz de pesos que relaciona ambos vectores de forma lineal.

### 3. Metodología

El objetivo principal que se persigue para este artículo es el aprendizaje en tiempo real para la clasificación de imágenes de rostros de personas individuales. Esto puede ser auxiliado con el uso de transferencia de aprendizaje con otras arquitecturas.

La metodología que se utiliza para este artículo consiste en utilizar el esquema presentado en el artículo de [3], representada en la figura 1, en la cual se dispone de un codificador visual que devuelve un vector de características  $\mathbf{u}$ . Normalmente, este codificador es una red neuronal convolucional preentrenada o un transformador visual.

El vector  $\mathbf{v}$  representa a la codificación one-hot de las etiquetas (que podrían ser introducidas por voz). Asimismo, el vector  $\mathbf{v}$  puede ser aproximado mediante la operación  $\mathbf{H}\mathbf{u}$ , de forma que la matriz de pesos  $\mathbf{H}$  es una aproximación lineal del vector de características al vector de etiquetas. Esta matriz de pesos  $\mathbf{H}$  se entrena utilizando aprendizaje hebbiano.

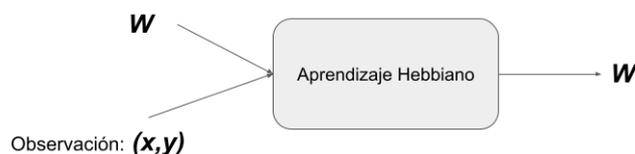
#### 3.1. Reglas de Hebb

Existen varias formulaciones de la llamada “regla de Hebb”, que conforman modelos de plasticidad sináptica. En este artículo consideraremos tres principales: la regla de Hebb Simple, la Regla de Oja (empleada en [24]), y la Regla BCM. Estas reglas se expresan en términos de ecuaciones diferenciales, pero se pueden discretizar utilizando el Método de Euler. Por lo general, estas reglas se pueden ejecutar en tiempo real, ya que reciben un dato a la vez y actualizan los parámetros de la red (véase la figura 2).

**Regla de Hebb Simple.** Consideremos un vector de tasa de disparo presináptico  $\mathbf{u}$  y la neurona postsináptica  $v$ , con el vector de pesos  $\mathbf{w}$ . La formulación más simple de la regla de Hebb está dada por la ecuación diferencial (Eq. 1) mostrada en [14]:

$$\tau_w \frac{d\mathbf{w}}{dt} = v\mathbf{u}, \quad (1)$$

donde  $\tau_w > 0$  es una constante que controla la razón de cambio de los pesos. Sin embargo, esta regla de aprendizaje presenta el problema del crecimiento no acotado de los pesos sinápticos.



**Fig. 2.** Esquema de ajuste de parámetros con aprendizaje hebbiano. Un dato etiquetado  $(x, y)$  es recibido y la red ajusta sus pesos  $W$ . En este sentido, no es necesario enviar un lote de entrenamiento o ver todo el conjunto de datos, sino que con un solo dato se realizan los ajustes.

**Regla de Oja.** La regla de Oja [30] es una solución al problema del crecimiento no acotado de los pesos al introducir normalización. La regla de Oja (Eq. 4) se puede describir con la ecuación diferencial. En este caso se fijó  $\beta = 0.01$ :

$$\tau_w \frac{d\mathbf{w}}{dt} = v\mathbf{u} - \beta v^2 \mathbf{w}. \quad (2)$$

**Regla BCM.** Otra solución al problema del crecimiento no acotado de los pesos está dada por la regla Bienenstock-Cooper-Munro (BCM), la cual introduce un umbral dinámico para regular los pesos y considera tanto a los fenómenos de LTP y LTD [9]. Esta regla de aprendizaje ha recibido evidencia empírica [23, 13] y está dada por la Eq. 5 y Eq. 6:

$$\tau_w \frac{d\mathbf{w}}{dt} = v\mathbf{u}(v - \theta_v), \quad (3)$$

$$\tau_\theta \frac{d\theta_v}{dt} = v^2 - \theta_v, \quad (4)$$

donde  $\tau_\theta > 0$  es la constante que controla la razón de cambio del umbral. Debido a que  $\theta_v \neq \tau_w$ , la discretización de  $\theta_v$  se expresa como  $\Delta\theta_v = \gamma(v^2 - \theta_v)$ . En este caso se fijó  $\gamma = 0.5$ .

**Reglas de Hebb Escaladas.** Utilizando el método de Euler, las reglas de Hebb se pueden discretizar de la forma siguiente:

$$\Delta\mathbf{w} = \alpha H(v, \mathbf{u}), \quad (5)$$

donde  $\alpha$  es la tasa de aprendizaje y  $H(v, \mathbf{u})$  es el modelo utilizado, por ejemplo  $H(v, \mathbf{u}) = v\mathbf{u}$  para la regla de Hebb Simple. Una forma de combatir el desbalance en los datos consiste en actualizar dividiendo entre el número de ocurrencias de la clase (Eq. 3), es decir:

$$\Delta\mathbf{w} = \frac{1}{|\{v(t) = 1\}|} H(v, \mathbf{u}). \quad (6)$$

Normalizar a la regla de Hebb ha sido implementada en otros artículos como [25, 4], pero generalmente se normaliza sobre la suma de los pesos  $\sum_i w_i$ , y no sobre la suma de las ocurrencias de  $v(t) = 1$ . Para nuestro conocimiento, no se ha implementado este tipo de normalización / escalamiento.



Fig. 3. Ejemplo de muestras de 5 Celebriety Faces Dataset.

### 3.2. Codificador visual

Un codificador visual apropiado para esta tarea está dado por el módulo de *face recognition* de Python [15], el cual está basado en el módulo *Dlib-ml* [18]. Este codificador realiza tanto reconocimiento de rostros (devolviendo las coordenadas de ubicación del rostro) como el vector de características  $\mathbf{u} \in \mathbb{R}^{128}$ , las cuales pueden ser utilizadas para su clasificación.

El detector de rostros utilizado por el módulo *Dlib-ml* es *MMOD CNN* que utiliza una *ConvNet* entrenada con el método de detección de objetos de máximo margen (*MMOD*) para detectar rostros en la imagen. Este algoritmo es capaz de detectar rostros desde diferentes ángulos de visión, condiciones de iluminación y oclusión.

### 3.3. Algoritmos de comparación

Para comparar los resultados de las reglas online, se utilizaron el algoritmo de *k*-vecinos más cercanos (*k*-nearest neighbors, *kNN*) con  $k = 3$  y una red neuronal simple (sin capas intermedias) con 100 épocas, optimizador *Adam* [19] sobre la función de costo de entropía cruzada categórica.



Fig. 4. Ejemplo de muestras de base de datos GPIC.

### 3.4. Bases de datos empleadas

Se emplearon dos bases de datos:

1. **5 Celebrity Faces Dataset:** Este conjunto de datos [7] fue creado con la finalidad de probar algoritmos en tareas de visión por computadora, cuenta con cinco clases pertenecientes a:
  - a) Ben Afflek,
  - b) Elton John,
  - c) Jerry Seinfeld,
  - d) Madonna,
  - e) Mindy Kaling.

Cada clase tiene entre 14 y 20 imágenes, sin embargo, 7 imágenes de esta base de datos fueron eliminadas porque no fueron identificadas como rostros por el codificador visual, debido a la presencia de dos rostros. La base de datos se restableció utilizando 5 imágenes de cada clase como parte del conjunto de prueba. Un ejemplo de cada clase puede ser observada en la figura 3.

2. **Base de datos GPIC:** Este conjunto de datos fue creado tomando como base a 36 trabajadores de la empresa de construcción mexicana GPIC. Se conforma de dos fotografías tomadas por el dispositivo móvil de cada persona que pertenece al conjunto de datos en posición frontal tipo selfie.

**Tabla 1.** Resultados de exactitud sobre el conjunto de prueba con la Regla de Hebb Simple, Regla de Oja, Regla BCM, Regla del Perceptrón (PLR), en comparación con el algoritmo de kNN y una red neuronal con optimizador Adam.  $|C_i|$  representa la cardinalidad de la clase  $i$  utilizada para entrenar.

$ C_0 $	$ C_1 $	$ C_2 $	$ C_3 $	$ C_4 $	Simple	Oja	BCM	PLR	Adam	kNN
1	1	1	1	1	0.8	0.8	0.4	0.8	0.96	0.32
2	2	2	2	2	0.92	0.92	0.6	0.92	1	1
4	4	4	4	4	0.92	0.92	0.6	0.92	1	1
5	5	5	5	5	0.96	0.96	0.64	0.96	1	1
7	7	7	7	7	0.96	0.96	0.68	0.96	1	1
8	8	8	8	8	0.92	0.92	0.68	0.96	1	1
9	9	9	9	9	0.92	0.92	0.68	0.92	1	1
12	12	12	12	12	0.92	0.92	0.68	0.84	1	1
12	13	13	13	13	0.92	0.92	0.68	0.64	1	1
12	14	14	14	14	0.72	0.72	0.68	0.6	1	1
12	15	15	15	15	0.76	0.76	0.68	0.6	1	1
12	16	15	16	16	0.6	0.6	0.68	0.6	1	1
12	17	15	17	17	0.6	0.6	0.68	0.6	1	1
12	18	15	18	18	0.6	0.6	0.68	0.6	1	1
12	19	15	19	18	0.6	0.6	0.68	0.6	1	1
12	20	15	20	18	0.52	0.56	0.68	0.6	1	1
12	20	15	21	18	0.4	0.56	0.68	0.48	0.96	1

Las imágenes no fueron controladas, por lo que la variación de luz, exposición, tamaño e incluso posición del rostro son más naturales y por ende, agrega dificultad al problema de clasificación. La razón por la cual se eligieron estas personas fue por la disposición que tuvieron para formar parte de este proyecto. Se solicitó la autorización por escrito para el uso de las imágenes con fines académicos y de investigación. La figura 4 muestra un ejemplo de algunas clases.

## 4. Resultados

### 4.1. Base de datos 5 celebrity faces dataset

Para el caso de la primera base de datos, se controló el número de datos para el conjunto de entrenamiento, dejando fijo el de prueba, con el objetivo de medir la influencia del número de datos en la decisión final para reglas de clasificación hebbianas. Además de las reglas BCM, Oja y Simple, se utilizó la regla del perceptrón [32] (Perceptron Learning Rule, PLR,  $\alpha = 0.01$ ).

La tabla 1 presenta los resultados en esta base de datos con las reglas sin escalar y en la tabla 2 se muestran los resultados con las reglas escaladas. En la figura 5 se muestra la evolución de la exactitud con respecto al número de datos máximo por clase controlados. Tal como se especificó previamente, también se utilizaron el algoritmo de aprendizaje de Adam en una red neuronal y el algoritmo de kNN.

**Tabla 2.** Resultados de exactitud sobre el conjunto de prueba con la Regla de Hebb Simple, Regla de Oja, Regla BCM, Regla del Perceptrón (PLR), todas las reglas en su forma escalada.  $|C_i|$  representa la cardinalidad de la clase  $i$  utilizada para entrenar.

$ C_0 $	$ C_1 $	$ C_2 $	$ C_3 $	$ C_4 $	Simple	Oja	BCM	PLR
12	13	13	13	13	0.92	0.92	0.68	0.92
12	14	14	14	14	0.92	0.92	0.68	0.92
12	15	15	15	15	0.96	0.92	0.68	0.96
12	16	15	16	16	0.96	0.92	0.8	0.96
12	17	15	17	17	0.92	0.92	0.8	0.92
12	18	15	18	18	0.92	0.92	0.76	0.92
12	19	15	19	18	0.92	0.92	0.4	0.92
12	20	15	20	18	0.92	0.92	0.4	0.92
12	20	15	21	18	0.92	0.92	0.4	0.92

#### 4.2. Base de datos GPIC

Para el caso de la base de datos GPIC, también se realizó control sobre el número de datos para entrenamiento, dejando fijo al conjunto de prueba. Las comparaciones que se realizaron fueron las mismas de la base de datos anterior y se presentan en la tabla 3.

### 5. Discusión

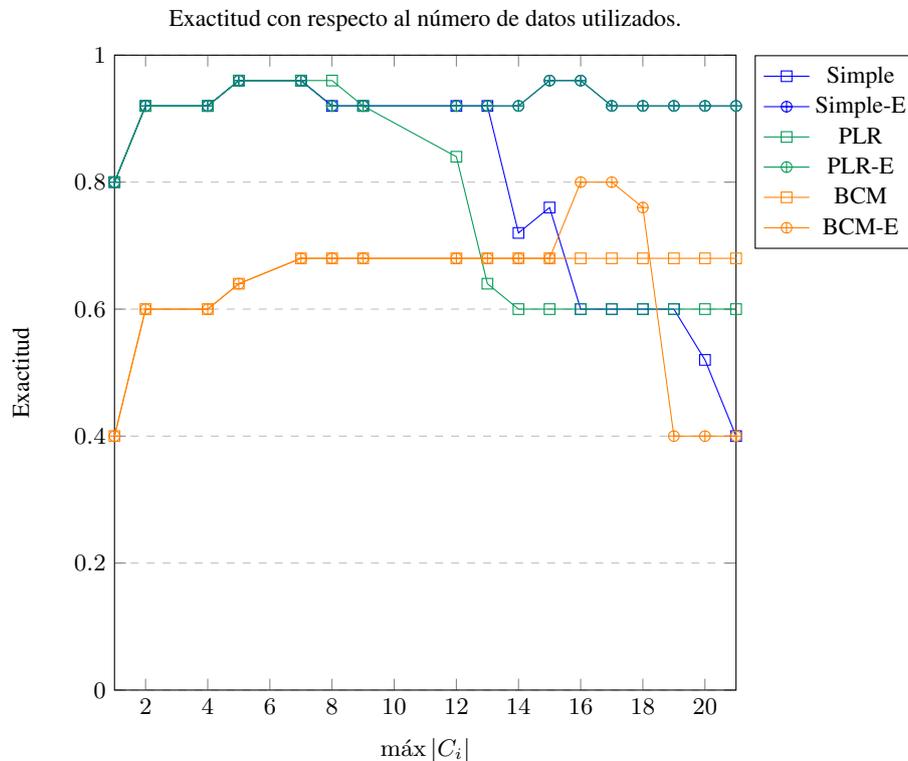
Para ambas bases de datos, el algoritmo de kNN el mejor para efectuar la clasificación, siendo únicamente inefectivo para conjuntos de entrenamiento extremadamente pequeños (una maestra por clase). En cuanto a las reglas de aprendizaje en tiempo real (hebbianas y PLR), tanto la Regla de Hebb Simple, Oja y Perceptrón obtuvieron desempeños muy similares, mientras que la Regla BCM observó un comportamiento menos predecible, siendo en ocasiones mejor que otras formas de aprendizaje y en otras ocasiones peor.

En la base de datos 5 Celebrity Faces Dataset, el optimizador Adam se mostró comparativamente mejor con respecto a las reglas online, aunque en algunos casos la diferencia no fue tan notoria.

Un aspecto destacable sobre estas reglas es que la exactitud se reduce con el aumento de los datos, lo cual parece ser un fenómeno contradictorio. Sin embargo, en su mayor parte, este fenómeno puede explicarse con la introducción de desbalance de datos, donde la regla de Hebb se muestra ampliamente sensible.

En ambas bases de datos, las reglas escaladas mostraron mejores resultados. Tanto la regla BCM como la regla de Oja evitan el crecimiento no acotado mediante técnicas distintas, sin embargo, como se observa en los resultados, las formas escaladas terminan siendo más apropiadas.

No obstante, incluso las reglas escaladas y hasta el optimizador Adam se mostraron sensibles a la introducción de ciertos datos, al grado de reducir la exactitud. Este fenómeno es más notorio en la segunda base de datos, donde observamos que únicamente el algoritmo kNN logra resolver el problema, pero incluso una red entrenada con el optimizador Adam tiende a presentar este problema.



**Fig. 5.** Evolución de la exactitud para las Reglas de Hebb Simple sin escalar (Simple) y escalada (Simple-E); la Regla del Perceptrón (PLR) y su versión escalada (PLR-E), la Regla BCM y su versión escalada (BCM-E).

El hecho de que tanto la regla de Oja como BCM no logren obtener mejores resultados significa que el crecimiento no acotado de los pesos puede tener escaso o ningún papel. Esto parece entrar en conflicto con las conclusiones arrojadas en [2], pero al tratarse de un problema más generalizado puede tratarse de un ejemplo del principio trash in, trash out.

No obstante, el hecho de que ciertos clasificadores clásicos como kNN evadan este problema puede ser muestra de que no se trata del caso mencionado o el uso de las distancias más cortas permita al algoritmo de kNN ser robusto a este problema. En la base de datos GPIC, la Regla del Perceptrón mostró un desempeño considerablemente bajo en comparación con reglas hebbianas (de hasta un 30 %), y aunque Adam también presentó problemas similares, mostró mejores resultados.

Finalmente, es importante mencionar el hecho de que la Regla de Hebb Simple en su versión escalada tuviera los resultados más robustos en cuanto a las reglas online. A diferencia de las otras reglas de aprendizaje, la Regla de Hebb Simple no necesita hiperparámetros y se obtiene el mismo resultado si se utilizan diferentes tasas de aprendizaje positivas. El desempeño disimilar de reglas como BCM y PLR, o incluso Oja, parecen indicar una falta de ajuste de los hiperparámetros.

**Tabla 3.** Resultados de exactitud en cuatro experimentos sobre el conjunto de prueba con la Regla de Hebb Simple, Regla de Oja, Regla BCM, Regla del Perceptrón (PLR), así como sus versiones escaladas (-E), en comparación con el algoritmo de kNN y una red neuronal con optimizador Adam.  $|C_i|$  representa la cardinalidad de la clase  $i$  utilizada para entrenar.

	Exp 1	Exp 2	Exp 3	Exp 4
$ C_0 $	1	2	2	2
$ C_1 $	1	2	3	3
$ C_2 $	1	2	2	2
$ C_3 $	1	2	2	2
$ C_4 $	1	2	2	2
$ C_5 $	1	2	2	2
$ C_6 $	1	2	3	5
$ C_7 $	1	2	2	2
$ C_8 $	1	2	2	2
$ C_9 $	1	2	2	2
$ C_{10} $	1	2	2	2
$ C_{11} $	1	2	2	2
$ C_{12} $	1	2	2	2
$ C_{13} $	1	2	3	3
$ C_{14} $	1	2	3	5
$ C_{15} $	1	2	2	2
$ C_{16} $	1	2	3	5
$ C_{17} $	1	2	2	2
$ C_{18} $	1	2	2	2
$ C_{19} $	1	2	2	2
$ C_{20} $	1	2	2	2
$ C_{21} $	1	2	3	3
$ C_{22} $	1	2	3	3
$ C_{23} $	1	2	3	3
$ C_{24} $	1	2	3	3
$ C_{25} $	1	2	2	2
$ C_{26} $	1	2	2	2
$ C_{27} $	1	2	2	2
$ C_{28} $	1	2	2	2
$ C_{29} $	1	2	2	2
$ C_{30} $	1	2	2	2
$ C_{31} $	1	2	2	2
$ C_{32} $	1	2	3	3
$ C_{33} $	1	2	2	2
$ C_{34} $	1	2	2	2
$ C_{35} $	1	2	3	5
Simple	0.75	0.83	0.31	0.11
Simple-E	0.75	0.83	0.39	0.11
Oja	0.75	0.83	0.31	0.11
Oja-E	0.75	0.83	0.44	0.11
BCM	0.64	0.72	0.28	0.11
BCM-E	0.64	0.72	0.47	0.47
PLR	0.75	0.53	0.25	0.11
PLR-E	0.75	0.53	0.36	0.11
Adam	0.56	0.92	0.64	0.22
kNN	0.31	1	1	1

## 6. Conclusiones

En este trabajo, se presentó el problema de clasificación de rostros para bases de datos pequeñas, con la restricción de que el aprendizaje se efectuara en tiempo real. Se utilizaron dos bases de datos pequeñas para tal fin, con 5 y 36 clases respectivamente, que corresponden a prototipos de situaciones reales de clasificación de rostros para entornos sociales reducidos como aulas, donde se tienen pocas muestras por persona.

De manera general, las reglas de aprendizaje hebbianas tuvieron un desempeño similar con respecto a la Regla del Perceptrón (basada en el gradiente y online) y en general, aceptable con respecto al optimizador Adam. Sin embargo, en general, el algoritmo de kNN parece más adecuado para esta tarea, exceptuando cuando se tiene solamente un dato por clase.

Las reglas implementadas en este artículo se mostraron ampliamente sensibles al desbalance de los datos, razón por la cual se propusieron las reglas escaladas, que tienen la desventaja de requerir dos iteraciones sobre los datos (para contar el número de elementos por clase) por lo que no serían completamente online.

## 7. Disponibilidad, privacidad y acceso a los datos

Los datos de la base de datos 5 Celebrity Faces Dataset es pública y puede consultarse en la referencia [7]. La base de datos GPIC es privada pero puede solicitarse directamente a los autores, siempre que se garantice respetar la privacidad de los participantes, los cuales firmaron de conformidad para que su imagen sea utilizada para publicación e investigación, análisis biométrico y desarrollo de software.

### Disponibilidad de código

El código fuente puede ser consultado de forma libre en [colab.research.google.com/drive/17AMrl5Pwe7K4dqSjr2w\\_aNV0ubMbJmSf?usp=sharing](https://colab.research.google.com/drive/17AMrl5Pwe7K4dqSjr2w_aNV0ubMbJmSf?usp=sharing).

**Agradecimientos.** Agradecemos al Instituto Politécnico Nacional por su apoyo para la realización de este trabajo; de igual manera, al apoyo del gobierno mexicano a través del Consejo Nacional de Ciencia y Tecnología (CONACYT).

## Referencias

1. Abbott, L. F., Nelson, S. B.: Synaptic plasticity: taming the beast. *Nature neuroscience*, vol. 3, no. 11, pp. 1178–1183 (2000) doi: 10.1038/81453
2. Aguilar-Canto, F., Calvo, H.: The role of the number of examples in convolutional neural networks with hebbian learning. In: *Advances in Computational Intelligence: 21st Mexican International Conference on Artificial Intelligence, MICAI 2022, Monterrey, Mexico, October 24–29, 2022, Proceedings, Part I*, pp. 225–238 (2022) doi: 10.1007/978-3-031-19493-1\_19

3. Aguilar Canto, F. J.: Convolutional neural networks with hebbian-based rules in online transfer learning. In: *Advances in Soft Computing: 19th Mexican International Conference on Artificial Intelligence*, pp. 35–49 (2020) doi: 10.1007/978-3-030-60884-2\_3
4. Aguilar Canto, F. J.: Eficacia de diferentes reglas hebbianas en el aprendizaje supervisado: Efficacy of different hebbian rules in supervised learning. *Tecnología Educativa Revista CONAIC*, vol. 7, no. 1, pp. 92–97 (2020) doi: 10.32671/terc.v7i1.22
5. Amato, G., Carrara, F., Falchi, F., Gennaro, C., Lagani, G.: Hebbian learning meets deep convolutional neural networks. In: *Image Analysis and Processing–ICIAP 2019: 20th International Conference*, pp. 324–334 (2019) doi: 10.1007/978-3-030-30642-7\_29
6. Bartlett, M., Sejnowski, T. J.: Viewpoint invariant face recognition using independent component analysis and attractor networks. *Advances in Neural Information Processing Systems*, vol. 9 (1996)
7. Becker, D.: 5 celebrity faces dataset (2018)
8. Belcar, D., Grd, P., Tomičić, I.: Automatic ethnicity classification from middle part of the face using convolutional neural networks. *Informatics*, vol. 9, no. 1, pp. 18 (2022) doi: 10.3390/informatics9010018
9. Bienenstock, E. L., Cooper, L. N., Munro, P. W.: Theory for the development of neuron selectivity: orientation specificity and binocular interaction in visual cortex. *Journal of Neuroscience*, vol. 2, no. 1, pp. 32–48 (1982) doi: 10.1523/jneurosci.02-01-00032.1982
10. Bliss, T. V., Lømo, T.: Long-lasting potentiation of synaptic transmission in the dentate area of the anaesthetized rabbit following stimulation of the perforant path. *The Journal of physiology*, vol. 232, no. 2, pp. 331–356 (1973) doi: 10.1113/jphysiol.1973.sp010273
11. Brennan, V., Principe, J.: Face classification using a multiresolution principal component analysis: Neural networks for signal processing VIII, In: *Proceedings of the 1998 IEEE Signal Processing Society Workshop*, pp. 506–515 (1998) doi: 10.1109/nnspp.1998.710681
12. Chiu, C. T., Ding, Y. C., Lin, W. C., Chen, W. J., Wu, S. Y., Huang, C. T., Lin, C. Y., Chang, C. Y., Lee, M. J., Tatsunori, S., Chen, T., Lin, F. Y., Huang, Y. H.: Chaos LiDAR based RGB-D face classification system with embedded CNN accelerator on FPGAs. *IEEE Transactions on Circuits and Systems I: Regular Papers*, vol. 69, no. 12, pp. 4847–4859 (2022) doi: 10.1109/tcsi.2022.3190430
13. Cooper, L. N., Bear, M. F.: The BCM theory of synapse modification at 30: Interaction of theory with experiment. *Nature Reviews Neuroscience*, vol. 13, no. 11, pp. 798–810 (2012) doi: 10.1038/nrn3353
14. Dayan, P., Abbott, L. F.: *Theoretical neuroscience: computational and mathematical modeling of neural systems*, MIT press (2005)
15. Geitgey, A.: *Face recognition* (2022)
16. Kamaruzaman, F., Shafe, A. A., Mustafah, Y. M.: Coincidence detection using spiking neurons with application to face recognition. *Journal of Applied Mathematics*, vol. 2015 (2015) doi: 10.1155/2015/534198
17. Khan, K., Attique, M., Syed, I., Gul, A.: Automatic gender classification through face segmentation. *Symmetry*, vol. 11, no. 6, pp. 770 (2019) doi: 10.3390/sym11060770
18. King, D. E.: Dlib-ml: A machine learning toolkit. *The Journal of Machine Learning Research*, vol. 10, pp. 1755–1758 (2009)
19. Kingma, D. P., Ba, J.: Adam: A method for stochastic optimization (2014) doi: 10.48550/ARXIV.1412.6980
20. Krizhevsky, A., Sutskever, I., Hinton, G. E.: ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, vol. 60, no. 6, pp. 84–90 (2017) doi: 10.1145/3065386
21. Kuśmiercz, Ł., Isomura, T., Toyozumi, T.: Learning with three factors: modulating hebbian plasticity with errors. *Current opinion in neurobiology*, vol. 46, pp. 170–177 (2017) doi: 10.1016/j.conb.2017.08.020

22. Lagani, G., Falchi, F., Gennaro, C., Amato, G.: Comparing the performance of hebbian against backpropagation learning using convolutional neural networks. *Neural Computing and Applications*, vol. 34, no. 8, pp. 6503–6519 (2022) doi: 10.1007/s00521-021-06701-4
23. Law, C. C., Cooper, L. N.: Formation of receptive fields in realistic visual environments according to the Bienenstock, Cooper, and Munro (BCM) theory. In: *Proceedings of the National Academy of Sciences, National Acad Sciences*, vol. 91, pp. 7797–7801 (1994) doi: 10.1073/pnas.91.16.7797
24. Leibo, J. Z., Liao, Q., Anselmi, F., Freiwald, W. A., Poggio, T.: View-tolerant face recognition and hebbian learning imply mirror-symmetric neural tuning to head orientation. *Current Biology*, vol. 27, no. 1, pp. 62–67 (2017) doi: 10.1016/j.cub.2016.10.015
25. Lindsay, G. W., Rigotti, M., Warden, M. R., Miller, E. K., Fusi, S.: Hebbian learning in a random network captures selectivity properties of the prefrontal cortex. *Journal of Neuroscience*, vol. 37, no. 45, pp. 11021–11036 (2017) doi: 10.1523/jneurosci.1222-17.2017
26. Lu, P., Song, B., Xu, L.: Human face recognition based on convolutional neural network and augmented dataset. *Systems Science and Control Engineering*, vol. 9, no. sup2, pp. 29–37 (2021)
27. Magotra, A., Kim, J.: Improvement of heterogeneous transfer learning efficiency by using hebbian learning principle. *Applied Sciences*, vol. 10, no. 16, pp. 5631 (2020) doi: 10.3390/app10165631
28. Markram, H., Lübke, J., Frotscher, M., Sakmann, B.: Regulation of synaptic efficacy by coincidence of postsynaptic APs and EPSPs. *Science*, vol. 275, no. 5297, pp. 213–215 (1997) doi: 10.1126/science.275.5297.213
29. Munakata, Y., Pfaffly, J.: Hebbian learning and development. *Developmental science*, vol. 7, no. 2, pp. 141–148 (2004) doi: 10.1111/j.1467-7687.2004.00331.x
30. Oja, E.: Simplified neuron model as a principal component analyzer. *Journal of mathematical biology*, vol. 15, no. 3, pp. 267–273 (1982) doi: 10.1007/bf00275687
31. Riesenhuber, M., Poggio, T.: Models of object recognition. *Nature neuroscience*, vol. 3, no. 11, pp. 1199–1204 (2000) doi: 10.1038/81479
32. Rosenblatt, F.: The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, vol. 65, no. 6, pp. 386 (1958) doi: 10.1037/h0042519
33. William, F., Aygun, R.: Convoforest classification of new and familiar faces using EEG. In: *IEEE 16th International Conference on Semantic Computing (ICSC)*, pp. 274–279 (2022) doi: 10.1109/icsc52841.2022.00052
34. Yao, P., Wu, H., Gao, B., Eryilmaz, S. B., Huang, X., Zhang, W., Zhang, Q., Deng, N., Shi, L., Wong, H. S. P., Qian, H.: Face classification using electronic synapses. *Nature communications*, vol. 8, no. 1, pp. 15199 (2017) doi: 10.1038/ncomms15199