

Clasificador de bosquejos utilizando memoria asociativa entrópica pesada

Julian Rodrigo González-Hernández¹, Karina M. Figueroa-Mora¹,
Luis A. Pineda², Rafael Morales-Gamboa³

¹ Universidad Michoacana de
San Nicolás de Hidalgo,
Mexico

² Instituto de Investigación en Matemáticas,
Universidad Nacional de México,
Mexico

³ Universidad de Guadalajara,
Mexico

karina.figueroa@umich.mx, lpineda@iimas.unam.mx,
rmorales@suv.udg.mx

Resumen. La memoria asociativa entrópica es un concepto relacionado con la capacidad de un sistema para almacenar y recuperar información de manera eficiente y confiable, incluso cuando las entradas son parciales o ruidosas. Utilizar este tipo de memoria ayuda a aprovechar eficientemente la memoria de un sistema, pues almacena los datos de manera compacta y los asocia inteligentemente, lo cual es muy útil en sistemas con recursos limitados. En este artículo se presenta un clasificador de bosquejos hechos a mano (fuente Quick, Draw! de Google Creative Lab) usando redes neuronales convolucionales como módulo de entrada y salida de información, implementando además un sistema de memoria asociativa entrópica pesada con el objetivo de almacenar y recuperar los elementos de la base de datos (trazos). En este artículo se muestran experimentos que exploran las configuraciones de memoria propuestas. Finalmente, se presenta la configuración óptima de la memoria para esta base de datos con respecto a las clases seleccionadas.

Palabras clave: Memoria asociativa entrópica, clasificador de imágenes, redes neuronales convolucionales.

Sketch Classifier using Weighted Entropic Associative Memory

Abstract. Entropic associative memory is a concept related to the ability of a system to store and retrieve information efficiently and reliably, even when the inputs are partial or noisy. Using this type of memory helps to efficiently take advantage of a system's memory, as it stores data compactly and associates it intelligently, which is very useful in systems with limited resources.

This article presents a hand-drawn sketch classifier (source Quick, Draw! from Google Creative Lab) using convolutional neural networks as an information input and output module. It also implements a Weighted entropy associative memory system to store and retrieve database elements (sketch). This article shows experiments exploring the proposed memory configurations. Finally, the optimal memory configuration for this database concerning the selected classes is presented.

Keywords: Entropic associative memory, images classifier, convolutional neural networks.

1. Introducción

Las memorias naturales de los seres humanos y otros animales con un sistema neuronal suficientemente desarrollado son asociativas [6]. Así, por ejemplo una imagen, un sabor o un olor pueden iniciar una cadena de recuerdos a partir de sus significados o contenidos. En otras palabras, estos estímulos se encuentran asociados con recuerdos, los cuales podrían representar información guardada en la memoria. El acceso a esta información es a través de señales, claves o descripciones, además la recuperación de la memoria es una operación constructiva, esto es un recuerdo puede servir de pista para recordar mas elementos adicionales por esto es importante su estudio.

En [6] los autores reportan que ha sido extremadamente difícil crear modelos computacionales de memorias asociativas dentro del paradigma simbólico, y aunque se han realizado importantes intentos de utilizar redes semánticas [9] desde el inicio y sistemas de producción más recientemente [1], aún hacen falta memorias asociativas simbólicas prácticas. Algunos trabajos han estudiado este tipo de memoria dentro del paradigma de las redes neuronales [10]. Esto es, almacenan una gran cantidad de patrones que pueden seleccionarse con señales completas o parciales, así como recuperar el patrón que está más cerca de la pista según una función abstracta.

Las posibles heurísticas usadas para representar la memoria reflejan estrategias análogas utilizadas en representaciones simbólicas donde la negación se equipara con la falta de prueba. Sin embargo, en este artículo se utiliza una tabla para representar la memoria asociativa como se describe en [5]. De manera general, el aporte de este artículo consiste en mostrar la configuración óptima de los parámetros para la implementación de una memoria asociativa entrópica pesada para la clasificación de bosquejos hechos a mano usando redes neuronales convolucionales como mecanismo de entrada/salida de información. Es importante resaltar que la red neuronal también se utilizará para comprobar el resultado de la memoria entrópica.

2. Estado del arte

El primer trabajo publicado sobre memorias asociativas entrópicas se puede consultar en [6]. En este los autores presentan la idea y cómo es posible usar este tipo de memoria para la recuperación de información.

$$\begin{array}{|c|c|c|c|} \hline \text{Aux-Reg} & & & \\ \hline v_7 & & & 1 \\ \hline v_6 & & 1 & \\ \hline v_5 & & & \\ \hline v_4 & & & \\ \hline v_3 & 1 & & \\ \hline v_2 & & & \\ \hline v_1 & & 1 & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad \lambda \quad
 \begin{array}{|c|c|c|c|} \hline \text{AMR}^t & & & \\ \hline v_7 & & & 31 \\ \hline v_6 & 7 & 30 & 12 \\ \hline v_5 & 18 & & \\ \hline v_4 & 6 & 15 & 9 \\ \hline v_3 & 25 & & 4 \\ \hline v_2 & 3 & & \\ \hline v_1 & 12 & & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad = \quad
 \begin{array}{|c|c|c|c|} \hline \text{AMR}^{t+1} & & & \\ \hline v_7 & & & 32 \\ \hline v_6 & 7 & 31 & 12 \\ \hline v_5 & 18 & & \\ \hline v_4 & 6 & 15 & 9 \\ \hline v_3 & 26 & & 4 \\ \hline v_2 & 3 & & \\ \hline v_1 & 12 & 1 & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}$$

(a)

$$\begin{array}{|c|c|c|c|} \hline \text{Aux-Reg}^t & & & \\ \hline v_7 & & & \\ \hline v_6 & & 1 & 1 \\ \hline v_5 & & & \\ \hline v_4 & 1 & & \\ \hline v_3 & 1 & & \\ \hline v_2 & & & \\ \hline v_1 & & & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad \eta \quad
 \begin{array}{|c|c|c|c|} \hline \text{AMR} & & & \\ \hline v_7 & & & 32 \\ \hline v_6 & 7 & 31 & 12 \\ \hline v_5 & 18 & & \\ \hline v_4 & 6 & 15 & 9 \\ \hline v_3 & 26 & & 4 \\ \hline v_2 & 3 & & \\ \hline v_1 & 12 & 1 & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad = \quad
 \begin{array}{|c|c|c|c|} \hline \text{Aux-Reg}^{t+1} & & & \\ \hline v_7 & & & \\ \hline v_6 & & 1 & 1 \\ \hline v_5 & & & \\ \hline v_4 & 1 & & \\ \hline v_3 & 1 & & \\ \hline v_2 & & & \\ \hline v_1 & & & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad = \quad \text{True}$$

$$\begin{array}{|c|c|c|c|} \hline \text{Aux-Reg}^t & & & \\ \hline v_7 & & & \\ \hline v_6 & & 1 & 1 \\ \hline v_5 & & & \\ \hline v_4 & 1 & & \\ \hline v_3 & & & \\ \hline v_2 & 1 & & \\ \hline v_1 & & & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad \eta \quad
 \begin{array}{|c|c|c|c|} \hline \text{AMR} & & & \\ \hline v_7 & & & 32 \\ \hline v_6 & 7 & 31 & 12 \\ \hline v_5 & 18 & & \\ \hline v_4 & 6 & 15 & 9 \\ \hline v_3 & 26 & & 4 \\ \hline v_2 & 3 & & \\ \hline v_1 & 12 & 1 & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad = \quad
 \begin{array}{|c|c|c|c|} \hline \text{Aux-Reg}^{t+1} & & & \\ \hline v_7 & & & \\ \hline v_6 & & 1 & 1 \\ \hline v_5 & & & \\ \hline v_4 & 1 & & \\ \hline v_3 & & & \\ \hline v_2 & 0 & & \\ \hline v_1 & & & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad = \quad \text{False}$$

(b)

$$\begin{array}{|c|c|c|c|} \hline \text{Aux-Reg}^t & & & \\ \hline v_7 & & & \\ \hline v_6 & & 1 & 1 \\ \hline v_5 & & & \\ \hline v_4 & 1 & & \\ \hline v_3 & 1 & & \\ \hline v_2 & & & \\ \hline v_1 & & & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad \beta \quad
 \begin{array}{|c|c|c|c|} \hline \text{AMR} & & & \\ \hline v_7 & & & 32 \\ \hline v_6 & 7 & 31 & 12 \\ \hline v_5 & 18 & & \\ \hline v_4 & 6 & 15 & 9 \\ \hline v_3 & 26 & & 4 \\ \hline v_2 & 3 & & \\ \hline v_1 & 12 & 1 & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}
 \quad = \quad
 \begin{array}{|c|c|c|c|} \hline \text{Aux-Reg}^{t+1} & & & \\ \hline v_7 & & & 1 \\ \hline v_6 & & 1 & \\ \hline v_5 & 1 & & \\ \hline v_4 & & & \\ \hline v_3 & 1 & & \\ \hline v_2 & & & \\ \hline v_1 & & & \\ \hline a_1 & a_2 & a_3 & a_4 \\ \hline \end{array}$$

(c)

Fig. 1. Operaciones de la memoria asociativa entrópica pesada [8].

En este primer artículo los autores presentan experimentos relacionados con el reconocimiento de dígitos escritos a mano utilizando el corpus MNIST, en el cual se obtuvieron resultados muy favorables con una memoria de tamaño 64×64 presentando 100 % de precisión, 95 % de recuperación y con una entropía promedio de 4.2.

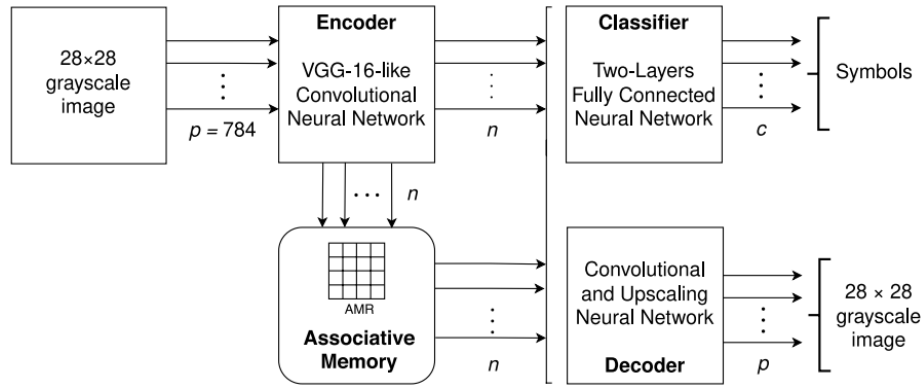


Fig. 2. Arquitectura de la memoria asociativa pesada [8].

Posteriormente, en [4] se presenta el uso de la memoria asociativa entrópica para la detección de símbolos manuscritos utilizando en ésta ocasión el corpus EMNIST donde los autores determinaron las características eficientes de la memoria para ese dominio; en éste caso la memoria de tamaño 64×128 con 87 % de precisión, 77 % de recuperación y una entropía promedio de 5.4. En [7] los autores introducen la idea de memoria asociativa entrópica pesada y muestran un caso de estudio de la representación y el aprendizaje fonético. En este artículo se muestran los experimentos para concluir los parámetros eficientes en el uso de este tipo de memoria específicamente en ese dominio utilizando el corpus de DIME \times 100; se muestra que el mejor tamaño de los registros de memoria es 32×32 en este caso.

3. Marco teórico

La memoria asociativa entrópica (EAM, por sus siglas en inglés) es un concepto que busca unir los procesos de memoria natural con los modelos computacionales. Los sistemas de EAM están definidos mediante el modo de computación relacional indeterminada (RIC, por sus siglas en inglés).

3.1. Computación relacional indeterminada

La RIC es un enfoque que combina la estructura relacional con cierta flexibilidad o ambigüedad en la interpretación de los datos. El objeto de computación básico de este modo es la relación matemática, entre un objeto en el dominio con uno ó varios objetos del co-dominio [6]. Sean los conjuntos $A = \{a_1, \dots, a_n\}$ y $V = \{v_1, \dots, v_m\}$, con cardinalidades n y m , el dominio y co-dominio de una relación finita $r : A \rightarrow V$, donde los objetos del dominio son llamados argumentos y los del co-dominio son llamados valores. Por cuestiones de notación para cualquier relación r se define una función $R : A \times V \rightarrow \{0, 1\}$ tal que $R(a_i, v_j) = 1$ si el argumento a_i se relaciona con el valor v_j y $R(a_i, v_j) = 0$ en caso contrario.



Fig. 3. Ejemplo los resultados al concluir el juego de Quick Draw! [3].

La RIC tiene una representación extensional, es decir, se centra en enumerar ejemplos concretos y propiedades generales de los conceptos, además sus algoritmos son indeterminados y entrópicos con una arquitectura distribuida y paralela.

Entropía Computacional La entropía computacional ó entropía de la información, introducido por Claude Shannon en 1948 [11], cuantifica la incertidumbre de variables aleatorias y puede ser utilizada para medir la indeterminación en una relación matemática. Por ejemplo, si la entropía de una función es cero, es porque está completamente determinada, y sería máxima cuando todos los elementos del dominio están relacionados con todos los del co-dominio.

Operaciones Relacionales En términos generales, el RIC se caracteriza por tres operaciones fundamentales: abstracción, inclusión y reducción. Consideremos dos relaciones arbitrarias, r_f y r_a , que mapean elementos desde un conjunto A a un conjunto V con una función f_a sobreyectiva. Es importante destacar que una función también es una relación, por lo que en las siguientes definiciones, las relaciones pueden ser funciones. Estas operaciones, de acuerdo a [5], se definen como sigue:

- **Abstracción:** $\lambda(r_f, r_a) = q$, tal que $Q(a_i, v_j) = R_f(a_i, v_j) \vee R_a(a_i, v_j)$ para todo $a_i \in A$ y $v_j \in V$, es decir, $\lambda(r_f, r_a) = r_f \cup r_a$. Es decir, construye una relación a partir de dos relaciones.

Tabla 1. Categorías utilizadas en el segundo conjunto de experimentos.

Categoría	Etiqueta	Categoría	Etiqueta	Categoría	Etiqueta	Categoría	Etiqueta
Avión	0	Manzana	5	Ave	10	Rana	15
Reloj despertador	1	Espárrago	6	Automóvil	11	Caballo	16
Ambulancia	2	Hacha	7	Gato	12	Calavera	17
Hormiga	3	Mochila	8	Perro	13	Camión	18
Yunque	4	Banana	9	Pato	14	Brazo	19



Fig. 4. Ejemplos de las imágenes obtenidas de Quick, Draw!

- **Inclusión:** $\eta(r_a, r_f)$ es verdadero si $R_a(a_i, v_j) \rightarrow R_f(a_i, v_j)$ para todo $a_i \in A$ y $v_j \in V$ (es decir implicación material), y falso en caso contrario.
- **Reducción:** $\beta(f_a, r_f) = f_v$ tal que si $\eta(f_a, r_f)$ es verdad $f_v(a_i) = r_f(a_i)$ para todo a_i , donde la distribución aleatoria se centra en f_a con varianza σ . Si $\eta(f_a, r_f)$ no se satisface $\beta(f_a, r_f)$ no está definida.

En las figuras 1 se muestran las operaciones posibles λ (registrar), η (reconocer), y β (recuperar) respectivamente.

Computación con tablas La implementación del modo de RIC en el formato de tablas se denomina aquí Computación con Tablas (CT)[5]. Esta representación consiste en una tabla con n columnas y m filas, donde cada una representa un Registro de Memoria Asociativo que contiene una relación entre el conjunto A argumentos $|A| = n$ y el V valores, $|V| = m$. En cada celda de la tabla es posible agregar el valor v_j del argumento a_i se expresa como un 1 en el renglón j de la columna i .

3.2. Memoria asociativa entrópica pesada

En la implementación original de la Memoria Asociativa Entrópica, el contenido de las unidades básicas de memoria o registros estaban encendidos o apagados, por lo tanto todos los objetos almacenados tenían el mismo peso. En [7] se introdujo una extensión de la EAM llamada Memoria Asociativa Entrópica Pesada (W-EAM o Weighted Entropic Associative Memory). Para este modelo se introduce el concepto de pesos en los registros de memoria; en lugar de la disyunción inclusiva, la operación λ (operación Registrar) incrementa en uno el valor de todas las celdas en el registro de memoria asociativa (RMA) correspondiente a las celdas en el registro auxiliar usado por la pista; la operación η (operación Reconocer) se define a través de la implicación material entre las celdas del registro auxiliar y las celdas correspondientes en el RMA; la operación β (operación Recuperar) selecciona una fila del RMA que corresponda al valor del objeto recuperado, para todas las celdas utilizadas por la pista [8]. Estas operaciones se ilustran en la Figura 1.

Tabla 2. Categorías utilizadas en el primer conjunto de experimentos.

Categoría	Etiqueta	Categoría	Etiqueta
Avión	0	Pato	5
Ave	1	Rana	6
Automóvil	2	Caballo	7
Gato	3	Calavera	8
Perro	4	Camión	9

3.3. Arquitectura

Se empleó la CT definida en la sección anterior para implementar un sistema de memoria asociativa entrópica pesada utilizada en el procesamiento de imágenes cuyo modelo se encuentra representado en la Figura 2. Los componentes principales son los mismos que utilizaron en [6]: un encoder (VGG-16-like), un clasificador, y un decoder para la reconstrucción del bosquejo.

4. Propuesta

Para lograr definir los límites que presenta la memoria asociativa entrópica pesada, en este trabajo se optó por trabajar con la base de datos del juego Quick, Draw! creado por Google.

4.1. Quick, Draw!

Quick, Draw! es un juego en línea desarrollado por Google que utiliza la inteligencia artificial para adivinar y reconocer dibujos realizados por el jugador. Véase la figura 3. La base de datos de Quick, Draw! [2] es una colección de 50 millones de imágenes distribuidas en 345 categorías, las cuales han sido contribuidas por los usuarios del juego. Cada imagen es guardada como un conjunto de vectores asociados a una marca de tiempo etiquetados con metadatos los cuales incluyen información como por ejemplo, qué fue lo que se le pidió dibujar al jugador, si el dibujo fue reconocido o no y el país de conexión el jugador. El tamaño de las imágenes fueron de 28×28 píxeles. En la Figura 4 se muestran algunos ejemplos de las imágenes contenidas en ésta base de datos.

5. Experimentación

Para estudiar los parámetros eficientes del uso de la memoria asociativa entrópica pesada se emplearon imágenes de tamaño 28×28 píxeles, y una sola memoria con $\sigma = 0.1$ como en [8]. La distribución de los datos fue de la siguiente manera, 70 % para entrenamiento del codificador y el decodificador, y el clasificador, 20 % para el llenado de la memoria, y el restante 10 % fue para pruebas. El sistema en general se configuró de la siguiente manera:

1. Se entrenan el clasificador y el autoencoder simultáneamente utilizando el conjunto de datos de entrenamiento, del cual se utiliza el 80 % para entrenar las redes y el 20 % para validación.
2. Se prueba el clasificador completo y el autocodificador usando el conjunto de datos de prueba completo.
3. Para todos los registros de memoria con co-dominio 2^m , donde $0 \leq m \leq 10$, se llenan con todo el conjunto de datos escogidos para este fin, incluyendo objetos de todas las clases. Posteriormente se evalúa el rendimiento de la operación de reconocimiento η utilizando cada objeto incluido en el conjunto de datos de prueba como señal, clasificando todos los objetos recuperados y comparando la clase asignada a dicho objeto con la clase asignada a la señal; después se seleccionan los registros de memoria con el mejor número de argumentos.
4. Se prueba el desempeño de la operación de reconocimiento η para los registros seleccionados en el paso anterior con las mejores filas llenándolas con diferentes cantidades del conjunto de datos de llenado, o niveles de entropía.
5. Se evalúa el procedimiento utilizando el método estándar de validación cruzada con $k = 10$.

5.1. Tamaño del dominio

Para este conjunto de experimentos se utilizaron 10 categorías (mostradas en la Tabla 2) las cuales contienen 10,000 elementos cada una. El objetivo de estos experimentos es determinar el dominio sobre el cual la memoria presenta un rendimiento óptimo. La Figura 5 muestra los resultados obtenidos para los distintos dominios, se muestran de izquierda a derecha: La matriz de confusión del clasificador; la precisión, recuperación y entropía promedio del reconocimiento del sistema, el dominio indica las columnas (argumentos) de las tablas, el eje horizontal muestra el número de filas y el eje vertical muestra los porcentajes de precisión y recuperación; así como el comportamiento del sistema.

Al analizar los resultados se puede observar que el sistema tiene un mejor rendimiento con 128 columnas, en este caso el clasificador obtuvo una precisión de 80.4 %, de igual manera los porcentajes de precisión y recuperación alcanzaron el 80 %. En la Figura 5 puede observar cómo el porcentaje de precisión y recuperación se mantiene casi constante al ir aumentando el número de filas, en este caso al estar probando los límites de la memoria se elige la memoria más grande con mejor resultado, la cual sería de tamaño 128×256 . Un registro de este tamaño contiene $128 \times 256 = 32,768$ celdas, cada una contiene 2 bytes que guardan números enteros, es decir, esta memoria utiliza 65,536 bytes.

5.2. Número de categorías

El objetivo de este conjunto de experimentos es determinar con que cantidad de categorías presenta un mejor rendimiento utilizando como base el mejor resultado del primer conjunto de experimentos, es decir, un sistema que presenta una memoria de dominio 128 con 10 categorías con 10,000 imágenes cada una.

Clasificador de bosquejos utilizando memoria asociativa entrópica pesada

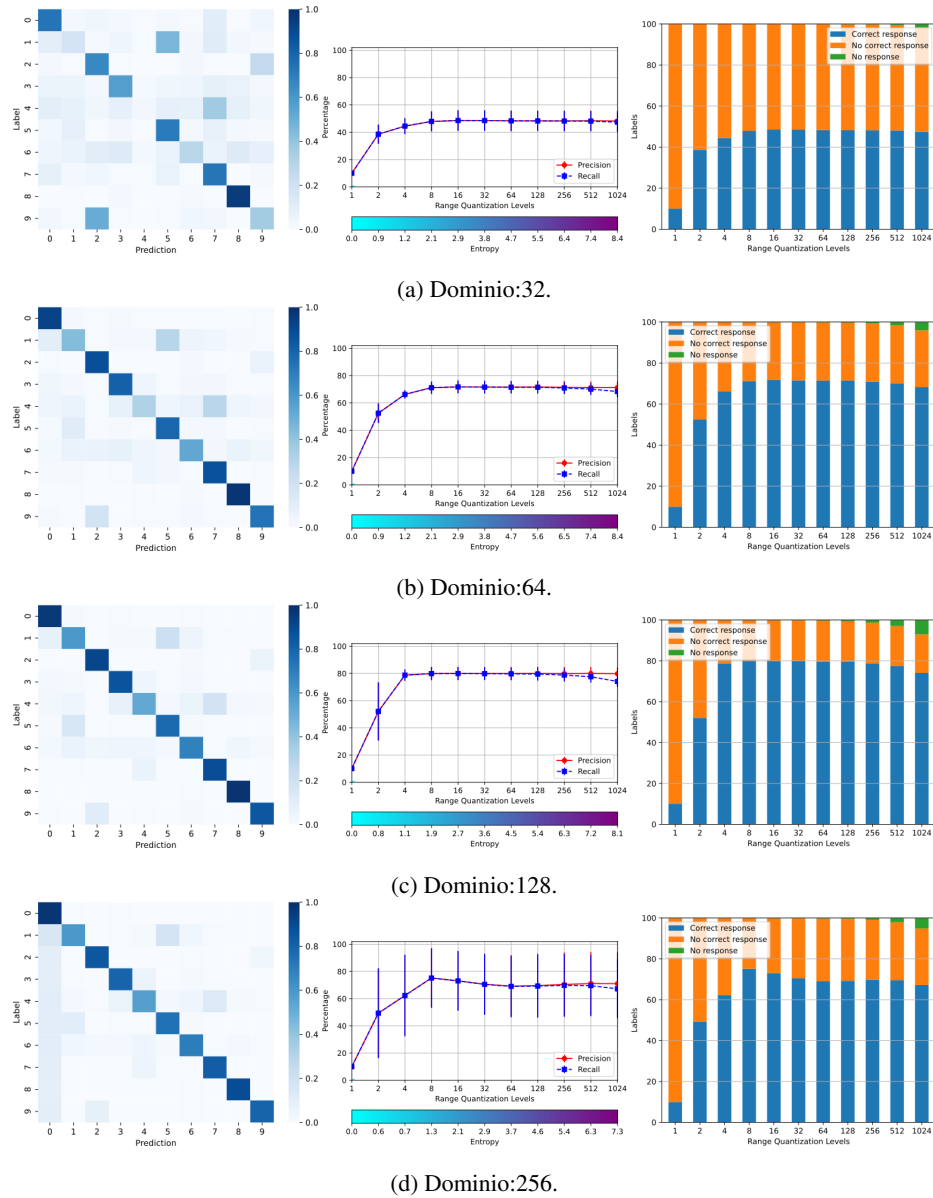


Fig. 5. Resultados del experimento con distintos dominios.

Se utilizan los mismos parámetros así como la misma distribución de los datos mostrados anteriormente. Se realiza el mismo procedimiento que en el conjunto de experimentos anterior pero en esta ocasión variando la cantidad de categorías, utilizando las mostradas en el cuadro 1. En la Figura 6 se presentan los resultados de estos experimentos, se observa como al aumentar la cantidad de categorías a partir de 10 los porcentajes de precisión y recuperación disminuyen al igual que la precisión

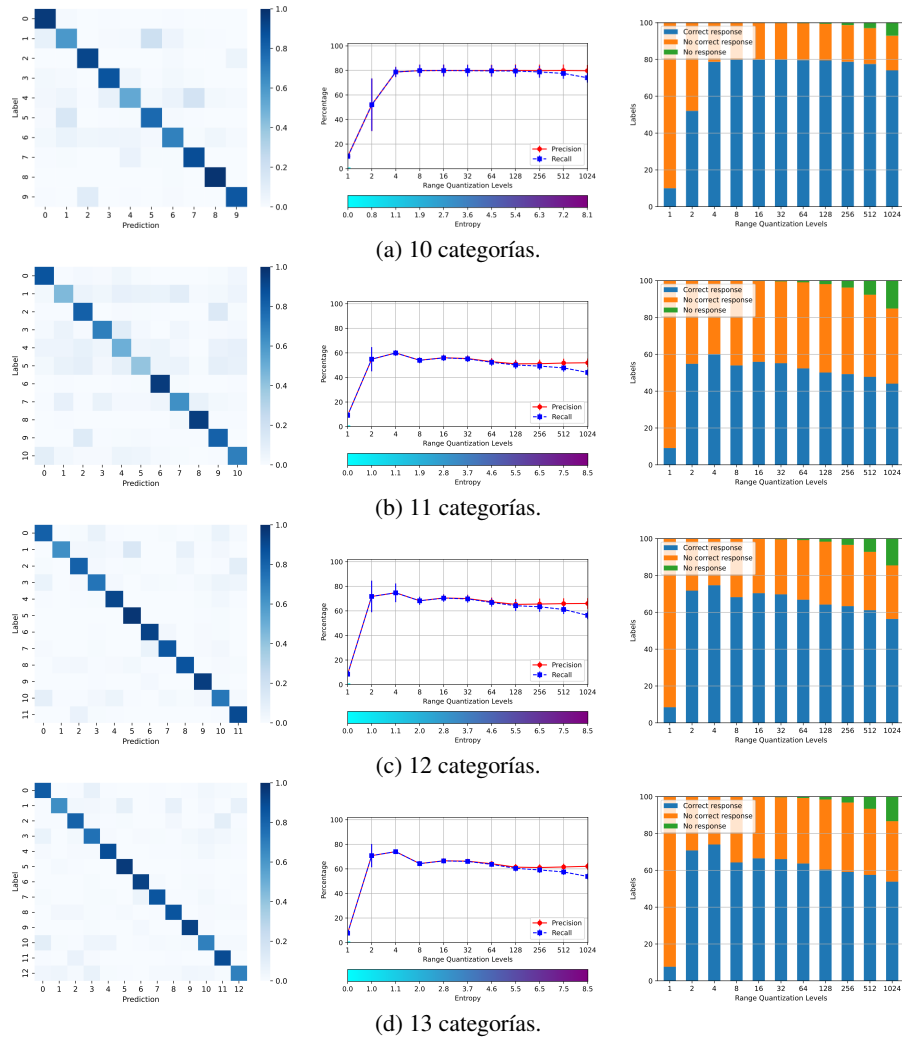


Fig. 6. Resultados del experimento con distintos números de categorías.

del clasificador. Sin embargo, los experimentos con 12 y 13 categorías mostraron un buen rendimiento con una memoria de tamaño 128×4 alcanzando 75% de precisión y recuperación. De acuerdo con los resultados de este conjunto de experimentos la cantidad de categorías con las cuales el sistema presenta un mejor resultado es 10 con 80% de precisión y recuperación al igual que en el conjunto de experimentos anterior.

6. Conclusiones

Las memorias naturales en humanos y animales son asociativas, declarativas y distribuidas, así que, cuando recordamos algo, las señales o descripciones activan una cadena de recuerdos relacionados basados en significados o contenidos.

De acuerdo con los resultados obtenidos en este trabajo se puede concluir que, dentro de los valores experimentados, la configuración más eficiente y de mayor capacidad de memoria asociativa entrópica pesada para un problema de clasificación de bosquejos de 28×28 , es utilizar una memoria de tamaño 128×256 , con 10 categorías y 10,000 elementos por categoría obteniendo 80 % de precisión.

Finalmente, una enorme ventaja de la memoria asociativa entrópica es su capacidad de comprimir. En este caso, cada imagen (de tamaño 28×28 píxeles y en formato PNG) extraída de la base de datos en promedio ocupaba 380 bytes; para llenar las memorias se utilizó el 20 % del corpus, es decir 20,000 imágenes que en formato PNG, lo que significa usar 7.6 MB. Al utilizar un sistema de memoria asociativa entrópica pesada se utilizaron 65,536 byte, es decir 0.065536 MB. Por lo tanto el factor de compresión de 116, lo que quiere decir que el espacio ocupado por la memoria distribuida es 115.9 veces menor, y permite tener ahorros de espacio de hasta un 99.1 %.

Debido a la capacidad del sistema de realizar búsquedas en paralelo así como la capacidad de rechazar patrones que no se encuentran alojados en la memoria de manera eficiente, se puede utilizar en sistemas de gestión de bases de datos para recuperar rápidamente datos en función de su contenido ó también se puede utilizar en procesamiento de imágenes. Como trabajo futuro se planea utilizar otros dominios para estudiar el comportamiento de la memoria asociativa entrópica.

Referencias

1. Anderson, J., Bothell, D., Byrne, M., Douglass, S., Lebiere, C., Qin, Y.: An integrated theory of the mind. *Psychological review*, vol. 111, no. 4, pp. 1036 (2004) doi: 10.1037/0033-295X.111.4.1036
2. Google Creative Lab: The quick, draw! dataset (2017) github.com/googlecreativelab/quickdraw-dataset
3. Google Creative Lab: Quick, draw! (2024) quickdraw.withgoogle.com
4. Morales, R., Hernández, N., Cruz, R., Cruz, V. D., Pineda, L. A.: Entropic associative memory for manuscript symbols. *PLOS ONE*, vol. 17, no. 8, pp. 1–27 (2022) doi: 10.1371/journal.pone.0272386
5. Pineda, L. A.: Racionalidad Computacional. Academia Mexicana de Computación (2021)
6. Pineda, L. A., Fuentes, G., Morales, R.: An entropic associative memory. *Scientific Reports*, vol. 11, no. 1, pp. 6948 (2021) doi: 10.1038/s41598-021-86270-7
7. Pineda, L. A., Morales, R.: Weighted entropic associative memory and phonetic learning. *Scientific Reports*, vol. 12, no. 1, pp. 16703 (2022) doi: 10.1038/s41598-022-20798-0
8. Pineda, L. A., Morales, R.: Imagery in the entropic associative memory. *Scientific Reports*, vol. 13, no. 1, pp. 9553 (2023) doi: 10.1038/s41598-023-36761-6
9. Quillian, M. R.: Semantic memory. Air Force Cambridge Research Laboratories, Office of Aerospace Research. (1966)
10. Ramsauer, H., Schäfl, B., Lehner, J., Seidl, P., Widrich, M., Gruber, L., Holzleitner, M., Pavlovic, M., Sandve, G. K., Greiff, V., Kreil, D. P., Kopp, M., Klambauer, G., Brandstetter, J., Hochreiter, S.: Hopfield networks is all you need (2020) doi: 10.48550/arXiv.2008.02217
11. Shannon, C. E.: A mathematical theory of communication. *The Bell System Technical Journal*, vol. 27, pp. 379–423 (1948) doi: 10.1002/j.1538-7305.1948.tb01338.x