

Simulación usando redes neuronales del Test cognitivo Analogía de Matrices

Jorge Alberto Horas⁽¹⁾⁽²⁾⁽⁴⁾, Juan Pablo Galanzini⁽¹⁾⁽⁴⁾, Carlos Kavka⁽³⁾⁽⁴⁾

Email: jhoras@unsl.edu.ar, pgalanzi@unsl.edu.ar, ckavka@unsl.edu.ar

Instituto de Matemática Aplicada San Luis⁽¹⁾. Departamento de Física⁽²⁾.

Departamento de Informática⁽³⁾. Facultad de Ciencias Físicas Matemáticas y Naturales⁽⁴⁾.

Universidad Nacional de San Luis

Av. Ejército de los Andes 950 1^{er} Piso. C.P. 5700.

San Luis. Argentina.

Resumen:

Mediante el uso de redes neuronales se simula un conocido test cognitivo utilizado en la batería K-ABC, que es un test de inteligencia utilizado para niños. Las redes neuronales utilizadas realizan primero una compresión y reducción de dimensionalidad de las imágenes y luego clasifican las mismas. La reducción de dimensionalidad es producida mediante un Autoasociador y las características relevantes se obtienen a partir de la información de la imagen original como un todo. La imagen así reducida configura la entrada de una red neuronal de dos capas que es entrenada por Backpropagation a fin de clasificar las mismas. Se estudia la habilidad de generalización de esta red variando la dimensionalidad y otros parámetros. Por último se comparan los resultados de generalización de las redes y de sujetos humanos.

Palabras Claves:

Redes Neuronales, Perceptron Multicapa, Autoasociador, Backpropagation, Habilidad de Generalización.

1.0 - Introducción y motivación

Describimos aquí la simulación y posterior comparación con resultados de sujetos humanos de un conocido test cognitivo denominado Analogía de Matrices. Este test forma parte de la batería K-ABC utilizada como test de inteligencia en niños (1).

La motivación de este trabajo es el uso, aplicación y análisis de redes neuronales a procesos reales provenientes de las ciencias cognitivas, en tareas de reconocimiento y clasificación de patrones para los cuales se muestran hábiles.

El objetivo de este trabajo es, además de tratar de simular mediante el uso de redes neuronales un test que intenta determinar la forma de procesamiento y el razonamiento por analogía, el de estudiar los resultados de las redes neuronales sometidas a diversas situaciones.

Se trata de estudiar la influencia que tiene el aprendizaje, variando los recursos de la red, sobre la habilidad de generalización de una red neuronal artificial entrenada para clasificar.

Coincidentemente con lo anterior, mostramos que una red neuronal mejora notablemente su capacidad de clasificación y generalización si recibe como entrada los datos comprimidos provenientes de la capa oculta de un Autoasociador. Esta parece ser también una característica de los humanos, procesan y elaboran sobre conjuntos de datos previamente comprimidos [2].

Mostramos también que un Autoasociador es capaz de extraer las características relevantes de un problema de mayor dimensionalidad.

El problema de clasificación puede verse en la Fig. 1, donde hay un signo de interrogación el sujeto humano (o la red en nuestro caso) deben responder cual de las siete figuras que se muestran es la correcta (1).

El modelo utilizado para simular [3] se muestra en la Fig. 2. El Autoasociador extrae las características fundamentales de cada uno de los ítems mostrados en la Fig. 1 y las representaciones internas desarrolladas en las activaciones de la capa oculta, es dada como entrada a una red de clasificación entrenada para responder si la respuesta es correcta o no. Se estudia la habilidad de generalización de esta red, o sea su capacidad de responder correctamente a ítems nunca vistos.

La red de autoasociación o Autoencoder es entrenada simplemente para reproducir su entrada y puesto que hace esto utilizando un número comparativamente pequeño de unidades en la capa oculta, es capaz de extraer las regularidades de los vectores de entrada durante el aprendizaje.

Si bien la red de autoasociación utiliza aprendizaje por Backpropagation, no se usa otro maestro que el propio vector de entrada, de esta forma el aprendizaje puede considerarse como no supervisado.

Mostramos que las características desarrolladas por el modelo son holísticas y ellas pueden combinarse para formar y dar respuestas sobre las cuales el clasificador no ha sido entrenado.

2.0 - Implementación

El problema bajo estudio, según se muestra en la Fig. 1, consta de un conjunto de 112 patrones que se forman a partir de los 16 ítems que se muestran al sujeto, y 7 probables respuestas de las cuales una es correcta.

Un primer asunto a resolver consiste en dilucidar si las redes neuronales generalizan mejor sobre datos comprimidos o no. Se hicieron exhaustivas pruebas con un perceptron de dos capas de pesos, en el cual se alimentaron los ítems completos (3600 entradas) y su correspondiente respuesta correcta (900 salidas), la habilidad de generalización de esta red fue pobrísima. Aun variando el número de unidades ocultas, el tamaño del conjunto de entrenamiento y los parámetros específicos de la red, se perdía toda información sobre la estructura de los patrones. Esto da clara respuesta al interrogante y justifica el uso del modelo mostrado.

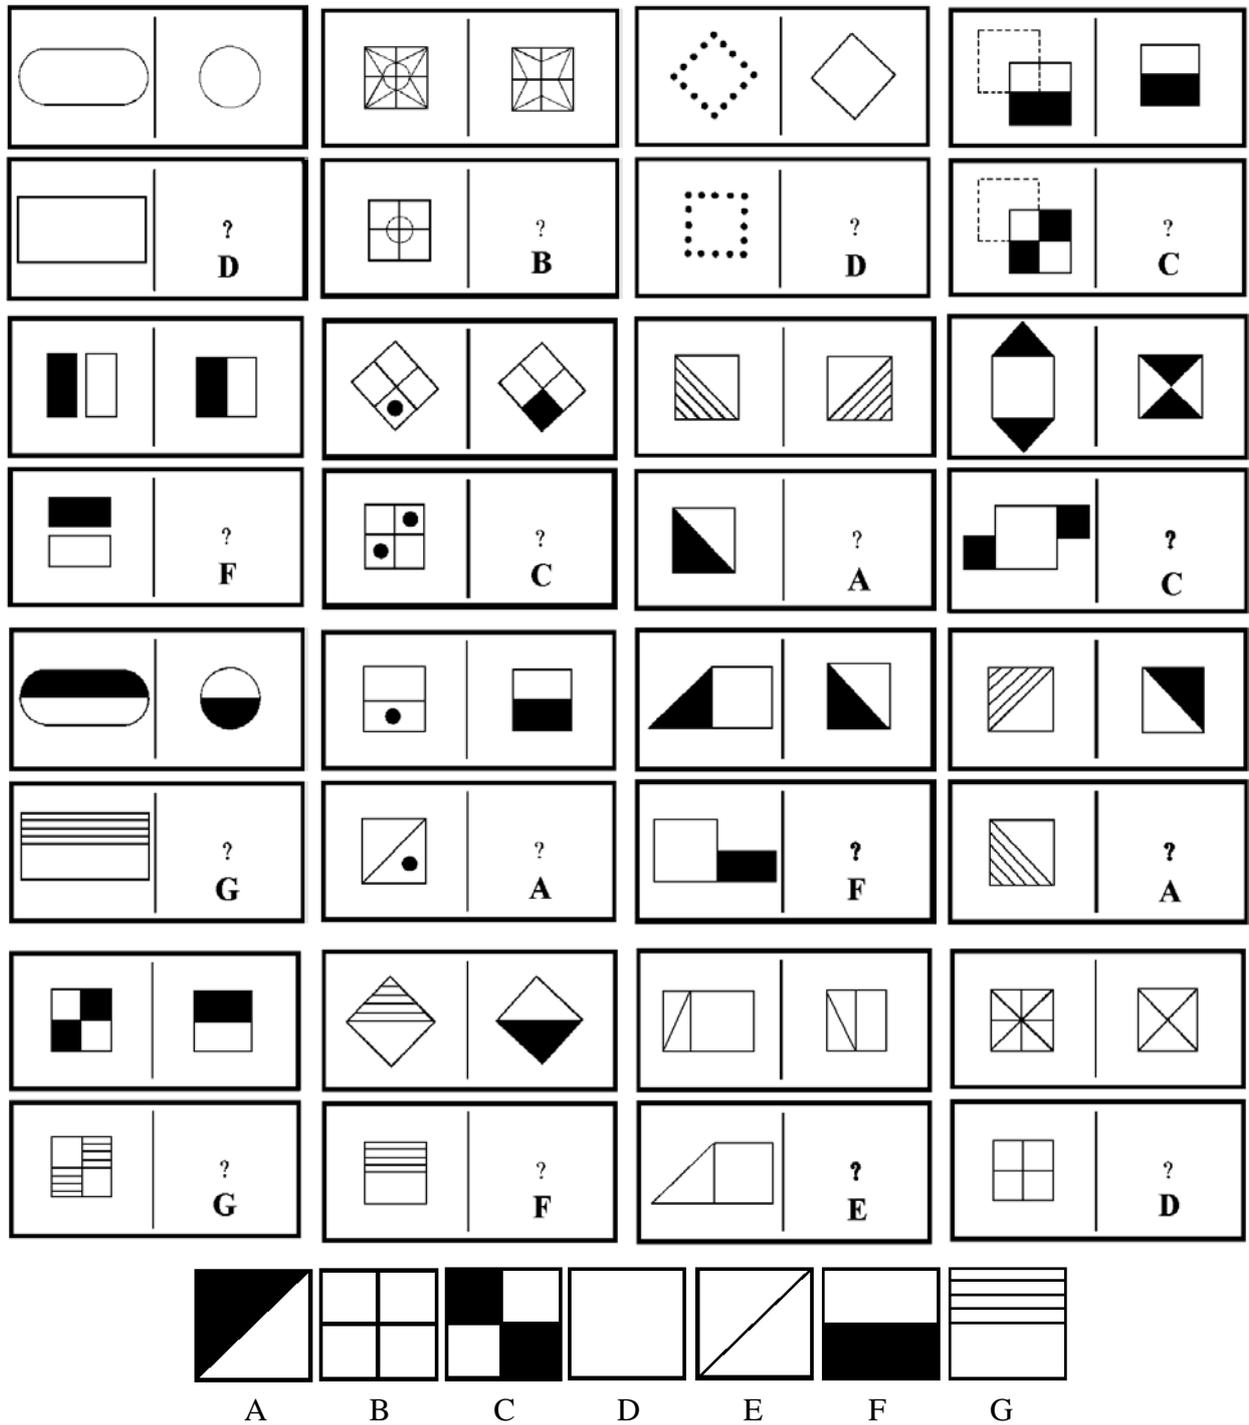


Fig. 1: Test de Analogía de Matrices y sus respuestas.

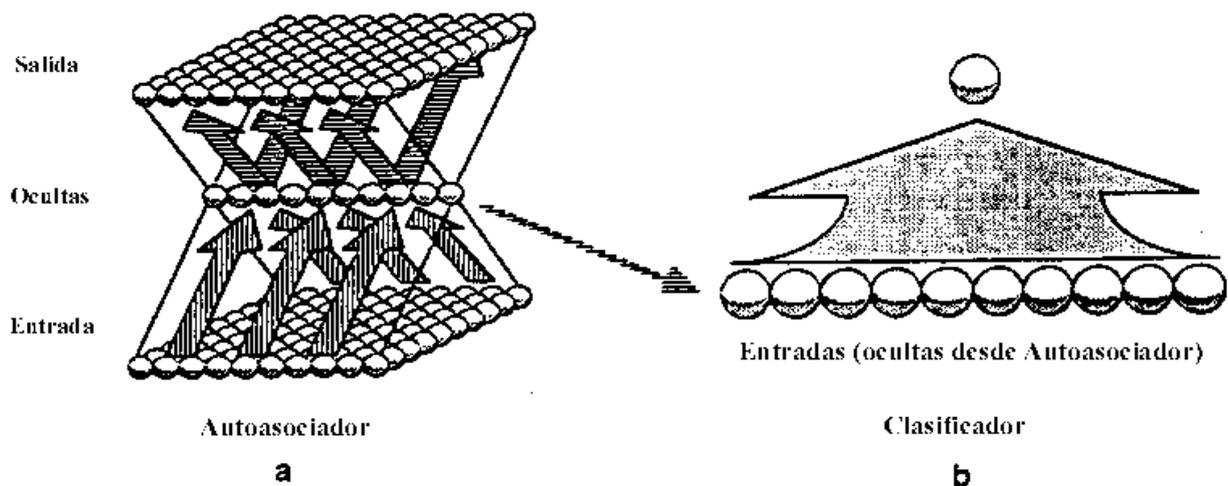


Fig. 2: El modelo para el Test de Analogía de Matrices. (a) Una red compresión de imágenes entrenada primero para comprimir las 3600 entradas en 15-35 unidades ocultas según al caso. (b) Las activaciones de las unidades ocultas obtenidas de la primera red son usadas como entradas de una red de clasificación con un número (5,10) de unidades ocultas según el caso y solo una de salida.

Consecuentemente con lo anterior, es conveniente entonces estudiar el problema en dos etapas: a) Reducción de la dimensionalidad de las imágenes. b) Clasificación de las respuestas entre correctas e incorrectas y determinación de la habilidad de generalización de las redes neuronales, que en definitiva es lo que se comparara con las respuestas de los humanos.

2.1 - Reducción de la dimensionalidad de las imágenes

2.1.1. - Procesamiento de Imágenes

Sé escanearon los 16 ítems y las 7 respuestas posibles a cada uno y su combinación dio los 112 patrones o ítems completos. Se convirtió cada uno de ellos a modo texto. En razón de que por el tipo de imágenes no es necesario dar niveles de grises se ajusto convenientemente el umbral y la codificación usada fue de 0 (blanco) y 1 (negro). Cada una de las imágenes fue reducida a un tamaño de 30x30 pixeles y por lo tanto un ítem completo (4 imágenes) corresponde a 3600 pixeles.

2.1.2 - Reducción de la dimensionalidad

Existen numerosas metodologías para la compresión de imágenes, entre ellas elegimos en este trabajo para reducir redundancias y comprimir la dimensionalidad tomar las representaciones internas producidas por un Autoasociador o Autoencoder según se muestra en la Fig. 2.

Cada uno de los ítems de 3600 dimensiones fue alimentado a la entrada y salida de este Autoasociador y su dimensionalidad se reduce a 15, 25 o 35 según el caso.

2.2 - Clasificación y generalización

A partir de que existe una fuerte indicación de que los sujetos humanos clasifican y procesan sobre representaciones reducidas [4], se utilizo para realizar la clasificación, un perceptron multicapa que tenia como entradas las activaciones de las neuronas ocultas del Autoasociador. Estas que son las entradas están densamente conectadas a un número de neuronas ocultas, y por ultimo todas ellas se conectan a una única neurona de salida que simplemente respondía correcta (1) o incorrectamente (0). Se estudió la habilidad de generalización del perceptron multicapa utilizado (MLP). Se

comprobó numéricamente que esta tarea de clasificación no puede ser llevada a cabo por un perceptron simple puesto que el problema no es linealmente separable.

3.0 - Procedimiento

3.1 - Autoencoder o Autoasociador

La imagen completa de cada ítem fue ingresada al Autoasociador de forma tal que la capa de entrada y la de salida tienen 30x30x4 neuronas. Usamos 15, 25 y 35 unidades en la capa oculta. En todos los casos se utilizó una función sigmoidea con un rango [0,1]. Debido a la extrema diferencia en el número de unidades entre las capas ocultas y de salida (15, 25 o 35 vs. 3600), se utilizaron parámetros de aprendizaje diferentes en estas dos capas. Esto último resultó en un muy notable aceleramiento de la velocidad de aprendizaje. Concretamente se utilizó un parámetro de aprendizaje en la capa oculta de 0,0001 y otro en la capa de salida de 0,1. El momento fue fijado en 0,8 para ambas capas y no se utilizaron técnicas de regularización o decaimiento de pesos. Los pesos iniciales fueron elegidos al azar en el rango [-0.5,0.5]. En razón de la no existencia de niveles de grises en las imágenes, las salidas mayores o iguales que 0,5 fueron tomadas como 1, y las menores a 0,5 fueron tomadas como 0.

3.2 - Perceptron de dos capas de pesos para clasificación y generalización

Los vectores producidos por la capa oculta de la red de compresión (Autoencoder) (35, 25 y 15 elementos), son dados como entrada a una red de dos capas de pesos que tenía 5 o 10 unidades ocultas. Esta red se usa para clasificar las imágenes. Es entrenada mediante el algoritmo de Backpropagation, correspondiendo el conjunto de entrenamiento a un número de los ítems completos mencionados a los que se adiciona la información de si la salida esperada es correcta o no.

El parámetro de aprendizaje, en este caso fue de 0,9 en ambas capas, y el término de momento también se fijó en 0,9. Los pesos iniciales fueron tomados al azar en el rango [-0.5,0.5] y tampoco se usaron técnicas de decaimiento de pesos o de regularización. Las salidas mayores o iguales que 0.5 fueron tomadas como 1 y las menores a 0.5 como 0.

4.0 - Resultados

En la Fig. 3 se muestra un gráfico de generalización donde la ordenada da el porcentaje de aciertos y la abscisa el número de patrones utilizados para entrenar. El total de 112 patrones fue dividido en un conjunto de entrenamiento (80, 90 o 100 patrones) y el correspondiente conjunto de testeo (32, 22 o 12 patrones), elegidos ambos al azar, tomándose especial cuidado de que en el último conjunto siempre hubiera el 30% de patrones de clases distintas (correctos o incorrectos).

En razón de que se comprimieron previamente las imágenes es importante determinar la existencia o no de variaciones relevantes al variar la reducción de dimensionalidad (35, 25, 15), o sea el número de unidades ocultas en el perceptrón multicapa que clasifica las respuestas. Se informa también en esta figura con qué confiabilidad, medida en porcentaje (95%, 99%, 100%) de píxeles (bits) correctos por imagen, fue reproducido el patrón en la capa de salida del Autoasociador. El entrenamiento fue realizado el número de épocas necesario para obtener el 100% de aciertos en el conjunto de patrones usados para entrenar, con la confiabilidad especificada.

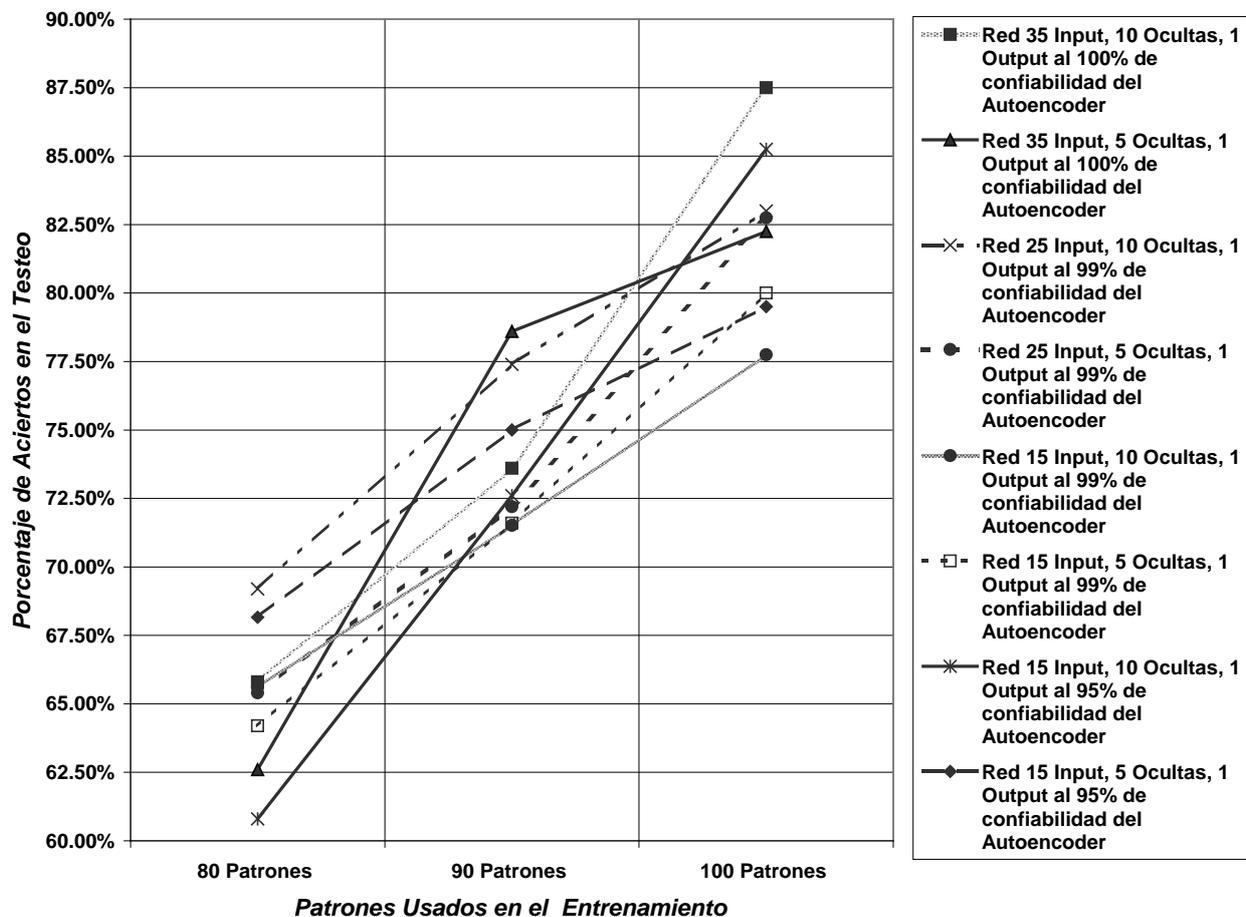


Fig. 3: Se gráfica el porcentaje de aciertos en testeo vs. la cantidad de patrones usados en el entrenamiento para varias arquitecturas en la etapa de clasificación.

Importa determinar si distintas reducciones y diferentes confiabilidades en la reproducción de la imagen original tienen influencia, y en su caso cual, sobre la habilidad de generalización medida en términos de porcentaje de aciertos en el testeo. Todo ello se muestra en la Fig. 4 a, b donde en la abscisa se da la confiabilidad de reproducción del Autoencoder y en la ordenada el porcentaje de aciertos en el conjunto de testeo. Se tomo aquí el conjunto de entrenamiento de 90 o 100 patrones, se entreno por completo sobre el, y el testeo fue realizado sobre los 22 o 12 restantes con idéntico criterio del 30% de patrones diferentes que ya fuera usado en el caso anterior.

Debe mencionarse que en ambas figuras cada punto representa el promedio sobre todos los patrones pertenecientes al conjunto de testeo y también sobre 100 redes.

Por ultimo en la Tabla 1 se muestran los resultados obtenidos en cada uno de los ítems. A fin de comparar la performance de nuestras redes con la de sujetos humanos que realizaron la misma tarea. Se utilizaron resultados del test Analogía de Matrices realizados a niños cuyas edades variaron de 5 a 7 años concurrentes a escuelas primarias de la ciudad de San Luis, según se informa en la referencia 4.

Varios factores (pequeño tamaño de la muestra humana en algunos casos, y su alta heterogeneidad) dificultan la confiabilidad estadística del testeo del modelo vs. los sujetos. Sin embargo es informativo comparar los resultados obtenidos por los dos conjuntos (humanos y redes) en cada uno de los ítems.

Fig. 4 (a)

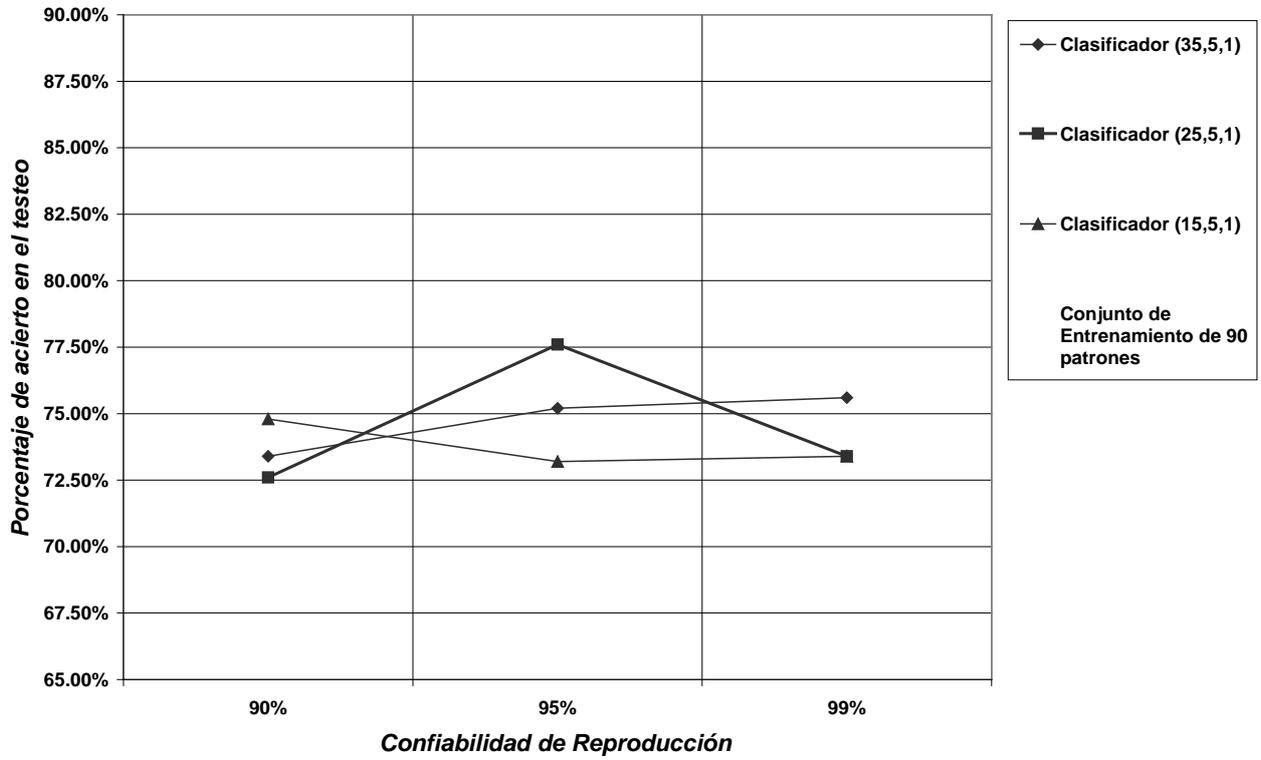


Fig. 4 (b)

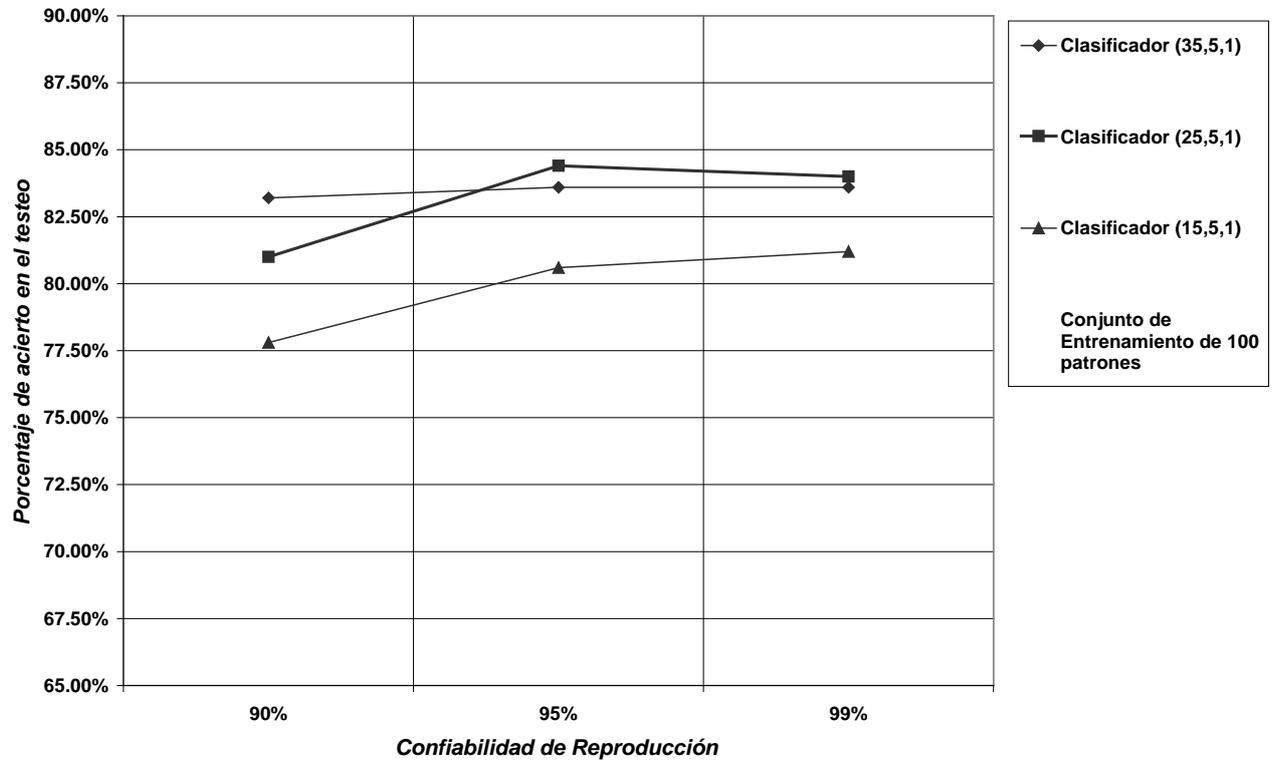


Fig. 4 a, b: Se gráfica el porcentaje de aciertos en testeo vs. la confiabilidad de la reproducción de la imagen original para distintos tamaños de la capa oculta en el Autoencoder.

En la Tabla 1 el número de sujetos varía entre 281 y 12, pero el número de redes se mantuvo constante en 100. Debe mencionarse que el resultado de las redes depende de si estas fueron entrenadas con 60, 90 o 100 patrones. No fue necesario variar otros parámetros dado que los resultados son representativos. Los porcentajes de aciertos informados son siempre sobre los conjuntos de testeo correspondientes, discriminados ahora los aciertos sobre cada uno de los patrones o ítems completos.

Ítem	Humano		Red (100)		
	Cantidad Test	Respuesta	60 Patrones (a)	90 Patrones (b)	100 Patrones (c)
1	281	53.38%	50.00%	78.38%	85.71%
2	281	51.60%	53.85%	66.67%	80.00%
3	281	48.04%	48.28%	80.65%	96.15%
4	281	64.06%	72.00%	78.38%	94.12%
5	281	60.14%	45.45%	88.10%	96.77%
6	281	29.89%	35.14%	80.00%	100.00%
7	281	49.11%	62.86%	85.29%	92.00%
8	281	25.27%	53.12%	81.48%	78.13%
9	68	76.47%	55.17%	84.38%	84.85%
10	68	27.94%	45.00%	80.00%	88.46%
11	68	20.59%	56.67%	88.46%	94.44%
12	68	20.59%	55.56%	68.75%	92.00%
13	12	66.67%	48.48%	56.25%	82.35%
14	12	0.00%	56.67%	80.65%	83.33%
15	12	25.00%	32.00%	74.07%	76.67%
16	12	0.00%	50.00%	86.36%	82.76%

Tabla 1: Comparación de resultados entre sujetos humanos y habilidad de generalización de las redes de clasificación para cada uno de los ítems presentados.

- a- Red 35,5,1 al 100% de confiabilidad en el Autoencoder.
- b- Red 35,5,1 al 100% de confiabilidad en el Autoencoder.
- c- Red 35,10,1 al 100% de confiabilidad en el Autoencoder.

5.0 - Discusión y análisis de los resultados

Realizamos primero un análisis de los resultados obtenidos por las redes (Autoencoder y clasificador), sometidas a diversas condiciones, variando el número de nodos, confiabilidad de la reproducción, etc. Por último comentamos los resultados de la comparación con niños.

5.1 - Redes Neuronales

La Fig. 3 es un gráfico que muestra la habilidad de generalización y su comportamiento a primera vista es típico puesto que el porcentaje de aciertos en testeo crece con el número de patrones con que la red ha sido entrenada.

Del análisis comparativo de la gráfica podemos señalar a la red de (35,5,1) y 100% del Autoencoder como la que tiene el comportamiento más llamativo puesto que cruza a todas las otras hasta el punto de 90 patrones, pero disminuye su pendiente de crecimiento en adelante. Destacable también es el comportamiento de la red (15,10,1) al 95% del Autoencoder cuyo comportamiento en generalización tiene una pendiente positiva y constante. Las tendencias ya mencionadas junto con la influencia del resto de parámetros que se muestran en esta figura, indican la existencia de un compromiso entre el número de nodos en la capa oculta del Autoencoder y la confiabilidad de reproducción, para obtener la mejor generalización.

Las Fig. 4 a y b permiten analizar el compromiso mencionado. En ellas se muestra comportamiento respecto de la confiabilidad del Autoencoder parametrizadas con las entradas del clasificador. Esto permite la detección de un óptimo para la generalización que estaría ubicado en el 95% de confiabilidad y una reducción a 25 nodos.

5.2 Comparación con sujetos.

En la Tabla 1, en la que debe insistirse su carácter informativo por las razones ya expresadas, se comparan las redes que dieron mejores resultados esta vez ítem por ítem. Una primera conclusión es que a diferencia de los humanos, las redes no presentan una dispersión importante en sus respuestas. Ello puede deberse a la característica y forma del aprendizaje, cuestión que será analizada en futuras contribuciones.

Sin embargo es claro que también para las redes existen ítems más difíciles que otros y por sobre todo que hay una clara dependencia, con la cantidad de patrones con que la red ha sido entrenada. Esto último es coincidente con que mayores niveles de escolaridad y capacidad (mayor aprendizaje) resultan en mejores resultados en los sujetos, lo cual se produce también en las redes.

6.0 - Conclusiones

Este trabajo permite concluir lo siguiente:

1. Que el modelo propuesto de dos redes neuronales, para comprimir y clasificar imágenes, se muestra apto para estudiar el test Analogía de Matrices
2. Que efectivamente la capacidad de generalización de una red neuronal aumenta si se trabaja con imágenes reducidas en dimensionalidad.
3. Que la técnica de tomar las activaciones la capa oculta de un Autoasociador capta las características fundamentales del patrón a analizar.
4. Que la confiabilidad de reproducción y el tamaño de reducción de los ítems son un dato importante a estudiar con la habilidad de generalización.

Bibliografía

1. Kaufman Alan S. Kaufman Nadeen L. *Kabc. Kaufman Assessment Battery Children*. American Guidance Service. Circle Pines, Minnesota. 1983.
2. Cohen Eyal. Ruppin Eytan. *On Parallel Versus Serial Processing: A Computational Study of Visual Search*. Advances in Neural Network Information Processing Systems, Vol. 10, pp.10-16. A Bradford Book. The MIT Press, Cambridge, Massachusetts. 1998.
3. Cottrell Garrison W. Metcalfe Janet. *Empath: Face, Emotion, and Gender Recognition Using Holons*. Advances in Neural Network Information Processing Systems, Vol. 3, pp.564-571. San Mateo, California: Morgan Kaufman Publishers. 1991.
4. A. Taborda, D. Diaz, J.P. Galanzini, J. Horas. *Adaptación y estandarización del Test K-ABC de Kaufman y Kaufman*, XV Congreso Argentino de Psiquiatría. Mar del Plata, Argentina, 15 al 18 de Abril de 1999. A. Taborda, D. Diaz. *Un estudio transcultural del Test K-ABC*, XXVII Congreso Interamericano de Psicología, Caracas, Venezuela. 27 de Junio al 2 de Julio de 1999.

5. Haykin Simon. *Neural Network. A Comprehensive Foundation*. Macmillan College Publishing Company, Inc. Englewood Cliffs, New Jersey. 1994.
6. Parks, W. Parks, Levine Daniel S, Long Debra L. *Fundamentals of Neural Network Modeling*. The MIT Press. Massachusetts Institute of Technology, Cambridge, Massachusetts. 1998