

PH. D. THESIS ABSTRACT

Memorias Asociativas Basadas en Relaciones de Orden y Operaciones Binarias

Associative Memories Based on Orderings and Binary Operators

Graduated: Cornelio Yáñez Márquez

Graduated on March 20, 2002

Centro de Investigación en Computación

Juan de Dios Bátiz s/n esq. Miguel Otrón de Mendizabal

Unidad Profesional Adolfo López Mateos

Del. Gustavo A. Madero, México, D. F.

e-mail: cyanez@cic.ipn.mx

Advisor: Juan Luis Díaz de León Santiago

Centro de Investigación en Computación

e-mail: jdiaz@cic.ipn.mx

Resumen

En este artículo se propone un nuevo modelo de memorias asociativas. Las herramientas matemáticas del nuevo modelo incluyen dos operaciones binarias inventadas ex profeso, cuyos operadores fueron bautizados arbitrariamente con las dos primeras grafías del alfabeto griego: α y β . Las nuevas memorias asociativas $\alpha\beta$ son de dos tipos y cada uno de ellos puede operar en dos modos diferentes. La operación α es útil en la fase de aprendizaje, mientras que la operación β da sustento a la fase de recuperación de patrones. Las propiedades algebraicas de las operaciones α y β permiten que las nuevas memorias asociativas $\alpha\beta$ exhiban características similares a las que son inherentes a las memorias asociativas morfológicas binarias, en cuanto a capacidades de aprendizaje y almacenamiento, tipos y cantidades de ruido a que son robustas, y las condiciones suficientes para exhibir respuesta perfecta; adicionalmente, es preciso enfatizar que la densidad aritmética de las nuevas memorias asociativas es menor que la correspondiente a las memorias asociativas morfológicas. La razón para tomar como referencia a las memorias asociativas morfológicas para la creación de las memorias $\alpha\beta$, consiste en que los autores de las primeras han mostrado que estas memorias superan en varios aspectos a los modelos conocidos de memorias asociativas hasta los inicios del tercer milenio.

Palabras clave: Memoria asociativa, operación binaria, relación de orden, memorias asociativas $\alpha\beta$, memorias asociativas morfológicas.

Abstract

A new model for associative memories is proposed in this paper. The mathematical tools used in this new model, include two binary operators designed specifically for the memories developed here. These operators were arbitrarily named as the first two letters from the Greek alphabet: α and β . The new associative memories ($\alpha\beta$) are of two kinds and are able to operate in two different modes. The operator α is useful at the learning phase, and the operator β is the basis for the pattern recall phase. The properties within the algebraic operators α and β , allow the $\alpha\beta$ memories to exhibit similar characteristics to the ones inherent to the binary version of the morphological associative memories, in the sense of: learning capacity, type and amount of noise against which the memory is robust, and the sufficient conditions for perfect recall. Moreover, it is important to point out that the arithmetic density of the proposed memories is smaller than the arithmetic density exhibited by the morphological ones. The main reason for taking the morphological associative memories as the reference point for the genesis of the proposed ones, consist in that the authors of the first ones have already shown that the morphological associative memories are superior in some aspects to the known models of associative memories, up to the beginning of the third millennium.

Keywords: Associative memory, binary operation, order relation, $\alpha\beta$ associative memories, morphological associative memories.

1 Introducción

El tema de las memorias asociativas ha estado vigente, desde hace varios lustros, dentro de algunas áreas de investigación. El propósito fundamental de una memoria asociativa es recuperar correctamente patrones completos a partir de patrones de entrada, los cuales pueden estar alterados con ruido aditivo, sustractivo o combinado: ésta es la característica más atractiva de las memorias asociativas, y constituye un tema abierto de investigación.

Notables investigadores han abordado el problema de generar modelos de memorias asociativas (Kohonen, 1972; Hopfield, 1982), y han logrado resultados de importancia tal, que algunos de los trabajos pioneros se han convertido en auténticos clásicos. La capacidad de aprendizaje y almacenamiento, la eficiencia en la respuesta o recuperación de patrones, la rapidez y la inmunidad al ruido, son tópicos de interés entre los investigadores.

La aparición, desarrollo, aplicaciones y consolidación de las memorias asociativas morfológicas (Ritter, Diaz-de-Leon & Sussner, 1999) marcó un hito en el campo de las memorias asociativas, en virtud de que superaron en prácticamente todos los aspectos de interés a los modelos conocidos.

En este trabajo se presenta un modelo alternativo a las memorias asociativas morfológicas, basado en la relación de orden usual y en dos operaciones binarias originales llamadas α y β ; la operación α es útil en la fase de aprendizaje, mientras que la operación β da sustento a la fase de recuperación de patrones. A este nuevo modelo se le ha asignado el nombre de **memorias asociativas $\alpha\beta$** .

Las nuevas memorias asociativas son similares, y en algunos casos superiores, a las memorias asociativas morfológicas en cuanto a capacidad de almacenamiento de patrones, eficiencia en respuesta e inmunidad al ruido.

Con la creación de las bases matemáticas y del modelo completo de las **memorias asociativas $\alpha\beta$** , se ha generado un producto original de investigación en la frontera del conocimiento científico; es un producto autóctono que eventualmente contribuirá con su granito de arena a avanzar en el afán de lograr ese noble propósito de alcanzar la independencia científica y tecnológica para nuestro país.

2 Memorias Asociativas

Por su naturaleza, el problema inherente al funcionamiento de las memorias asociativas se escinde en dos fases claramente distinguibles:

1. Fase de *aprendizaje* (generación)
2. Fase de *recuperación* (operación)

El propósito fundamental de una memoria asociativa es recuperar patrones completos a partir de patrones de entrada que pueden estar alterados con ruido aditivo, sustractivo o combinado. De acuerdo con esta afirmación, una *memoria asociativa* M puede formularse como un sistema de entrada y salida, idea que se esquematiza a continuación (Hassoun, 1993):

$$x \rightarrow [M] \rightarrow y$$

El *patrón de entrada* se representa por un vector columna denotado por x y el *patrón de salida*, por un vector columna denotado por y .

Cada uno de los patrones de entrada forma una *asociación* con el correspondiente patrón de salida. La notación para una asociación es (x, y) ; en general, para un número entero positivo k específico, la asociación correspondiente será (x^k, y^k) . La memoria asociativa M se representa mediante una matriz cuya componente ij -ésima es m_{ij} (Palm, Schwenker, Sommer & Strey, 1997); la matriz M se genera a partir de un conjunto finito de asociaciones conocidas de antemano: éste es el *conjunto fundamental de asociaciones*, o simplemente *conjunto fundamental*. Se denota por p la cardinalidad del conjunto fundamental (p es un número entero positivo).

Si μ es un índice, el conjunto fundamental se representa de la siguiente manera:

$$\{(x^\mu, y^\mu) \mid \mu = 1, 2, \dots, p\}$$

A los patrones que conforman las asociaciones del conjunto fundamental, se les llama *patrones fundamentales*.

La naturaleza del conjunto fundamental proporciona un importante criterio para clasificar las memorias asociativas. Si se cumple que $x^\mu = y^\mu \forall \mu \in \{1, 2, \dots, p\}$, se dice que la memoria es *autoasociativa*; de otro modo, la memoria es *heteroasociativa* (Kohonen, 1972). Es evidente que para una memoria heteroasociativa se cumple lo siguiente: $\exists \mu \in \{1, 2, \dots, p\}$ para el que $x^\mu \neq y^\mu$.

Es posible que los patrones fundamentales sean alterados con diferentes tipos de ruido. Para diferenciar un patrón alterado del correspondiente patrón fundamental, usaremos la tilde en la parte superior; así, el patrón \tilde{x}^k es una versión alterada del patrón fundamental x^k , y el tipo de alteración que representa \tilde{x}^k se evidenciará en el contexto específico donde se use.

Si al presentarle a la memoria M un patrón alterado \tilde{x}^ω como entrada ($\omega \in \{1, 2, \dots, p\}$), M responde con el correspondiente patrón fundamental de salida y^ω , se dice que la recuperación es *perfecta*.

Se especifican dos conjuntos A y B ; las componentes de

los vectores columna que representan a los patrones, tanto de entrada como de salida, serán elementos del conjunto A , y las entradas de la matriz M serán elementos del conjunto B . Sean m, n números enteros positivos; se denota por n la dimensión de los patrones de entrada, y por m la dimensión de los patrones de salida.

Cada vector columna que representa a un patrón de entrada tiene n componentes cuyos valores pertenecen al conjunto A , y cada vector columna que representa a un patrón de salida posee m componentes cuyos valores pertenecen al conjunto A . Es decir:

$$x^\mu \in A^n \text{ y } y^\mu \in A^m \forall \mu \in \{1, 2, \dots, p\}$$

La j -ésima componente de un vector columna se indica con la misma letra del vector, pero sin negrilla, colocando a j como subíndice ($j \in \{1, 2, \dots, n\}$ o $j \in \{1, 2, \dots, m\}$ según corresponda). La j -ésima componente de un vector columna x^μ se representa por

$$x_j^\mu$$

Al usar el superíndice t para indicar el transpuesto de un vector, se obtienen las siguientes expresiones para los vectores columna que representan a los patrones fundamentales de entrada y de salida, respectivamente:

$$x^\mu = (x_1^\mu, x_2^\mu, \dots, x_n^\mu)^t = \begin{pmatrix} x_1^\mu \\ x_2^\mu \\ \vdots \\ x_n^\mu \end{pmatrix} \in A^n$$

$$y^\mu = (y_1^\mu, y_2^\mu, \dots, y_m^\mu)^t = \begin{pmatrix} y_1^\mu \\ y_2^\mu \\ \vdots \\ y_m^\mu \end{pmatrix} \in A^m$$

Problema general de las memorias asociativas:

1. **Fase de aprendizaje.** Encontrar los operadores adecuados y una manera de generar una matriz M que almacene las p asociaciones del conjunto fundamental

$$\{(x^1, y^1), (x^2, y^2), \dots, (x^p, y^p)\}$$

, donde $x^\mu \in A^n$ y $y^\mu \in A^m \forall \mu \in \{1, 2, \dots, p\}$. Si $\exists \mu \in \{1, 2, \dots, p\}$ tal que $x^\mu \neq y^\mu$, la memoria será *heteroasociativa*; si $m = n$ y $x^\mu = y^\mu \forall \mu \in \{1, 2, \dots, p\}$, la memoria será *autoasociativa*.

2. **Fase de recuperación.** Hallar los operadores adecuados y las condiciones suficientes para obtener el patrón fundamental de salida y^μ , cuando se opera la memoria M con el patrón fundamental de entrada x^μ ; lo anterior para todos los elementos del conjunto fundamental y para ambos modos: autoasociativo y heteroasociativo. Exhibir y caracterizar, además, el ruido que puede soportar la memoria en el patrón de entrada \tilde{x}^ω , para entregar como salida y^ω .

3 Herramientas Matemáticas

Esta sección consta de tres partes. En la primera se presentan las dos operaciones binarias originales α y β , las cuales sirven de base para construir cuatro operaciones matriciales, que son presentadas en la segunda parte; finalmente, en la tercera parte se enfatiza el papel que juegan las relaciones de orden en este trabajo, al definir los diferentes tipos de ruido que pueden alterar un patrón binario dado.

3.1 Operaciones Binarias α y β

Los conjuntos A y B se definen así:

$$A = \{0, 1\} \quad \text{y} \quad B = \{0, 1, 2\}$$

La operación binaria $\alpha : A \times A \rightarrow B$ está definida en la siguiente tabla:

x	y	$\alpha(x, y)$
0	0	1
0	1	0
1	0	2
1	1	1

La operación binaria α exhibe algunas propiedades algebraicas, expuestas a continuación, donde \vee es el operador *máximo* y \wedge es el operador *mínimo*:

$\alpha(x, x) = 1$
$(x \leq y) \leftrightarrow \alpha(x, y) \leq \alpha(y, x)$
$(x \leq y) \leftrightarrow \alpha(x, z) \leq \alpha(y, z)$
$(x \leq y) \leftrightarrow \alpha(z, x) \geq \alpha(z, y)$
$\alpha(x \vee y, z) = \alpha(x, z) \vee \alpha(y, z)$
$\alpha(x \wedge y, z) = \alpha(x, z) \wedge \alpha(y, z)$

La operación binaria $\beta : B \times A \rightarrow A$ está definida en la siguiente tabla:

x	y	$\beta(x, y)$
0	0	0
0	1	0
1	0	0
1	1	1
2	0	1
2	1	1

Propiedades algebraicas de la operación binaria β :

$\beta(1, x) = x$
$\beta(x, x) = x \quad \forall x \in A$
$(x \leq y) \rightarrow \beta(x, z) \leq \beta(y, z)$
$(x \leq y) \rightarrow \beta(z, x) \leq \beta(z, y)$
$\beta(x \vee y, z) = \beta(x, z) \vee \beta(y, z)$
$\beta(x \wedge y, z) = \beta(x, z) \wedge \beta(y, z)$
$\beta(x, (y \vee z)) = \beta(x, y) \vee \beta(x, z)$
$\beta(x, (y \wedge z)) = \beta(x, y) \wedge \beta(x, z)$

Propiedades de la aplicación combinada de ambas operaciones α y β :

$\beta(\alpha(x, y), y) = x$
$\beta(\alpha(x, y), x) = x$
$\beta(\alpha(x, x), y) = y$

Lo anterior significa que β es la inversa de α por la derecha y por la izquierda.

Los conjuntos A y B , las operaciones α y β junto con los operadores \wedge (mínimo) y \vee (máximo) usuales, conforman el sistema algebraico $(A, B, \alpha, \beta, \wedge, \vee)$ en el que están inmersas las nuevas memorias asociativas $\alpha\beta$.

3.2 Operaciones Matriciales $\mathbb{U}_\alpha, \mathbb{M}_\alpha, \mathbb{U}_\beta$ y \mathbb{M}_β

Se definen las siguientes cuatro operaciones entre matrices:

1. Operación αmax : $P_{m \times r} \mathbb{U}_\alpha Q_{r \times n} = [f_{ij}^\alpha]_{m \times n}$, donde

$$f_{ij}^\alpha = \bigvee_{k=1}^r \alpha(p_{ik}, q_{kj})$$

2. Operación βmax : $P_{m \times r} \mathbb{U}_\beta Q_{r \times n} = [f_{ij}^\beta]_{m \times n}$, donde

$$f_{ij}^\beta = \bigvee_{k=1}^r \beta(p_{ik}, q_{kj})$$

3. Operación αmin : $P_{m \times r} \mathbb{M}_\alpha Q_{r \times n} = [h_{ij}^\alpha]_{m \times n}$, donde

$$h_{ij}^\alpha = \bigwedge_{k=1}^r \alpha(p_{ik}, q_{kj})$$

4. Operación βmin : $P_{m \times r} \mathbb{M}_\beta Q_{r \times n} = [h_{ij}^\beta]_{m \times n}$, donde

$$h_{ij}^\beta = \bigwedge_{k=1}^r \beta(p_{ik}, q_{kj})$$

k es un entero positivo que puede tomar valores entre 1 y r inclusive.

Obsérvese la *dualidad* entre los pares de operaciones \mathbb{U}_α y \mathbb{M}_α por un lado, y entre \mathbb{U}_β y \mathbb{M}_β por el otro.

Restricciones:

- Ninguna de las cuatro operaciones está definida si $\exists j, k$ tales que $q_{kj} = 2$.
- Las operaciones \mathbb{U}_α y \mathbb{M}_α no están definidas si $\exists i, j, k$ tales que $p_{ik} = 2$ o $q_{kj} = 2$.

Estas restricciones aparentan ser causa de potenciales problemas que podrían aparecer al usar las operaciones anteriores; sin embargo, las nuevas memorias asociativas están diseñadas de modo que nunca ocurra algún caso prohibido.

Lema 1. Sean $x \in A^n$, $y \in A^m$; entonces $y \mathbb{U}_\alpha x^t$ es una matriz de dimensiones $m \times n$, y además se cumple que: $y \mathbb{U}_\alpha x^t = y \mathbb{M}_\alpha x^t$.

El símbolo \boxtimes representará a las dos operaciones \mathbb{U}_α y \mathbb{M}_α .

cuando se opere un vector columna de dimensión m con un vector fila de dimensión n :

$$y \circledast x^t = y \boxtimes x^t = y \circledast_\alpha x^t$$

La ij -ésima componente de la matriz $y \boxtimes x^t$ está dada por:

$$[y \boxtimes x^t]_{ij} = \alpha(y_i, x_j)$$

Es decir, la ij -ésima componente de la matriz $y^\mu \boxtimes (x^\mu)^t$ se expresa de la siguiente manera:

$$[y^\mu \boxtimes (x^\mu)^t]_{ij} = \alpha(y_i^\mu, x_j^\mu)$$

Lema 2. Sean $x \in A^n$ y P una matriz de dimensiones $m \times n$. La operación $P_{m \times n} \circledast_\beta x$ da como resultado un vector columna de dimensión m , cuya i -ésima componente tiene la siguiente forma: $(P_{m \times n} \circledast_\beta x)_i = \bigvee_{j=1}^n \beta(p_{ij}, x_j)$

Lema 3. Sean $x \in A^n$ y P una matriz de dimensiones $m \times n$. La operación $P_{m \times n} \circledast_\beta x$ da como resultado un vector columna de dimensión m , cuya i -ésima componente tiene la siguiente forma: $(P_{m \times n} \circledast_\beta x)_i = \bigwedge_{j=1}^n \beta(p_{ij}, x_j)$

3.3 Relaciones de Orden y Tipos de Ruido

La relación de orden usual tiene importancia central al definir operativamente los tipos de ruido que es posible encontrar en los patrones de entrada, y en el papel que juegan los operadores \bigvee y \bigwedge en la generación y operación de las memorias α, β .

A continuación se enuncian algunos conceptos respecto de la relación de orden entre matrices, considerando a los vectores columna como casos particulares (Moore, 1968; Rosen, 1995). Las componentes de matrices y vectores serán elementos de uno de los conjuntos A o B .

El máximo de dos matrices P y Q es otra matriz M que se representa por $M = P \bigvee Q$, y cuya ij -ésima entrada se define como $m_{ij} = p_{ij} \bigvee q_{ij}$.

El mínimo de dos matrices P y Q es otra matriz N que se representa por $N = P \bigwedge Q$, y cuya ij -ésima entrada se define como $n_{ij} = p_{ij} \bigwedge q_{ij}$.

La notación $P \leq Q$ indica que la matriz P es menor o igual que la matriz Q , y esto se cumple si y sólo si $p_{ij} \leq q_{ij}, \forall i \forall j$.

$P < Q$ indica que la matriz P es estrictamente menor que la matriz Q , y esto se cumple si y sólo si $p_{ij} \leq q_{ij}, \forall i \forall j$ y $\exists i_0, j_0$ tales que $p_{i_0 j_0} < q_{i_0 j_0}$.

Las anteriores consideraciones tienen relevancia en el contexto de este trabajo, al considerar los diferentes tipos de ruido que pueden distorsionar un patrón de entrada dado.

Sean dos vectores columna $x^1 \in A^n$ y $x^2 \in A^n$; se dice que x^1 es menor o igual a x^2 si y sólo si cada una de las componentes del vector x^1 es menor o igual a la correspondiente componente en el vector x^2 . Esto se expresa así:

$$x^1 \leq x^2 \iff x_i^1 \leq x_i^2 \forall i \in \{1, 2, \dots, n\}$$

Sean dos vectores columna $x^1 \in A^n$ y $x^2 \in A^n$; se dice que x^1 es menor a x^2 si y sólo si: cada una de las componentes del vector x^1 es menor o igual a la correspondiente componente en el vector x^2 , y existe al menos un valor $i_0 \in \{1, 2, \dots, n\}$ para el cual se cumple la desigualdad estricta. Simbólicamente, esto se expresa así:

$$x^1 < x^2 \iff \left[\begin{array}{l} x_i^1 \leq x_i^2 \forall i \in \{1, 2, \dots, n\} \\ \text{y } \exists i_0 \in \{1, 2, \dots, n\} \text{ tal que } x_{i_0}^1 < x_{i_0}^2 \end{array} \right]$$

Para el caso de dos vectores columna y^1 y y^2 que pertenecen al conjunto A^m las definiciones anteriores siguen siendo válidas:

$$y^1 \leq y^2 \iff \left[\begin{array}{l} y_j^1 \leq y_j^2 \forall j \in \{1, 2, \dots, m\} \\ \text{y } \exists j_0 \in \{1, 2, \dots, m\} \text{ tal que } y_{j_0}^1 < y_{j_0}^2 \end{array} \right]$$

Ahora, sea $x \in A^n$ un patrón fundamental de entrada para una memoria asociativa α, β . El patrón x puede ser alterado, para dar lugar a un vector \bar{x} , por tres tipos de ruido:

1. Ruido *aditivo*, si $x \leq \bar{x}$. Esto significa que todos los posibles cambios en los valores de las coordenadas de x para obtener \bar{x} consisten en colocar un valor 1 donde había un valor 0; es decir, la única posibilidad de cambio en las coordenadas de x se traduce en: $\exists i \in \{1, 2, \dots, n\}$ para el que $x_i = 0$ y $\bar{x}_i = 1$, pero no existe $j \in \{1, 2, \dots, n\}$ para el que $x_j = 1$ y $\bar{x}_j = 0$. Además: $x \leq \bar{x} \rightarrow x_i \leq \bar{x}_i, \forall i \in \{1, 2, \dots, n\}$
2. Ruido *sustractivo*, si $x \geq \bar{x}$. Esto significa que todos los posibles cambios en los valores de las coordenadas de x para obtener \bar{x} consisten en colocar un valor 0 donde había un valor 1; es decir, la única posibilidad de cambio en las coordenadas de x se traduce en: $\exists i \in \{1, 2, \dots, n\}$ para el que $x_i = 1$ y $\bar{x}_i = 0$, pero no existe $j \in \{1, 2, \dots, n\}$ para el que $x_j = 0$ y $\bar{x}_j = 1$. Además: $x \geq \bar{x} \rightarrow x_i \geq \bar{x}_i, \forall i \in \{1, 2, \dots, n\}$
3. Ruido *combinado* o *mezclado*, si el ruido es una mezcla de aditivo con sustractivo. En este caso no es posible establecer un orden entre el patrón limpio y el ruidoso, dado que los valores podrán ser cambiados aleatoriamente, sin respetar necesariamente las reglas de los ítems 1 y 2.

Si el ruido es de 0%, es claro que $x = \bar{x}$

4 Las Memorias Asociativas $\alpha\beta$

En esta sección se presenta la obtención, justificación teórica y uso de las nuevas memorias asociativas basadas en las operaciones binarias originales α y β .

4.1 Memorias Heteroasociativas $\alpha\beta$

Se proponen dos tipos de memorias heteroasociativas $\alpha\beta$: tipo **V** y tipo **A**; se desarrollarán sólo las de tipo **V** ya que las propiedades de las memorias tipo **A** se obtienen por dualidad.

Se usará el operador \boxtimes el cual tiene la siguiente forma, para los índices $\mu \in \{1, 2, \dots, p\}$, $i \in \{1, 2, \dots, m\}$, y $j \in \{1, 2, \dots, n\}$:

$$[y^\mu \boxtimes (x^\mu)^t]_{ij} = \alpha(y_i^\mu, x_j^\mu)$$

Fase de aprendizaje.

PASO 1 Para cada $\mu = 1, 2, \dots, p$, a partir de la pareja (x^μ, y^μ) se construye la matriz

$$[y^\mu \boxtimes (x^\mu)^t]_{m \times n} \quad (1)$$

PASO 2 Se aplica el operador binario máximo \vee a las matrices obtenidas en el paso 1:

$$V = \bigvee_{\mu=1}^p [y^\mu \boxtimes (x^\mu)^t] \quad (2)$$

La entrada ij -ésima está dada por la siguiente expresión:

$$\nu_{ij} = \bigvee_{\mu=1}^p \alpha(y_i^\mu, x_j^\mu) \quad (3)$$

Es posible observar que $\nu_{ij} \in B$, $\forall i \in \{1, 2, \dots, m\}$, $\forall j \in \{1, 2, \dots, n\}$

Fase de recuperación.

CASO 1: Patrón fundamental Se presenta un patrón x^ω , con $\omega \in \{1, 2, \dots, p\}$, a la memoria heteroasociativa $\alpha\beta$ tipo **V** y se realiza la operación \boxtimes_{β} :

$$V \boxtimes_{\beta} x^\omega \quad (4)$$

Dado que las dimensiones de la matriz **V** son $m \times n$ y x^ω es un vector columna de dimensión n , el resultado de la operación anterior debe ser un vector columna de dimensión m , cuya i -ésima componente es:

$$(V \boxtimes_{\beta} x^\omega)_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, x_j^\omega) \quad (5)$$

$$(V \boxtimes_{\beta} x^\omega)_i = \bigwedge_{j=1}^n \beta \left\{ \left[\bigvee_{\mu=1}^p \alpha(y_i^\mu, x_j^\mu) \right], x_j^\omega \right\} \quad (6)$$

CASO 2: Patrón alterado Se presenta un patrón binario \bar{x} (patrón alterado de algún patrón fundamental x^μ) que es un vector columna de dimensión n , a la memoria heteroasociativa $\alpha\beta$ tipo **V** y se realiza la operación \boxtimes_{β} :

$$V \boxtimes_{\beta} \bar{x} \quad (7)$$

El resultado de la operación anterior es un vector columna de dimensión m , cuya i -ésima componente se expresa de la siguiente manera:

$$(V \boxtimes_{\beta} \bar{x})_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, \bar{x}_j) \quad (8)$$

$$(V \boxtimes_{\beta} \bar{x})_i = \bigwedge_{j=1}^n \beta \left\{ \left[\bigvee_{\mu=1}^p \alpha(y_i^\mu, x_j^\mu) \right], \bar{x}_j \right\} \quad (9)$$

Lema 4. Sea $\{(x^\mu, y^\mu) \mid \mu = 1, 2, \dots, p\}$ el conjunto fundamental de una memoria heteroasociativa $\alpha\beta$ representada por **V**. Si ω es un valor arbitrario de índice tal que $\omega \in \{1, 2, \dots, p\}$ entonces $V \boxtimes_{\beta} x^\omega \geq y^\omega$.

Demostración. Sea $i \in \{1, 2, \dots, m\}$ arbitraria. La i -ésima componente del vector $V \boxtimes_{\beta} x^\omega$ se expresa así:

$$(V \boxtimes_{\beta} x^\omega)_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, x_j^\omega)$$

pero

$$\nu_{ij} = \bigvee_{\mu=1}^p \alpha(y_i^\mu, x_j^\mu)$$

por ello:

$$(V \boxtimes_{\beta} x^\omega)_i = \bigwedge_{j=1}^n \beta \left\{ \left[\bigvee_{\mu=1}^p \alpha(y_i^\mu, x_j^\mu) \right], x_j^\omega \right\}$$

Por otro lado, por hipótesis $\omega \in \{1, 2, \dots, p\}$, y esto significa que:

$$\bigvee_{\mu=1}^p \alpha(y_i^\mu, x_j^\mu) \geq \alpha(y_i^\omega, x_j^\omega)$$

Se realiza la operación binaria β , eligiendo los dos miembros de esta desigualdad como operandos izquierdos, y x_j^ω como operando derecho en ambos casos. Dado que β es creciente por la izquierda, se tiene:

$$\beta \left\{ \left[\bigvee_{\mu=1}^p \alpha(y_i^\mu, x_j^\mu) \right], x_j^\omega \right\} \geq \beta \left[\alpha(y_i^\omega, x_j^\omega), x_j^\omega \right]$$

Al tomar el mínimo de ambos miembros respecto del índice j :

$$\bigwedge_{j=1}^n \beta \left\{ \left[\bigvee_{\mu=1}^p \alpha(y_i^\mu, x_j^\mu) \right], x_j^\omega \right\} \geq \bigwedge_{j=1}^n \beta \left[\alpha(y_i^\omega, x_j^\omega), x_j^\omega \right]$$

Por transitividad de la desigualdad anterior:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i \geq \bigwedge_{j=1}^n \beta[\alpha(y_i^{\omega}, x_j^{\omega}), x_j^{\omega}]$$

Además:

$$\beta[\alpha(y_i^{\omega}, x_j^{\omega}), x_j^{\omega}] = y_i^{\omega}$$

esto es:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i \geq \bigwedge_{j=1}^n y_i^{\omega}$$

Pero

$$\bigwedge_{j=1}^n y_i^{\omega} = y_i^{\omega}$$

porque y_i^{ω} no depende de j , es decir:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i \geq y_i^{\omega}$$

Dado que i se escogió de manera arbitraria, se puede afirmar que la expresión anterior es válida para todos los valores de i , es decir:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i \geq y_i^{\omega} \quad \forall i \in \{1, 2, \dots, m\}$$

Por lo tanto:

$$\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega} \geq \mathbf{y}^{\omega} \quad \text{Conclusión.}$$

En virtud de que el valor ω es arbitrario dentro del conjunto de índices para los patrones del conjunto fundamental, este Lema deja en claro que la desigualdad se cumple para *todas* las parejas de patrones que son elementos del conjunto fundamental, sin imponer condición alguna.

Teorema 1. Sea $\{(x^{\mu}, y^{\mu}) \mid \mu = 1, 2, \dots, p\}$ el conjunto fundamental de una memoria heteroasociativa $\alpha\beta$ representada por \mathbf{V} . Si ω es un valor de índice arbitrario tal que $\omega \in \{1, 2, \dots, p\}$, y si además para cada $i \in \{1, \dots, m\}$ se cumple que $\exists j = j_0 \in \{1, \dots, n\}$, el cual depende de ω y de i , tal que $\nu_{ij_0} = \alpha(y_i^{\omega}, x_{j_0}^{\omega})$, entonces la recuperación $\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega}$ es perfecta; es decir $\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega} = \mathbf{y}^{\omega}$.

Demostración.- Sea $i \in \{1, 2, \dots, m\}$ arbitraria. La i -ésima componente del vector $\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega}$ se expresa así:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, x_j^{\omega})$$

pero al mismo tiempo, al hacer $j = j_0$, se cumple la siguiente desigualdad: $\bigwedge_{j=1}^n \beta(\nu_{ij}, x_j^{\omega}) \leq \beta(\nu_{ij_0}, x_{j_0}^{\omega})$, y por transitividad se llega a:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i \leq \beta(\nu_{ij_0}, x_{j_0}^{\omega})$$

Además, por hipótesis $\nu_{ij_0} = \alpha(y_i^{\omega}, x_{j_0}^{\omega})$, es decir:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i \leq \beta[\alpha(y_i^{\omega}, x_{j_0}^{\omega}), x_{j_0}^{\omega}]$$

Además, se tiene

$$\beta[\alpha(y_i^{\omega}, x_{j_0}^{\omega}), x_{j_0}^{\omega}] = y_i^{\omega}$$

por lo que la desigualdad anterior queda así:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i \leq y_i^{\omega}$$

Dado que i se escogió de manera arbitraria, se puede afirmar que la expresión anterior es válida para todos los valores de i , por lo que:

$$(\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega})_i \leq y_i^{\omega} \quad \forall i \in \{1, 2, \dots, m\}$$

La expresión anterior se traduce en la siguiente desigualdad vectorial:

$$\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega} \leq \mathbf{y}^{\omega}$$

Pero al cumplirse la hipótesis del Lema 4, se tiene la desigualdad en el otro sentido

$$\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega} \geq \mathbf{y}^{\omega}$$

Por lo tanto, se llega a la recuperación perfecta del patrón \mathbf{y}^{ω} :

$$\mathbf{V} \circledast_{\beta} \mathbf{x}^{\omega} = \mathbf{y}^{\omega} \quad \text{Conclusión.}$$

Teorema 2 (forma equivalente matricial del Teorema 1).

Si para cada asociación $(\mathbf{x}^{\omega}, \mathbf{y}^{\omega})$ del conjunto fundamental de una memoria heteroasociativa $\alpha\beta$ \mathbf{V} , se cumple que cada fila de la matriz $\mathbf{V} - \mathbf{y}^{\omega} \otimes (\mathbf{x}^{\omega})^t$ contiene una entrada cero, entonces la memoria \mathbf{V} recupera el conjunto de patrones de salida fundamentales en forma perfecta.

Demostración.- Dado que la tesis es igual, es suficiente encontrar un enunciado que sea lógicamente equivalente a la hipótesis del Teorema 1.

Como ω es un valor de índice arbitrario tal que $\omega \in \{1, 2, \dots, p\}$, la hipótesis se puede expresar así:

$$\forall \omega \in \{1, 2, \dots, p\} \text{ y cada } i \in \{1, \dots, m\}, \\ \exists j_0 \in \{1, \dots, n\} \text{ tal que } \nu_{ij_0} = \alpha(y_i^{\omega}, x_{j_0}^{\omega})$$

Pero las siguientes expresiones son válidas:

$$\alpha(y_i^{\omega}, x_{j_0}^{\omega}) = \left[\mathbf{y}^{\omega} \otimes (\mathbf{x}^{\omega})^t \right]_{ij_0} \\ \nu_{ij_0} = [\mathbf{V}]_{ij_0}$$

por ello, la expresión:

$$\nu_{ij_0} = \alpha(y_i^{\omega}, x_{j_0}^{\omega})$$

es equivalente a

$$[\mathbf{V}]_{ij_0} = \left[\mathbf{y}^{\omega} \otimes (\mathbf{x}^{\omega})^t \right]_{ij_0}$$

que a su vez se puede transformar en

$$[\mathbf{V}]_{ij_0} - \left[\mathbf{y}^{\omega} \otimes (\mathbf{x}^{\omega})^t \right]_{ij_0} = 0$$

y finalmente en la expresión

$$\left[\mathbf{V} - \mathbf{y}^{\omega} \otimes (\mathbf{x}^{\omega})^t \right]_{ij_0} = 0$$

Por lo anterior podemos obtener una expresión lógicamente

equivalente a la hipótesis del Teorema:

$$\forall \omega \in \{1, 2, \dots, p\} \text{ y cada } i \in \{1, \dots, m\},$$

$$\exists j_0 \in \{1, \dots, n\} \text{ tal que } \left[\mathbf{V} - \mathbf{y}^\omega \boxtimes (\mathbf{x}^\omega)^t \right]_{i j_0} = 0$$

La última expresión se puede enunciar del siguiente modo equivalente: para todas las asociaciones del conjunto fundamental de la memoria heteroasociativa $\alpha\beta \mathbf{V}$, se cumple que cada fila de la matriz $\mathbf{V} - \mathbf{y}^\omega \boxtimes (\mathbf{x}^\omega)^t$ contiene una entrada cero.

Ha llegado el momento de atacar un problema trascendental en el tema de las memorias asociativas: encontrar las condiciones *suficientes* para que una memoria asociativa (en este caso para la memoria heteroasociativa $\alpha\beta$ tipo \mathbf{V}) recupere patrones de salida fundamentales a partir de patrones de entrada distorsionados con ruido, es decir, patrones de entrada no fundamentales. Dentro de esas condiciones suficientes debe incluirse la cantidad y los tipos de ruido a los que la memoria es inmune: aditivo o sustractivo.

Lema 5. Sea $\{(\mathbf{x}^\mu, \mathbf{y}^\mu) \mid \mu = 1, 2, \dots, p\}$ el conjunto fundamental de una memoria heteroasociativa $\alpha\beta$ representada por \mathbf{V} , y sea $\tilde{\mathbf{x}} \in A^n$ un patrón alterado que se presenta a la memoria \mathbf{V} como entrada. Si $\exists \omega \in \{1, 2, \dots, p\}$ tal que es posible obtener el patrón $\tilde{\mathbf{x}}$ alterando el patrón fundamental \mathbf{x}^ω con ruido aditivo, entonces $\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}} \geq \mathbf{y}^\omega$.

Demostración. Sea $i \in \{1, 2, \dots, m\}$ arbitraria. La i -ésima componente del vector $\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}}$ se expresa así:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, \tilde{x}_j) \quad (10)$$

Por otro lado, por hipótesis $\tilde{\mathbf{x}}$ es una alteración con ruido aditivo del patrón fundamental \mathbf{x}^ω , y se tiene $\mathbf{x}^\omega \leq \tilde{\mathbf{x}}$; es decir: $\tilde{x}_j \geq x_j^\omega$, lo cual implica que

$$\tilde{x}_j \geq x_j^\omega, \quad \forall j \in \{1, 2, \dots, n\}$$

Se realiza la operación binaria β , eligiendo los dos miembros de esta desigualdad como operandos derechos, y a la ij -ésima componente ν_{ij} de \mathbf{V} como operando izquierdo en ambos casos. Dado que β es creciente por la derecha, se tiene:

$$\beta(\nu_{ij}, \tilde{x}_j) \geq \beta(\nu_{ij}, x_j^\omega) \quad \forall j \in \{1, 2, \dots, n\}$$

Al tomar el mínimo de ambos miembros respecto del índice j :

$$\bigwedge_{j=1}^n \beta(\nu_{ij}, \tilde{x}_j) \geq \bigwedge_{j=1}^n \beta(\nu_{ij}, x_j^\omega)$$

Por transitividad de la desigualdad anterior con la expresión 10:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i \geq \bigwedge_{j=1}^n \beta(\nu_{ij}, x_j^\omega)$$

Pero

$$\bigwedge_{j=1}^n \beta(\nu_{ij}, x_j^\omega) = (\mathbf{V} \boxtimes_{\beta} \mathbf{x}^\omega)_i$$

esto es:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i \geq (\mathbf{V} \boxtimes_{\beta} \mathbf{x}^\omega)_i$$

Además, por Lema 4

$$(\mathbf{V} \boxtimes_{\beta} \mathbf{x}^\omega)_i \geq y_i^\omega$$

y por transitividad con la expresión anterior:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i \geq y_i^\omega$$

Dado que i se escogió de manera arbitraria, se puede afirmar que la expresión anterior es válida para todos los valores de i , es decir:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i \geq y_i^\omega \quad \forall i \in \{1, 2, \dots, m\}$$

Por lo tanto:

$$\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}} \geq \mathbf{y}^\omega \quad \text{Conclusión.}$$

Teorema 3. Sea $\{(\mathbf{x}^\mu, \mathbf{y}^\mu) \mid \mu = 1, 2, \dots, p\}$ el conjunto fundamental de una memoria heteroasociativa $\alpha\beta$ representada por \mathbf{V} , y sea $\tilde{\mathbf{x}} \in A^n$ un patrón alterado con ruido aditivo respecto de algún patrón fundamental \mathbf{x}^ω con $\omega \in \{1, 2, \dots, p\}$. Si se presenta $\tilde{\mathbf{x}}$ a la memoria \mathbf{V} como entrada, y si además para cada $i \in \{1, \dots, m\}$ se cumple la condición de que $\exists j = j_0 \in \{1, \dots, n\}$, el cual depende de ω y de i tal que $\nu_{ij_0} \leq \alpha(y_i^\omega, \tilde{x}_{j_0})$, entonces la recuperación $\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}}$ es perfecta; es decir $\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}} = \mathbf{y}^\omega$.

Demostración. Sea $i \in \{1, 2, \dots, m\}$ arbitraria. La i -ésima componente del vector $\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}}$ se expresa así:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, \tilde{x}_j)$$

pero al mismo tiempo, al hacer $j = j_0$, se cumple la desigualdad:

$$\bigwedge_{j=1}^n \beta(\nu_{ij}, \tilde{x}_j) \leq \beta(\nu_{ij_0}, \tilde{x}_{j_0})$$

y por transitividad se llega a:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i \leq \beta(\nu_{ij_0}, \tilde{x}_{j_0}) \quad (11)$$

Por otro lado, por hipótesis $\nu_{ij_0} \leq \alpha(y_i^\omega, \tilde{x}_{j_0})$; se realiza la operación binaria β , eligiendo los dos miembros de esta desigualdad como operandos izquierdos, y \tilde{x}_{j_0} como operando derecho en ambos casos. Dado que β es creciente por la izquierda (propiedad $\beta 3$ de la Tabla 3.4), se tiene:

$$\beta(\nu_{ij_0}, \tilde{x}_{j_0}) \leq \beta[\alpha(y_i^\omega, \tilde{x}_{j_0}), \tilde{x}_{j_0}]$$

Por transitividad de esta desigualdad con la expresión 11:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i \leq \beta[\alpha(y_i^\omega, \tilde{x}_{j_0}), \tilde{x}_{j_0}]$$

Además:

$$\beta[\alpha(y_i^\omega, \tilde{x}_{j_0}), \tilde{x}_{j_0}] = y_i^\omega$$

esto es:

$$(\mathbf{V} \boxtimes_{\beta} \tilde{\mathbf{x}})_i \leq y_i^\omega$$

Dado que i se escogió de manera arbitraria, se puede afirmar que esta expresión es válida para todos los valores de i , por lo que:

$$(\mathbf{V} \circledast \tilde{\mathbf{x}})_i \leq y_i^\omega \quad \forall i \in \{1, 2, \dots, m\}$$

Esta expresión se traduce en la siguiente desigualdad vectorial:

$$\mathbf{V} \circledast \tilde{\mathbf{x}} \leq \mathbf{y}^\omega$$

Por lo tanto, aplicando el Lema 5, se llega a la recuperación perfecta del patrón \mathbf{y}^ω .

$$\mathbf{V} \circledast \tilde{\mathbf{x}} = \mathbf{y}^\omega \quad \text{Conclusión.}$$

El Lema 5 y el Teorema 3 indican que las memorias heteroasociativas $\alpha\beta$ tipo \mathbf{V} tienen cierta inmunidad al ruido **aditivo**, y especifican las condiciones que deben cumplirse para que la respuesta sea perfecta en presencia de ruido aditivo.

De inmediato surge una interrogante: ¿qué pasa con el ruido **sustractivo**? Las memorias $\alpha\beta$ tipo \mathbf{V} son sensibles a ruido sustractivo; una pequeña cantidad de ruido sustractivo puede tener efectos no deseados en la operación de este tipo de memorias, los cuales son caracterizados por el Teorema siguiente:

Teorema 4. Sea $\{\{\mathbf{x}^\mu, \mathbf{y}^\mu\} \mid \mu = 1, 2, \dots, p\}$ el conjunto fundamental de una memoria heteroasociativa $\alpha\beta$ representada por \mathbf{V} , y sea $\tilde{\mathbf{x}} \in A^n$ un patrón alterado con ruido sustractivo respecto de algún patrón fundamental \mathbf{x}^ω con $\omega \in \{1, 2, \dots, p\}$. Al presentar $\tilde{\mathbf{x}}$ a la memoria \mathbf{V} como entrada se cumple lo siguiente: para cada $j_0 \in \{1, \dots, n\}$ tal que $x_{j_0}^\omega$ haya sido alterado para obtener \tilde{x}_{j_0} , si $\exists i_0 \in \{1, \dots, m\}$ para el que $\nu_{i_0 j_0} = 1$, entonces $(\mathbf{V} \circledast \tilde{\mathbf{x}})_{i_0} = 0$.

Demostración. Sea $\tilde{\mathbf{x}}$ una versión distorsionada con ruido sustractivo del patrón fundamental \mathbf{x}^ω ; es decir, $\tilde{\mathbf{x}} \leq \mathbf{x}^\omega$, lo cual implica que $\tilde{x}_j \leq x_j^\omega \quad \forall j \in \{1, 2, \dots, n\}$. Dependiendo del porcentaje de ruido sustractivo con que se ha alterado \mathbf{x}^ω , puede haber más de un valor de j , hasta el número de bits con valor 1 en \mathbf{x}^ω , para los que se cumple la desigualdad estricta $\tilde{x}_j < x_j^\omega$.

Sea $j_0 \in \{1, \dots, n\}$ un índice para el que se cumple la desigualdad estricta: $\tilde{x}_{j_0} < x_{j_0}^\omega$; es decir, debe cumplirse que $\tilde{x}_{j_0} = 0$ y $x_{j_0}^\omega = 1$. La expresión para la componente i del vector recuperado es:

$$(\mathbf{V} \circledast \tilde{\mathbf{x}})_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, \tilde{x}_j)$$

Reescribamos la expresión anterior para tomar en cuenta explícitamente el valor de j_0 :

$$(\mathbf{V} \circledast \tilde{\mathbf{x}})_i = \bigwedge \left\{ \begin{array}{l} \left[\bigwedge_{j=1}^{j_0-1} \beta(\nu_{ij}, \tilde{x}_j) \right], \\ \left[\beta(\nu_{ij_0}, \tilde{x}_{j_0}) \right], \\ \left[\bigwedge_{j=j_0+1}^n \beta(\nu_{ij}, \tilde{x}_j) \right] \end{array} \right\}$$

Es decir:

$$(\mathbf{V} \circledast \tilde{\mathbf{x}})_i = \bigwedge \left\{ \begin{array}{l} \left[\bigwedge_{j=1}^{j_0-1} \beta(\nu_{ij}, \tilde{x}_j) \right], \\ \left[\beta(\nu_{ij_0}, 0) \right], \\ \left[\bigwedge_{j=j_0+1}^n \beta(\nu_{ij}, \tilde{x}_j) \right] \end{array} \right\}$$

Por hipótesis, $\exists i_0 \in \{1, \dots, m\}$ para el que $\nu_{i_0 j_0} = 1$. Analicemos este caso crítico:

$$(\mathbf{V} \circledast \tilde{\mathbf{x}})_{i_0} = \bigwedge \left\{ \begin{array}{l} \left[\bigwedge_{j=1}^{j_0-1} \beta(\nu_{i_0 j}, \tilde{x}_j) \right], \\ \left[\beta(\nu_{i_0 j_0}, 0) \right], \\ \left[\bigwedge_{j=j_0+1}^n \beta(\nu_{i_0 j}, \tilde{x}_j) \right] \end{array} \right\}$$

$$(\mathbf{V} \circledast \tilde{\mathbf{x}})_{i_0} = \bigwedge \left\{ \begin{array}{l} \left[\bigwedge_{j=1}^{j_0-1} \beta(\nu_{i_0 j}, \tilde{x}_j) \right], \\ \left[\beta(1, 0) \right], \\ \left[\bigwedge_{j=j_0+1}^n \beta(\nu_{i_0 j}, \tilde{x}_j) \right] \end{array} \right\}$$

Pero $\beta(1, 0) = 0$, por lo que la expresión anterior se transforma en:

$$(\mathbf{V} \circledast \tilde{\mathbf{x}})_{i_0} = \bigwedge \left\{ \begin{array}{l} \left[\bigwedge_{j=1}^{j_0-1} \beta(\nu_{i_0 j}, \tilde{x}_j) \right], \\ \left[0 \right], \\ \left[\bigwedge_{j=j_0+1}^n \beta(\nu_{i_0 j}, \tilde{x}_j) \right] \end{array} \right\}$$

Por lo tanto:

$$(\mathbf{V} \circledast \tilde{\mathbf{x}})_{i_0} = 0$$

Nota importante: Sin embargo, dado el j_0 del Teorema 4, si $\nu_{i_0 j_0} \neq 1, \forall i \in \{1, \dots, m\}$, entonces el ruido sustractivo en la componente \tilde{x}_{j_0} no afecta la posible recuperación perfecta del patrón \mathbf{y}^ω . Esto significa que las memorias $\alpha\beta$ tipo \mathbf{V} son capaces de soportar ciertas cantidades de ruido sustractivo.

Las memorias heteroasociativas $\alpha\beta$ tipo \mathbf{A} se desarrollan por dualidad, partiendo de los resultados obtenidos para las memorias heteroasociativas $\alpha\beta$ tipo \mathbf{V} . Para ello, se realizan los siguientes cambios:

- Donde haya un operador \vee colocar un \wedge
- Donde haya un operador \wedge colocar un \vee
- Usar el operador \circledast en lugar del operador \circledcirc

Mientras que las memorias heteroasociativas $\alpha\beta$ tipo \mathbf{V} tienen cierta inmunidad al ruido aditivo y son sensitivas a ruido sustractivo, con las memorias heteroasociativas $\alpha\beta$ tipo \mathbf{A} sucede precisamente lo contrario: son inmunes a cierta cantidad de ruido sustractivo, pero sensitivas a ruido aditivo. Una pequeña cantidad de ruido aditivo puede tener efectos no deseados en la operación de este tipo de memorias $\alpha\beta$; sin embargo, las memorias $\alpha\beta$ tipo \mathbf{A} son capaces de soportar ciertas cantidades de ruido aditivo.

4.2 Memorias Autoasociativas $\alpha\beta$

Si a una memoria heteroasociativa se le impone la condición de que $\mathbf{y}^\mu = \mathbf{x}^\mu \forall \mu \in \{1, 2, \dots, p\}$, entonces deja de ser heteroasociativa y ahora se le denomina memoria *autoasociativa*.

A continuación se enlistan algunas características de las memorias autoasociativas $\alpha\beta$:

1. El conjunto fundamental toma la forma $\{(\mathbf{x}^\mu, \mathbf{x}^\mu) \mid \mu = 1, 2, \dots, p\}$
2. Los patrones fundamentales de entrada y de salida son de la misma dimensión; denotémosla por n .
3. La memoria es una matriz cuadrada, para ambos tipos, \mathbf{V} y \mathbf{A} . Si $\mathbf{x}^\mu \in A^n$, entonces $\mathbf{V} = [\nu_{ij}]_{n \times n}$ y $\mathbf{A} = [\lambda_{ij}]_{n \times n}$.

Al igual como se hizo para las memorias heteroasociativas, se desarrollarán sólo las memorias autoasociativas $\alpha\beta$ de tipo \mathbf{V} , ya que las propiedades de las memorias tipo \mathbf{A} se obtienen por dualidad.

Fase de aprendizaje.

PASO 1 Para cada $\mu = 1, 2, \dots, p$, a partir de la pareja $(\mathbf{x}^\mu, \mathbf{x}^\mu)$ se construye la matriz

$$\left[\mathbf{x}^\mu \otimes (\mathbf{x}^\mu)^t \right]_{n \times n} \quad (12)$$

PASO 2 Se aplica el operador binario *máximo* \vee a las matrices obtenidas en el paso 1:

$$\mathbf{V} = \bigvee_{\mu=1}^p \left[\mathbf{x}^\mu \otimes (\mathbf{x}^\mu)^t \right] \quad (13)$$

La entrada ij -ésima de la memoria está dada así:

$$\nu_{ij} = \bigvee_{\mu=1}^p \alpha(x_i^\mu, x_j^\mu) \quad (14)$$

Se tiene que $\nu_{ij} \in B, \forall i \in \{1, 2, \dots, n\}, \forall j \in \{1, 2, \dots, n\}$

Fase de recuperación.

CASO 1: Patrón fundamental Se presenta un patrón \mathbf{x}^ω , con $\omega \in \{1, 2, \dots, p\}$, a la memoria autoasociativa $\alpha\beta$ tipo \mathbf{V} y se realiza la operación \otimes_{β} :

$$\mathbf{V} \otimes_{\beta} \mathbf{x}^\omega \quad (15)$$

El resultado de la operación anterior será un vector columna de dimensión n .

$$(\mathbf{V} \otimes_{\beta} \mathbf{x}^\omega)_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, x_j^\omega) \quad (16)$$

$$(\mathbf{V} \otimes_{\beta} \mathbf{x}^\omega)_i = \bigwedge_{j=1}^n \beta \left\{ \left[\bigvee_{\mu=1}^p \alpha(x_i^\mu, x_j^\mu) \right], x_j^\omega \right\} \quad (17)$$

CASO 2: Patrón alterado Se presenta un patrón binario $\bar{\mathbf{x}}$ que es un vector columna de dimensión n , a la memoria

autoasociativa $\alpha\beta$ tipo \mathbf{V} y se realiza la operación \otimes_{β} :

$$\mathbf{V} \otimes_{\beta} \bar{\mathbf{x}} \quad (18)$$

Al igual que en el caso 1, el resultado de la operación anterior es un vector columna de dimensión n , cuya i -ésima componente se expresa de la siguiente manera:

$$(\mathbf{V} \otimes_{\beta} \bar{\mathbf{x}})_i = \bigwedge_{j=1}^n \beta(\nu_{ij}, \bar{x}_j) \quad (19)$$

$$(\mathbf{V} \otimes_{\beta} \bar{\mathbf{x}})_i = \bigwedge_{j=1}^n \beta \left\{ \left[\bigvee_{\mu=1}^p \alpha(x_i^\mu, x_j^\mu) \right], \bar{x}_j \right\} \quad (20)$$

Lema 6. Una memoria autoasociativa $\alpha\beta$ tipo \mathbf{V} tiene únicamente unos en su diagonal principal.

Demostración. - La ij -ésima entrada de una memoria autoasociativa $\alpha\beta$ tipo \mathbf{V} está dada por

$$\nu_{ij} = \bigvee_{\mu=1}^p \alpha(x_i^\mu, x_j^\mu)$$

Las entradas de la diagonal principal se obtienen de la expresión anterior, haciendo $i = j$:

$$\nu_{ii} = \bigvee_{\mu=1}^p \alpha(x_i^\mu, x_i^\mu), \quad \forall i \in \{1, 2, \dots, n\} \quad (21)$$

Pero se tiene que

$$\alpha(x_i^\mu, x_i^\mu) = 1$$

por lo que la expresión 21 se transforma en:

$$\nu_{ii} = \bigvee_{\mu=1}^p (1) = 1, \quad \forall i \in \{1, 2, \dots, n\}$$

Teorema 5. Una memoria autoasociativa $\alpha\beta$ tipo \mathbf{V} recupera de manera perfecta el conjunto fundamental completo; además, tiene máxima capacidad de aprendizaje.

Demostración. - Sea $\omega \in \{1, 2, \dots, p\}$ arbitrario. De acuerdo con el Lema 6, para cada $i \in \{1, \dots, n\}$ escogida arbitrariamente

$$\nu_{ii} = 1 = \alpha(x_i^\omega, x_i^\omega)$$

Es decir, para $i \in \{1, \dots, n\}$ escogida arbitrariamente, $\exists j_0 = i \in \{1, \dots, n\}$ que cumple con:

$$\nu_{ij_0} = \alpha(x_i^\omega, x_{j_0}^\omega)$$

Por lo tanto, de acuerdo con el Teorema 2:

$$\mathbf{V} \otimes_{\beta} \mathbf{x}^\omega = \mathbf{x}^\omega, \quad \forall \omega \in \{1, 2, \dots, p\}$$

Esto significa que la memoria autoasociativa $\alpha\beta$ tipo \mathbf{V} recupera de manera perfecta el conjunto fundamental completo. Además, en la demostración de este Teorema, en ningún momento aparece restricción alguna sobre p , que es la cardinalidad del conjunto fundamental; esto quiere decir que el conjunto fundamental puede crecer tanto como se quiera. La consecuencia directa es que el número de patrones que puede apren-

der una memoria autoasociativa $\alpha\beta$ tipo V, con recuperación perfecta, es máximo.

Teorema 6. Sea $\{(x^\mu, x^\mu) \mid \mu = 1, 2, \dots, p\}$ el conjunto fundamental de una memoria autoasociativa $\alpha\beta$ representada por V, y sea $\bar{x} \in A^n$ un patrón alterado con ruido aditivo respecto de algún patrón fundamental x^ω con $\omega \in \{1, 2, \dots, p\}$. Si se presenta \bar{x} a la memoria V como entrada, y si además para cada $i \in \{1, \dots, n\}$ se cumple la condición de que $\exists j = j_0 \in \{1, \dots, n\}$, el cual depende de ω y de i tal que $\nu_{ij_0} \leq \alpha(x_i^\omega, \bar{x}_{j_0})$, entonces la recuperación V $\oplus_{\beta} \bar{x}$ es perfecta; es decir V $\oplus_{\beta} \bar{x} = x^\omega$.

Demostración. Por hipótesis se tiene que $y^\mu = x^\mu \forall \mu \in \{1, 2, \dots, p\}$ y, por consiguiente, $m = n$. Al establecer estas dos condiciones en el Teorema 4, se obtiene el resultado: V $\oplus_{\beta} \bar{x} = x^\omega$.

El Teorema 6 confirma que las memorias autoasociativas $\alpha\beta$ tipo V son inmunes a cierta cantidad de ruido aditivo.

Dado un $i \in \{1, \dots, n\}$ cualquiera, consideremos las relaciones que hay entre los valores de x_i^ω y las coordenadas del vector \bar{x} , con el fin de analizar brevemente cada uno de los casos posibles en la fase de recuperación. Según la hipótesis del Teorema 6 la recuperación del valor x_i^ω se garantiza siempre y cuando para este valor i se pueda encontrar un $j_0 \in \{1, \dots, n\}$ que cumpla con la desigualdad $\nu_{ij_0} \leq \alpha(x_i^\omega, \bar{x}_{j_0})$. Existen dos casos posibles para el valor de x_i^ω :

1. Si $x_i^\omega = 1$, es suficiente que alguna de las entradas del patrón \bar{x} sea cero, para garantizar la recuperación del valor x_i^ω . Veamos: si existe $j_0 \in \{1, \dots, n\}$ para el cual $\bar{x}_{j_0} = 0$ entonces, de acuerdo con la Tabla 3.1, $\alpha(x_i^\omega, \bar{x}_{j_0}) = \alpha(1, 0) = 2$ y esto significa que $\nu_{ij_0} \leq \alpha(x_i^\omega, \bar{x}_{j_0})$, porque el máximo valor posible para ν_{ij_0} es precisamente 2, según la misma Tabla.
2. Este caso es más restrictivo. Si $x_i^\omega = 0$, no basta con encontrar una entrada cero en el patrón \bar{x} . Al hallar el valor de $j_0 \in \{1, \dots, n\}$ para el cual $\bar{x}_{j_0} = 0$, se debe pedir como condición adicional que $\nu_{ij_0} \neq 2$, porque (según Tabla 3.1) $\alpha(x_i^\omega, \bar{x}_{j_0}) = \alpha(0, 0) = 1$ y esto significa que la desigualdad $\nu_{ij_0} \leq \alpha(x_i^\omega, \bar{x}_{j_0})$ se da siempre y cuando $\nu_{ij_0} \neq 2$. Si se llegase a tener carencia de ceros en las coordenadas del patrón \bar{x} , la condición para recuperar el valor de x_i^ω , al tener $\bar{x}_{j_0} = 1$, es más fuerte: $\nu_{ij_0} = 0$, porque $\alpha(0, 1) = 0$.

Las memorias autoasociativas $\alpha\beta$ tipo A se desarrollan por dualidad, partiendo de los resultados obtenidos para las memorias autoasociativas $\alpha\beta$ tipo V; para ello, se realizan cambios similares a los que se indicaron para las memorias heteroasociativas. También, mientras que las memorias autoasociativas

$\alpha\beta$ tipo V son inmunes a cierta cantidad de ruido aditivo pero sensibles a ruido sustractivo, con las memorias autoasociativas $\alpha\beta$ tipo A sucede lo contrario.

5 Densidad Aritmética

Una colección de operadores lógicos es *funcionalmente completa* si toda proposición compuesta es lógicamente equivalente a una proposición compuesta que involucre sólo a los operadores de la colección (Rosen, 1995).

Es un hecho establecido que los tres operadores lógicos de negación (\neg), conjunción (\wedge) y disyunción (\vee) forman una colección funcionalmente completa de operadores lógicos:

$$\{\neg, \wedge, \vee\}$$

Existen colecciones funcionalmente completas que constan de dos o de un único operador. Uno de estos operadores es el que corresponde a la Tabla de verdad de la disyunción negada: la conectiva lógica *nor*, que denotaremos con el operador \downarrow .

Sean x y y dos variables lógicas booleanas. El operador \downarrow se define de la siguiente manera:

$$x \downarrow y = \neg(x \vee y) \quad (22)$$

Esto significa que la colección $\{\downarrow\}$ es funcionalmente completa, como lo afirma la Proposición 1.

Proposición 1. El operador \downarrow constituye, por sí mismo, una colección funcionalmente completa $\{\downarrow\}$; si x y y son variables lógicas booleanas, entonces se cumplen las siguientes equivalencias:

$$\begin{aligned} \neg x &= x \downarrow x \\ x \vee y &= (x \downarrow y) \downarrow (x \downarrow y) \\ x \wedge y &= (x \downarrow x) \downarrow (y \downarrow y) \end{aligned} \quad (23)$$

Tanto para las memorias asociativas morfológicas como para las memorias asociativas $\alpha\beta$ se considera un conjunto fundamental de p asociaciones, donde los patrones de entrada tienen dimensión n , y los patrones de salida, dimensión m .

Al realizar el cálculo del total de operaciones requeridas para ambas fases en las memorias asociativas morfológicas, se llega a los siguientes resultados:

La fase de aprendizaje de una memoria asociativa morfológica requiere de $28mp$ operaciones \downarrow y $m(n-1)$ operaciones de orden.

La fase de recuperación de un patrón de salida en una memoria asociativa morfológica requiere de $198mn$ operaciones \downarrow y $m(n-1)$ operaciones de orden.

Al realizar el cálculo del total de operaciones requeridas para ambas fases en las memorias asociativas $\alpha\beta$, se llega a los siguientes resultados:

La fase de aprendizaje de una memoria asociativa $\alpha\beta$ requiere de $28mnp$ operaciones \downarrow y $mn(p-1)$ operaciones de orden. La fase de recuperación de un patrón de salida en una memoria asociativa $\alpha\beta$ requiere de $147mn$ operaciones \downarrow y $m(n-1)$ operaciones de orden.

A diferencia de lo que sucede con las densidades aritméticas de aprendizaje, las cuales son iguales en ambos tipos de memorias asociativas, la densidad aritmética de recuperación es menor para las memorias asociativas $\alpha\beta$ que la correspondiente a las memorias morfológicas.

Resultado comparativo de la densidad aritmética: La fase de recuperación de las memorias asociativas morfológicas requiere de un 34,7% adicional en el número de operaciones lógicas \downarrow , respecto de lo que requieren las memorias asociativas $\alpha\beta$.

6 Conclusiones

Este trabajo tiene como producto un modelo de memoria asociativa que utiliza dos operadores binarios originales que, al combinarlos de ciertas maneras, dan lugar a cuatro operaciones novedosas entre matrices y vectores.

Las memorias asociativas $\alpha\beta$ tienen al menos una ventaja sobre las morfológicas: la densidad aritmética de las memorias $\alpha\beta$ es menor. Además, exhiben capacidad máxima de almacenamiento y aprendizaje: la recuperación es perfecta para todo el conjunto fundamental.

Las memorias asociativas $\alpha\beta$ tipo V son robustas a ruido aditivo pero vulnerables ante ruido sustractivo.

Las memorias asociativas $\alpha\beta$ tipo A son robustas a ruido sustractivo pero vulnerables ante ruido aditivo.

Las nuevas memorias carecen de problemas de convergencia (son memorias asociativas *one shot*), lo que potencialmente les permite ser más rápidas que las memorias que requieren convergencia.

Agradecimientos. Los autores agradecen el apoyo de las siguientes instituciones: Secretaría Académica y COFAA del Instituto Politécnico Nacional, CONACYT y Sistema Nacional de Investigadores.

Referencias

Anderson, J. A. and E. Rosenfeld (Eds.), *Neurocomputing: Foundations of Research*, MIT Press, Cambridge, 1990.

Díaz-de-León, J. L. y C. Yáñez, "Memorias asociativas con respuesta perfecta y capacidad infinita", *Memoria del Taller de Inteligencia Artificial TAINA'99, México, D.F.*, 1999, pp. 23-38.

Díaz-de-León, J. L. y C. Yáñez, *Introducción a la Morfología Matemática de Conjuntos*, CCC-CIC-IPN, México, (Obra a publicarse en 2003).

Díaz-de-León Santiago, J.L. y C. Yáñez-Márquez, "Memorias Heteroasociativas Morfológicas max: condiciones suficientes para convergencia, aprendizaje y recuperación de patrones", *IT-174, Serie Azul*, ISBN 970-36-0033-6, CIC-IPN, México, 2003.

Díaz-de-León Santiago, J.L. y C. Yáñez-Márquez, "Memorias Heteroasociativas Morfológicas min: condiciones suficientes para convergencia, aprendizaje y recuperación de patrones", *IT-176, Serie Azul*, ISBN 970-36-0034-4, CIC-IPN, México, 2003.

Hassoun, M. H. (Ed.), *Associative Neural Memories*, Oxford University Press, New York, 1993.

Hopfield, J.J., "Neural networks and physical systems with emergent collective computational abilities", *Proceedings of the National Academy of Sciences*, 79, 1982, pp. 2554-2558.

Kohonen, T., "Correlation matrix memories", *IEEE Transactions on Computers*, C-21, 4, 1972, pp. 353-359.

Moore, J., *Elements of linear algebra and matrix theory*, Mc Graw-Hill, New York, 1968.

Palm, G., F. Schwenker, F.T. Sommer and A. Strey, "Neural associative memories", In A. Krikelis & C. C. Weems (Eds.), *Associative Processing and Processors*, Los Alamitos: IEEE Computer Society, 1997, pp. 307-326.

Ritter, G. X., P. Sussner and J.L. Díaz-de-León, "Morphological associative memories", *IEEE Transactions on Neural Networks*, 9, 1998, pp. 281-293.

Ritter, G. X., J.L. Díaz-de-León and P. Sussner, "Morphological bidirectional associative memories", *Neural Networks*, 12, 1999, pp. 851-867.

Rosen, K. H., *Discrete Mathematics and its Applications*, Mc Graw-Hill, New York, 1995.

Serra, J., *Image Analysis and Mathematical Morphology, Volume 2: Theoretical Advances*, Academic Press, London, 1992.

Yáñez-Márquez, C., *Memorias Asociativas basadas en Relaciones de Orden y Operadores Binarios*. Tesis doctoral, CIC-IPN, México, 2002.

Yáñez-Márquez, C. y J.L. Díaz-de-León Santiago, "Memorias Autoasociativas Morfológicas max: condiciones suficientes para convergencia, aprendizaje y recuperación de patrones", *IT-175, Serie Azul*, ISBN 970-36-0035-2, CIC-IPN, México, 2003.

Yáñez-Márquez, C. y J.L. Díaz-de-León Santiago, "Memorias Autoasociativas Morfológicas min: condiciones suficientes para convergencia, aprendizaje y recuperación de patrones", *IT-177, Serie Azul*, ISBN 970-36-0036-0, CIC-IPN, México, 2003.



Cornelio Yáñez Márquez obtuvo la licenciatura en Física y Matemáticas en 1989 por la ESFM-IPN. Los grados de Maestro en Ciencias en 1995 en Ingeniería de Cómputo y de Doctor en Ciencias de la Computación en 2002, en el CIC-IPN. Actualmente, es profesor investigador titular C del CIC-IPN y miembro fundador del Grupo de Robótica y Análisis de Imágenes. Mención honorífica en el examen de grado de doctorado y Presea Lázaro Cárdenas 2002, recibida de manos del C. Presidente de la República. Es miembro del Sistema Nacional de Investigadores. Nombramiento de asociado honorario de la Asociación Boliviana para el Avance de la Ciencia (ABAC), perteneciente a la Academia Nacional de Ciencias de Bolivia. Otorgamiento oficial de testimonio de bienvenida y entrega de las llaves de la Ciudad de la Provincia de Cercado Cochabamba, Bolivia por su trayectoria profesional, en mayo de 2003.

Áreas de Interés: *Memorias Asociativas, Redes Neuronales, Morfología Matemática, Análisis de Imágenes y Robótica Móvil.*



Juan Luis Díaz de León Santiago, obtuvo el grado de Maestro en Ciencias en Control Automático en 1993 y el de Doctor en Ciencias en Morfología Matemática en 1996, ambos en el CINVESTAV-IPN. Fue investigador invitado (1996) y profesor visitante (1997) de la Universidad de Florida. Director de Tecnología (2000-2001) del Sistema Nacional de Seguridad Pública. Actualmente, es Director e investigador titular C del CIC-IPN y Director Fundador del Grupo de Robótica y Análisis de Imágenes (GRAI). Miembro del Sistema Nacional de Investigadores y Premio Nacional de Investigación y Desarrollo Tecnológico de Excelencia Luis Enrique Erro. Nombramiento de asociado honorario de la Asociación Boliviana para el Avance de la Ciencia (ABAC), perteneciente a la Academia Nacional de Ciencias de Bolivia. Otorgamiento oficial de testimonio de bienvenida y entrega de las llaves de la Ciudad de la Provincia de Cercado Cochabamba, Bolivia por su trayectoria profesional. Distinguido por el Departamento de Cochabamba, Bolivia, con el Reconocimiento "Honor al Mérito" por sus aportes a la investigación, en mayo de 2003.

Áreas de Interés: *Morfología Matemática, Análisis de Imágenes, Redes Neuronales Morfológicas, Teoría de Control y Robótica Móvil.*

