

UNIVERSIDAD DE GUADALAJARA

CENTRO UNIVERSITARIO DE CIENCIAS BIOLÓGICAS Y AGROPECUARIAS
DEPARTAMENTO DE CIENCIAS AMBIENTALES
CENTRO DE ESTUDIOS E INVESTIGACIONES EN COMPORTAMIENTO



SIMULANDO DEPENDENCIA, INTERFERENCIA Y FACILITACIÓN CONTEXTUAL CON EL MODELO DONAHOE- BURGOS-PALMER

TESIS
QUE PARA OBTENER EL GRADO DE

MAESTRA EN CIENCIAS DEL COMPORTAMIENTO
OPCIÓN ANÁLISIS DE LA CONDUCTA

PRESENTA:

ESTHER MURILLO RODRÍGUEZ

DIRECTOR:

DR. JOSÉ E. BURGOS TRIANO

COMITÉ:

DR. JOSÉ E. BURGOS TRIANO
DR. ÓSCAR GARCÍA LEAL
DR. GERARDO ALONSO ORTÍZ RUEDA

GUADALAJARA, JALISCO, MÉXICO, NOVIEMBRE DEL 2005

Esta tesis corresponde a los estudios realizados con una beca otorgada por el Gobierno de México, a través del Instituto Mexicano de Cooperación Internacional (IMEXCI) de la Secretaría de Relaciones Exteriores

Esta tesis no se habría podido finalizar sin la inestimable ayuda de las siguientes personas e instituciones:

Embajada de México en España
 Secretaría de Relaciones Exteriores (SRE)
 Universidad de Guadalajara (UdG)
 Centro Universitario de Ciencias Biológicas y Agropecuarias (CUCBA)
 Centro de Estudios e Investigaciones en Comportamiento (CEIC)
 Dr. José Enrique Burgos Triano
 Dr. Emilio Ribes Iñesta
 Dr. Félix Héctor Martínez Sánchez
 Dr. Óscar García Leal
 Dr. Felipe Cabrera González
 Dr. Gerardo Alonso Ortiz Rueda
 M. C. Antonio Ponce Rojo
 Dr. Julio Agustín Varela Barraza
 Dr. François Tonneau
 Dr. Pablo Adarraga
 Personal de apoyo académico, administrativo y bibliotecario del CEIC y CUCBA
 Alumnos de Licenciatura, Maestría y Doctorado
 Mi familia y amigos

A todos ellos

.... por apostar y creer en mí
 por su paciencia
 por estar ahí y no sentirme sola pese a la distancia
 por compartir su sabiduría conmigo
 por enseñarme día a día a superarme
 por brindarme la oportunidad de compartir parte de su tiempo conmigo
 por permitirme ser quien soy y sobretodo, quien seré

GRACIAS

CONTENIDO

1. INTRODUCCIÓN	6
1.1. PREGUNTA DE INVESTIGACIÓN	9
1.2. OBJETIVO GENERAL	10
1.3. OBJETIVOS ESPECÍFICOS	10
1.3.1. OBJETIVO ESPECÍFICO 1	10
1.3.2. OBJETIVO ESPECÍFICO 2	10
1.3.3. OBJETIVO ESPECÍFICO 3	10
2. CONDICIONAMIENTO CONTEXTUAL	11
3. CONEXIONISMO	19
3.1. ELEMENTOS Y ORGANIZACIÓN DE UNA RED NEURONAL	32
3.1.1. UNIDADES DE PROCESAMIENTO	32
3.1.2. ARQUITECTURA	34
3.1.2.1. Unidades de entrada	37
3.1.2.2. Unidades ocultas	37
3.1.2.3. Unidades de salida	38
3.1.3. FUNCIONAMIENTO	39
4. MODELOS BASADOS EN REDES NEURONALES PARA LA SIMULACIÓN DE FENÓMENOS CONDUCTUALES	44

5. MODELO DONAHOE-BURGOS-PALMER (DBP)	50
5.1. SUBMODELO NEUROCOMPUTACIONAL	52
5.2. SUBMODELO DE REDES	57
5.2.1. UNIDADES DE ENTRADA	59
5.2.2. UNIDADES OCULTAS	59
5.2.3. UNIDADES DE SALIDA	60
6. SIMULACIÓN 1: DEPENDENCIA CONTEXTUAL	62
7. SIMULACIÓN 2: INTERFERENCIA CONTEXTUAL	67
8. SIMULACIÓN 3: FACILITACIÓN CONTEXTUAL	71
9. DISCUSIÓN GENERAL	75
10. BIBLIOGRAFÍA	78
ANEXO	88

1. INTRODUCCIÓN

Las simulaciones digitales se han convertido en un recurso cada vez más utilizado en ciencia experimental (Casti, 1997; Emmeche, 1991), incluyendo entre ellas, a las ciencias de la conducta. Estos *experimentos imaginarios*¹, como Dawkins (1982) ha llamado a las simulaciones, sufren constantes ataques por los científicos experimentales, quienes las acusan de ser poco realistas. Pero de ahí la importancia de utilizar experimentos de simulaciones con redes neuronales, para poder alcanzar un nivel de entendimiento del fenómeno lo suficientemente diverso y completo, teniendo en consideración un mayor número de posibilidades que, probablemente, con organismos reales no sería posible realizar.

Queda claro que las simulaciones pueden ser realistas en algunos casos, pero la ventaja precisamente es que *pueden no serlo*, sin perder por ello su relevancia. Las simulaciones son ante todo herramientas para pensar de manera sistemática (ordenada, rigurosa, clara, precisa) acerca de algún fenómeno o aspecto de la realidad. También, son dispositivos que nos ayudan a explorar las implicaciones de una cierta teoría. Por último, en ocasiones representan la única herramienta de investigación posible, debido a que la complejidad (y/o escala espaciotemporal) del fenómeno de interés hace imposible un estudio experimental controlado (e.g., la evolución de las especies, el origen y evolución de galaxias, etc.).

Con base a las redes neuronales se han establecido modelos de que han conseguido simular gran cantidad de fenómenos conductuales observados en organismos reales. De entre estos modelos cabe destacar el modelo propuesto

¹ "Thought experiments", en inglés.

por Donahoe, Burgos y Palmer (1993), que en honor a sus autores puede llamarse Modelo DBP, el cual está cobrando importancia dentro del análisis de la conducta por dos razones principalmente. Por un lado, es uno de los pocos modelos conductuales que ha podido simular con éxito una gran diversidad de fenómenos conductuales. En segundo lugar, es uno de los pocos modelos de redes neuronales que no hace una distinción teórica (aunque sí operacional) entre condicionamiento pavloviano (o respondiente) y condicionamiento operante. Más bien, propone una síntesis teórica entre que ambos tipos de aprendizaje, a diferencia de otros modelos que hacen una distinción teórica tajante entre condicionamiento pavloviano (e.g., Schmajuk, Lam y Gray, 1996) y condicionamiento operante (e.g., Schmajuk y Thieme, 1992).

Un aspecto importante de este tipo de investigación tiene que ver con la plausibilidad conductual, es decir, la capacidad de un modelo para simular fenómenos conductuales conocidos. El interés principal del presente trabajo se centra sobre la plausibilidad conductual del Modelo DBP. Un fenómeno conductual que aún no se ha intentado simular con el Modelo DBP es el llamado "condicionamiento contextual". Este fenómeno ha sido estudiado más frecuentemente en condicionamiento pavloviano que en condicionamiento operante (e. g., Thomas, 1985). En líneas generales, podemos argumentar que todo aprendizaje ocurre en un contexto, es decir, en un ambiente, ya que ningún estímulo o respuesta ocurre en un vacío estimulativo. Esta suposición se aplica a cualquier tipo de organismo y en todo tipo de condicionamiento. De ahí la importancia del condicionamiento contextual dentro de la ciencia de la conducta. En el caso de la investigación experimental en condicionamiento, las luces o el piso

de la cámara experimental, o incluso el nivel de ruido de fondo de las paredes de dicha cámara, actúan como estímulos contextuales (Balsam, 1985).

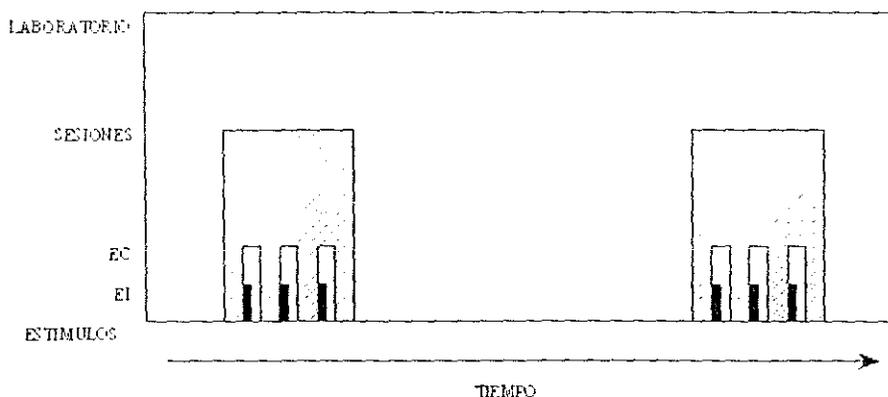


Figura 1. Representación esquemática de la estructura jerárquica del contexto en un experimento de condicionamiento Pavloviano (tomado de Balsam, 1985, p. 2).

Si tenemos en cuenta un experimento simple de condicionamiento Pavloviano como el que se ilustra en la Figura 1, al sujeto se le coloca dentro de una cámara experimental, que sería el contexto de aprendizaje. Posteriormente, se presenta un estímulo condicionado (EC) en el contexto de la cámara experimental. El estímulo incondicionado (EI), a su vez, se le presenta en el contexto del EC. Después de un determinado número de exposiciones a ambos estímulos, el EC evocará una respuesta condicionada (RC). Sin embargo, esta RC no es únicamente un indicador del efecto de la relación EC-EI. Si ese EC se prueba en contextos distintos al contexto de entrenamiento, la fuerza de la RC se verá significativamente disminuida. Por lo tanto, la efectividad del EC está modulada por las relaciones contexto-EI (e.g., Durlach, 1984; Gabriel, 1972; McAllister y McAllister, 1965), así como por las relaciones contexto-EC (e.g., Rescorla, 1984) y por la potenciación de las relaciones EC-EI por el contexto (e.g., Holland, 1983).

Hay muchas relaciones de primer orden que influyen en el comportamiento, pero lo más difícil para las teorías asociacionistas es explicar cómo un determinado estímulo puede controlar una RC dependiendo del contexto en el que el EC ha sido apareado con el EI, ya que se ha demostrado que una función del contexto es modular los efectos de esa relación. De ahí que las teorías contemporáneas intenten dar cuenta de este tipo de control ejercido por el contexto sobre la RC.

En el presente trabajo se intenta comprobar si el fenómeno del condicionamiento contextual puede ser simulado bajo el modelo de redes neuronales DBP, con el objeto de determinar la plausibilidad conductual de este modelo, como parte integral del trabajo de modelamiento del comportamiento desde una perspectiva bioconductual. Por otro lado, y de forma más general, este trabajo pretende profundizar en el campo de las simulaciones computacionales con redes neuronales y simulaciones digitales de fenómenos conductuales.

1.1. PREGUNTA DE INVESTIGACIÓN

La pregunta básica que ha guiado el presente trabajo es la siguiente:
¿Puede el Modelo DBP simular el condicionamiento contextual?

A continuación se presentan los objetivos que se pretenden alcanzar con este proyecto de investigación.

1.2. OBJETIVO GENERAL

Abonar al conocimiento de los alcances y limitaciones del Modelo DBP, explorando el papel que el contexto tiene en el aprendizaje en redes neuronales artificiales.

1.3. OBJETIVOS ESPECÍFICOS

El condicionamiento contextual está constituido por distintos fenómenos. Como punto de partida, en el presente trabajo se tomarán en consideración tres de esos fenómenos, en términos de los cuales formulamos a continuación los objetivos específicos del mismo.

1.3.1. OBJETIVO ESPECÍFICO 1

Determinar si el Modelo DBP puede simular la dependencia contextual del condicionamiento pavloviano.

1.3.2. OBJETIVO ESPECÍFICO 2

Determinar si el Modelo DBP puede simular la interferencia contextual del condicionamiento pavloviano.

1.3.3. OBJETIVO ESPECÍFICO 3

Determinar si el Modelo DBP puede simular la facilitación contextual del condicionamiento pavloviano.

2. CONDICIONAMIENTO CONTEXTUAL

La modulación contextual del aprendizaje se ha documentado en pájaros, roedores y primates (Balsam, 1985). También se ha observado tanto en condicionamiento apetitivo como aversivo, así como con estímulos interoceptivos y exteroceptivos (Overton, 1985). Todos los fenómenos básicos del aprendizaje que se han estudiado (excitación, inhibición, extinción, discriminación) han demostrado que están modulados por las manipulaciones contextuales (Balsam, 1985). Ahora bien, ¿cuáles son las condiciones necesarias para que un contexto definido arbitrariamente pueda ejercer una influencia sobre el aprendizaje y la ejecución? Una condición suficiente es que exista un reforzamiento diferencial de un EC por cambios en los estímulos contextuales. Las discriminaciones contextuales componen estas condiciones tanto para los ECs como para el contexto, lo cual se ilustra tanto en procedimientos apetitivos como aversivos, en los que un EC se refuerza o extingue sólo por la presencia de una característica distintiva. Bajo estas circunstancias, el contexto en el que se presenta el EC determinará el nivel de ocurrencia de una RC. En cambio, el reforzamiento diferencial del EC en más de un contexto parece no ser una condición necesaria para el control contextual del ambiente.

Thomas (1985) y Medin y Reynolds (1985) mostraron evidencia para el control contextual incluso cuando el EC y el contexto sólo se han experimentado juntos durante las sesiones experimentales. No obstante, los sujetos experimentaron otros contextos distintos al contexto definido en las sesiones experimentales, y de hecho, las cámaras experimentales son a menudo diferencialmente reforzadas con respecto a los otros contextos (Balsam, 1984;

Mackintosh, 1977; Thomas, 1985). Puede ser que el reforzamiento diferencial de los contextos o que la simple exposición a los cambios en el contexto sea una condición necesaria para conseguir el control por parte de los estímulos contextuales.

El contexto se puede definir con base en dos tipos de definiciones (Balsam, 1985). Una de ellas es de tipo *estructural*, y se refiere a todos los aspectos de un ambiente experimental que se presentan concurrentemente con un EC. El contexto también puede ser definido *funcionalmente*, refiriéndose a los estímulos que modulan el control ejercido por otro estímulo.

Dentro de las teorías asociacionistas existen múltiples explicaciones sobre cómo el contexto puede modular el aprendizaje, que suponen distintos modelos como el de competición, comparativo, sumatorio, de recuperación y de análisis de características de la discriminación. Según los modelos de competición, el contexto compite con los estímulos por la fuerza asociativa (Rescorla y Wagner, 1972) o por la atención (Mackintosh, 1975). En este tipo de modelos, estímulos y contexto son funcionalmente equivalentes, de manera que la conducta controlada por el contexto puede interferir con la conducta controlada por un estímulo (Balsam, 1984; Tomie, 1985).

Según los modelos comparativos, las características de los estímulos y el contexto pueden compararse con otros contextos para determinar el nivel de aprendizaje. En un análisis comprehensivo de los paradigmas de aprendizaje animal, Gibbon y sus colegas (Gibbon, 1977; Gibbon y Balsam, 1981; Gibbon y Church, 1984) propusieron una tasa de comparación de la demora global del reforzamiento en un contexto con una tasa de demora local de reforzamiento

subyacente a la ejecución de la conducta aprendida. Cuando esta tasa de expectativa excede un umbral, el sujeto responde. Por lo tanto, los sujetos aprenden acerca de ambos, tanto estímulos como contexto, y la ejecución está en función de la tasa de sus expectativas.

Según los modelos sumatorios, el condicionamiento de las señales contextuales podría sumarse con los valores asociativos de un EC y así aumentar la fuerza de la RC (Konorski, 1967). Este tipo de sumación del contexto y el valor del EC ha servido para explicar la facilitación de respuesta que se ha encontrado cuando un EC se prueba en un contexto asociado con el mismo EI que se ha utilizado para condicionar el EC (Bouton y Bolles, 1985; Miller y Schachtman, 1985; Rescorla, Durlach y Grau, 1985).

Los modelos de recuperación proponen que el contexto puede actuar como una señal de recuperación, ya que puede formar parte de una asociación entre otros estímulos y respuestas. La probabilidad de recuperación se ve influida, en todo caso, por si el contexto de prueba es similar o no al contexto de entrenamiento (Mediri y Reynolds, 1985). El contexto puede servir también como una señal de recuperación para otro tipo de relaciones, como por ejemplo la relación EC-EI (Miller y Schachtman, 1985) o la relación RC-EI (Spear, Smith, Bryan, Gordon, Timmons y Chiszar, 1980).

Otro tipo de modelos se basan en el análisis de las características de las discriminaciones positivas y negativas de Holland (1983), en las cuales se presenta repetidamente un estímulo y se refuerza de manera ocasional y, por lo tanto, se establecen las ocasiones en las que el estímulo se reforzará diferencialmente. En este paradigma, especialmente cuando una característica distintiva precede a

un estímulo común, la característica sirve para facilitar una relación particular EC-EI. De manera similar, el conjunto de ocasiones de un estímulo puede facilitar una relación instrumental RC-EI. Por lo tanto, un estímulo discriminativo realiza una función contextual en el sentido de que señala cuándo se efectúa una relación particular respuesta-reforzador (Medin y Reynolds, 1985; Overton, 1985; Thomas, 1985).

Teniendo en cuenta todos los modelos existentes que explican los efectos que el contexto tiene sobre el aprendizaje, existen dos estrategias generales para evaluar dicho efecto. Una de ellas examina el efecto de las manipulaciones contextuales sobre el control ejercido por un EC o estímulo discriminativo. La otra estrategia examina la adquisición o mantenimiento de la conducta que está controlada directamente por los estímulos contextuales.

Una técnica es la prueba del cambio de contexto², en la que se entrena al sujeto en un contexto de entrenamiento y se compara su ejecución en dicho contexto con la ejecución en contextos de prueba que difieren en distintas formas del contexto de entrenamiento. En líneas generales, la RC en un contexto distinto al contexto de entrenamiento disminuirá (Archer, Sjöden y Nilson, 1985; Medin y Reynolds, 1985; Miller y Schachtman, 1985; Nadel, Willner y Kurz, 1985; Overton, 1985). Según las teorías asociacionistas, esta disminución en la RC puede ser un reflejo del nivel de control excitatorio ejercido por un estímulo (Thomas, 1985). La RC también está modulada por la fuerza de la relación entre el contexto de prueba y el EI. Dicha relación a veces aumenta la fuerza de la RC (Bouton y Bolles, 1985; Rescorla, Durlach y Grau, 1985; Miller y Schachtman, 1985), mientras

² En inglés, *context-shift test*

que en otras circunstancias reduce el control excitatorio ejercido por un EC (Kaplan y Hearst, 1985; Miller y Schachtman, 1985; Randich y Ross, 1985).

Otra técnica es la prueba de retardo, a través de la cual se examina el condicionamiento de un EC seguido de señales contextuales preentrenadas. Las teorías asociacionistas asumen que un contexto condicionado previamente interferirá con la adquisición subsiguiente en el aprendizaje (Rescorla y Wagner, 1972) y/o el nivel de ejecución (Gibbon y Balsam, 1981).

Con la prueba de preferencia, utilizada exclusivamente para estudiar condicionamiento aversivo, se realiza una prueba de preferencia para diferentes contextos donde se han experimentado distintas historias de entrenamiento. A los sujetos se les da a elegir entre permanecer en un contexto preentrenado y otro contexto no preentrenado (Bouton y Bolles, 1985; Odling-Smee, 1975; Randich y Roch, 1985), o entre dos contextos que han sido preentrenados de maneras diferentes (Fanselow, 1980). Los resultados de la prueba de preferencia revelan diferencias en el aprendizaje sobre los contextos. Por ejemplo, los sujetos prefieren contextos en los que los choques eléctricos están precedidos por señales a aquellos contextos que no están precedidos por señales (Bouton y Bolles, 1985; Fanselow, 1980; Odling-Smee, 1975). Estas preferencias se han interpretado como un reflejo de la fuerza de la relación entre contexto y EI. Sin embargo, si asumimos que tanto la relación del contexto y el EC, así como la relación del EC y el EI, pueden influir en la elección final del sujeto, la prueba de preferencia nos indicará únicamente qué contexto es preferido por el sujeto, pero no las razones.

La prueba de sumación examina los efectos de presentar estímulos contextuales sobre la conducta operante, y es utilizada en procedimientos de

respuesta emocional condicionada (REC). Distintos autores han argumentado que cuando se produce un condicionamiento clásico aversivo en la misma caja experimental que fue utilizada para un condicionamiento operante apetitivo, la tasa de la respuesta puede servir como una prueba del condicionamiento contextual (Baker, Mercier, Gabel y Baker, 1981). Presumiblemente, el contexto afecta a la tasa de respuesta de la misma manera que un EC nominal lo hace en un procedimiento de REC. De hecho, cuando a los sujetos se les administran sesiones de condicionamiento fuera de la línea base, el condicionamiento contextual puede inferirse a partir de los efectos de la presentación no reforzada de señales contextuales sobre la conducta operante (Patterson y Overmier, 1981).

Finalmente, existen técnicas que se centran en constatar la resistencia del contexto al reforzamiento. Una de estas técnicas de medida del control contextual fue diseñada por Tomie (1985), según la cual los sujetos se exponen primeramente a un procedimiento de preentrenamiento. En la siguiente fase del experimento se presenta un contexto preentrenado, que funcionalmente sería como un EC emparejado con un EI. Aquí, el condicionamiento contextual se infiere a partir de la efectividad de la señal contextual precedente para actuar como un EC. Los efectos de este procedimiento están modulados por el estado asociativo de las señales contextuales que permanecen durante la fase de prueba. Cuando el contexto de entrenamiento y el contexto de prueba son el mismo, la adquisición de la RC se retarda, mientras que un cambio de contexto entre entrenamiento y prueba da lugar a una facilitación en la adquisición de la RC.

Con este tipo de pruebas se ha llegado a conocer de manera más precisa fenómenos de condicionamiento contextual como la dependencia contextual del aprendizaje, la interferencia contextual y la facilitación contextual, que precisamente son el objeto de estudio en el presente trabajo. En términos generales, las relaciones contexto-EI se desarrollan rápidamente. En procedimientos de condicionamiento aversivo, el aprendizaje contextual se ha demostrado justo después de unas cuantas presentaciones del EI (Archer, Sjöden y Nilsson, 1985; Bouton y Bolles, 1985; Odling-Smee, 1975; Randich y Ross, 1985), así como después de un número pequeño de apareamientos EC-EI (McAllister, McAllister y Benton, 1983).

En procedimientos de condicionamiento apetitivo se ha demostrado que las relaciones contexto-EI se forman rápidamente utilizando la prueba de retardo; es más, el aprendizaje contextual es rápido incluso cuando las presentaciones del EI están precedidas por estímulos. Los efectos de estas relaciones parecen mantenerse con el tiempo, como demuestra la continua influencia sobre los niveles de ejecución (Balsam, 1984; Balsam y Schwartz, 1981; Durlach, 1984; Randich y Lolordo, 1979; Randich y Ross, 1985; Rescorla, Durlach y Grau, 1985; Tomie, 1985) y por los efectos de las manipulaciones contextuales después de un entrenamiento (Bouton y Bolles, 1985; Overton, 1985; Rescorla, Durlach y Grau, 1985; Thomas, 1985).

Sobre la interferencia de las relaciones contexto-EI con la RC, Rescorla y Wagner (1972) postularon una relación inversa entre el valor asociativo del contexto y la fuerza de la RC. También existe evidencia empírica para afirmar que las relaciones contexto-EI pueden interferir con las relaciones EC-EI (Balsam, 1984;

Balsam y Schwartz, 1985; Durlach, 1984; Rescorla, Durlach y Grau, 1985; Tomie, 1981). La mayoría de esta evidencia proviene de estudios que demuestran que la adquisición de la RC se incrementa por un condicionamiento contextual previo, que los ensayos masificados en el tiempo producen una adquisición de la RC sustancialmente más lenta que los ensayos espaciados, y que las presentaciones del EI durante el intervalo entre ensayos también interfiere con la adquisición de la RC. El análisis experimental de estos efectos indica que la interferencia contextual con la RC es el resultado tanto de mecanismos de aprendizaje como de ejecución (Balsam, 1985).

Según los modelos asociacionistas, la naturaleza del aprendizaje que subyace al efecto de interferencia del contexto puede ser de dos tipos. En uno de ellos, las relaciones contexto-EI bloquean la formación de relaciones EC-EI. Por otro lado, las relaciones contexto-EI pueden cambiar la relación EC-RC.

En relación a la facilitación contextual, se ha demostrado que las relaciones contexto-EI están directamente relacionadas con la fuerza de la RC en estudios que emplean una prueba de contexto cambiante. Generalmente, cuando un EC bien establecido se prueba en un contexto diferente del contexto de entrenamiento, se observa un decremento en la fuerza de la RC (Archer, Sjödnén y Nilsson, 1985; Durlach, 1984; Medin y Reynolds, 1985; Miller y Schachtman, 1985). Sin embargo, la fuerza de la RC es mayor en un contexto de prueba asociado previamente con el EI que un contexto de prueba no asociado con el EI (Durlach, 1984; Gabriel, 1972; McAllister y McAllister, 1965; Rescorla, Durlach y Grau, 1985).

Modelos asociacionistas como el Rescorla y Wagner (1972) y las aproximaciones teóricas asociacionistas propuestas en Gibbon y Balsam (1985) dan cuenta del condicionamiento contextual en los términos detallados con anterioridad. En cambio, hay otra aproximación teórica (más cercana a la estructura y funcionamiento real de los organismos), que puede dar cuenta de los fenómenos de condicionamiento contextual que son objeto de estudio en el presente trabajo: estamos hablando de los modelos conexionistas, que utilizan redes neuronales artificiales para tratar de comprender y explicar la conducta. Mientras que para las teorías asociacionistas la base para el aprendizaje son las asociaciones, las teorías de redes neuronales desarrollan descripciones mecanicistas que implementan la idea psicológica de la asociación, capturando aspectos del procesamiento de información de las neuronas (Schmajuk, 1997).

3. CONEXIONISMO

El Conexionismo es una filosofía de la mente según la cual los estados mentales no son más que estados cerebrales constituidos por patrones de activaciones de grandes números de neuronas que se afectan unas a otras en virtud de estar conectadas entre sí. Las primeras reseñas sobre el Conexionismo se remontan a finales del siglo XIX y provienen de la neurofisiología. Sin embargo, autores como Hebb (1949) impulsaron el desarrollo del Conexionismo, concibiendo una unión entre Psicología y Fisiología para dar cuenta de un modelo de aprendizaje: si un conjunto de neuronas conectadas entre sí se activan repetidamente, sus sinapsis aumentan su conductividad. O dicho de otro modo: conjuntos de neuronas sincrónicamente activadas tienden a organizarse

en conjuntos conectados. A dichos conjuntos, Hebb les llamó "asambleas neuronales". Estas ideas de Hebb han resultado particularmente fructíferas, y han servido como base para redes neuronales propuestas por autores como Uttley (1954).

Anterior a Hebb, el neurofisiólogo Warren McCulloch y el matemático Walter Pitts, quienes publicaron un artículo que tuvo mucha relevancia porque en él se concibió al cerebro como un organismo computacional (McCulloch y Pitts, 1943), modelizaron matemáticamente la actividad de unidades de computación neuronal interconectadas en forma de redes, definidas a partir de una abstracción de las propiedades fisiológicas de las neuronas. Estas unidades sólo podían tener dos estados: activas (adquirían el valor de 1) o inactivas (cuyo valor era 0) y se afectaban unas a otras mediante conexiones con una cierta fuerza o peso constante. Las unidades podían verse afectadas por conexiones tanto excitatorias como inhibitorias, de manera que si una unidad recibe señales de otras unidades por medio de sinapsis excitatorias, estas señales se añaden linealmente. Si el resultado de la suma supera el valor de un umbral, la unidad se activa; en caso contrario, la neurona permanece inactiva. Si una unidad recibe señales a través de sinapsis inhibitorias, la unidad se inhibe con independencia del valor de la suma de las sinapsis excitatorias. Este tipo de unidades recibieron el nombre de *unidades McCulloch-Pitts*, y su regla de activación es la siguiente:

La neurona se activa (y por tanto, su salida $F = 1$) si la siguiente inecuación es verdadera:

$$X_1W_1 + X_2W_2 + \dots + X_jW_j + \dots + X_nW_n > T$$

O, en su forma compacta:

$$\sum X_j W_j > T$$

McCulloch y Pitts partieron del supuesto de que la actividad de cada unidad representaba un enunciado lógico. De esta forma, la activación de un umbral de entrada representaba una proposición verdadera, mientras que una activación de valor 0 representaba una proposición falsa.

Sin embargo, las redes de McCulloch y Pitts resultan ser poco realistas y, además, desde un punto de vista neurocientífico, era inverosímil que cada neurona representara una proposición lógica. Otra de las críticas al modelo McCulloch y Pitts es que se asumía que todas las sinapsis excitatorias eran igualmente eficaces, y las conexiones se establecían a mano (*hand-wired*) por un agente externo al sistema y de acuerdo a un objetivo computacional muy concreto. Posteriormente, Von Neumann (1956), mejoró las redes McCulloch-Pitts creando redes más confiables, incluyendo para ello la redundancia. Mejoras posteriores a esta aportación vinieron con las redes de Winograd-Cowan (1963).

Otra limitación importante del modelo McCulloch-Pitts es que no incluye un algoritmo para cambiar los pesos de las conexiones de manera automática. Este tipo de algoritmo se conoce como *regla de aprendizaje*, y representa un aspecto central de todo sistema nervioso, a saber: su plasticidad. El trabajo de Rosenblatt (1958, 1962) es relevante en este sentido. Rosenblatt defendió la importancia de las redes neuronales para la computación y de los métodos probabilísticos más que de los métodos lógicos en el uso de las redes, además de proponer una regla

de aprendizaje basada en una mejora de la regla inicialmente propuesta por Hebb. Al modelo resultante lo llamó *Perceptrón*. Un Perceptrón podría estar compuesto por una red con varias capas de neuronas, llamadas *unidades de umbral lógico* (TLU) y basadas en las neuronas de McCulloch y Pitts (1943).

La primera TLU fue propuesta como un modelo de retina, compuesto por varias unidades distribuidas en forma de matriz bidimensional que registraban el estímulo en forma de un determinado patrón de activación. Esta capa inicial se proyectaba sobre la siguiente capa, llamada capa de asociación. Las unidades de esta capa de asociación estaban conectadas parcialmente con las unidades de la capa de la retina. Por otro lado, la capa de asociación se conectaba con la capa de respuesta, donde se producía la respuesta de clasificación. Las unidades de esta capa de respuesta tenían un patrón de conectividad similar a las de la capa de asociación. Para Rosenblatt, solamente una de las unidades de la capa de respuesta podía activarse, debido al proceso de competición entre las unidades de respuesta, técnica habitualmente empleada en la computación neuronal (Figura 2).

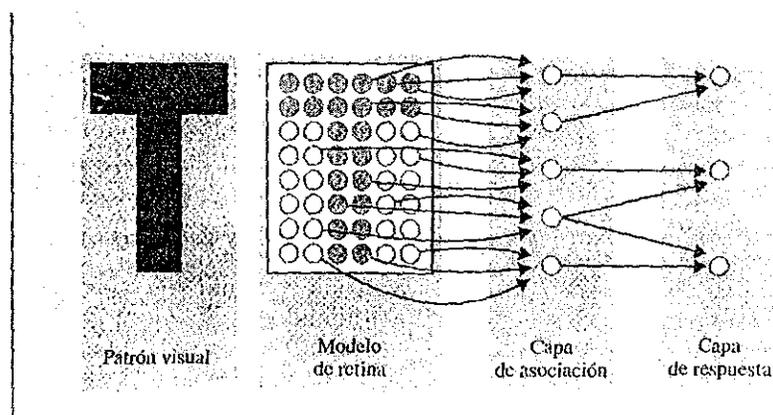


Figura 2. Ejemplo de un Perceptrón simple (tomado de Cobos, 2005).

Las unidades de la capa de asociación y de respuesta son unidades lógicas con umbral que pueden tomar dos posibles valores de activación o de salida (1 y 0, o bien 1 y -1), en función de si la suma de las señales de entrada sobrepasa o no un determinado valor de umbral (la misma función de activación del modelo McCulloch-Pitts). La señal de entrada que una unidad i recibe de otra neurona j es igual al valor de salida de j multiplicado por el peso de la conexión en la dirección $j \rightarrow P(ij)$. De esta forma, la tarea que tenía que resolver la red era la modificación de los pesos de las conexiones entre las capas de asociación y de respuesta, de manera que, dado cualquier patrón de entrenamiento, se activara sólo la unidad de respuesta correcta.

La regla de aprendizaje que diseñó Rosenblatt estaba basada en una señal correctora que actuaba ensayo a ensayo: en cada ensayo se introducía un patrón de entrada en la retina de acuerdo con la forma de algún estímulo visual. Si la respuesta de la red era correcta, no se producían cambios en los pesos de conexión. Sin embargo, si la respuesta de la red era incorrecta, se producían cambios en los pesos de conexión entre las unidades de la capa de asociación y las unidades de la capa de respuesta. Este *Teorema de convergencia del Perceptrón*, desarrollado formalmente con posterioridad por Block (1962), garantiza que la red se estabiliza en un patrón de pesos que logre separar adecuadamente las distintas categorías de patrones de entrada, siempre que dichas categorías sean linealmente separables³:

³ Se dice que dos clases de patrones de entradas son linealmente separables cuando, si los representamos por puntos en un espacio, podemos trazar una línea recta (o un plano si se trata de tres dimensiones, o un hiperplano si se trata de más) entre los patrones de una clase y los de la otra.

$$\Delta P_{ij} = \eta \cdot K \cdot s_i \cdot s_j$$

donde P_{ij} es el incremento (o decremento) en el peso de la conexión entre las unidades j e i ; η es una constante que oscila entre 0 y 1; s_i y s_j son los valores de salida de la unidad de respuesta i y de asociación j , respectivamente; y K es la señal de error, que oscila entre -1 y 0, en función de si la red emite una respuesta errónea o correcta, respectivamente (Cobos, 2005).

Rosenblatt (1958) entrenó a perceptrones en distintas condiciones, y demostró que eran hábiles en condiciones de ruido, generalizan lo aprendido a patrones nuevos, y toleran muy bien tanto la falta de información como lesiones (supresión de unidades o de conexiones). Sin embargo, los perceptrones mostraban una serie de limitaciones, como detallaron Minsky y Papert (1969), ya que no podían resolver problemas perceptivos cuya estructura era la función OEX (O exclusivo), así como relaciones funcionales del estilo "más pequeño que", "más verde que", etc.

Bernard Widrow y Marcial Hoff crearon una variante del Perceptrón y un nuevo procedimiento de aprendizaje, conocido como la *Regla Delta del Aprendizaje* (Widrow y Hoff, 1960). Su red recibió el nombre de ADALINE (por "Adaptive linear neuron", o neurona lineal adaptativa) y se diferenciaba del Perceptrón en el procedimiento de aprendizaje empleado. Sin embargo, los Perceptrones y ADALINES elementales (los que constan sólo de dos capas) tenían serias limitaciones ya que no eran capaces de reconocer patrones sencillos.

Es en los años ochenta cuando el Conexionismo empieza a tener un éxito considerable, debido a la aparición de "*Parallel Distributed Processing*:"

Explorations in the microstructure of cognition" (Rumelhart y McClelland, 1986), donde se demuestra cómo las redes con más de dos capas pueden solucionar las objeciones matemáticas que tanto limitaron el desarrollo en la investigación de redes neuronales. Mediante un algoritmo de aprendizaje de retropropagación (Rumelhart, Hinton y Williams, 1986) se superaban esas dificultades que se le presentaban a una red neuronal de cara a discriminar entre dos clases linealmente no separables. La retropropagación consiste en propagar el error hacia atrás, es decir, desde la capa de salida hacia la capa de entrada, pasando por las capas ocultas intermedias y ajustando los pesos de las conexiones con el fin de reducir dicho error. Hay distintas versiones o reglas del algoritmo de retropropagación y distintas arquitecturas conexionistas (aunque todas ellas anterógradas) a las que pueden ser aplicados.

La descripción matemática del algoritmo de retropropagación para redes no recurrentes, con función de activación sigmoideal y conectividad total entre capas es la siguiente⁴:

1. Distribuir aleatoriamente los pesos de las conexiones.
2. Presentar un patrón de entrada y calcular la salida.
3. Dada una unidad j -ésima de la capa de salida y unidades i -ésimas de la capa oculta inmediatamente anterior, calcular la entrada total ponderada y la salida o activación de la misma.

⁴ Para mayor información, consultar Hinton (1992)

4. Una vez computadas las actividades de todas las unidades de salida se calcula una estimación del error, generalmente una función cuadrática de los errores individuales cometidos por cada unidad, siendo cada error individual E la diferencia entre la salida deseada y la obtenida
5. Computar la rapidez de variación del error al cambiar la activación de cada unidad de salida
6. Computar la rapidez de variación del error al cambiar la entrada total que recibe cada unidad de salida
7. Computar la rapidez de variación del error al modificar un peso de la conexión aferente a una unidad de salida
8. Conocido dicho valor del punto 7, se pueden usar distintas reglas para modificar ese peso para reducir dicho error. Una de las primeras reglas que aprovechó este algoritmo es la *regla delta generalizada*, que calcula el incremento a aplicar a un peso como una proporción directa de la tasa de variación del error. Sin embargo, existen extensiones a la regla delta generalizada, como la *regla DBD (delta-bar-delta)* (Jordan, 1988) y la *regla EDBD (extended delta-bar-delta)* (Minai y Williams, 1990). Mientras que la regla DBD usa un coeficiente de aprendizaje propio y variable para cada conexión, la regla EDBD añade el *momentum*⁵ a la regla DBD.

Sin embargo, el algoritmo de retropropagación presenta ciertos problemas, algunos referentes a su dudosa plausibilidad neurofisiológica, y otros referentes a ciertos aspectos computacionales, como los siguientes:

⁵ Coeficiente que determina la cantidad de cambio realizado sobre un peso (Rumelhart, Winton y Williams, 1986).

- Los resultados dependen de los valores iniciales de las conexiones. Esto hace que sea conveniente entrenar varias redes con distintos valores iniciales y elegir la que mejor funcione.
- A veces se requiere mucho tiempo para obtener soluciones sencillas: el tiempo de cómputo aumenta mucho al aumentar el tamaño de la red. Si bien el volumen de cálculo es proporcional al número total de conexiones, en la práctica, al aumentar el tamaño de la red, hacen falta más ejemplos de aprendizaje, y eso provoca un aumento mucho mayor del tiempo de aprendizaje. Para incrementar la velocidad de convergencia se han desarrollado diferentes modificaciones del algoritmo.
- El empeoramiento en el rendimiento del sistema, como consecuencia de la incorporación de nuevos ejemplos de aprendizaje.
- La "parálisis" sucede cuando los pesos quedan ajustados a valores muy grandes, lo cual hace operar a las unidades de proceso con una activación muy próxima a 1, y por lo tanto no se producen modificaciones en los pesos (y por ende, el aprendizaje queda detenido). Por eso es conveniente aleatorizar los pesos de las conexiones con valores pequeños.
- Inestabilidad temporal: si usamos un coeficiente de aprendizaje elevado, se van a producir incrementos grandes en los pesos, de manera que es fácil pasarse de incremento y tener que tratar de compensarlo en el siguiente ciclo, de manera que se producirían oscilaciones continuas. Esto se soluciona usando un coeficiente pequeño, o, para no tener un aprendizaje muy lento, modificar dicho coeficiente adaptativamente (aumentarlo si el error global disminuye, y disminuirlo en caso contrario).

- El problema de los mínimos locales: el algoritmo de retropropagación usa una técnica por gradiente descendiente, esto significa que sigue la "superficie del error" siempre hacia abajo, hasta alcanzar un mínimo local, pero no garantiza que se alcance una solución globalmente óptima. Sin embargo, se ha comprobado que el hecho de alcanzar mínimos locales no impide que se consigan resultados satisfactorios. Por otro lado, se han desarrollado métodos para solventar este problema, como el modo de operación asíncrono o probabilístico. Podemos considerar el error como una superficie llena de desniveles, si soltamos una pelota caerá en algún valle, pero no necesariamente en el más hondo, sino en el más cercano (un mínimo local). Una idea intuitiva para solucionar esto, sería aplicarle cierta energía a esa superficie agitándola o haciéndola vibrar, esto haría saltar a la pelota de valle en valle, como de los valles más profundos es más difícil salir, tendería a estar en valles cada vez más profundos. Si dejamos de agitar esa superficie poco a poco, al final tendremos la pelota en el valle más profundo de la superficie (ver Figura 3). Otras técnicas que pueden ayudar a no caer en mínimos locales consisten en añadir cierto nivel de ruido a las modificaciones de los pesos de las conexiones. Otra medida propuesta es añadir ruido a las conexiones, pero esto es más útil para darle robustez y aumentar la capacidad de generalización de la red. Estas medidas, por contra, aumentan el tiempo de aprendizaje.

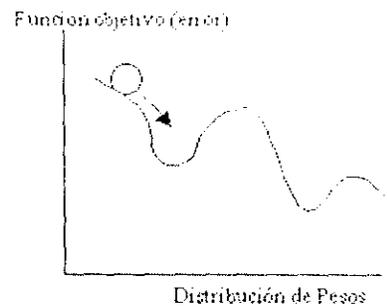


Figura 3. Problema de los mínimos locales.

La invención y perfeccionamiento del algoritmo de retropropagación dio un gran impulso al desarrollo del campo de las redes neuronales, debido a que tiene un buen fundamento matemático y, a pesar de sus limitaciones, ha expandido enormemente el rango de problemas donde se aplican las redes neuronales. Es a partir de entonces cuando se suceden multitud de investigaciones, artículos y congresos, tanto en los campos de la Inteligencia Artificial como en los de la Psicología, convirtiéndose el Conexionismo en un movimiento revolucionario en el panorama de la ciencia cognitiva. En este contexto se crean la *Sociedad Europea de Redes Neuronales (ENNS)* y la *Sociedad Internacional de Redes Neuronales (INNS)*, que organizan congresos y reuniones anuales y editan revistas para la divulgación de las investigaciones en este campo de investigación, entre las que destacan *Neural Networks* (revista oficial de la Sociedad Internacional de Redes Neuronales); *Network, Computation in Neural System*, *Transactions on Neural Networks*, *Neural Networks Council*, *Neural Computation* e *International Journal of Neural Systems*.

Tras este recorrido por la historia del Conexionismo, puede argumentarse que las redes neuronales son sistemas formados por una determinada cantidad de elementos o neuronas artificiales conectadas entre sí, capaces de procesar y

almacenar información, e influir unos en el estado de los otros a través de esas conexiones. El Conexionismo considera adecuada la explicación del fenómeno a simular cuando la red es capaz de realizar, a partir del vector de entrada, los distintos cálculos que provocan la emisión del vector de salida deseado.

Una red neuronal puede construirse de tres maneras:

- *Físicamente*: como un sistema mecánico, eléctrico, electrónico, etc.
- *Matemáticamente*: se desarrolla una descripción matemática completa de los elementos que la componen y sus relaciones
- *Simulaciones*: se desarrollan programas con algún lenguaje de programación mediante computadora. Esta es la alternativa más frecuente y es la que se utilizará en el presente proyecto.

Dentro de las simulaciones, las características presentes en la mayoría de los modelos conexionistas son las siguientes:

1. La red neuronal es un conjunto de unidades de procesamiento muy simples.
2. La arquitectura de una red neuronal se refiere a su organización general, es decir, al patrón de conexiones que la constituyen: redes de flujo directo, redes recurrentes, redes de una, dos, tres o más capas, redes con o sin conexiones intracapa, etc.
3. Por las redes fluye una magnitud, llamada "activación", que es el equivalente al impulso nervioso o potencial de acción y se expresa de forma cuantitativa.

4. Las conexiones entre unidades tienen diferentes pesos, que representan el grado en el que una conexión es más o menos fuerte. Al igual que la activación, se expresa de manera cuantitativa.
5. Los estímulos que afectan a las unidades de entrada se expresan, igualmente, en términos cuantitativos.
6. El procesamiento y almacenamiento de la información se realiza de forma paralela y distribuida.
7. Existen reglas o funciones que computan la información en distintos niveles del procesamiento (para la modificación del nivel de activación a partir de las entradas, para la producción de la salida a partir del nivel de activación, etc.).
8. Existen reglas o funciones de aprendizaje que le permiten a la red modificar los pesos de las conexiones para ajustar de modo cada vez más perfecto la información de entrada a la salida requerida. La modificación de los pesos de las conexiones es la base del aprendizaje.
9. La función de cada unidad o neurona consiste en realizar cálculos con las entradas que reciben y producir la información que envían a las unidades con las que están conectadas.
10. Las señales de salida que emite la red se expresan en términos cuantitativos.

3.1. ELEMENTOS Y ORGANIZACIÓN DE UNA RED NEURONAL

Existen distintos tipos de redes neuronales, y todas ellas implican la integración de diversos elementos y formas de organización. Sin embargo, estas redes neuronales tienen elementos comunes.

3.1.1. UNIDADES DE PROCESAMIENTO

Los elementos básicos de procesamiento de la información en el cerebro son las neuronas; dado que los modelos conexionistas son modelos de inspiración biológica, a las unidades básicas encargadas del procesamiento en las redes conexionistas se las llama habitualmente *neuronas*, aunque también podemos encontrar en la literatura los términos "células", "unidades", "neuronas artificiales", "nodos", "elementos de procesamiento" (PEs) o, simplemente, "elementos". La función de estas unidades tiene que ver fundamentalmente con la recepción y tratamiento de la información: la neurona computa una función de transferencia que asigna a cada patrón de valores de entrada un único valor de salida.

Estos valores que fluyen por la red reciben el nombre de *activación*, y se trata de un valor numérico que representa el grado de actividad de cada neurona en un momento dado. La función de transferencia es un vector de entrada, un vector de activación y un vector de salida, como se muestra en la Figura 4.

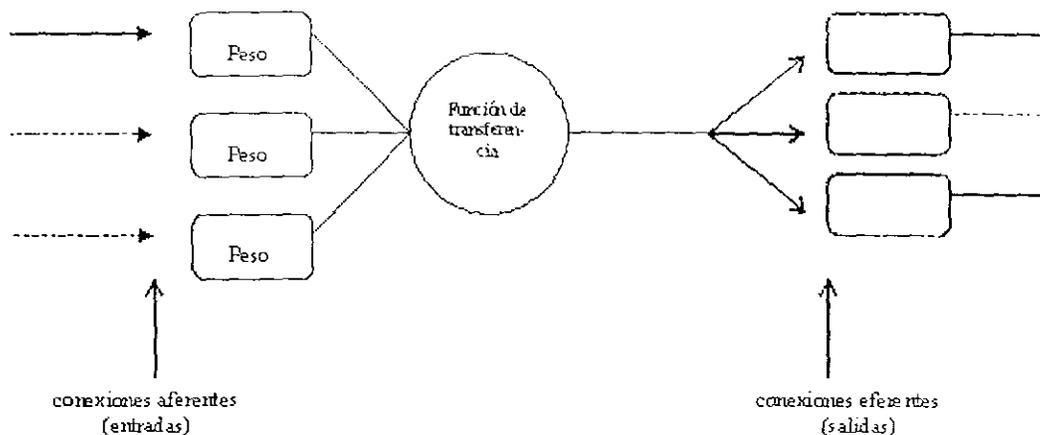


Figura 4. Función de transferencia: una neurona artificial recibe conexiones aferentes y la función de transferencia computa su valor para emitir la activación, a través de las conexiones eferentes, a las neuronas artificiales con las que está conectado. Para un mayor detalle, ver la exposición detallada a continuación.

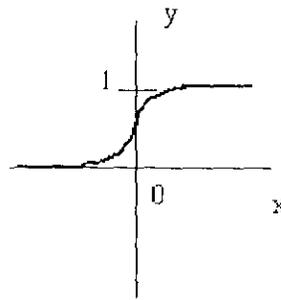
- *Vector de entrada:* la neurona realiza un cómputo total de su entrada o activación a partir de las activaciones recibidas por cada conexión aferente (o_i), ponderada por los pesos de cada conexión (w_{ij}). Así,

$$net_j = \sum o_i \cdot w_{ij}$$

- *Vector de activación:* a partir del resultado de la función de entrada (net_j), la neurona computa su propio y nuevo nivel de activación a_j . En los casos más simples se trata de una función lineal de net_j pero lo más frecuente es que se trate de funciones sigmoideas, que capturan con mayor detalle y realismo el funcionamiento de las neuronas del sistema nervioso. La ecuación típicamente utilizada para estas funciones es:

$$a_j = \frac{1}{1 + e^{-net_j}}$$

Esta ecuación da lugar a la siguiente curva de activación:



Función Sigmoide

- *Vector de salida*: el nivel de activación alcanzado por una neurona se transmite a las neuronas con las que está conectada; en determinados casos, la neurona computa una función umbral, de manera que la salida que estuviese dando anteriormente sólo se modifica si la activación excede el valor de dicho umbral.

3.1.2. ARQUITECTURA

La arquitectura de una red neuronal consiste en la estructura que presenta la red (Cobos, 2005). Para definir la arquitectura de una red, puede ser útil distinguir tres niveles de análisis (Maren, Harston y Pap, 1990): el nivel de la microestructura, el de la mesoestructura y el de la macroestructura. Mientras que el nivel de la microestructura hace referencia al procesamiento de las neuronas, los niveles de la mesoestructura y la macroestructura aluden a la arquitectura propiamente dicha.

En la mesoestructura se describe la estructura de la red, la cual afecta de manera crucial a las interacciones que se dan entre distintas neuronas, así como al comportamiento y propiedades globales de la red. Por tanto, en este nivel de análisis se debe conocer cuántas capas tiene una red neuronal, el número de

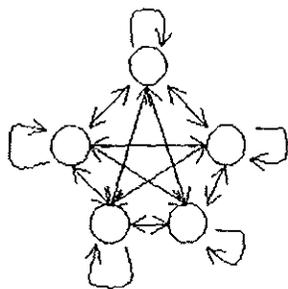
unidades que integran cada capa y el modo en el que están conectadas las neuronas.

Según el número de capas de una red neuronal, se distinguen redes sin capas, donde todas las neuronas son iguales desde un punto de vista estructural (ver Figura 5). Se conocen como *autoasociadores* o redes completamente recurrentes. Cuando la red tiene dos capas se llama *red bicapa*, y si el número de capas es superior a dos, se denomina *red multicapa* (Cobos, 2005).

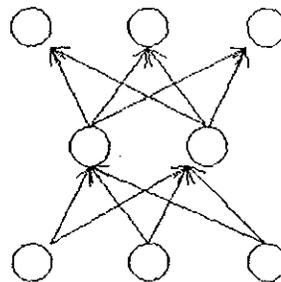
Según la dirección en la que se propaga la información en la red, o la dinámica de la misma, se conocen las *redes de propagación hacia delante*, donde la información sólo se propaga desde la capa de entrada hacia la capa de salida, y *redes recurrentes o de propagación hacia delante y hacia atrás*, donde la información se propaga en ambos sentidos entre dos o más capas (ver Figura 5). El que exista o no recurrencia en una red cambia enormemente su comportamiento (Cobos, 2005).

Otro caso especial de redes son las *redes competitivas*, que incluyen capas con conexiones laterales entre neuronas de una misma capa con el objetivo de establecer una dinámica competitiva entre grupos de neuronas (Cobos, 2005).

a)



b)



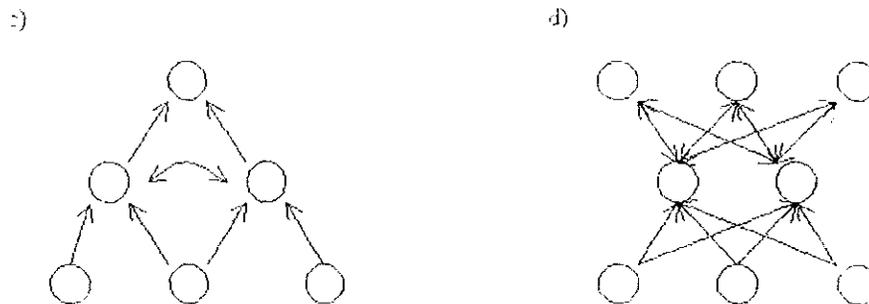


Figura 5. Distintos tipos de estructuras de una red neuronal. a) autoasociador o red completamente recurrente; b) red multicapa con propagación hacia delante; c) red multicapa con propagación hacia delante y con conexiones laterales inhibitorias en la capa intermedia; d) red multicapa semirrecurrente.

La tendencia que predomina en los modelos conexionistas, y en los modelos computacionales en general, consiste en analizar un aspecto específico del procesamiento que tiene lugar en una tarea concreta. Si cada componente involucrado en dicha tarea se concibe como una red con una arquitectura propia, nos encontramos entonces con que el modelo de red neuronal se muestra como una red de redes, y ahí estaríamos hablando del nivel de la macroestructura.

Normalmente, la arquitectura de una red neuronal se define atendiendo únicamente a la microestructura y a la mesoestructura. La modificación de uno de estos aspectos generará una multiplicidad de variaciones no sólo en la arquitectura, sino en el funcionamiento de la propia red neuronal. De ahí la importancia de especificar los elementos de diseño arquitectónico de una red neuronal.

Una red neuronal típica, exceptuando las redes de tipo Hopfield (1982) o Kohonen (1982), consta de tres tipos de unidades: unidades de entrada, unidades ocultas y unidades de salida.

3.1.2.1. UNIDADES DE ENTRADA

Estas unidades reciben información de fuentes externas a la propia red. Si la red dispone de sensores (por ejemplo, un scanner), la información externa es información sensorial; si la red está conectada con otras redes, las unidades de entrada reciben datos de las salidas de las otras redes; en otros casos, simplemente, las unidades de entrada reciben los datos que el usuario de la red introduce manualmente en la computadora.

3.1.2.2. UNIDADES OCULTAS

Aunque no todas las redes poseen este tipo de unidades o neuronas, las redes mínimamente sofisticadas las incluyen (e.g. retropropagación). Estas neuronas no tienen una relación directa ni con la información de entrada ni con la de salida, por lo que no son visibles al ambiente exterior a la red (de ahí su nombre). Su función es mediar la señal de entrada y la de salida, procesando la información en niveles más complejos, ya sea directamente de las unidades de entrada o de otras unidades ocultas, y transmitirla ya sea a otras unidades ocultas o directamente a las unidades de salida.

3.1.2.3. UNIDADES DE SALIDA

Estas unidades emiten las señales o información al exterior de la red, es decir, emiten la respuesta del sistema. Si la red dispone de conexiones con sistemas motores (por ejemplo, robots) su respuesta será la intervención en el mundo físico; si la red está conectada con otras redes, su respuesta serán datos de entrada para estas últimas redes; y si, simplemente, son redes que utilizamos en nuestra computadora, las unidades de salida arrojan datos al usuario de la red para su posterior análisis.

En la Figura 6 se pueden observar los distintos tipos de unidades de una red neuronal, así como su distribución en capas.

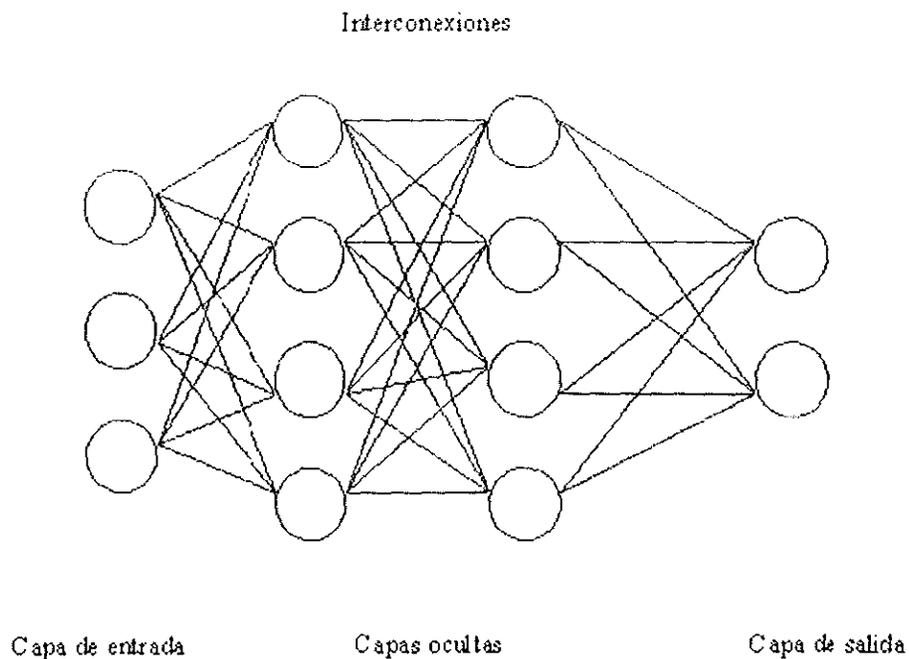


Figura 6. Arquitectura de una red neuronal: se observa la organización en capas (de izquierda a derecha, la capa de entrada, las capas ocultas y por último, la capa de salida). Cada círculo representa una neurona artificial y las líneas que los unen representan conexiones entre dichas neuronas. La información fluye de izquierda a derecha.

3.1.3. FUNCIONAMIENTO

Como se vio en el apartado 3.1.2., el nivel de la microestructura hace referencia al procesamiento de las neuronas, las cuales realizan principalmente, las siguientes operaciones:

- *Integración de las entradas procedentes de otras unidades:* suele ser un sumatorio de cada uno de las entradas individuales. A su vez, cada entrada individual es el resultado de multiplicar el valor de la señal de salida de la neurona emisora por el peso de su conexión con la neurona receptora. Éste es el modo más generalizado en los modelos de redes neuronales, aunque hay otras formas de integrar las entradas.
- *Cálculo del valor de activación y su transmisión a otras unidades:* el valor de activación es el resultado de aplicar una función de transferencia sobre la entrada neta, que es la señal integrada de activación, como se ha visto anteriormente. La elección de la función de activación puede afectar de manera drástica a lo que una red neuronal es capaz de computar, así como a sus propiedades (Cobos, 2005). Así, podemos encontrar funciones de activación lineales, lógicas, sigmoides, etc.
- *Cómputo de la regla de aprendizaje:* existe una infinidad de reglas de aprendizaje, que de manera somera se dividen en reglas de aprendizaje supervisado y no supervisado. La regla de aprendizaje influye en lo que la red puede computar y en sus propiedades.

En las redes neuronales se dice que la red aprende cuando es capaz de ofrecer, ante un determinado patrón de entrada, el correspondiente patrón de salida, por medio de una modificación de uno o más de los pesos de sus conexiones. Esta capacidad para emparejar adecuadamente los vectores de entrada y los vectores de salida se consigue mediante la modificación de los patrones de conexión. Las redes neuronales biológicas realizan estas modificaciones mediante, al menos, los siguientes procedimientos:

1. el desarrollo de nuevas conexiones;
2. la pérdida de las conexiones existentes;
3. la modificación de la fuerza de las conexiones que ya existen.

Los aspectos 1 y 2 han sido poco tratados en el marco de las redes neuronales conexionistas. De todos modos, pueden considerarse como un caso especial de 3, puesto que el cambio de la fuerza de conexión de cero a algún otro valor, sea positivo o negativo, tiene un efecto similar al hecho de desarrollarse una nueva conexión; y, a la inversa, siempre que se modifique la fuerza de conexión situándola en cero es como si se perdiese una conexión existente. En definitiva, el aprendizaje en las redes conexionistas consiste en la modificación de los pesos de las conexiones; las reglas de aprendizaje no son otra cosa que procedimientos para cambiar estos pesos, de manera tal que la salida de la red se adecue a las exigencias de su ambiente. Para ello, los modelos de redes neuronales incorporan alguna regla de aprendizaje, a través de la cual se actualizan los pesos a lo largo del proceso de entrenamiento (a excepción del modelo McCulloch y Pitts, 1943).

Existen tres tipos principales de reglas de aprendizaje, a saber: aprendizaje supervisado, no supervisado y reforzado. Los modelos de redes neuronales basados en aprendizaje supervisado más representativos son el Perceptrón (Rosenblatt, 1958), la regla delta de Widrow y Hoff (1960), las redes de retropropagación (Rummelhart y McClelland, 1986), redes de contrapropagación (Freeman y Skapura, 1991) y Máquinas de Boltzmann (Freeman y Skapura, 1991). En esta modalidad de aprendizaje existe un agente externo (supervisor o maestro) que controla el proceso de aprendizaje de la red. La red debe relacionar dos fenómenos (X e Y) mediante la presentación de un conjunto de ejemplos (x_1, y_1) , (x_2, y_2) ,..., (x_n, y_n) , de manera que el ajuste de los pesos se desarrolle evaluando el funcionamiento general de la red hasta lograr una salida deseada ante una configuración de patrones de entrada predeterminados. Se presenta a la red una entrada X y la red produce una salida. Si esta salida no coincide con la salida esperada, debe calcular un error de salida, y proceder a la modificación de los pesos utilizando alguna regla de aprendizaje con la finalidad de aproximar la salida obtenida a la salida deseada. Tras esta modificación se presenta el siguiente patrón de entrada y se procede de la misma manera. Cuando se termina con el último patrón, se empieza de nuevo, debido a que los pesos se han modificado y es preciso comprobar que la red responde adecuadamente. A cada uno de los pasos completos del juego de ensayo se le llama ciclo; dependiendo de las entradas y las salidas esperadas, serán precisos pocos o muchos ciclos para el aprendizaje. La fase de aprendizaje termina cuando los pesos se estabilizan o convergen en unos valores óptimos. En este caso la red consigue responder correctamente a todas las presentaciones de los patrones de

entrada. Aunque el ideal de aprendizaje es el 100% de aciertos, se considera que el aprendizaje concluye cuando se minimizan razonablemente los errores ante el conjunto de ejemplos presentados.

Por lo tanto, en el aprendizaje supervisado, el entrenamiento de la red consiste en una evaluación de la salida actual que la red emite ante un patrón de entrada determinado, y su comparación con la salida que la red debería presentar ante esta entrada. La diferencia entre la salida obtenida y la salida deseada se utiliza para calcular el ajuste que debe darse al interior de la red en cada uno de los pesos de conexiones, con la finalidad de obtener la salida más adecuada al patrón de entrada.

En conclusión, se considera que un proceso de aprendizaje supervisado en una red neuronal ha tenido éxito cuando el ajuste de pesos, realizado a partir de un conjunto de ejemplos, le permite un desempeño óptimo ante problemas análogos a los ejemplificados, aunque nunca se hayan introducido en el sistema con anterioridad. De ahí que una característica de las redes neuronales basadas en el aprendizaje supervisado sea su capacidad para generalizar los aprendizajes previamente logrados.

Por otro lado, los modelos de redes neuronales basados en aprendizaje no supervisado más representativos son las de Redes de Hopfield (Hopfield, 1982), Mapas auto-asociativos de Kohonen (Kohonen, 1982) y Mapas auto-asociativos bidimensionales de Kohonen (Kaski, 1997). En este tipo de aprendizaje se modifican los pesos sinápticos en función de una corrección de la salida de la red. Con este tipo de aprendizaje se busca que la red se autoorganice y encuentre por sí misma características, regularidades, correlaciones o categorías

en los datos de entrada. En el aprendizaje no supervisado es necesario presentar un mayor número de patrones de entrada y utilizar reglas de aprendizaje distintas a las que nos sirven para el caso del aprendizaje supervisado; además las arquitecturas de las redes suelen ser distintas (por ejemplo, muchas de ellas tienen dos capas). El cálculo que realiza la red entre los datos de entrada y los de salida se puede realizar de diversas maneras, desde las más simples basados en la distancia de Hamming⁶ hasta otros más complejos (Skapura, 1995; Maravall Gómez-Allende, 1994).

Los modelos de redes neuronales basados en aprendizaje por reforzamiento más representativos son "Linear-reward penalty" o LRP de Narendra y Tathacher en 1974, (Hilera y Martínez, 2000), "Associative Reward-Penalty" ARP (Barto y Anandan, 1985) y Adaptive Heuristic Critic, presentado por Barton, Sutton y Anderson en 1983 (Hilera y Martínez, 2000). Muchos de los algoritmos de aprendizaje supervisado y no supervisado en redes neuronales requieren de datos de entrenamiento precisos para modificar los pesos de la red. Sin embargo, en la vida real, es habitualmente difícil (y en muchos casos, imposible) obtener datos precisos para poder realizar un proceso de entrenamiento. Por ello existe un interés creciente por los algoritmos de aprendizaje basados en el reforzamiento. En cierto modo, el aprendizaje por reforzamiento es una variante del aprendizaje supervisado ya que también utiliza un supervisor que examina las salidas del sistema.

⁶ La distancia de Hamming (D_H) se define como el total de elementos distintos, en valor y posición, entre dos vectores. Así, el vector 1 = {1, 0, 1, 1, 0} se encontraría a una $D_H = 1$ del vector 2 = {1, 1, 1, 1, 0}.

Sin embargo, en el aprendizaje por reforzamiento no se dispone de salidas deseadas precisas, por lo que no es posible computar el error para cada una de las unidades de salida. El supervisor valora el comportamiento global de la red mediante un criterio y en función de dicho criterio modifica los pesos mediante un mecanismo de probabilidades. Para ilustrar la diferencia entre este tipo de aprendizaje y el supervisado se suele indicar que en el aprendizaje por reforzamiento el supervisor se comporta como un "crítico", el cual opina sobre la respuesta de la red, mientras que en el aprendizaje supervisado el supervisor se comporta como un "maestro", que indica a la red la respuesta concreta que debe generar (Hilera y Martínez, 2000). En el aprendizaje por reforzamiento los algoritmos son más complejos que en el supervisado y el tamaño de las muestras es superior.

Desde el punto de vista cognitivo y biológico, el aprendizaje por reforzamiento es más parecido al modo en el que se realiza el aprendizaje en organismos superiores, habiendo incluso autores como Cheng-Lian y Chin-Teng Lin (1996) que han inspirado sus algoritmos de aprendizaje por reforzamiento en modelos matemáticos del comportamiento que incluso han logrado que se emita respuesta antes de que se proporcione la señal de refuerzo.

4. MODELOS BASADOS EN REDES NEURONALES PARA LA SIMULACIÓN DE FENÓMENOS DE CONDICIONAMIENTO

Bajo este modelo de aprendizaje se encuentran los modelos específicos para la simulación de fenómenos de condicionamiento. Las redes neuronales pueden proporcionarnos elementos para conocer cuáles son los procesos neurales

subyacentes al condicionamiento (Moore, 1991). Aunque los modelos de aprendizaje específicamente dedicados para la simulación y estudio de fenómenos de condicionamiento tienen un objetivo común, existen diferencias teóricas importantes entre ellos, destacando principalmente la forma en la que conciben al reforzamiento. Existen modelos que asumen una diferencia teórica entre condicionamiento clásico y condicionamiento operante y con base en ello, se dedican a simular exclusivamente uno u otro tipo de aprendizaje. Pero por otro lado, nos encontramos con modelos que asumen que no existe distinción alguna entre los dos tipos de condicionamiento, como el Modelo DBP, que, como ya se ha mencionado, propone una síntesis teórica entre ambos tipos de condicionamiento.

De entre los modelos basados en condicionamiento clásico, uno de ellos se asienta en las observaciones de Sokolov (1960), para quien el cerebro construye un modelo neuronal de los eventos ambientales. Cuando hay concordancia entre los eventos externos y las predicciones generadas por el modelo, los animales responden sin cambiar su modelo interno del ambiente. Sin embargo, cuando los eventos externos no coinciden con el modelo interno previamente establecido, aparece una respuesta de orientación y el modelo se modifica (Schmajuk, 1997). A este tipo de modelo se le conoce como modelo de mapas cognitivos (Schmajuk y Moore, 1988). Posteriormente, Sutton y Barto (1981) presentaron una versión de tiempo real del modelo Rescorla-Wagner (1943), la cual es capaz de simular fenómenos de condicionamiento pavloviano como la adquisición, extinción, inhibición condicionada, bloqueo, ensombrecimiento, efectos de primacía y condicionamiento de segundo orden (Schmajuk, 1997).

Esta versión fue mejorada posteriormente por los mismos autores (Barto y Sutton, 1990) y por Klopf (1988), ampliando con ello la variedad de fenómenos a simular.

Otro tipo de modelos de redes neuronales son los *atencionales*, en los que se asume que los EC compiten por una capacidad limitada en la memoria a corto plazo de acuerdo a su saliencia y el valor de sus asociaciones con el EI (Mackintosh, 1975; Grossberg, 1975). De esta manera, los predictores más salientes se seleccionarán para asociarse con el EI o con otros EC. Los aspectos más relevantes de una red de este tipo son los siguientes (Schmajuk, 1997):

1. El EC activa una representación sensorial de la memoria de corto plazo (STM), X_{ij}
2. El EI activa neuronas de la representación del drive del EI, Y .
3. Las representaciones sensoriales compiten entre ellas por la activación de una STM de capacidad limitada, que se refleja en la memoria a largo plazo (LTM). Los estímulos con mayor X_{ij} cambian sus V_i^7 y Z_i^8 más rápidas que un estímulo con débil X_{ij} .
4. Las representaciones sensoriales X_{ij} se asocian con la salida de Y . La asociación LTM se implementa incrementando el peso sináptico V_i .
5. Después de que las representaciones sensoriales se asocian con Y , se convierte en un reforzador secundario para otros EC.

⁷ Asociaciones de representación sensorial X_{ij} con la representación del drive

⁸ Incentivo de la representación sensorial X_{ij}

6. Las representaciones sensoriales X_{ij} también pueden asociarse a una tasa diferente con Y . Esta segunda asociación LTM, interpretada como un incentivo, se implementa incrementando el pesos sináptico Z_{ij} .
7. Las asociaciones de incentivo median la mejora de las representaciones sensoriales X_{ij} .
8. La amplitud de la RC es proporcional a la suma de todas las representaciones sensoriales X_{ij} por sus asociaciones con V_i .

Por otro lado, el modelo Schmajuk-Law-Gray (SLG) ha sido propuesto para simular inhibición latente (el retardo en la adquisición de una RC como resultado de una preexposición al EC sólo). El modelo está basado en los modelos de mapa cognitivo y formaliza algunas de las ideas de Sokolov y de Gray (Schmajuk, Lam y Gray, 1996). Siempre que se detecta alguna novedad (es decir, cuando existe alguna inconsistencia entre lo predicho y los eventos ambientales actuales), se produce una respuesta de orientación, y el modelo interno se modifica. En cambio, cuando existe coincidencia entre lo observado y el estímulo predicho, el animal puede responder sin cambiar el modelo neuronal que ha construido del mundo. Investigación reciente (Burgos, 2003) ha mostrado que el modelo DBP es capaz de simular los aspectos básicos de la inhibición latente, sin necesidad de incluir conexiones inhibitorias. Aquí la suposición básica del modelo es que los pesos iniciales de ciertas conexiones (las que van de la capa de entrada a la primera capa oculta) son lo suficientemente altos (debido a aprendizaje sensorial previo)

como para que la presentación del EC sólo cause el decremento de los pesos de estas conexiones, lo cual a su vez redundaría en un retardo en la adquisición (ver más adelante descripción del modelo).

El modelo SGL asume que un EC activa las representaciones internas. El sistema atencional mejora las representaciones internas de los EC activos al mismo tiempo cuando la novedad total del ambiente es grande (incrementando la atención), y decreta las representaciones internas de aquellos EC activos al mismo tiempo cuando la novedad total es pequeña (decrementando la atención o quitando la atención por completo). La magnitud de las representaciones internas controla el almacenamiento de información al interior del modelo del ambiente (asociabilidad) y la recuperación de información del modelo (recuperabilidad). Por lo tanto, eventos con grandes representaciones internas muestran una capacidad incrementada de formar asociaciones nuevas con otros eventos ambientales, así como una eficacia aumentada para recuperar asociaciones viejas. Eventos con representaciones internas pequeñas, muestran una capacidad decreta para formar nuevas asociaciones con otros eventos ambientales, así como una eficacia decreta para recuperar viejas asociaciones.

Otro tipo de modelo de redes neuronales establece un modelo del mundo que predice qué eventos siguen a otros, y también especifica el tiempo en el que ocurrirán. Es decir, la red neuronal es capaz de aprender relaciones temporales entre eventos (Grossberg y Schmajuk, 1989). El modelo está formado por tres capas de elementos neuronales. La presentación del EC excita a la primera capa (que contiene muchos elementos, cada uno de los cuales reacciona en diferente

tiempo). La salida de cada elemento en la primera capa es una función sigmoideal que activa la segunda capa. Finalmente, la salida de estos elementos activa un elemento de memoria a largo plazo. La activación de cada uno de estos elementos se añade linealmente para determinar la magnitud de la RC.

Por otro lado, de entre los modelos basados en condicionamiento operante, cabe destacar el modelo de escape-evitación de Schmajuk (1994). Las redes neuronales de este tipo aprenden distintas respuestas ya que combinan el condicionamiento clásico con un mecanismo de "selección de respuesta". Los aspectos más importantes de este modelo son los siguientes:

1. La red incluye dos procesos: condicionamiento clásico y condicionamiento operante.
2. Las asociaciones clásicas cambian de acuerdo a la versión de tiempo real del modelo Rescorla-Wagner (1972).
3. El nodo M computa el desajuste entre la actual intensidad del EI y su predicción B ($US-B$).
4. Las asociaciones clásicas V_i incrementan cuando $(US-B)$ es mayor que 0.
5. El nodo I computa la diferencia $(B-US)$ usado por el bloque de condicionamiento operante
6. Las asociaciones operantes Z_{ik} incrementan cuando $(B-US)$ es mayor a 0.

7. La respuesta más fuertemente activada se selecciona y es ejecutada por el sistema.
8. La amplitud de la RC, interpretada como *miedo* del El aversivo, es proporcional a la predicción (US-B).
9. La fuerza de la salida está modulada por la amplitud de la RC clásica. Así, similares fuerzas de salida pueden obtenerse con múltiples combinaciones de asociaciones clásicas y operantes.

Otros modelos basados en condicionamiento operante son el Modelo Schmajuk y Blair (1993) sobre aprendizaje espacial y el Modelo Schmajuk y Thieme (1992) sobre aprendizaje en laberinto y mapas cognitivos.

5. MODELO DONAHOE-BURGOS-PALMER (DBP)

El modelo Donahoe-Burgos-Palmer (1993) es de carácter bioconductual y expresa de manera formal el principio unificado del reforzamiento (Donahoe, Crowley, Millard y Stickney, 1982), el cual reza así:

"whenever a behavioral discrepancy occurs, an environment-behavior relation is selected that consists – other things being equal – of all those stimuli occurring immediately before the discrepancy and all those responses occurring immediately before and at the same time as the elicited response" (Donahoe y Palmer, 1994, p. 49).

A diferencia del resto de los modelos de condicionamiento, y dada la importancia de la síntesis en la ciencia, este principio (el cual es estrictamente conductual), no hace distinción teórica alguna entre condicionamiento pavloviano y condicionamiento operante. Además, el principio ha sido complementado mediante consideraciones biológicas acerca de la estructura y funcionamiento del sistema nervioso, bajo la suposición de que lo biológico debe tomarse en cuenta para lograr un entendimiento más comprehensivo de la conducta. Por ello, parte importante de ese esfuerzo teórico ha sido implementar el principio unificado del reforzamiento en un modelo de redes neuronales adaptativas (Donahoe, Burgos y Palmer, 1993).

Una red neuronal del tipo DBP es un sistema digital que involucra ejecuciones de un programa previamente diseñado y escrito en un cierto lenguaje de programación, como BASIC, Pascal o C. Por supuesto, como cualquier otro modelo, los modelos de redes neuronales involucran una simplificación considerable, pero ése es precisamente el objetivo del trabajo de modelamiento, lograr situaciones lo suficientemente simples como para que sean metodológica y conceptualmente manejables, lo cual resulta indispensable para un tratamiento claro, preciso, y riguroso.

El modelo DBP está formado por dos submodelos, a saber: neurocomputacional y de redes. El primero describe cómo las activaciones y los pesos de las conexiones cambian con el tiempo, mientras que el último es una

clasificación de los elementos procesadores neuronales (NPE)⁹, al mismo tiempo que establece las reglas básicas de la arquitectura neuronal.

5.1. SUBMODELO NEUROCOMPUTACIONAL

La función de activación es similar a la originalmente propuesta por Fukushima (1975), en la que está involucrada una partición de las entradas presinápticas de un elemento NPE en excitatorias e inhibitorias, y separa también el cómputo de la red de la cantidad de excitación e inhibición que afecta a un NPE. Un NPE dado puede recibir o no entradas de ambos tipos, dependiendo de la arquitectura. Cuando así ocurre, su activación se determina por la cantidad de entrada excitatoria y por la cantidad de entrada inhibitoria de manera independiente y por separado. En este modelo, cada cantidad se usa como un argumento de la función logística.

El submodelo neurocomputacional es un modelo matemático de tiempo discreto que consiste en dos funciones: la función de activación y la función de aprendizaje (Burgos, 2000). La *función de activación* determina el estado de activación en un momento en el tiempo t (se trata de un modelo de tiempo discreto). La activación de un NPE es un número real entre 0 y 1 y puede interpretarse como la probabilidad de que ocurra un potencial de acción. La función de activación permite a un NPE tener una activación espontánea, es decir, una activación superior a 0 en ausencia de señales de entrada.

⁹ NPE proviene del inglés, *neural processing element*, y es la unidad de análisis funcional y estructural de una red neuronal.

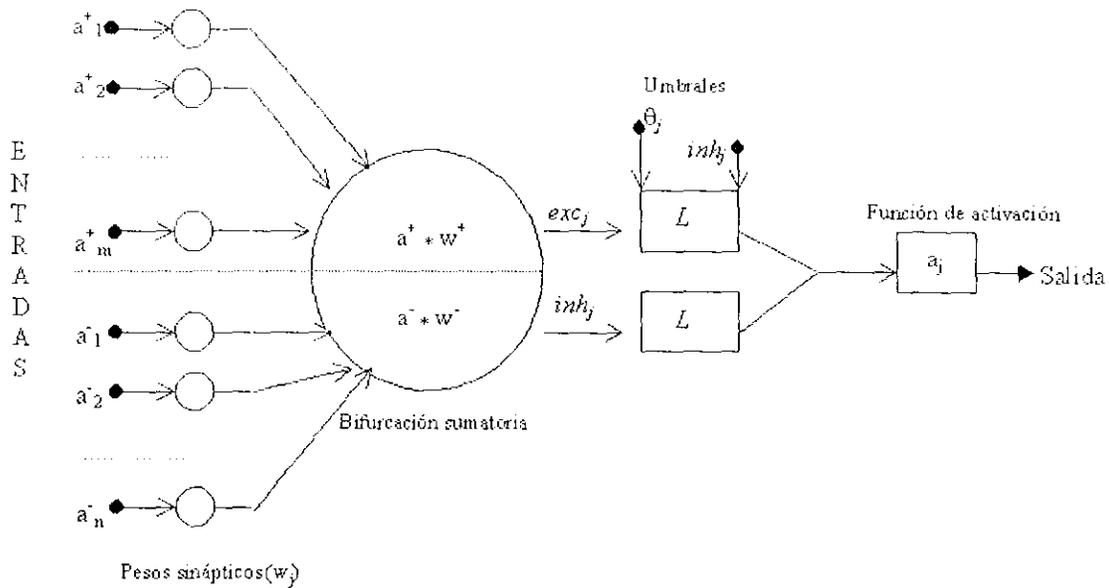


Figura 7. Elemento procesador neuronal (NPE) del modelo DBP

Según la Figura 7, los valores de entrada son el resultado de la sumatoria del producto interno del vector de entrada (señales de activación que recibe el NPE) y el vector de pesos (fuerza de cada conexión). Este cómputo viene representado por las siguientes ecuaciones (Donahoe, Burgos y Palmer, 1993):

$$n^+ = \sum a(e,t) \cdot w(e,j,t)$$

$$n^- = \sum a(i,t) \cdot w(i,j,t)$$

donde $a(e,t)$ denota la activación de la unidad excitatoria e en el momento t , $a(i,t)$ denota la activación de la unidad inhibitoria i en t , $w(e,j,t)$ denota el peso de la conexión de e a j (el NPE cuya activación se desea calcular) y $w(i,j,t)$ denota el peso de la conexión de i a j . En todo momento t , se calculan separadamente n^+ (la neta excitatoria) y n^- (la neta inhibitoria). Posteriormente, cada neta obtenida en cada momento t se pasa por una función logística L , que en el caso del

modelo DBP (como en la mayoría de los modelos de redes neuronales) se define como:

$$L(x)_t = \frac{1}{1 + e^{-x}}$$

donde $x = n^+$ o $x = n^-$. Esta función establece un suelo y un techo a la activación de un NPE.

La función de activación $a(j,t)$ de un NPE j en un momento t es una regla constituida por tres condiciones posibles mutuamente excluyentes (Donahoe, Burgos y Palmer, 1993):

- Si $L(n^+)_t \leq L(n^-)_t$, $a(j,t) = 0$
- Si $L(n^+)_t > L(n^-)_t$ y $L(n^+)_t \geq \theta$, $a(j,t) = (L(n^+)_t + \tau \cdot L(n^+)_t \cdot (1 - L(n^+)_t)) - L(n^-)_t$
- Si $L(n^+)_t > L(n^-)_t$ y $L(n^+)_t < \theta$, $a(j,t) = (a(j,t-1) - \kappa \cdot a(j,t-1)) - L(n^-)_t$

donde

j denota al NPE,
 t denota al momento temporal,
 L denota a la función logística,
 n^+ denota la cantidad de excitación¹⁰,
 n^- denota la cantidad de inhibición¹¹,
 τ denota la sumación temporal¹²,
 θ denota el umbral excitatorio¹³,
 κ denota la tasa de decaimiento¹⁴.

¹⁰ Producto interno de los pesos y activaciones de las entradas excitatorias.

¹¹ Producto interno de los pesos y activaciones de las entradas inhibitorias.

¹² Parámetro libre que determina la cantidad de excitación del momento $t-1$ que se acarrea al momento t . El valor por defecto es 0.1, aunque su valor oscila entre 0 y 1.

¹³ Parámetro libre que es un número aleatorio entre 0 y 1 generado de acuerdo a una distribución Gaussiana con una media de 0.2 y una desviación estándar de 0.15.

¹⁴ Parámetro libre que determina la proporción de decaimiento de la activación de un NPE de $t-1$ a t . Su valor por defecto es de 0.1.

Por otro lado, la *función de aprendizaje* es una ecuación que especifica cambios en los pesos de las conexiones en momentos sucesivos en el tiempo. Un peso de conexión es una magnitud que representa la fuerza de una conexión entre dos NPE. Esta magnitud es también un número real entre 0 y 1, y puede ser interpretado neurológicamente como la proporción de receptores de neurotransmisores postsinápticos que son controlados por un proceso presináptico dado. Estos cambios en los pesos no dependen únicamente de las activaciones presinápticas y de la activación del NPE, sino también de una señal externa al NPE que proviene de un tipo especial de NPE cuya activación representa el funcionamiento de neuronas dopaminérgicas, que se ha visto que juegan un papel importante en el condicionamiento (Burgos, 1999). Dicha señal se calcula como la discrepancia en la activación de ese tipo de NPE entre el momento temporal presente y el momento inmediatamente anterior.

La regla de aprendizaje para conexiones excitatorias posee dos modalidades de cambio de pesos excitatorios (Donahoe, Burgos y Palmer, 1993):

- *Modalidad de fortalecimiento o incremental (adquisición)*

$$\text{Si } d(t) \geq 0.001, \Delta w(e,j,t) = \alpha(j) \cdot a(j,t) \cdot d(t) \cdot p(e,t) \cdot r(j,t)$$

- *Modalidad de debilitamiento o decremental (extinción)*

$$\text{Si } d(t) < 0.001, \Delta w(e,j,t) = -\beta(j) \cdot w(e,j,t-1) \cdot a(e,t) \cdot a(j,t)$$

donde

e denota al elemento presináptico (que es excitatorio),
 j denota al NPE postsináptico,
 t denota el momento temporal,
 α denota la tasa de adquisición¹⁵,

d denota la señal de discrepancia (ver abajo),
 $p(e,t)$ denota la proporción de contribución de $a(e,t) \cdot w(e,j,t-1)$ a n^+ ¹⁶,
 $r(j,t)$ denota la cantidad de peso libre disponible en j ,
 β denota la tasa de extinción¹⁷.

Dependiendo de si j es un elemento sensorial o motor (ver más adelante), el valor de $d(t)$ se calcula de la siguiente manera (Donahoe, Burgos y Palmer, 1993):

- Si j es sensorial, $d(t) = d_S(t) = \phi(t) + v(t) \cdot (1 - v(t))$
- Si j es motor, $d(t) = d_M(t) = v(t)$

donde

$$\phi(t) = |h(t) - h(t-1)|$$

$$v_t = v(t) - v(t-1)$$

$$p(e,t) = \frac{a(e,t) \cdot w(e,j,t-1)}{n^+},$$

$$r(j,t) = 1 - \sum w(e,j,t).$$

donde h denota la activación de una unidad cal y v la activación de una unidad vta (ver más adelante).

Sólo una modalidad de la regla de aprendizaje estará en funcionamiento en un momento determinado, según sea el valor de la señal de discrepancia en ese momento. Si el valor es mayor o igual que 0.001, entonces la regla de aprendizaje funciona en la modalidad incremental. De lo contrario, la regla

¹⁵ Parámetro libre que modula la proporción de incremento en el peso cuando la regla de aprendizaje actúa en el modo incremental. Su valor por defecto es 0.5, aunque puede tomar valores entre 0 y 1.

¹⁶ Esta magnitud introduce un tipo de competición en el que los elementos presinápticos (ya sean excitatorios o inhibitorios) que son más fuertemente activados y que están más fuertemente conectados consiguen más cantidad disponible de peso (ver más abajo su cálculo).

¹⁷ Parámetro libre que modula (en combinación con otras magnitudes) la proporción de decremento de peso cuando la regla de aprendizaje funciona en el modo decremental. Su valor por defecto es de 0.10, aunque puede tomar valores entre 0 y 1.

funciona en la modalidad decremental (ver Burgos, 2003, para una explicación de porqué se usó 0.001 como umbral). Cuando la regla de aprendizaje funciona en modalidad incremental, el valor de la discrepancia modula el incremento en los pesos sinápticos. Se trata de una señal difusa, es decir, el cambio en todos los pesos sinápticos excitatorios en un momento dado están modulados exactamente por el mismo valor de la discrepancia en ese momento (Burgos, 1999).

La regla de aprendizaje para conexiones inhibitorias sólo posee la modalidad incremental, por lo cual, una vez fortalecidas, no pueden ser debilitadas. Ello es congruente con la evidencia de que el inhibidor condicionado no se extingue (Burgos, 1999). Sin embargo, las redes utilizadas en el presente trabajo no incluyeron unidades inhibitorias.

5.2. SUBMODELO DE REDES

Este submodelo especifica una clasificación del tipo de elementos que pueden constituir una red neuronal, y determinadas reglas que indican cómo deben estar conectados. La clasificación propuesta incluye tres tipos de NPEs:

- Unidades de Entrada
 - Sensoriales primarias (e.g., detectores de luces, sonidos, etc.)
 - Reforzador o S^* (e.g., detector de comida, agua, etc.)

- Unidades Ocultas
 - Corticales
 - Sensorial-asociativas (sa)
 - Motor-asociativas (ma)
 - Subcorticales
 - caI (fuente de d_s)
 - vta (fuente de d_M)
- Unidades de Salida
 - Operante (R)
 - Respondiente (CR/UR)

En general, la activación de una unidad de entrada representa la ocurrencia de un estímulo exteroceptivo, ya sea de una cierta modalidad sensorial (e.g., una luz o un tono) o de un cierto canal sensorial dentro de una misma modalidad (e.g., luz roja o luz verde). Por su parte, que la activación de una unidad de salida representa la ocurrencia de una respuesta¹⁸. El elemento de entrada puede representar estímulos de modalidad sensorial en sí mismos o canales sensoriales dentro de una modalidad dada. Un elemento de salida puede representar un grupo de neuronas del tracto corticoespinal en la corteza motora, que controlan algunas respuestas topográficas, o un componente de dicho grupo.

¹⁸ Estrictamente, las activaciones son continuas, mientras que una respuesta es un evento discreto. Por ello, para poder hablar de respuestas en el presente modelo se requiere especificar una activación de salida que sirva de criterio de respuesta. En la investigación basada en este modelo, la activación criterio más comúnmente utilizada ha sido 0.5 (e.g., Burgos y Donahoe, 2000).

5.2.1. UNIDADES DE ENTRADA

Las activaciones de las unidades de entrada representan la ocurrencia de eventos ambientales externos a la red que la afectan de una u otra forma. Algunas de tales unidades son sensorial-primarias, cuya activación simula la ocurrencia de estímulos sensoriales exteroceptivos tales como luces y tonos, usualmente utilizados como ECs en condicionamiento pavloviano. Otro tipo de unidad de entrada es la unidad de reforzador (S^*), cuya activación simula la ocurrencia de un reforzador primario (e.g., comida o agua), usualmente utilizados como EIs en condicionamiento pavloviano. Estrictamente hablando, los elementos de entrada no son NPEs, ya que sus estados no se computan mediante la regla de activación descrita anteriormente, sino que se asignan manualmente, según algún procedimiento de entrenamiento preestablecido. Los estados de activación de los elementos de entrada se representan por un número real entre 0 y 1, donde diferentes magnitudes simulan diferentes intensidades de estímulo.

5.2.2. UNIDADES OCULTAS

Los elementos ocultos se clasifican en corticales y subcorticales, en un esfuerzo por capturar la organización anatómica gruesa de los cerebros de los mamíferos. Los elementos ocultos corticales se clasifican en sensorial-asociativos (sa) y motor-asociativos (ma), mientras que los elementos ocultos subcorticales se clasifican en $ca1$ (su nombre proviene de la región CA1 del hipocampo, ya que su interpretación neurobiológica es de sinapsis modulatorias axo-axónicas desde el hipocampo hacia la corteza sensorial asociativa) y vta (su nombre proviene del área tegmento-ventral, y su interpretación neurobiológica es de sinapsis

modulatorias axo-axónicas de las neuronas dopaminérgicas a la corteza de asociación motora).

La activación de las unidades subcorticales es la fuente de las señales de reforzamiento. Específicamente, la activación de vta es la fuente de la señal de discrepancia que modula los cambios en los pesos de las conexiones hacia NPE ma , de salida y vta, es decir, $d_M(t)$. La activación de ca1 es la fuente de la señal que hace lo mismo para las conexiones de las entradas a las unidades sa y de éstas a ca1 (o a otras unidades sa). A esta señal la hemos llamado "discrepancia sensorial" o $d_S(t)$, y es una amplificación de $d_M(t)$. La interpretación neuronal de estas fuentes de discrepancia se describe en mayor detalle en Donahoe y Palmer (1994).

5.2.3. UNIDADES DE SALIDA

Los elementos de salida se dividen en operantes (R) y respondientes (CR/UR). La única diferencia es que los NPE respondientes pueden ser directamente activados por S^* , mientras que los NPE operantes no. De esta manera, la distinción entre respuestas operantes y respondientes en el presente modelo se muestra como una distinción anatómica que conlleva una distinción funcional.

En cuanto a la conectividad, el presente modelo impone restricciones muy generales y flexibles. La mayoría de las redes que se usan en las simulaciones digitales basadas en el modelo DPB comparten una característica básica (también encontrada en otros modelos), llamada conectividad anterógrada o "hacia adelante" ("feedforward", en inglés). En este tipo de conectividad, los NPE

se organizan en capas y se conectan de una capa a la siguiente. Las conexiones anterógradas son unidireccionales, lo cual significa que una señal se propaga de un elemento al otro, pero no viceversa.

Tal y como se muestra en la Figura 8, una red neuronal mínima en este modelo consiste de una capa de entrada, dos capas ocultas (una *sa* y una *ma*), una capa de salida, y dos elementos subcorticales (uno *cal* y uno *vta*).

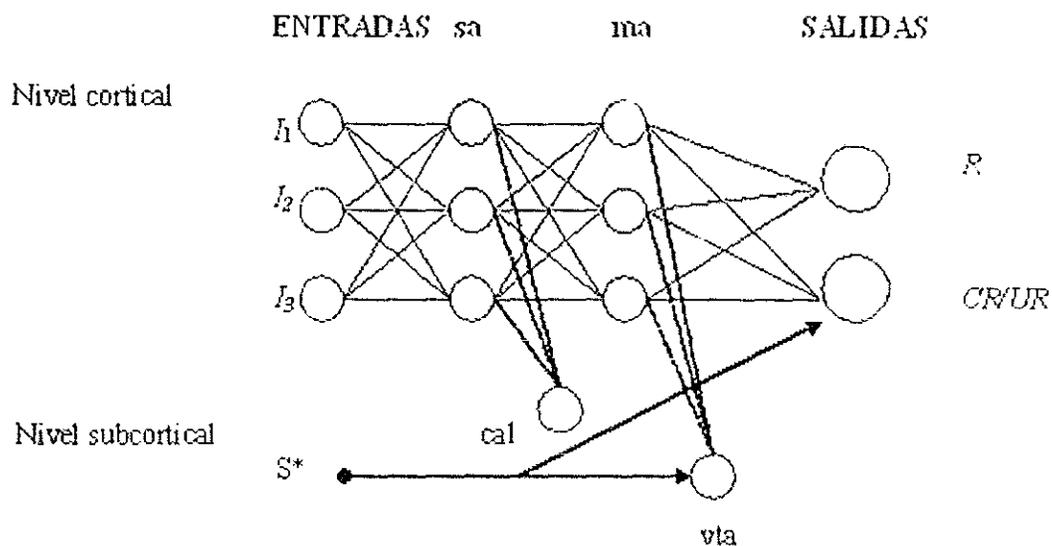


Figura 8. Ejemplo de una red neuronal del tipo DBP.

El funcionamiento básico de una red neuronal de este tipo es el siguiente. La estimulación ambiental viene representada por las activaciones de las unidades de entrada. Dichas activaciones, a su vez, sirven de señales de entrada a los NPE que constituyen la primera capa oculta de izquierda a derecha ('*sa*' en la figura), y así sucesivamente, hasta afectar a los NPE de salida, cuya activación representa el responder del sistema. Se distingue entre dos tipos de NPE de salida, a saber, R y CR/UR . Como se dijo antes, la única diferencia es que CR/UR puede

ser incondicional y máximamente activado por la unidad S^* , en virtud de una conexión no plástica y máximamente fuerte que va de S^* a CR/UR (flechas en la figura). Tal activación representa un *reflejo incondicionado* en el modelo DBP, donde la activación de S^* es un EI (evocador) y la activación de CR/UR es una respuesta incondicionada (RI).

Además, CR/UR puede también ser activado por los NPE que constituyen la última capa oculta (' ma ' en la Figura 8). Tal activación (así como la del resto de los NPE que constituyen la red), sin embargo, depende críticamente de cambios en los pesos de las conexiones, los cuales se rigen por la regla de aprendizaje, y describen, tal y como el nombre lo indica, la forma en la cual el responder de una red neuronal se adapta a su medio ambiente.

Respecto a la unidad de salida R , adquiere su sentido más importante en simulaciones de condicionamiento operante. Sin embargo, dado que el presente trabajo se concentra sobre condicionamiento Pavloviano, las redes utilizadas no incluyeron dicha unidad.

6. SIMULACIÓN 1: DEPENDENCIA CONTEXTUAL

Para la primera simulación se utilizaron ocho redes, distribuidas en dos condiciones (cuatro redes por condición): C1 y C2. Tal y como se muestra en la Figura 9, las ocho redes tenían conectividad anterógrada total y estaban compuestas por las siguientes unidades:

- Cuatro unidades de entrada: una entrada para el Contexto A (I_1), una entrada para el Contexto B (I_2), una entrada para el EC (I_3), y una entrada para el EI (I_4).
- Una unidad de salida CR/UR .
- Una única unidad $ca1$ y una unidad vta .
- Una capa sa con tres unidades y una capa ma también con tres unidades (ver Figura 9).

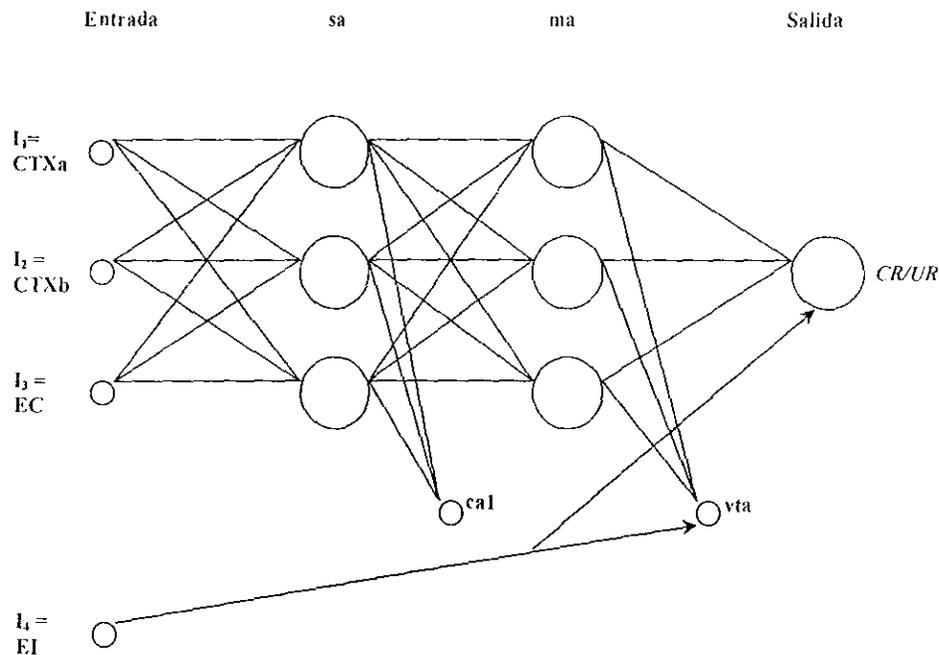


Figura 9. Arquitectura de las redes empleadas en la Simulación 1.

Todos los pesos fueron inicializados en 0.01, lo cual simula un organismo experimentalmente ingenuo. A medida que se realizaba el entrenamiento, los pesos fueron modificados según la función de aprendizaje del modelo DBP, excepto en los casos de las conexiones entre la unidad receptora del EI (I_4) y las unidades vta y CR/UR . En ambos casos, los pesos de conexión fueron fijos y tenían

un valor de 1.0. Los parámetros libres para la función de activación fueron los siguientes: $\tau = 0.1$, $\kappa = 0.2$, $\sigma = 0.1$. Los parámetros libres para la función de aprendizaje fueron: $\alpha = 0.5$, $\beta = 0.05$.

En todas las simulaciones se empleó una computadora personal con las siguientes características:

- Procesador Pentium IV
- Velocidad de 3,01 GHz
- 512 MB de memoria RAM
- Disco duro de 112 GB
- Unidad de lectura-escritura de CD-ROM y DVD
- Sistema operativo Microsoft Windows XP Professional Edition
- Software: simulador del modelo DBP, "Selnet", creado con Borland Delphi versión 6.0 por José E. Burgos Triano.

Cada condición consistió de dos fases: una en la que se entrenó a cada red a responder ante un EC en un determinado contexto (Contexto A para C1 y Contexto B para C2), y otra fase en la que se entrenó a la red a que respondiera ante ese mismo estímulo de la primera fase pero en otro contexto diferente al contexto de entrenamiento (Contexto B para C1 y Contexto A para C2). C2, entonces, fue el contrabalanceo de C1.

Para la Fase 1 de ambas condiciones se empleó un procedimiento de condicionamiento pavloviano anterógrado demorado, en el cual las redes recibieron 150 ciclos de 15 momentos temporales cada uno. El EC se presentó en los momentos temporales 10 a 15, ambos inclusive, y fue definido como una activación de I_3 con un nivel de 1.0. El EI se definió como la activación de I_4 en el momento 15 con un nivel de 1.0. El Contexto A fue definido como la activación de I_1 con un nivel de 0.5 en todos los momentos en la C1, siendo de 0.0 en la C2. El Contexto B fue definido como la activación de I_2 con un nivel de 0.5 en todos los momentos en la C2, siendo de 0.0 en la C1. Estas dos últimas activaciones pretenden simular el carácter tónico de la estimulación contextual. La activación menor de las señales tónicas se basa sobre la suposición de que son menos salientes que las señales fásicas (Rescorla y Wagner, 1972). Para la Fase 2 se desactivó la función de aprendizaje con objeto de registrar activaciones puras, sin aprendizaje. En cada ensayo se registró el nivel de activación de CR/UR en el momento temporal 14 (el momento justo antes de la presentación del EI). El diseño se muestra en la Tabla 1.

	Fase 1	Fase 2
C1	EC-EI en Contexto A	Prueba de EC en Contexto B
C2	EC-EI en Contexto B	Prueba de EC en Contexto A

Tabla 1. Diseño de la Simulación 1

En la Figura 10 se muestran los valores de activación de CR/UR en $t = 14$, en cada condición y fase de la simulación, para una red elegida al azar de cada condición (ver Anexo para los resultados de las otras redes).

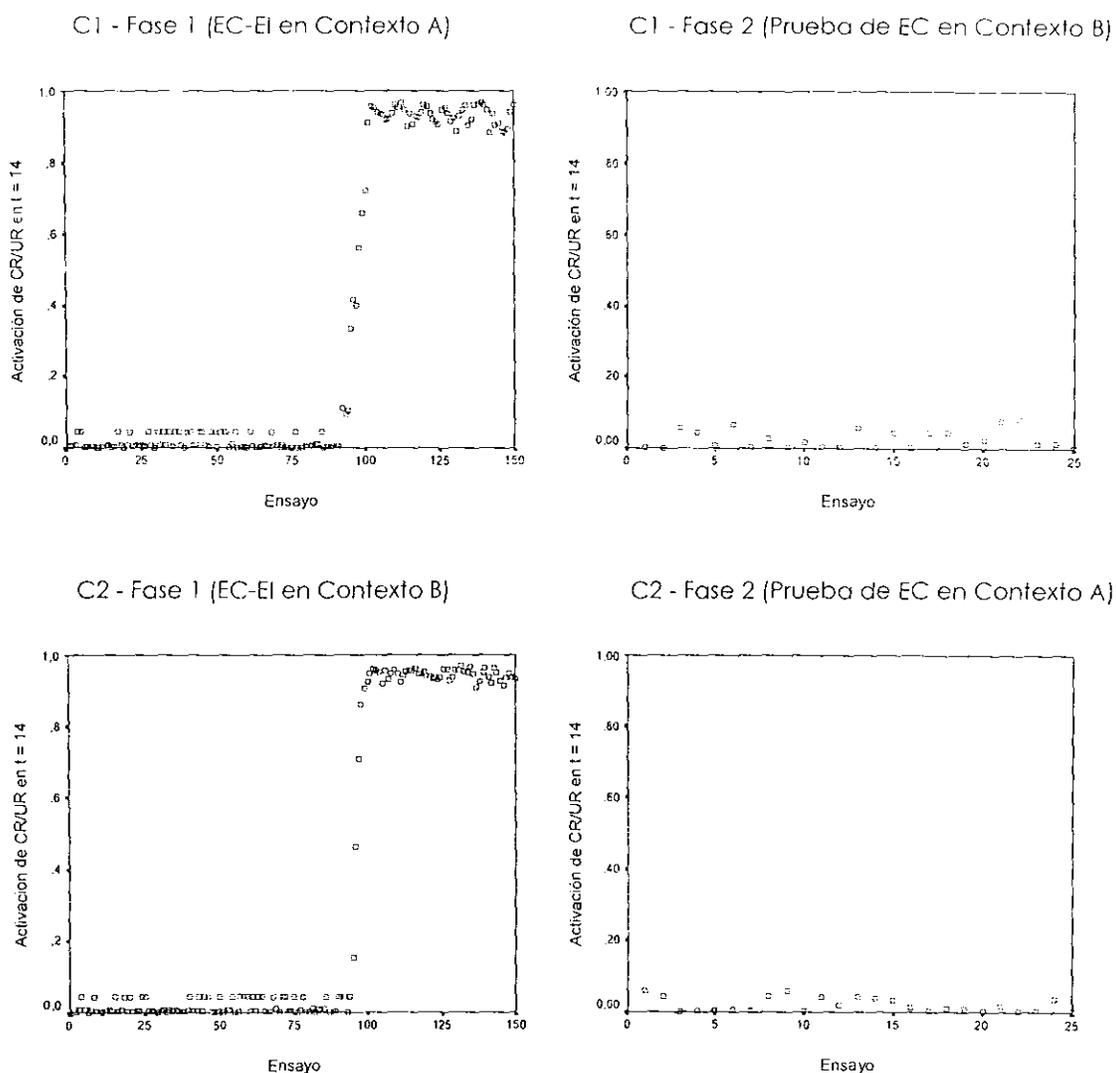


Figura 10. Valor de activación de CR/UR en $t = 14$, en todas y cada una de las condiciones de la simulación, para una red elegida al azar de cada condición.

El efecto de dependencia contextual del aprendizaje se observa en la comparación entre los paneles izquierdos (Fase 1) y los paneles derechos (Fase 2) de la Figura 10. En los paneles izquierdos se aprecia que, aproximadamente, a partir del ensayo 100 de entrenamiento, el nivel de activación del elemento CR/UR se mantiene con un valor alto (por encima de 0.80), manteniéndose relativamente estable hasta el final del entrenamiento. En los paneles derechos se aprecia que la respuesta de la red ante un contexto distinto al contexto de

entrenamiento produce una disminución considerable de la activación del elemento *CR/UR*, no llegando a superar valores de 0.05.

Los resultados muestran que el modelo DBP es capaz de simular la dependencia contextual del condicionamiento pavloviano. Bajo este modelo, el resultado se explica de la siguiente manera. El apareamiento del EC y el EI en el contexto de entrenamiento favoreció el incremento de los pesos de las conexiones provenientes tanto de la unidad del EC (I_3 en ambas condiciones) como de la unidad contextual de entrenamiento (I_1 para C1, I_2 para C2). La activación de *CR/UR*, entonces, resultó de la presencia concurrente de ambas señales (la fásica del EC y la tónica del contexto de entrenamiento) en el momento 14 de cada ciclo. Puesto que la unidad contextual de prueba (I_2 para el C1, I_1 para C2) nunca fue activada durante el entrenamiento, los pesos correspondientes se mantuvieron en su nivel inicial de 0.01. Al cambiarse el contexto, el bajo valor de estos pesos conllevó una activación más débil de *CR/UR* por parte de la unidad contextual. El efecto neto de ello fue una activación de salida sustancialmente menor en las fases de prueba.

7. SIMULACIÓN 2: INTERFERENCIA CONTEXTUAL

Para llevar a cabo la segunda simulación se contó con ocho redes neuronales, estructuralmente idénticas a las empleadas en la Simulación 1, divididas en cuatro redes por cada condición: Condición Experimental (CE) y Condición Control (CC). La CE estaba compuesta por dos fases experimentales: en una primera fase se entrenó a las redes a un procedimiento de EI sólo (ausencia de EC) en un determinado contexto (Contexto A), y en la segunda fase se entrenó a

las mismas redes a un entrenamiento de condicionamiento clásico anterógrado demorado, metodológicamente idéntica a la C1 - Fase 1, de la Simulación 1. En ambas fases, las redes recibieron 150 ciclos de 15 momentos temporales cada uno. Con el objetivo de apreciar la interferencia contextual producida por el preentrenamiento de señales contextuales, se incluyó una CC con la que se realizarían las comparaciones respecto a la CE; dicha CC constaba únicamente de una fase, que es la de entrenamiento de condicionamiento clásico anterógrado demorado. Para efectos prácticos, no se consideró oportuno realizar un contrabalanceo en esta simulación, puesto que en la Simulación 1 ya se constató que el Modelo DBP es capaz de simular el fenómeno particular de condicionamiento contextual tanto en un contexto de entrenamiento como en otro.

Para la primera fase de la CE se empleó un procedimiento de EI sólo, compuesto por 150 ciclos de 15 momentos temporales cada uno, donde el EI se definió como la activación de I_4 en los momentos 5, 10 y 15 con un nivel de 1.0. Al tratarse de un procedimiento de sólo EI, el valor de activación del elemento I_3 (que representa al EC) fue de 0.0. El Contexto A fue definido como la activación de I_1 con un nivel de 0.5 en todos los momentos. Esta última activación pretende simular el carácter tónico de la estimulación contextual. Dado que única y exclusivamente se realizó el entrenamiento en el Contexto A, el valor de activación del elemento I_2 (Contexto B) fue de 0.0 en todos y cada uno de los momentos temporales, y en todas y cada una de las condiciones y fases. En cada ensayo se registró el nivel de activación de CR/UR en el momento temporal 14 (el momento justo antes de la presentación del EI).

Para la segunda fase de la CE se empleó un procedimiento de condicionamiento pavloviano anterógrado demorado, en el cual cada red recibió 150 ciclos de 15 momentos temporales cada uno. El EC se presentó en los momentos temporales 10 a 15, ambos inclusive y fue definido como una activación de I_3 con un nivel de 1.0. El EI se definió como la activación de I_4 en el momento 15 con un nivel de 1.0. El Contexto A fue definido como la activación de I_1 con un nivel de 0.5 en todos los momentos. Esta segunda fase de la CE fue idéntica, metodológicamente hablando, a la fase única de la CC. En cada ensayo se registró el nivel de activación de CR/UR en $t = 14$ (el momento justo antes de la presentación del EI). El diseño experimental se muestra en la Tabla 2.

	Fase 1	Fase 2
CE	El sólo en Contexto A	EC- EI en Contexto A
CC	EC-EI en Contexto A	

Tabla 2. Diseño de la Simulación 2.

En la Figura 11 se muestran los valores de activación de CR/UR en $t = 14$, en cada una de las condiciones del diseño para una red elegida al azar de cada condición (ver Anexo para los resultados de las otras redes).

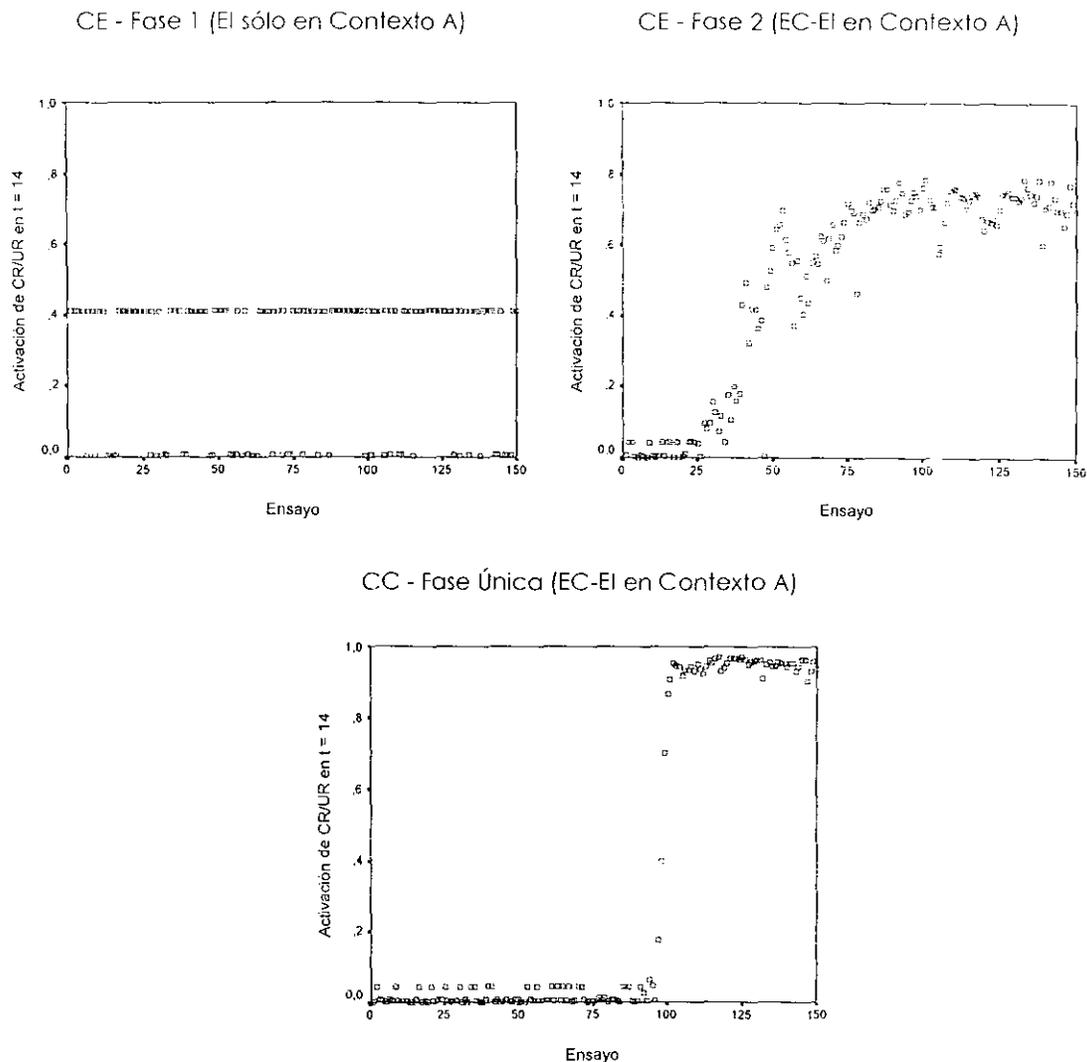


Figura 11. Valor de activación de CR/UR en $t = 14$, en todas y cada una de las condiciones de la simulación, para una red elegida al azar de cada condición

El efecto de interferencia se observa en la comparación entre el panel superior derecho (CE - Fase 2) y el panel inferior (CC - Fase Única) de la Figura 11. En el panel superior izquierdo (CE - Fase 1) se aprecia que la activación condicionada de CR/UR tiende a mantenerse en niveles cercanos a 0.0 (las activaciones en 0.4 son niveles decaídos de la RI debido a la presencia del EI). En la Fase 2 de CE se aprecia que aunque los niveles asintóticos de dicha activación son cercanos a 0.80, son visiblemente menores que los observados en la CC

(aunque esta red alcanzó su ejecución asintótica en menos ensayos que en la CE)

Estos resultados muestran que el modelo DBP es capaz de simular la interferencia contextual del condicionamiento pavloviano. Bajo el modelo, el efecto se explica de la siguiente manera. En el caso de CE - Fase 1, debido a la activación de I_4 (EI) en el contexto de la activación de I_1 (Contexto A), los pesos de las conexiones de I_1 hacia las unidades sa se incrementaron sustancialmente. Dado el carácter competitivo de la función de aprendizaje, y en el caso de la CE, Fase 2, este incremento impidió que los pesos de las conexiones de I_3 (EC) se incrementaran lo suficiente como para activar CR/UR con niveles tan altos como los observados en CC.

8. SIMULACIÓN 3: FACILITACIÓN CONTEXTUAL

Para esta simulación se contó con ocho redes neuronales, estructuralmente idénticas a las empleadas en las dos simulaciones anteriores, divididas en cuatro redes por condición. La Condición Experimental (CE) consistió de tres fases. En la Fase 1, las redes fueron entrenadas en un procedimiento anterógrado demorado en el Contexto A, donde cada red recibió 150 ciclos de 15 momentos temporales cada uno. El EC se presentó en los momentos temporales 10 a 15, ambos inclusive, y fue definido como una activación de I_3 con un nivel máximo de 1.0. El EI se definió como la activación de I_4 en el momento 15 con un nivel de 1.0. El Contexto A fue definido como la activación de I_1 con un nivel de 0.5 en todos los momentos (tal activación continua pretende simular el carácter tónico de la estimulación contextual.). En la Fase 2, las redes fueron expuestas a presentaciones del EI sólo (sin

el EC) en el Contexto B. Ello se simuló en forma de 150 ciclos de 15 momentos temporales cada uno, donde el EI se definió como la activación de I_4 en los momentos 5, 10 y 15 con un nivel de 1.0, y el Contexto B fue definido como la activación de I_2 con un nivel de 0.5 en todos los momentos. La Fase 3 fue una fase de prueba con el EC sólo en el Contexto B. La Condición Control (CC) consistió de una fase única de prueba del EC sólo en el Contexto B. Para las fases de prueba se desactivó la función de aprendizaje con objeto de registrar activaciones puras, sin aprendizaje. El diseño se muestra en la Tabla 3.

	Fase 1	Fase 2	Fase 3
CE	EC-EI en Contexto A	EI sólo en Contexto B	Prueba de EC en Contexto B
CC	Prueba de EC en Contexto B		

Tabla 3. Diseño de la Simulación 3.

En la Figura 12 se muestran los valores de activación de CR/UR en $t = 14$, en cada una de las condiciones del diseño, para una red elegida al azar de cada condición (ver Anexo para los resultados de las otras redes).

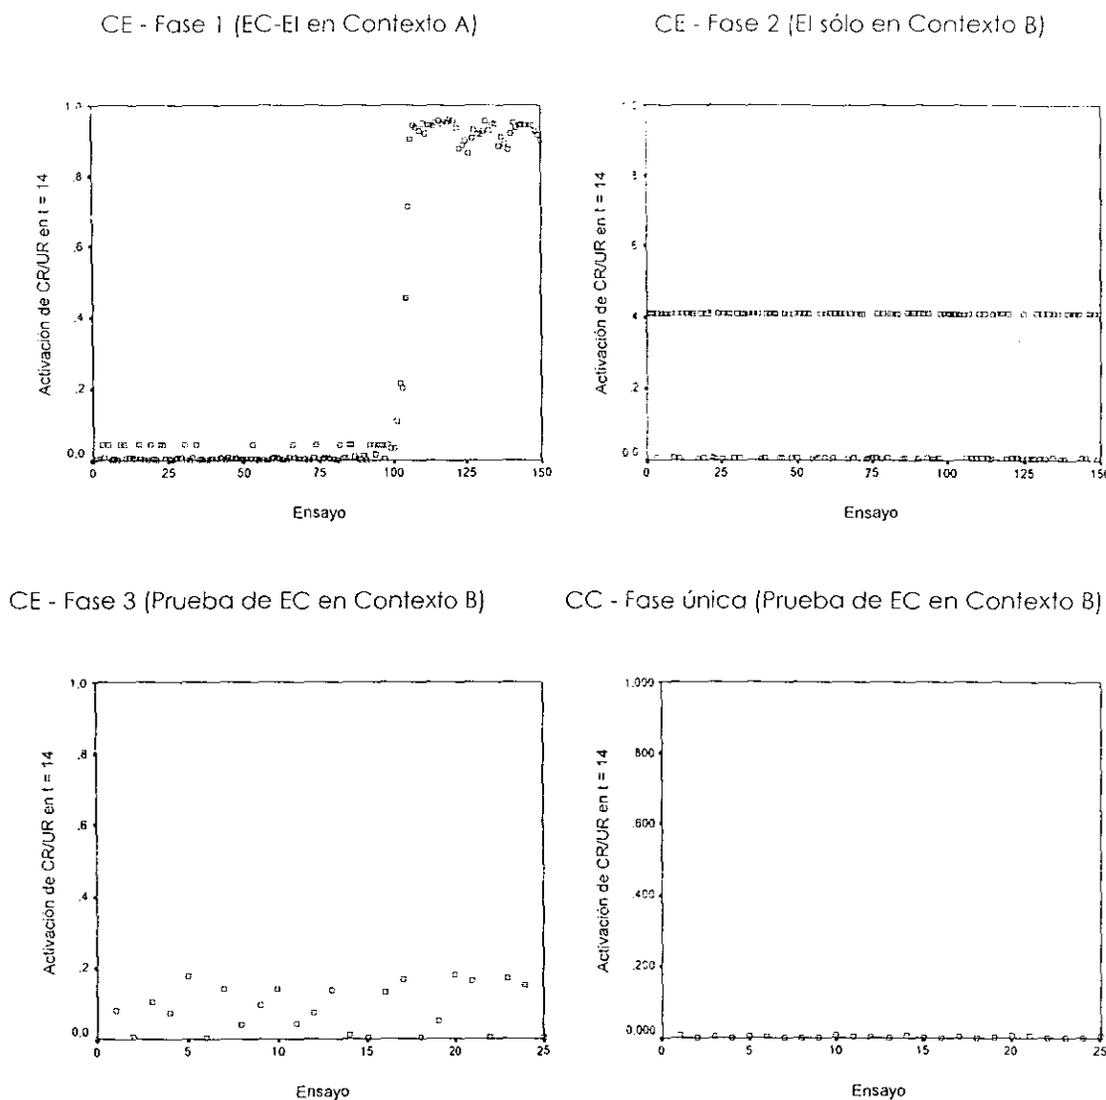


Figura 12. Valor de activación de CR/UR en $t = 14$, en todas y cada una de las condiciones de la simulación, para una red elegida al azar de cada condición

El efecto de facilitación se observa en la comparación entre los paneles inferiores izquierdo (CE - Fase 3) y derecho (CC - Fase Única) de la Figura 12. En el panel superior izquierdo (CE - Fase 1) se aprecia que, aproximadamente a partir del ensayo 100 de entrenamiento, los niveles de activación del elemento CR/UR se mantienen con un valor sustancialmente alto (por encima de 0.9), manteniéndose relativamente estables hasta el final del entrenamiento. El panel

superior derecho (CE - Fase 2) muestra que la activación condicionada de *CR/UR* tiende a mantenerse en niveles cercanos a 0.0 (las activaciones en 0.4 son niveles decaídos de la RI debidos a la presencia del EI). En el panel inferior izquierdo (CE - Fase 3) se observa que los niveles de activación de *CR/UR* se mantienen a lo largo de los 150 ensayos con un valor cercano a 0.2 que, en comparación con el panel inferior derecho (CC - Fase Única), es visiblemente superior a la activación del elemento *CR/UR* en la CC.

Estos resultados muestran que el modelo DBP es capaz de simular el fenómeno de la facilitación contextual del aprendizaje. Bajo este modelo, el resultado se explica de la siguiente manera. En CE - Fase 1, el apareamiento del EC (activación de I_3) y el EI (activación de I_4) en el Contexto A (activación de I_1) favoreció el incremento de los pesos de las conexiones provenientes I_1 e I_3 , lo cual conllevó un incremento en la activación de *CR/UR* a niveles asintóticos cercanos al nivel máximo posible (1.0). Esta activación resultó de la presencia concurrente de ambas señales (la fásica del EC y la tónica del contexto de preentrenamiento) en el momento 14 de cada ciclo. Por otro lado, en CE - Fase 2, la presentación del EI sólo en el Contexto B (activación de I_2) llevó a un incremento de los pesos de las conexiones provenientes de I_2 , aunque no fue suficiente como para producir una activación condicionada sustancial de *CR/UR* (las activaciones en 0.4 son niveles decaídos de la RI debidos a la presencia del EI). Sin embargo, el efecto facilitador de tal incremento se observa en CE - Fase 3, donde la presentación concurrente del Contexto B y el EC (previamente entrenado en otro contexto) redundó en una activación visiblemente más sustancial de *CR/UR*, en comparación con CC.

9. DISCUSIÓN GENERAL

En este trabajo se ha explorado la plausibilidad conductiva del modelo de redes neuronales artificiales de Donahoe, Burgos y Palmer (1993), respecto a su capacidad para simular tres fenómenos básicos de condicionamiento contextual, a saber: dependencia, interferencia y facilitación contextual, quedando comprobada dicha plausibilidad a lo largo de las tres simulaciones realizadas. No obstante, deben mencionarse algunas dificultades. En primer lugar, el modelo no simula un nivel sustancial de activación condicionada evocada por el contexto (ver paneles superior izquierdo de la Figura 11 y superior derecho de la Figura 12). Tal y como se explicó en las simulaciones, el nivel medio bajo (0.4) de activación de *CR/UR* por parte del contexto representa un decaimiento de la *RI* debido a la presencia del *EI*. Sin embargo, a pesar del bajo nivel de activación condicionada de *CR/UR* producida por el contexto, el condicionamiento contextual causó cambios en los pesos de las conexiones, cambios que se observaron en otras fases de las simulaciones.

En segundo lugar, tal y como lo muestra la Simulación 2, la interferencia contextual fue simulada en forma de un decremento en la asíntota del responder, no en la velocidad de adquisición de la *RC*. Tal y como lo muestra el panel superior derecho de la Figura 11, tal interferencia ocurrió luego de una adquisición más rápida de la *RC* en la condición experimental. Este resultado difiere de los predichos por modelos asociacionistas, como el de Gibbon y Balsam (1981), donde la interferencia se da a nivel de la adquisición, no de la ejecución asintótica.

Una tercera dificultad tiene que ver con la distinción entre el tipo de explicaciones que se dan en términos del modelo DBP y aquellas que se dan por medio de modelos asociacionistas (e.g., Gibbon y Balsam, 1981; Rescorla y Wagner, 1972). Al respecto, sólo cabe decir que la diferencia entre los modelos asociacionistas y los modelos conexionistas aun dista de estar clara. Las características definitorias de una red neuronal artificial (unidades de procesamiento inspiradas en la estructura y funcionamiento neuronales, dependencia estructural-anatómica de lo funcional, procesamiento distribuido en paralelo, representación distribuida, procesamiento numérico en oposición a simbólico) parecen estar claras. Sin embargo, tales características parecieran poder ser emuladas igualmente por modelos asociacionistas (e.g., Kehoe, 1989), lo cual reduce sustancialmente la distinción en cuestión.

Cuarto, es obvio que toda simulación implica una simplificación de la realidad, y las redes empleadas en el presente trabajo distan mucho de capturar la inmensa complejidad estructural y funcional de los organismos naturales usados en investigación en condicionamiento pavloviano. Sin embargo, sólo simplificando tal complejidad se puede llegar a controlar y conocer variables que, quizá, en experimentos realizados con organismos naturales resulten más difíciles de controlar y podrían convertirse en variables contaminantes de los resultados obtenidos. En particular, el tipo de prueba que se realizó en las presentes simulaciones involucró la desactivación de la función de aprendizaje, lo cual sería imposible de realizar con organismos naturales. En estos organismos, inevitablemente toda prueba está contaminada de aprendizaje.

Finalmente, teniendo en cuenta que el contexto ha sido simulado como un EC más, el trabajo posterior puede enfocarse hacia ese aspecto: manipular la arquitectura de la red y emplear redes más complejas y con más entradas, que representen ciertas características del contexto más concretas (por ejemplo, manipulando el valor de activación y/o pesos iniciales de las distintas unidades de entrada que lo representan), ahondando con ello en aspectos más específicos del condicionamiento contextual (e.g. saliencia). Además, realizar una exploración sobre el condicionamiento contextual en situaciones que no involucren condicionamiento pavloviano exclusivamente, y/o modificando el tipo de entrenamiento de condicionamiento pavloviano al que son sometidas las redes neuronales (demorado, de huella, etc.). Cabe resaltar que, dados los alcances del modelo en la simulación de gran cantidad de fenómenos conductuales, la tarea se vuelve aún más compleja al tener que conservar los logros alcanzados hasta ahora al momento de avanzar en la resolución del problema. Ello implicaría buscar la solución del problema tratando de conservar hasta el máximo posible el propio modelo.

Junto con el condicionamiento contextual, que ha sido simulado siguiendo la metodología empleada por la literatura clásica, se incrementa el número los fenómenos que el modelo DBP ha sido capaz de simular, demostrando consigo que se trata de uno de los modelos de redes neuronales artificiales más importantes e influyentes de los últimos 10 años. Sin embargo, aún quedan muchos fenómenos conductuales por simular para contrastar la plausibilidad que este modelo ha tenido a la hora de simular otros fenómenos.

10. BIBLIOGRAFÍA

- Archer, T., Sjöden, P., Nilson, E. (1985). *Contextual control of taste-aversion conditioning and extinction*. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Baker, A. G., Mercier, P., Gabel, J. & Baker, P. A. (1981). Contextual conditioning and the US preexposure effect in conditioned fear. *Journal of Experimental Psychology: Animal Behavior Processes*, **7**, 109-128.
- Balsam, P. D. (1984). *Bringing the background to the foreground: The role of contextual cues in autoshaping*. En M. Commons, R. Herrnstein y A. R. Wagners (Eds.), *Quantitative Analysis of Behavior: Volume 3, Acquisition*. Cambridge, Mass: Ballinger.
- Balsam, P. D. (1985). *The functions of context in learning and performance*. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Balsam, P. D & Schwartz, A. L. (1981). Rapid contextual conditioning in autoshaping. *Journal of Experimental Psychology: Animal Behavior Processes*, **1**, 382-393.
- Barto, A.G. & Anadan, P. (1985). Pattern recognizing stochastic learning autómatas. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 15.
- Barto, A. G. & Sutton, R. S. Time derivative models of Pavlovian conditioning. En M. Gabriel y J. Moore (Eds.), *Learning and computational neuroscience: Foundations of adaptative networks*. Cambridge, MA: MIT Press.
- Block, H. D. (1962). The perceptron: a model for brain functioning. *Reviews of Modern Physics*, **34**, 123-135.

- Bouton, M. E. & Bolles, R. C. (1985). Context, event-memories and extinction. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbaum Associates, Publishers.
- Burgos, J. E. (1999). Una reconstrucción neuro-computacional del problema de los dos tipos de condicionamiento. En A. L. Rangel, L. M. Sánchez, M. Lozada & C. Silva (comp.). *Contribuciones a la psicología en Venezuela. Tomo III* (pp. 215-249). Caracas: Fondo Editorial de la Facultad de Humanidades y Educación.
- Burgos, J. E. (2000). Superstition in artificial neural networks: a case study for selectionist approaches to reinforcement. *Revista mexicana de análisis de la conducta*, **26**, 159-188.
- Burgos, J. E. (2003). Theoretical note: Simulating latent inhibition with selection neural networks. *Behavioral Processes*, **62**, 183-192.
- Burgos, J. E., y Donahoe, J. W. (2000). Structure and function in selectionism: Implications for complex behavior. En J. Leslie & D. Blackman (Eds.), *Issues in experimental and applied analyses of human behavior*. Reno: Context Press.
- Casti, John L. 1997. *Would-be worlds: How simulation is changing the frontiers of science*. New York: John Wiley & Sons.
- Cheng-Lian & Lin Chin-Teng (1996). Reinforcement Learning for an ART-Based Fuzzy Adaptative Learning Control Network. *IEEE Transactions on Neural Networks*, Vol. 7, **3**, 709- 731.
- Cobos, P. L. (2005). *Conexionismo y cognición*. Madrid: Pirámide.
- Dawkins, R. (1982). *The Extended Phenotype*. Oxford, Oxford University Press.

- Donahoe, J. W., Burgos, J. E. y Palmer, D. C. (1993). Selectionist approach to reinforcement. *Journal of the Experimental Analysis of Behavior*, **60**, 17-40.
- Donahoe, J. W. & Palmer, D. C. (1994). *Learning and complex behavior*. Boston: Allyn & Bacon.
- Durlach, P. (1984). Pavlovian learning and performance when CS and US are uncorrelated. En M. Commons, R. Herrnstein y A. R. Wagner (Eds.). *Quantitative analysis of behavior: Volume 3: Acquisition*. Cambridge, Mass: Ballinger.
- Emmeche, C. (1991). A semiotical reflection on biology, living signs and artificial life. *Biology and Philosophy*, **6**, 325-340.
- Fanselow, M. S. (1980). Signaled shock-free periods and preference for signaled shock. *Journal of Experimental Psychology: Animal Behavior Processes*, **6**, 65-80.
- Freeman, J., & Skapura, D. (1991). *Neural Networks*. Reading MA: Addison-Wesley.
- Fukushima, K. (1975). Cognitron: A self-organizing multilayered neural network. *Biological Cybernetics*, **20**, 121-136.
- Gabriel, M. (1972). Incubation of avoidance produced by generalization to stimuli of the conditioning apparatus. En R. Thompsons y A. Voss (Eds.), *Topics in learning and performance*. New York: Academic Press.
- Gibbon, J. (1977). Scalar expectancy theory and Weber's law in animal timing. *Psychological Review*, **84**, 279-325.
- Gibbon, J. & Balsam, P. D. (1981). The spread of association in time. En C. M. Locurto, H. S. Terrace y J. G. Gibbon (Eds.), *Autoshaping and conditioning theory*. New York: Academic Press.

- Gibbon, J. & Church, R. M. (1984). Source of variance in an information processing theory of timing. En H. Roitblat, T. Bever y H. Terrace (Eds.), *Animal cognition*. Hillsdale, N. J.: Lawrence Erlbaum Associates.
- Grossberg, S. (1975). A neural model of attention, reinforcement and discrimination learning. *International Review of Neurobiology*, **18**, 263-327.
- Grossberg, S. & Schmajuk, N. A. (1989). Neural dynamics of adaptive timing and temporal discrimination during associative learning. *Neural networks*, **2**, 79-102.
- Hebb, D. O. (1949). *The organization of behavior*. Nueva York, Wiley.
- Hilera, J. R. y V J. Martínez (2000). *Redes Neuronales Artificiales, Fundamentos, modelos y aplicaciones*, México, Editorial Alfa Omega.
- Hinton, G. E. (1992). Redes neuronales que aprenden de la experiencia. *Investigación y Ciencia*, **194**, 105-112.
- Holland, P. C. (1983). "Occasion-setting" in conditional discriminations. En M. Commons, R. Herrnstein y A. R. Wagner (Eds.), *Quantitative Analyses of Behavior: Vol. 4: Discrimination processes*. New York: Ballinger.
- Hopfield, J.J. (1982). Neural Networks and Physical systems with emergent collective computational abilities, *Proceedings of The National Academy of Sciences*, **79**, 2554- 2558.
- Jordan, M. L. (1988). *Serial order: A parallel distributed processing approach*. ICS Report 8604, Institute for Cognitive Science, UCLA.

- Kaplan, P. S. & Hearst, E. (1985). Contextual control and excitatory versus inhibitory learning: studies of extinction, reinstatement and interference. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbaum Associates, Publishers.
- Kaski, S. (1997). *Data exploration using self-organizing maps*, Número 82 de la serie Acta Polytechnica Scandinavica, Mathematics, Computing and Management in Engineering Series, (English version) Finnish Academy of Technology, Espoo.
- Kehoe, E. J. (1989). Connectionist models of conditioning: a tutorial. *Journal of the Experimental Analysis of Behavior*, **52**, 427-440.
- Klopf, A. H. (1988). A neuronal model of classical conditioning. *Psychobiology*, **16**, 85-125.
- Kohonen, T. (1982). Self Organized formation of topologically correct feature maps, *Biological Cybernetics*, **43**, 59-69.
- Konorski, J. (1967). *Integrative activity of the brain*. Chicago: University of Chicago Press.
- Mackintosh, N. J. (1975). Theory of attention. *Psychological Review*, **72**, 201-209.
- Mackintosh, N. J. (1977). Stimulus control: Attentional factors. En W. K. Honing y J. E. R. Staddon (Eds.), *Handbook of operant behavior*. Englewood Cliffs, N. J.: Prentice-Hall.
- Maravall Gómez-Allende, D. (1994). *Reconocimiento de formas y visión artificial*, Wilmington, Delaware, Addison-Wesley Iberoamericana/RAMA.

- Maren, A., Harston, C. & Pap, R. (1990). *Handbook of neural computing applications*. San Diego, California: Academic Press.
- McAllister, W. R. & McAllister, D. (1965). Variables influencing the conditioning and measuring of acquired fear. En W. F. Prokasy (Eds.), *Classical conditioning*. New York: Appleton-Century-Crofts.
- McAllister, W. R., McAllister, D. & Benton, M. M. (1983). Measurement of fear of the conditioned stimulus and of situational cues at several stage of two-way avoidance learning. *Learning and Motivation*, **14**, 92-106.
- McCulloch, W. S. & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, **5**, 115-133.
- Medin, D. L. & Reynolds, T. J. (1985). Cue-context interactions in discrimination, categorization and memory. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Miller, R. R. & Schachman, T. R. (1985). The several roles of context at the time of retrieval. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Minai, A.A. y Williams, R.D. (1990). Acceleration of back-propagation trough learning rate and momentum adaptation. *International Joint Conference on Neural Networks*, **1**, 676-679.
- Minsky, M. & Papert, S. (1969). *Perceptrons: An introduction to Computational Geometry*. Cambridge, MA: MIT Press.
- Moore, J. W. (1991). Implementing connectionist Algorithms for Classical Conditioning in the brain. *Neural Network Models of Conditioning and Action*. Nueva York: Lawrence Erlbaum Associates Publishers.

- Nadel, L., Willner, J., Kurz, E. M. (1985). Cognitive maps and environmental context. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Odling-Smee, F. J. (1975). The role of background stimuli during Pavlovian conditioning. *Quarterly Journal of Experimental Psychology*, **27**, 201-209.
- Overton, D. A. (1985). Contextual stimulus effects of drugs and internal states. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Patterson, J. & Overmier, J. B. (1981). A transfer of control test for contextual associations. *Animal Learning and Behavior*, **9**, 316-321.
- Randich, A. & Lolordo, V. M. (1979). Associative and nonassociative theories of the UCS preexposure phenomenon: implications for Pavlovian conditioning. *Psychological Bulletin*, **86**, 523-548.
- Randich, A. & Ross, R. T. (1985). Contextual stimuli mediate the effects of pre- and postexposure to the unconditioned stimulus on conditioned suppression. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Rescorla, R. A. (1984). Associations between Pavlovian CSs and context. *Journal of Experimental Psychology: Animal Behavior Processes*, **10**, 195-204.
- Rescorla, R. A., Durlach, P. J & Grau, J. W. (1985). Contextual learning in Pavlovian Conditioning. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Rescorla, R. A. & Wagner, A. R. (1972). A theory of Pavlovian conditioning: Variations in the effectiveness of reinforcement and nonreinforcement. En

- A. H. Black & W. F. Prokasy (Eds.), *Classical Conditioning II: Current theory and research*. New York: Appleton-Century-Crofts.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological Review*, **65**, 386-408.
- Rosenblatt, F. (1962). *Principles of Neurodynamics*. Spartan, New York.
- Rummelhart D. & J. McClelland (1986). *Parallel distributed processing: Explorations in the microstructure of cognition*, Vol. 1. Mass: MIT-Press.
- Rummelhart, D., Winton, G. E. & Williams, R. J. (1986). Learning internal representations by error propagation. En Rummelhart y McClelland (Eds.). *Parallel distributed processing: Explorations in the microstructure of cognition*, Vol. 1. Mass: MIT Press.
- Schmajuk, N. E. (1994) Behavioral dynamics of escape and avoidance: A neural network approach. En D. Cliff, P. Husbands, J. A. Meyer y S. Wilson (Eds.). *From animals to animats 3*. Cambridge, MA: MIT Press.
- Schmajuk, N. E. (1997). *Animal learning and cognition. A neural network approach*. USA: Cambridge University Press
- Schmajuk, N. E. & Blair, H. T. (1993). Stimulus configuration, place learning and the hippocampus. *Behavioral Brain Research*, **59**, 103-117.
- Schmajuk, N. E., Lam, Y. W & Gray, J. A. (1996). Latent inhibition: A neural network approach. *Journal of Experimental Psychology: Animal behavior processes*, **22**, 321-349.

- Schmajuk, N. E. & Moore, J. W. (1988). The hippocampus and the classically conditioned nictitating membrane response: A real-time attentional associative model. *Psychobiology*, **46**, 20-35.
- Schmajuk, N. E. & Thieme, A. D. (1992). Purposive behavior and cognitive mapping: An adaptative neural network. *Biological cybernetics*, **67**, 165-174.
- Skapura, D. M. (1995). *Building Neural Networks*, Nueva York, Nueva York, ACM Press.
- Sokolov, E. N. (1960). Neuronal models and the orienting reflex. En M. B. A. Brazier (Ed.), *The central nervous system and behavior*. New York: Macy Foundation.
- Spear, N. E., Smith, G. J., Bryan, R. G., Gordon, W. C., Timmons, R. & Chiszar, D. A. (1980). Contextual influences on the interaction between conflicting memories in the rat. *Animal learning and behavior*, **8**, 273-281.
- Sutton, R. S. & Barto, A. G. (1981). An adaptative network that constructs and uses an internal model of its world. *Cognition and Brain Theory*, **4**, 217-246.
- Thomas, D. R. (1985). Contextual stimulus control of operant responding in pigeons. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Tomie, A. (1985). Effects of the test context on the acquisition of autoshaping to a formerly random keylight or a formerly contextual keylight. En Balsam y Tomie (ed.). *Context and Learning*. Hillsdale, New Jersey: Lawrence Erlbau Associates, Publishers.
- Uttley, A. M. (1954) *The Classification of Signals in the Nervous System*. R.R.E. Memorandum No. 1048

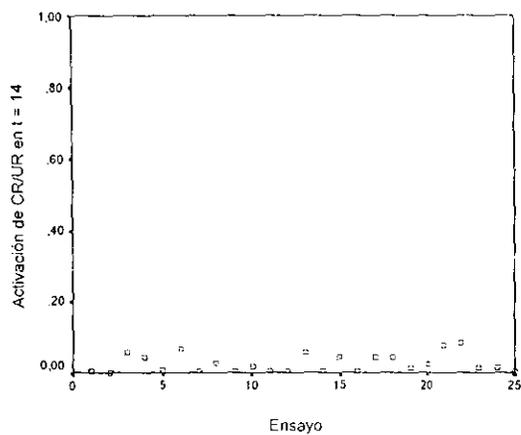
Von Neumann, J. (1956). *Probabilistic Logics and the Synthesis of Reliable Organisms from Unreliable Components*. Princetown University Press.

Widrow, B. & Hoff, M. E. (1960). Adaptative switching circuits. 1960 IRE WESCON Convention Record. Nueva York: IRE.

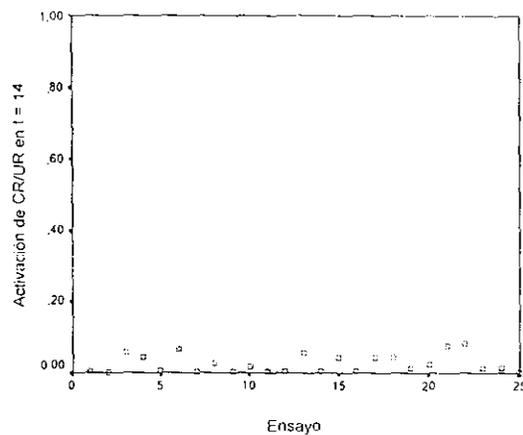
Winograd, S. & Cowan, J. D. (1963) *Reliable Computation in the Presence of Noise*. MIT Press.

SIMULACIÓN 1: CONDICIÓN 1 FASE 2

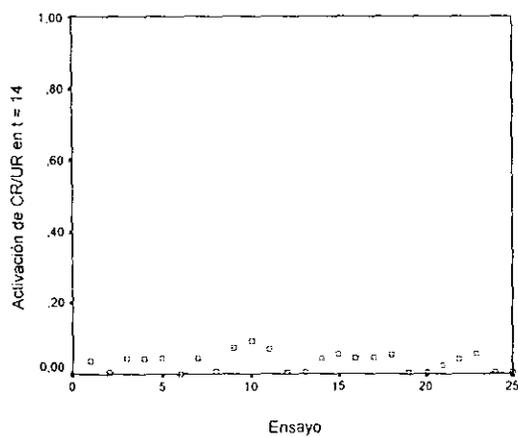
C1 - FASE 2 (REPLICACIÓN 1)



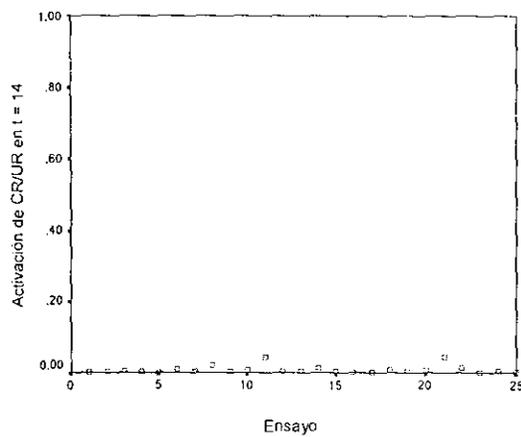
C1 - FASE 2 (REPLICACIÓN 2)



C1 - FASE 2 (REPLICACIÓN 3)

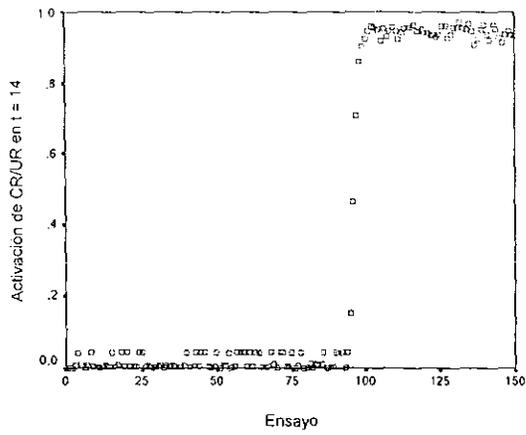


C1 - FASE 2 (REPLICACIÓN 4)

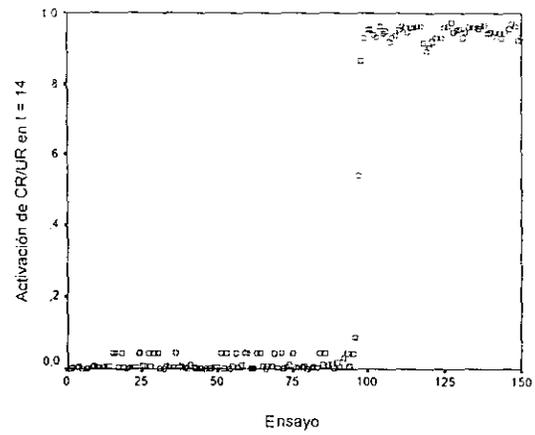


SIMULACIÓN 1: CONDICIÓN 2 FASE 1

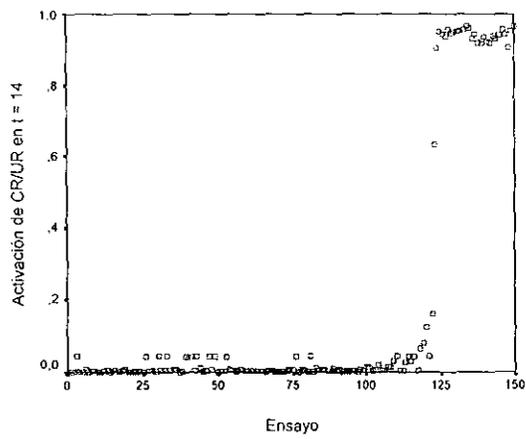
C2 - FASE 1 (REPLICACIÓN 1)



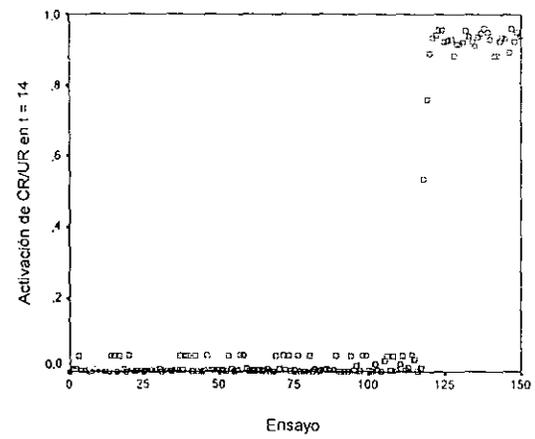
C2 - FASE 1 (REPLICACIÓN 2)



C2 - FASE 1 (REPLICACIÓN 3)

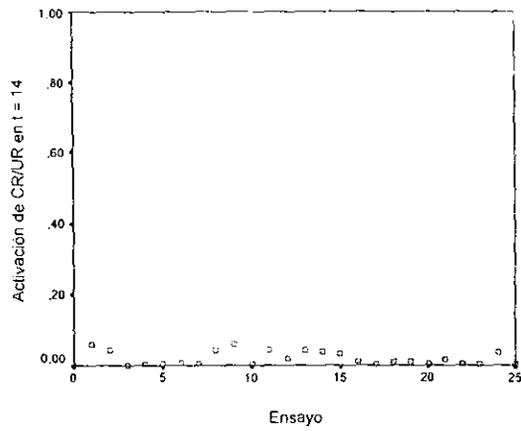


C2 - FASE 1 (REPLICACIÓN 4)

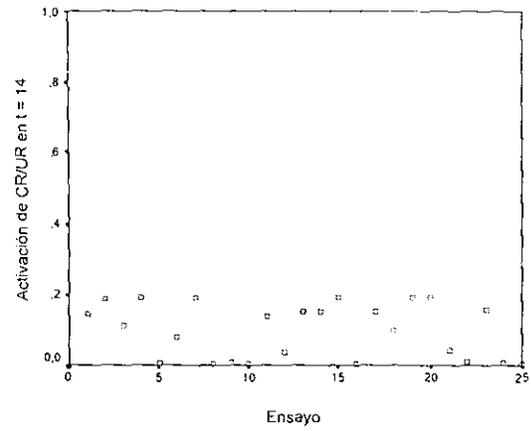


SIMULACIÓN 1: CONDICIÓN 2 FASE 2

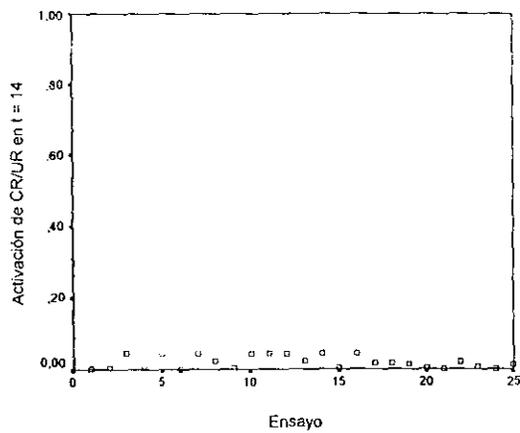
C2 - FASE 2 (REPLICACIÓN 1)



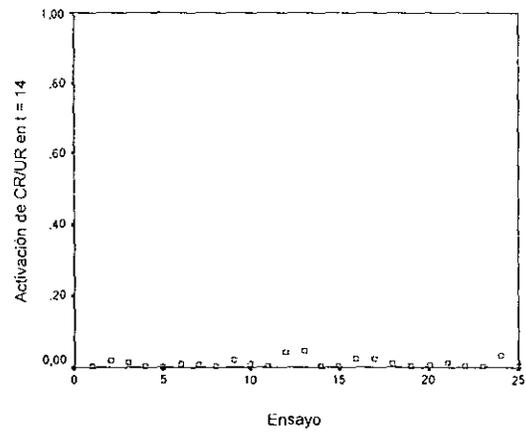
C2 - FASE 2 (REPLICACIÓN 2)



C2 - FASE 2 (REPLICACIÓN 3)

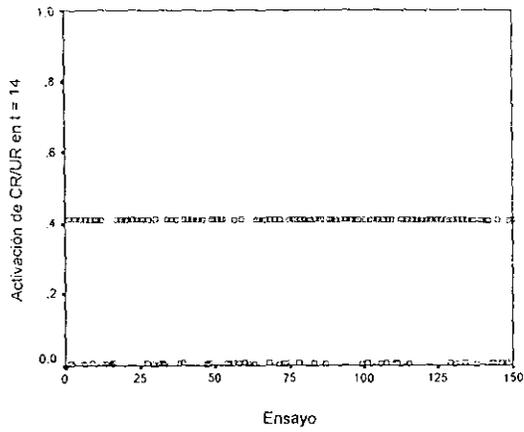


C2 - FASE 2 (REPLICACIÓN 4)

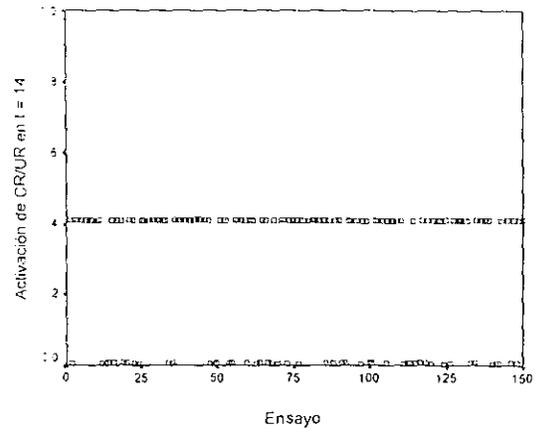


SIMULACIÓN 2: CONDICIÓN EXPERIMENTAL FASE 1: SÓLO E1

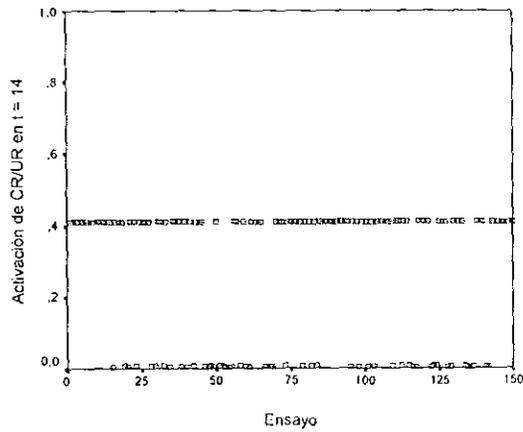
CE - FASE 1 (REPLICACIÓN 1)



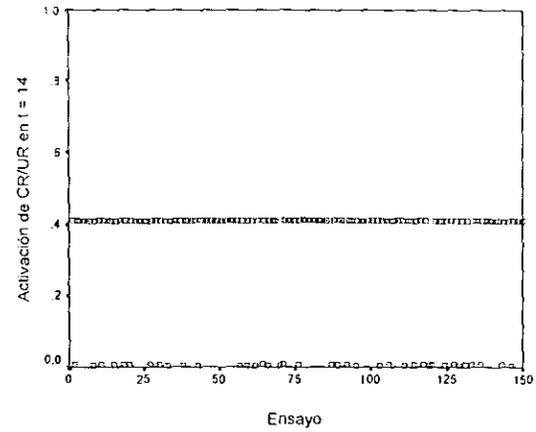
CE - FASE 1 (REPLICACIÓN 2)



CE - FASE 1 (REPLICACIÓN 3)

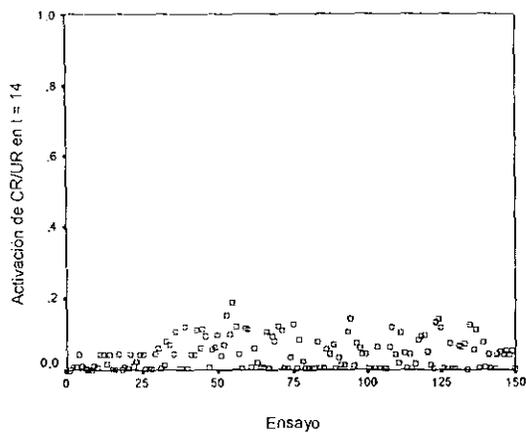


CE - FASE 1 (REPLICACIÓN 4)

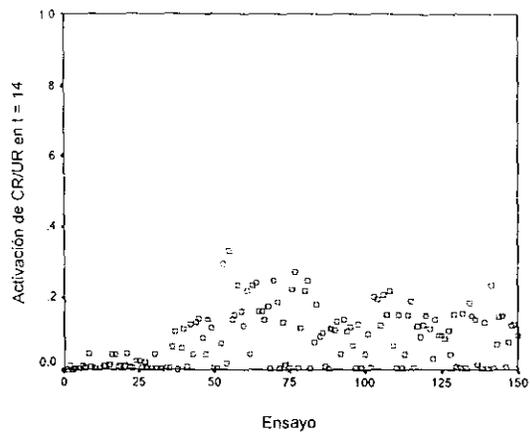


SIMULACIÓN 2: CONDICIÓN EXPERIMENTAL FASE 2: ENTRENAMIENTO

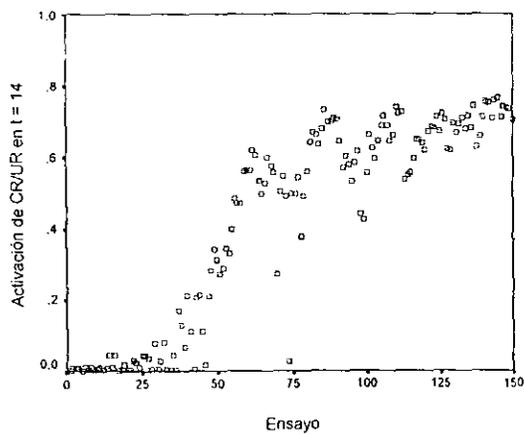
CE - FASE 2 (REPLICACIÓN 1)



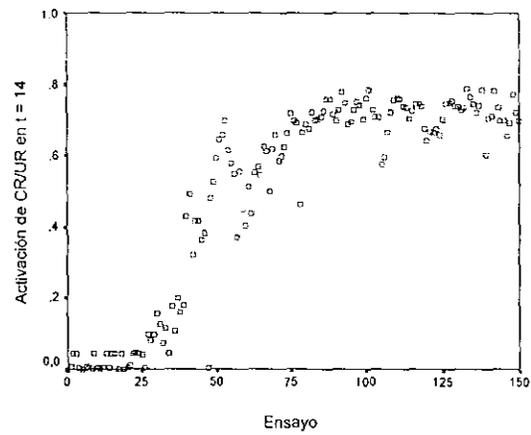
CE - FASE 2 (REPLICACIÓN 2)



CE - FASE 2 (REPLICACIÓN 3)

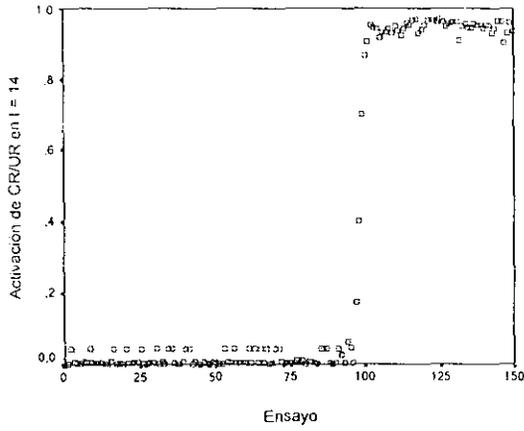


CE - FASE 2 (REPLICACIÓN 4)

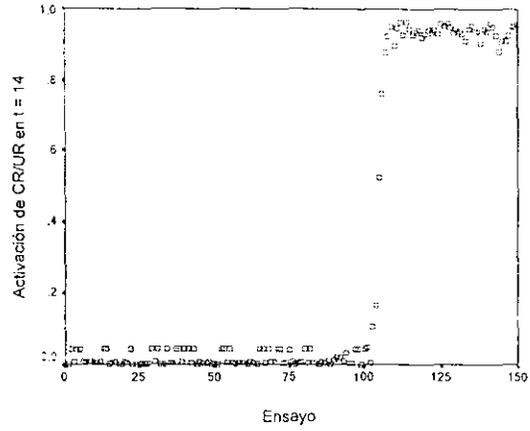


SIMULACIÓN 2: CONDICIÓN CONTROL: ENTRENAMIENTO

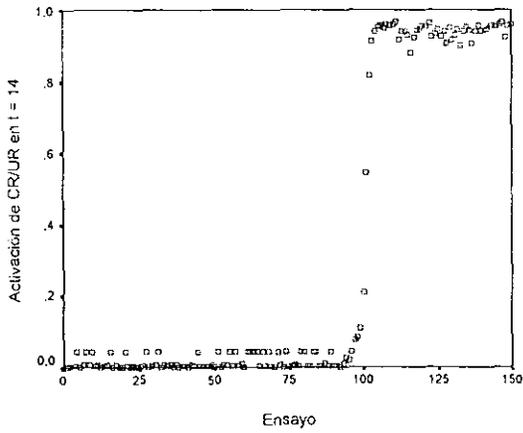
CONDICIÓN CONTROL (REPLICACIÓN 1)



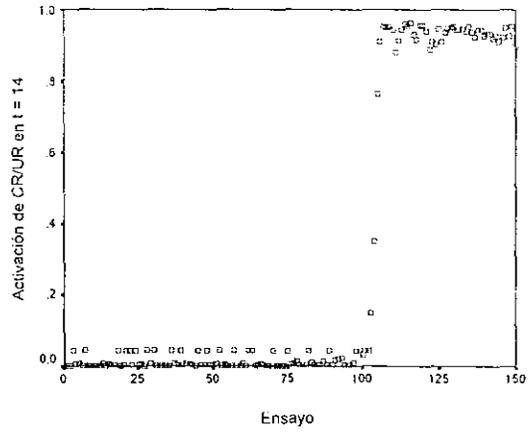
CONDICIÓN CONTROL (REPLICACIÓN 2)



CONDICIÓN CONTROL (REPLICACIÓN 3)

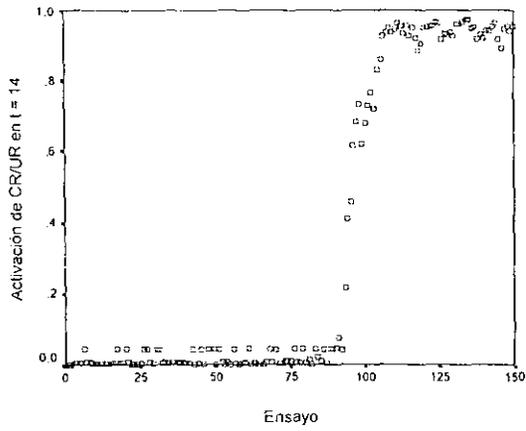


CONDICIÓN CONTROL (REPLICACIÓN 4)

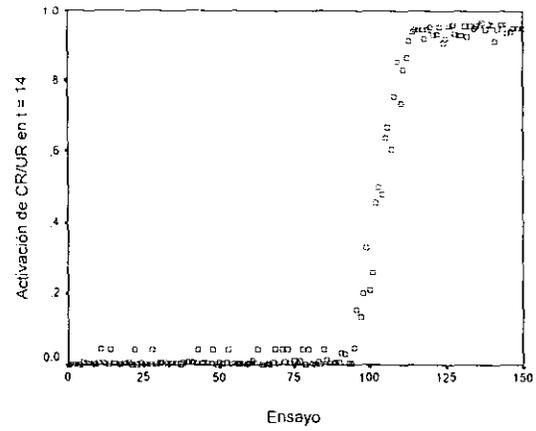


SIMULACIÓN 3: CONDICIÓN EXPERIMENTAL FASE 1: ENTRENAMIENTO

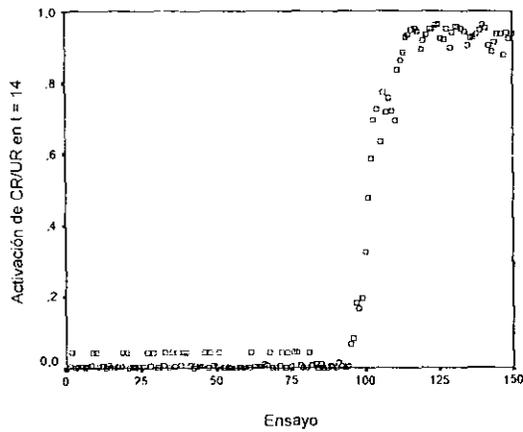
CE - FASE I (REPLICACIÓN 1)



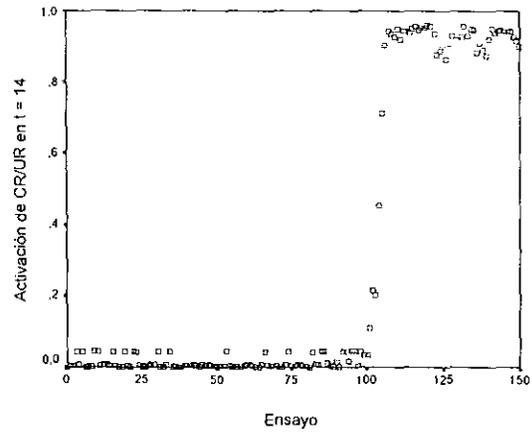
CE - FASE I (REPLICACIÓN 2)



CE - FASE I (REPLICACIÓN 3)

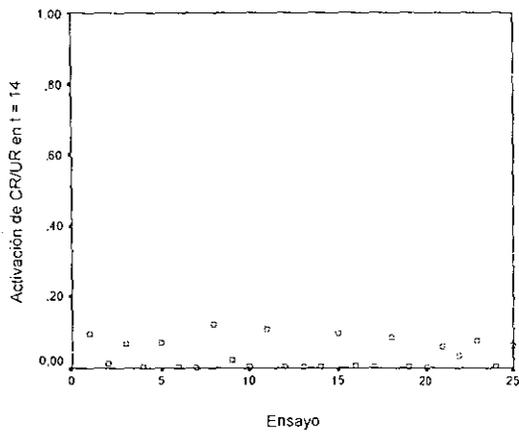


CE - FASE I (REPLICACIÓN 4)

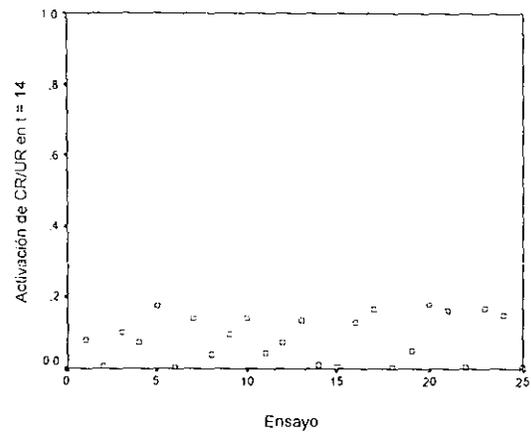


SIMULACIÓN 3: CONDICIÓN EXPERIMENTAL FASE 3: SÓLO EC

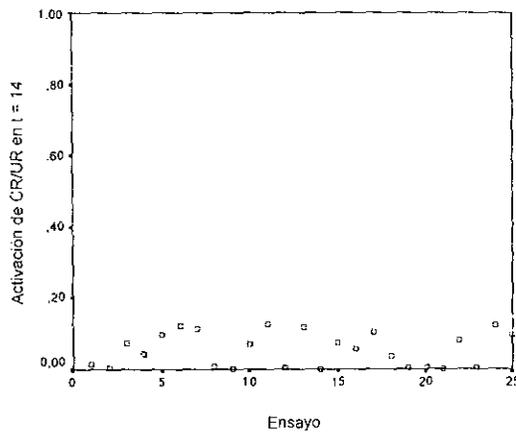
CE - FASE 3 (REPLICACIÓN 1)



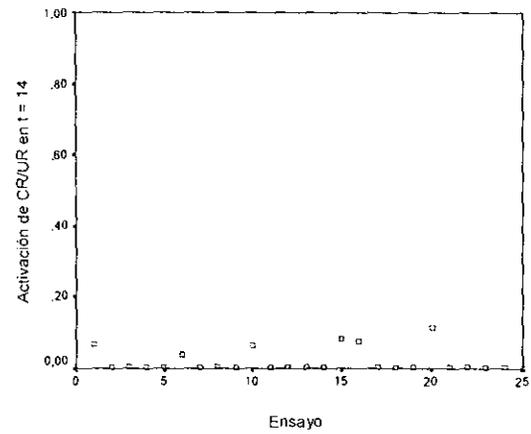
CE - FASE 3 (REPLICACIÓN 2)



CE - FASE 3 (REPLICACIÓN 3)



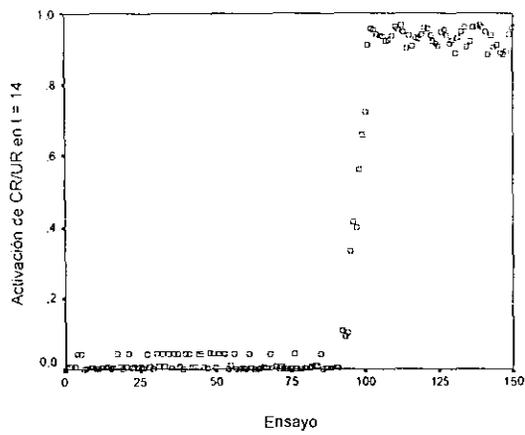
CE - FASE 3 (REPLICACIÓN 4)



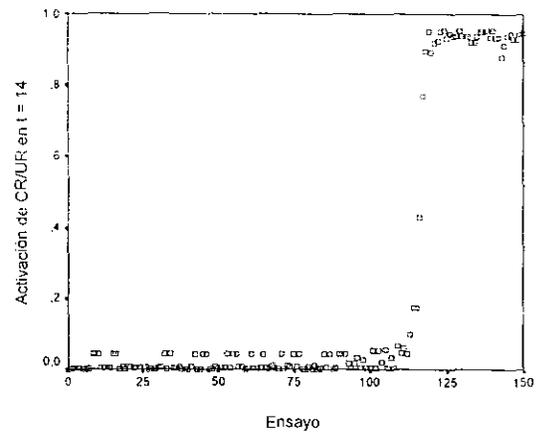
ANEXO

SIMULACIÓN 1: CONDICIÓN 1 FASE 1

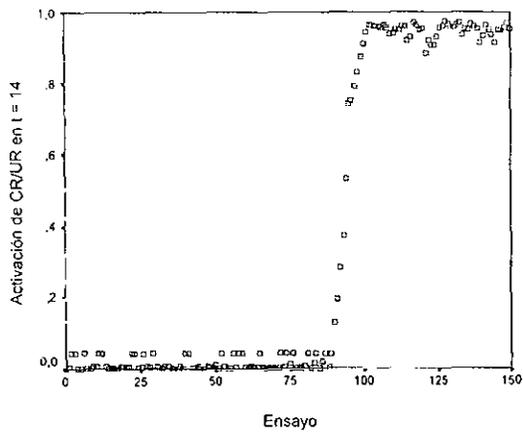
C1 - FASE 1 (REPLICACIÓN 1)



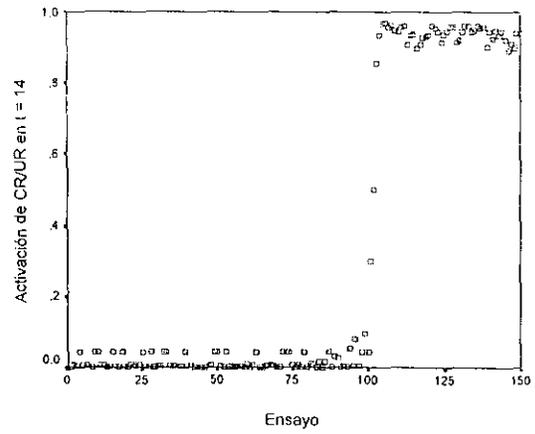
C1 FASE 1 (REPLICACIÓN 2)



C1 - FASE 1 (REPLICACIÓN 3)

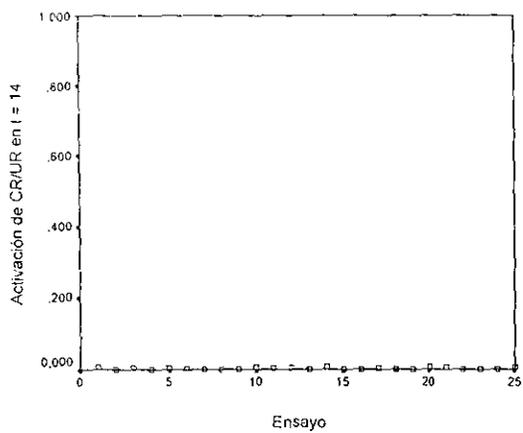


C1 - FASE 1 (REPLICACIÓN 4)

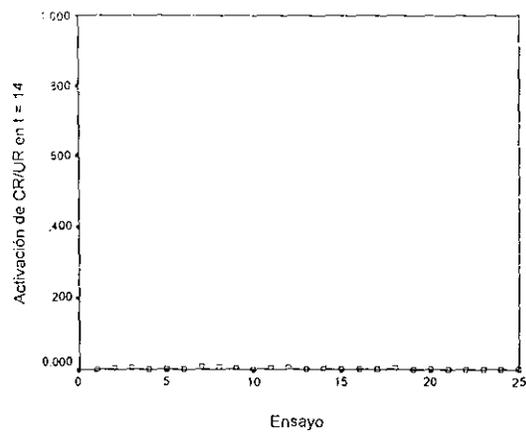


SIMULACIÓN 3: CONDICIÓN CONTROL

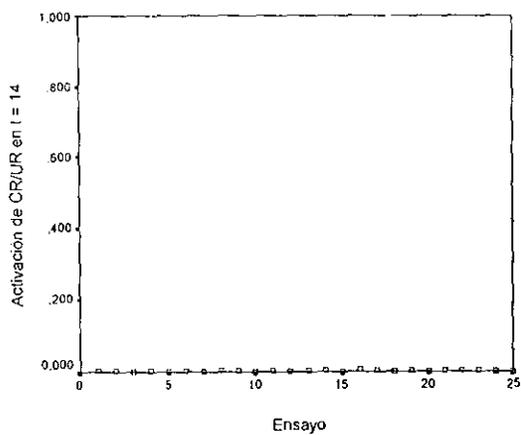
CONDICIÓN CONTROL (REPLICACIÓN 1)



CONDICIÓN CONTROL (REPLICACIÓN 2)



CONDICIÓN CONTROL (REPLICACIÓN 3)



CONDICIÓN CONTROL (REPLICACIÓN 4)

