

ARTÍCULOS



REPRESENTACION DE LAS REDES SEMANTICAS EN LOS MODELOS NEURONALES

Iza Miqueleiz, Mauricio

1.- INTRODUCCION.

Desde su introducción por Quillian (1968) las redes semánticas han jugado un papel importante en la investigación sobre la representación del conocimiento. Las redes semánticas expresan el conocimiento en términos de conceptos, sus propiedades, y la relación jerárquica sub/superclase entre conceptos. Cada concepto está representado por un nodo y la relación jerárquica entre conceptos es representada conectando nodos de concepto apropiados vía enlaces 'ES-UN' o 'INSTANCIA-DE'. Los nodos al nivel más bajo en la jerarquía ES-UN denotan individuos ('Tokens') mientras los nodos a niveles más altos denotan clases o categorías de individuos ('Types'). Las propiedades también están representadas por nodos y el hecho de que una propiedad se aplique a un concepto está representado conectando los nodos del concepto y la propiedad vía un nexo etiquetado. Típicamente, una propiedad está sujeta al concepto más alto en la jerarquía conceptual a la que se aplica la propiedad, y si una propiedad está sujeta a un nodo C se 'asume' que se aplica a todos los nodos que son descendientes de C.

Pero, a pesar de las limitaciones de los modelos de redes semánticas (primitivos semánticos, sin aprendizaje, etc), éstos han sido utilizados en un amplio rango de estudios en inteligencia artificial y ciencia cognitiva. Una línea de trabajo utiliza "difusión de la activación" en redes conceptuales para modelar los efectos del contexto, por ejemplo, percepción de palabra (McClelland y Rumelhart, 1981), desambiguación (Quillian, 1969; Cottrell y Small, 1983), producción del habla (Dell, 1985) y recuperación de memoria (Anderson, 1983). La mayor parte de los otros trabajos utilizando modelos de redes semánticas asumen que la red es pasiva y es 'interpretada' por un programa de control. Las redes semánticas interpretadas pueden ser divididas en aplicaciones de reconocimiento y deducción de las redes. El reconocimiento de escenas visuales complejas está basado casi universalmente en modelos de red a niveles conceptuales altos (Ballard y Brown, 1982; Marr y Nishihara, 1978) y el trabajo en reconocimiento del habla a menudo tiene este carácter (Lowerre y Reddy, 1979). Los modelos de deducción que emplean redes semánticas son generalmente empleados en lenguaje natural e investigaciones relacionadas (Walker, 1978; Findler, 1979).

Los modelos computacionales más actuales que utilizan el mecanismo de 'difusión de la activación' ('spreading activation'), como el ACT de Anderson (donde existe un conjunto inicial de representaciones proposicionales primitivas) o los modelos conexionistas de representación local (donde cada unidad representa un concepto), caen también, como veremos, en algunas de las limitaciones de los modelos anteriores (por ejemplo, se debe hacer una discreta decisión todo-o-nada para crear un nuevo concepto).

El conexionismo supone una actitud radicalmente diferente, ya que sostiene precisamente el supuesto contrario a la psicología cognitiva: que al menos algunos aspectos del sustrato físico de la cognición (es decir, del cerebro) son fundamentales para entender ésta; y especialmente lo es el hecho de que el cerebro opera en paralelo, es decir, funciona como una vasta red de elementos interconectados (neuronas) que funcionan simultáneamente. En esto se diferencia de los ordenadores digitales convencionales, en los que un procesador central es el responsable de todas las operaciones y ha de hacerlas una a una. Consecuentemente con ello, los modelos de procesamiento distribuido en paralelo tratan de reproducir fenómenos cognitivos a base de construir complejas redes de unidades electrónicas sencillas, semejantes a neuronas, que funcionan en paralelo.

Desde el punto de vista de la memoria, la más importante característica de los modelos conexionistas es que proponen que ésta almacena la información codificada en representaciones subsimbólicas (Smolensky, 1988). Esto significa que no existe una correspondencia entre, por ejemplo, los conceptos y su representación en los modelos conexionistas. En una red semántica podemos <<señalar con el dedo>> dónde está el concepto de <<ave>>; en un modelo conexionista, dicho concepto no está en ninguna parte y está en todas. No hay ninguna unidad de una red conexionista, ni ningún conjunto definido de ellas, que se pueda considerar una representación simbólica de éste o cualquier otro concepto. Lo que ocurre es que la misma red, cuando recibe un determinado tipo de input, <<se comporta>> conforme a ese concepto, pero cuando recibe otra clase de input lo hace de acuerdo con otros conceptos. El aparato matemático-computacional utilizado para construir esas funciones de relación entre inputs y comportamientos de la red es, como puede imaginarse, muy complejo, y tanto más cuanto más sofisticado y complejo sea el fenómeno cognitivo que se trate de modelar.

De este modo, los autores conexionistas han apuntado explicaciones en sus propios términos de nociones cognitivas como las de <<esquema>> o <<red semántica>> (por ejemplo, Schneider, 1988).

Las simulaciones de representación dirigen los problemas a la distinción entre tipo ('type') y caso ('token'), la representación de 'categorías léxicas', y la representación de 'estructura gramatical'. Los resultados sugieren que las representaciones conexionistas pueden en efecto poseer estructura interna y permitir una conducta sistemática, y que un mecanismo que es sensible al contexto es capaz de capturar generalizaciones de varios grados de abstracción.

Los modelos conexionistas son sensibles al contexto y capaces de exhibir respuestas graduadas a diferencias sutiles en estímulos. Pero, algunas veces, la conducta del lenguaje parece estar caracterizada por patrones abstractos que son menos sensibles al contexto.

Otra cuestión es si los modelos que son fundamentalmente sensibles-al-contexto son también capaces de llegar a generalizaciones que son altamente abstractas.

Por último, los modelos conexionistas pueden ser sistemas de aprendizaje muy efectivos que dan un gran paso en la computación del aprendizaje (salvando la concepción, por parte de la inteligencia artificial, de la mente como una 'tabula rasa'). Sin embargo, pueden no llegar a realizar estas operaciones de manera análoga al aprendizaje humano (por ejemplo, según Norman (1986): el conexionismo debe tratar con el procesamiento secuencial que es típico en la solución de problemas). Aunque posteriormente, y como veremos, se han propuesto nuevos modelos conexionistas, como pueden ser los sistemas híbridos, para salvar éste y otros problemas que no eran resueltos satisfactoriamente por los modelos iniciales.

En el próximo apartado, estudiaremos cómo se representan las estructuras conceptuales, las redes semánticas, en los modelos conexionistas, y, cómo esta representación puede ser utilizada para simular mecanismos inferenciales, como pueden ser la herencia y el reconocimiento, de la mente humana. Más adelante, veremos también, cómo estos modelos también poseen algunas limitaciones como modelamiento de la mente humana, y, las soluciones que se han planteado.

2.- REDES SEMANTICAS CONEXIONISTAS.

Un sistema conexionista que intente implementar las clases de estructuras conceptuales que la gente utiliza tiene que ser capaz de representar dos diferentes clases de jerarquía:

1º) La jerarquía "ES-UN" que relaciona tipos con instancias de estos tipos. Sus características más importantes son que las propiedades conocidas de los tipos deben ser "heredadas" por las instancias, y propiedades que son encontradas para aplicarlas a todas las

instancias de un tipo deben normalmente ser atribuidas al tipo. Esta jerarquía puede ser implementada haciendo 'incluir' en la representación distribuida de una instancia, como una subparte, la representación distribuida para el tipo. Esta representación trampa automáticamente produce la característica más importante de la jerarquía ES-UN, pero la trampa sólo puede ser utilizada para un tipo de jerarquía.

2º) La jerarquía parte/todo que relaciona items con los items constituyentes de los que está compuesto. Si utilizamos esta relación entre patrones de actividad para representar la relación tipo/instancia entre items, parece que tampoco podemos utilizarla para representar la relación parte/todo entre items. No podemos hacer que la representación del todo sea la suma de las representaciones de sus partes. El uso de patrones que representan combinaciones identidad/rol permite a la jerarquía parte/todo ser representada del mismo modo que la jerarquía tipo/instancia [véase Hinton, 1981]. Podemos ver el todo simplemente como una particular instancia de un número de tipos más generales, donde cada uno de los cuales puede ser definido como el tipo que tiene una particular clase de parte jugando un rol particular.

En los modelos simbólicos (tipo frame) es fácil construir enlaces "es-un" desde instancias a sus tipos, y desde tipos a supertipos, etc., para formar jerarquías con herencia de propiedades. Así, la información o propiedades puede ser heredada desde los niveles más altos. Los modelos subsimbólicos (inspirados por mecanismos neuronales y basados en el procesamiento paralelo de representaciones distribuidas) realizan la herencia sólo en la extensión donde una representación comparte rasgos con otra. Esta representación 'trampa' automáticamente produce la característica más importante de la jerarquía "es-un", pero esta 'trampa' sólo puede ser utilizada para un tipo de jerarquía. Asimismo, como no hay un lugar donde el conocimiento sobre un tipo 'en general' es almacenado en estos modelos subsimbólicos, no es posible añadir hechos sobre este tipo en general y, automáticamente e inmediatamente, hacer este nuevo conocimiento disponible a todas sus instancias, como es posible en los modelos simbólicos (Dyer, 1988).

Sin embargo, y para salvar estas limitaciones, se ha intentado representar las redes semánticas en los modelos conexionistas (por ejemplo, el NETL que es un sistema conexionista para el conocimiento simbólico) utilizando representaciones que no sean puramente distribuidas: locales o distribuidas con unidades específicas de rol.

Las redes localistas tienden a formar capas jerárquicas de unidades. Esto refleja la eficiencia de las computaciones jerárquicas y la facilidad con la que las relaciones ES-UN y PARTE-DE pueden ser conectadas utilizando el enfoque una-unidad un-concepto y enlaces excitatorios. La

construcción de redes localistas tiene un fuerte componente empírico. Esto es principalmente debido a que las estructuras conexionistas que se derivan formalmente para una tarea dada es difícil (con algunas excepciones, por ejemplo, Shastri y Feldman, 1986). Sin embargo, existen heurísticos y técnicas poderosas para construir redes localistas (Shapiro, 1987).

Un modelo donde se puede apreciar las ventajas que resultan de la utilización de representaciones locales es el modelo de Shastri y Feldman (1986).

Shastri y Feldman introducen un conjunto de mecanismos (conexionistas) para la representación e inferencia de información conceptual. Sugieren que estos mecanismos forman una base adecuada para el estudio de problemas en la comprensión del lenguaje. Sólo consideran sistemas sin un interpretador (un programa de control) e intentan mostrar cómo tales sistemas pueden soportar todas las aplicaciones existentes de las redes semánticas. Los únicos primitivos computacionales en sus modelos son el cálculo y la transmisión de estados de actividad. Intentan demostrar que las redes semánticas tienen una realización natural en las redes neuronales. Su modelo realiza un razonamiento evidencial o probabilístico y puede tratar con excepciones y situaciones de herencia múltiple que provienen de valores de atributo por defecto (Shastri y Ajjanagadde, 1989b).

Basándose en el enfoque evidencial y en el paralelismo, utilizan una representación local (similar a los nuevos modelos de redes semánticas actuales en inteligencia artificial que incorporan métodos en la estructura frame) Pero, tienen problemas: el uso de múltiples ligamientos rol-concepto en una rutina da lugar al problema de 'cross-talk' (control de la difusión de la activación). Además, en el contexto de la visión, asumen que los conceptos que corresponden a propiedades primitivas como color, forma y textura están ya presentes en la red de memoria de un agente junto con conceptos que representan algunos valores básicos de estas propiedades. Asimismo, suponen que las formas simples de aprendizaje resultan de la formación de conceptos que representan colecciones coherentes de propiedades y valores existentes. Las formas más complejas de aprendizaje conducen a la generalización de conceptos y la formación de propiedades complejas que conducen al desarrollo de conceptos más complejos.

Este aprendizaje se daría gracias a la rica estructura pre-existente en la red conexionista. Aunque no solucionan realmente este problema, piensan que el aprendizaje podría ocurrir en la Red de Memoria basándose en las nociones de reclutamiento ('recruitment') y recodificación ('chunking') (Feldman, 1982; Wickelgren, 1979) para representar nuevas instancias y desarrollar conceptos que serían generalizaciones de conceptos ya existentes (por ejemplo, "recodificando" los nodos 'binder' para formar conceptos; Shastri y Feldman, 1986, pp.196-199).

En una variación posterior de este modelo (Shastri, 1988), también se describe cómo el conocimiento sobre conceptos, sus propiedades, y las relaciones jerárquicas entre ellos pueden ser codificados como una red masivamente paralela 'sin un interpretador' ('interpreter-free') de elementos de procesamiento simples, y, cómo puede solucionar una clase interesante de problemas de 'herencia' y 'reconocimiento' extremadamente rápido -en tiempo proporcional a la profundidad de la jerarquía conceptual.

2.1.- Inferencia limitada.

Generalmente se asume que una actividad computacional enorme subyace a alguna de las conductas cognitivas más comunes. Si observamos estas computaciones como operaciones gobernadas por reglas sistemáticas en estructuras simbólicas (esto es, inferencias) nos enfrentamos al siguiente reto: alguna noción generalizada de inferencia es intratable, sin embargo, nuestra habilidad para realizar tareas cognitivas tales como la comprensión del lenguaje en tiempo real (que requiere solucionar varias sub tareas como reconocer fonemas, análisis sintáctico, desambiguar significados de palabras, resolver referencias anafóricas,...) sugiere que somos capaces de realizar un amplio rango de inferencias con extrema eficiencia -casi como una cuestión de 'reflejo' (diferenciándola de la inferencia 'reflexiva' donde el agente es consciente del proceso de razonamiento). Una respuesta a este reto es que la formulación tradicional es simplemente inapropiada y es erróneo considerar las computaciones que subyacen a la cognición como operaciones gobernadas por reglas sistemáticas en estructuras simbólicas.

La noción de representación simbólica 'es' fundamental para un modelo computacional de la cognición y, en ésto, se basa la opinión de que las computaciones en un sistema cognitivo corresponden a operaciones gobernadas por reglas sistemáticas. Sin embargo, hay más que una relación computacional de la cognición que lo que es capturado por estas afirmaciones. Lo que está ausente es una apreciación de la relación íntima y 'simbiótica' entre la naturaleza de la representación, la efectividad de la inferencia, y la arquitectura computacional en la que las computaciones están situadas.

En este sentido, el enfoque conexionista estructurado ofrece un marco apropiado para explicar estas relaciones simbólicas y enfrentarse con el reto de la efectividad computacional.

Si analizamos la conducta humana encontramos que a pesar de operar con una gran base de conocimiento, los agentes humanos toman unos pocos cientos de milisegundos para realizar un amplio rango de tareas cognitivas, tales como reconocimiento de objetos, comprensión del lenguaje hablado y escrito, y la realización de inferencias tales como: "Tweedy es un pájaro y por lo tanto vuela". Los datos de la realización humana indican que la representación de la información conceptual y los procesos cognitivos que acceden a ella son tales que no sólo son hechos relevantes 'recuperados' espontáneamente, sino que ciertos tipos de 'inferencias' también consiguen dibujarse con 'extrema eficiencia'.

Necesitamos explicar cómo los humanos realizan ciertas inferencias con gran eficiencia. Una solución posible a esta paradoja aparente puede residir en una síntesis del enfoque de 'inferencia limitada' y el 'paralelismo masivo' (Shastri, 1988).

De acuerdo con la estrategia de inferencia limitada, uno debe identificar una clase limitada pero interesante de inferencia que necesita ser realizada muy rápidamente, y desarrollar técnicas de estructuración del conocimiento apropiado, algoritmos, y modelos computacionales para realizar esta clase de inferencia dentro de un aceptable marco de tiempo. El paso crítico al ejercer el enfoque de inferencia limitada es circunscribir tal clase de inferencia. Hay varios modos de hacerlo, y de hecho, varias posibilidades han sido investigadas (Ballard, 1986; Frisch y Allen, 1982; Levesque, 1984). Aquí, nos centraremos en una clase de inferencia que es un componente interesante del conocimiento de sentido común, a saber, herencia y reconocimiento en redes semánticas.

Se asume que junto a los hechos que se enumeran sobre el mundo, también, identificamos las 'conexiones' o 'dependencias inferenciales' importantes entre estos hechos. Ahora bien, si cada pieza de información está codificada como un nodo conexionista, y las dependencias entre las piezas de información son codificadas como enlaces explícitos entre los nodos apropiados, entonces la inferencia puede ser vista como una difusión de la activación en una red conexionista. Esta metáfora tiene un tremendo interés ya que sugiere un modo extremadamente eficiente de realizar la inferencia.

Para soportar una inferencia extremadamente eficiente el proceso de difusión de la activación debe converger extremadamente rápido. De hecho, quisiéramos que el proceso converja en un número 'constante' de pases (preferiblemente uno o dos) a través de la red.

Para que una red conexionista compute las soluciones en un 'único' pase de difusión de la activación, las dependencias entre las piezas de conocimiento deben ser 'acíclicas' ('acyclical') [nota 1], es decir, el flujo de información ha de pasar por un grafo acíclico dirigido (DAG) donde cada nodo en el grafo es un elemento de procesamiento y cada arco es un enlace bien conectado ('hardwired'). Esta afirmación -aunque sencilla- tiene un impacto significativo en la naturaleza de las representaciones y conduce a la identificación de restricciones importantes en la estructura conceptual.

Un aspecto importante es aumentar la sintaxis del lenguaje de representación de modo que la 'forma' (esto es, la estructura sintáctica) de la representación 'refleje' directamente la 'estructura inferencial' del conocimiento [nota 2].

Una representación que provee naturalmente el requisito de acoplamiento entre la estructura sintáctica de la representación y la estructura inferencial del dominio de conocimiento es un grafo cuyos nodos corresponden a 'unidades' de información (constantes, predicados, conceptos, propiedades, rasgos, frames, o cualquier cosa) y cuyos arcos corresponden a dependencias inferenciales entre estas unidades. La adopción de tal representación gráfica tiene la consecuencia interesante de que la inferencia se reduce a buscar en un grafo instanciado físicamente. Esto no soluciona el problema de efectividad ya que la búsqueda de grafos arbitrarios es una operación costosa. Sin embargo, una vez identificamos la inferencia como una búsqueda en un grafo, es posible relacionar la 'efectividad' del proceso de inferencia (búsqueda) con las 'propiedades estructurales' de la representación (grafo). Por ejemplo, buscar un árbol o un grafo acíclico dirigido (DAG) es más barato que buscar un grafo general -especialmente si la búsqueda puede ser realizada en paralelo. Esto sugiere que si deseamos efectividad computacional nuestra representación debería proyectar o mapear el conocimiento del dominio en un grafo con la siguiente propiedad:

Partes del grafo que son relevantes para la solución de un problema de inferencia reflejan deben ser árboles o DAGs.

La relación 'directa' entre las propiedades estructurales de la representación y la efectividad de la inferencia reduce el problema de la inferencia refleja al problema de elegir primitivos representacionales apropiados; primitivos que comunican las propiedades estructurales requeridas al grafo codificando el conocimiento del dominio (Shastri, 1990, p.70).

Cuando el conocimiento es codificado en redes conexionistas, los enlaces, los pesos en los enlaces, y las características computacionales de los nodos codifican no sólo el conocimiento sino también cómo los varios constituyentes de conocimiento interactúan durante la computación. También, la codificación paralela (para una búsqueda en menos tiempo) requiere que un procesador sea asignado a cada nodo en el grafo. Un ejemplo puede ser la red conexionista de Shastri (1988).

Pero, aunque es verdad que en algún sistema de representación del conocimiento conexionista dado, la clase de inferencia que ha sido instalada puede ser realizada con extrema eficiencia, también se da el caso que las otras inferencias que quedan pueden no ser realizadas del todo o sólomente pueden ser "aproximadas". Una limitación similar también existe en implementaciones tradicionales de sistemas de representación del conocimiento. Sin embargo, en los sistemas tradicionales es más fácil aumentar el interpretador añadiendo procedimientos apropiados (por ejemplo, el código LISP) al sistema. No se da esto en una codificación conexionista; las características computacionales completas de los nodos y sus interconexiones dependen críticamente en la naturaleza de las inferencias a ser instaladas, e introducir algunos cambios en la habilidad inferencial 'básica' de un sistema puede requerir una mayor reorganización del sistema. En vista de esto, es esencial que la clase de inferencia limitada debe ser elegida con gran cuidado y la naturaleza de las aproximaciones hechas por el sistema deben ser hechas explícitas.

Así, la organización y estructuración de la información en una red semántica nos lleva a una realización eficiente de dos tipos de inferencias: herencia y reconocimiento.

2.2.- Herencia y reconocimiento.

La herencia es la forma de razonamiento que conduce a un agente a inferir propiedades de un concepto basada en las propiedades de sus ascendientes en la jerarquía.

El reconocimiento es el complementario del problema de la herencia. A diferencia de la herencia, que busca un valor de propiedad de un concepto dado, el reconocimiento busca un concepto que tiene algunos valores de propiedad especificados. En este sentido, puede ser argumentado que estas dos formas de razonamiento residen en el corazón de la conducta inteligente y actúan como precursores de procesos de razonamiento más complejos y especializados; ya que ambas son realizadas automáticamente [nota 3].

Sin embargo, se pueden dar casos donde un concepto puede pertenecer a dos jerarquías distintas y tenga problemas a la hora de heredar propiedades; o, por el contrario, puede haber una propiedad que no se aplica a todos los miembros de una clase, es decir, un concepto puede tener una propiedad específica suya que no debe ser heredada por sus descendientes.

Las excepciones y la herencia múltiple conflictiva en redes semánticas dan lugar a no-monotonicidad y ambigüedad, ninguna de las cuales puede ser manejada dentro de la lógica de primer orden (LPO). Consecuentemente, las formalizaciones basadas en LPO de redes semánticas (Charniak, 1981; Hayes, 1979), y muchos lenguajes de representación, tal como KL-ONE (Brachman y Schmolze, 1985), no pueden tratar con excepciones ni situaciones de herencia múltiple. Al mismo tiempo, la traducción a LPO no explica cómo la información codificada en una red semántica puede ser utilizada para solucionar problemas de reconocimiento.

Reconociendo las limitaciones de la LPO en la formalización de las redes semánticas con jerarquías múltiples y excepciones, Etherington y Reiter (1983) propusieron una formalización basada en la lógica por defecto (Reiter, 1980). Su propuesta maneja excepciones, pero su tratamiento de herencia múltiple resulta insatisfactorio. Por ejemplo, en situaciones de herencia múltiple, nuestra intuición sugiere que la conclusión final podría reflejar el efecto 'combinado' de toda la información relevante.

La limitación de la lógica por defecto reside en el supuesto de que todas las afirmaciones tienen la misma importancia ('import'). Este supuesto es inapropiado en muchos casos. La necesidad de combinar información relevante y tasar la importancia relativa de la información disponible llega a ser incluso más aparente si consideramos las creencias del sujeto.

La propuesta de Touretzky (Touretzky, 1986), basada en el Principio de Ordenamiento de la Distancia Inferencial, provee una especificación precisa de qué inferencias serían extraídas por una jerarquía de herencia en situaciones suponiendo excepciones. Su formalismo es también una mejora en la propuesta de Etherington y Reiter en la que se hace explícita la significancia inferencial de los enlaces ES-UN. Sin embargo, Touretzky no soluciona el problema de combinar información desde fuentes dispares, y su sistema presentaría ambigüedades en situaciones de herencia múltiple.

Para tratar con situaciones que suponen información conflictiva es necesario adoptar una representación más rica epistemológicamente que nos permita representar el significado relativo de las reglas. Una posibilidad es tratar las afirmaciones como "los pájaros vuelan" como "**afirmaciones evidenciales**".

Dentro de una formulación evidencial, encontrar soluciones para los problemas de herencia y reconocimiento equivaldría a elegir la alternativa más probable a partir de un conjunto de alternativas; la computación de probabilidad puede ser llevada a cabo respecto del conocimiento codificado en la jerarquía conceptual.

En el modelo CSN de Shastri (1988), para reformular los problemas de herencia y reconocimiento en términos del razonamiento evidencial, extiende la representación tradicional de red semántica para incluir la información evidencial que es codificada en términos de 'frecuencias relativas' que especifican cómo instancias de ciertos conceptos son distribuidas con respecto a ciertos valores de propiedad.

Como hemos visto, 'asociando' simplemente valores de propiedad con tipos no es suficiente. El agente puede querer hacer distinciones más sutiles y utilizar tal información para reconocer cosas y predecir sus propiedades. Un modo de capturar estas distinciones puede ser almacenar distribuciones de frecuencia de los conceptos con respecto a 'ciertos' valores de propiedad. Pero, este enfoque supone una simplificación excesiva, hay situaciones en las que un agente puede tener que codificar una relación evidencial entre un concepto y un valor atributo sin el conocimiento de algunas distribuciones de frecuencia. O, puede haber ocasiones donde la conclusión correcta no sea la más probable sino otra cualquiera.

Así, la elección de designar algún(os) par(es) [propiedad, valor] para ser un concepto está siempre disponible para el agente, pero hacer ésto supone una renuncia por algo bien definido: por un lado, requiere un compromiso de fuentes computacionales adicionales tales como nodos bastante primitivos (tales como los nodos 'encuadernadores' ('binder') que asocian objetos, propiedades y valores de propiedad; y que sólo se activan cuando reciben simultáneamente activación desde un par de nodos), enlaces, elementos de procesamiento, y así sucesivamente, aunque por otro lado, hace más fácil extraer ciertas inferencias.

También, en un sistema como el CSN, puede haber problemas cuando la activación (no) tiene que difundirse más allá de lo "preprogramado". Por ejemplo, este sistema no es capaz de inferir sobre un hecho nuevo ni inferir cosas nuevas que no están en el conjunto de respuestas, fenómeno que podría ocurrir si se utilizase una representación distribuida ya que el nuevo hecho podría llegar a emerger como un modo de 'autoaprendizaje'.

Pero, aunque ha habido intentos de simular las redes semánticas con representaciones distribuidas, especialmente con unidades específicas de rol, no se han conseguido los resultados obtenidos por los sistemas con representación local. Un ejemplo puede ser Hinton (1981).

3.- LIMITACIONES DE LOS MODELOS CONEXIONISTAS.

Aunque las redes conexionistas han salvado muchos problemas irresolubles hasta el momento desde el punto de vista 'clásico', también han recibido críticas (Fodor y Pylyshyn, 1988; Massaro, 1988; Lachter y Bever, 1988; Pinker y Prince, 1988) debido a que muchos problemas no han quedado resueltos del todo, como puede ser la inferencia lógica o el supuesto de los primitivos semánticos.

Así, los conexionistas deben limitarse a expresar cómo se podrían implementar las elaboraciones de un nivel más alto (simbólico versus subsimbólico; Smolensky, 1988).

Hinton, McClelland y Rumelhart (1986) afirman que las representaciones distribuidas podrían contribuir a los formalismos de alto nivel de la psicología computacional clásica (simbólica) de las siguientes formas:

- 1.- Legitimando ciertas operaciones primitivas poderosas, que de otra forma resultarían arbitrarias.
- 2.- Enriqueciendo el repertorio de operaciones primitivas.
- 3.- Sugiriendo que los formalismos de alto nivel sólo pueden descubrir las características primarias de las capacidades computacionales de los mecanismos de procesamiento subyacentes.

En este sentido, varias otras soluciones han sido sugeridas tales como el uso de conexiones dinámicas (Feldman, 1982), 'parallel constraint satisfaction' (Touretzky y Hinton, 1988), codificación específica de la posición (Barnden, 1989), 'tensor product representation' (Dolan y Dyer, 1988) y 'signatures' (Lange y Dyer, 1989).

Por ejemplo, las implementaciones conexionistas de 'sistemas de producción' (Touretzky y Hinton, 1988; Dolan y Smolensky, 1989) o de 'transformaciones sintácticas' (Touretzky, 1986; Chalmers, 1990), operan en items estructurados complejos (por lo general tripletes de la forma (A,B,C)), asociándolos con nuevas estructuras, mientras operan al nivel de la representación distribuida (los constituyentes de las estructuras originales nunca son extraídas explícitamente). Estos modelos asocian ciertos tripletes específicos con otros tripletes específicos -(A,B,C) debe ser

asociado con (N,P,G)- de modo que no sea sistemáticamente dependiente de la estructura presente en los tripletes. Pero, aparte del uso de una noción limitada de 'ligamiento variable' ('variable binding'), no ha habido ningún intento de modelar exactamente operaciones sensibles a la estructura, o de capturar algún tipo de generalización.

Otro importante problema no resuelto para los modelos conexionistas es la representación de estructuras de datos secuenciales y recursivas de tamaño variable, tales como árboles o pilas, en sistemas de recurso fijado (analizadores para oraciones de longitud fijada (Cottrell, 1985; Fianty, 1985; Selman, 1985; Hanson y Kegl, 1987) o los 'flat' (McClelland y Kawamoto, 1986)). Algún diseño de trabajo ha sido realizado en representaciones distribuidas de propósito general con alguna capacidad para estructuras recursivas o secuenciales (Tourezky y Hinton, 1985; Rumelhart y McClelland, 1986), pero ningún sistema hasta la actualidad ha desarrollado la suya propia.

Parte de la razón para la limitación en capacidad generativa, para representar estructuras de datos secuenciales y recursivos de tamaño variable, es que la restricción conexionista del lento cambio de pesos cuando se combinaba con un supuesto 'por defecto' ('default') donde los inputs eran combinados linealmente lleva estrictamente a sistemas de realización de estados finitos. La otra razón es que los tipos de representaciones utilizados por los sistemas conexionistas son bastante primitivos.

Parte de la solución, que ha tratado Pollack (1987), es el uso de combinaciones de alto nivel, o conexiones multiplicativas, que introducen codificación análoga ('analog gating') y reconfiguración dinámica en redes conexionistas. La otra parte de la solución supone encontrar representaciones distribuidas útiles y utilizables.

De este modo, Pollack (1988) presenta mecanismos conexionistas junto con una estrategia general para desarrollar tales representaciones automáticamente: Recursive Auto-associative Memory (RAAM) [nota 4]. Utiliza un régimen modificado de aprendizaje de propagación del error autoasociativo para desarrollar representaciones de extensión fijada y mecanismos de acceso para pilas y árboles. La estrategia supone la co-evolución del medio de entrenamiento junto con los mecanismos de acceso y las representaciones distribuidas. Estas representaciones son composicionales, basadas en la similaridad, y recursivas, y pueden conducir a muchas nuevas aplicaciones de redes neuronales en tareas simbólicas tradicionales.

Un ejemplo, puede ser el experimento realizado por Chalmers (1990) donde utiliza una RAAM para construir representaciones distribuidas de oraciones estructuradas sintácticamente. De

este modo, una red 'feed-forward' es entrenada para operar directamente en estas representaciones, modelando las transformaciones sintácticas de las oraciones representadas y obteniendo un entrenamiento y una generalización satisfactorios, demostrando que la estructura implícita presente en estas representaciones puede ser utilizada por un tipo único de procesamiento sensible a la estructura en el dominio conexionista.

Las operaciones sensibles a la estructura ('structure-sensitive') que son utilizadas aquí son transformaciones sintácticas en oraciones (pasivización de oraciones). Las transformaciones son utilizadas como un ejemplo del tipo de operación compleja y estructurada en lenguaje natural con las que se supone que los enfoques conexionistas tienen dificultades.

Las operaciones son directas y holísticas, pero sus experimentos no explotan el completo potencial de éstas. Después de todo, las transformaciones sintácticas son manejadas fácilmente por sistemas puramente simbólicos. El potencial real de las operaciones holísticas surge por una propiedad especial de las redes conexionistas: pueden llevar su propio contenido, o al menos parte de él. En términos de Hinton (1988), tales representaciones son 'descripciones reducidas' de los objetos originales, representaciones libres de contenido que son el fundamento de los modelos simbólicos. La información transportada en los patrones de activación puede ser utilizada no sólo para la composición y extracción, sino también para operaciones significantes semánticamente (Chalmers, 1990).

Pero, sus representaciones distribuidas composicionales tienen mecanismos de acceso simples y deterministas, un número muy grande de especies primitivas, y la utilización de codificaciones análogas.

La mayoría del trabajo en la teoría del aprendizaje asume que el medio (los datos a ser aprendidos) y el mecanismo de aprendizaje son estáticos. En el caso del niño, sin embargo, este es un supuesto no realista. El aprendizaje del primer lenguaje ocurre precisamente en el punto en el tiempo cuando el niño comienza a experimentar cambios significativos en su desarrollo. Elman (1991), describe los resultados de simulaciones en las que los modelos de redes son incapaces de aprender una gramática compleja cuando la red y el input quedan sin cambiar. Sin embargo, cuando, o bien, el input es presentado incrementalmente, o -más realísticamente- la red comienza con una memoria limitada que gradualmente incrementa, la red es capaz de aprender la gramática. Visto así, las tempranas limitaciones en un aprendiz pueden jugar un rol positivo y crítico, y hacerle posible dominar un cuerpo de conocimiento que podría no ser aprendido en un sistema maduro.

4.- NUEVOS MODELOS COMO ALTERNATIVA .

A partir de las limitaciones de los modelos de red feed-forward, han surgido nuevos modelos que van desde los modelos híbridos a los nuevos modelos derivados de la máquina Boltzmann, como el MFT (Peterson y Hartman, 1989; Peterson, 1991), y, que intentan solucionar los problemas no resueltos satisfactoriamente por los anteriores modelos y por la misma máquina de Boltzmann, como puede ser la cantidad de tiempo que necesita para realizar sus cómputos.

En una máquina Boltzmann, una representación distribuida se corresponde con un mínimo de energía, y, de este modo, el problema de crear una buena colección de representaciones distribuidas es equivalente al problema de crear un buen paisaje energético ("energy landscape"). El algoritmo de aprendizaje que han presentado es capaz de solucionar este problema, y, por consiguiente, hace que las representaciones distribuidas sean considerablemente más plausibles. La difusión de alguna pieza de conocimiento no es una objeción seria, ya que la simplicidad matemática de la distribución Boltzmann hace posible manipular todos los pesos locales difusos de un modo coherente en la base de información puramente local. Por ejemplo, Ackley, Hinton y Sejnowski (1985) ilustran la formación de un conjunto simple de representaciones distribuidas por medio de los problemas codificador (p.164).

El trabajo teórico previo demostraba que la información puede ser almacenada y recuperada sin asumir un almacenamiento diferente de los items individuales (Anderson y Hinton, 1981; Hinton y Anderson, 1981; Kohonen, 1977). Además, los modelos de memoria distribuida han sido aplicados a una variedad de procesos cognitivos, incluyendo aprendizaje asociativo (Anderson, 1983; Eich, 1982; Murdock, 1982), tareas de aprendizaje de listas (Anderson, 1973, 1977), como percepción categorial, análisis de rasgos distintivos, y aprendizaje por probabilidad (Anderson, Silverstein, Ritz, y Jones, 1977).

Así, un sistema conexionista con representaciones puramente distribuidas donde los predicados y los argumentos están representados como patrones hacia un conjunto 'común' de nodos (Hinton, 1981; Touretzky y Hinton, 1988) podría realizar estas propiedades sin necesidad de un interpretador (programa control innato) como lo demuestran los nuevos modelos derivados de la Boltzmann Machine (Mean Field Theory: Peterson y Hartman, 1989; Peterson, 1991; Hinton, 1989; Levy y Bairaktaris, 1991).

Respecto a los modelos convencionales (de procesamiento secuencial) hay diferencias, sobre todo, en el tema del aprendizaje: las reglas y las categorías básicas emergen estadísticamente, y el aprendizaje se da por una adaptación incremental. Pero, estos modelos también tienen sus

limitaciones, como, en detalles de la codificación de los inputs y de la arquitectura de la red, y, en el hecho de que el modelo sólo trata con la adquisición de conocimiento implícito (McClelland, 1988, p.33), o como, la ausencia de una capacidad generativa infinita con una memoria fijada y sin poder trabajar con variables ("crosstalk"; Dyer, 1988).

De este modo, las representaciones conexionistas capturan una noción de adecuación ('appropriateness') en términos de su relación de similaridad con otras representaciones; emplean representaciones que adquieren sus propiedades semánticas naturalmente.

Los nuevos sistemas dinámicos neuronales artificiales utilizan elementos neuronales artificiales con dinamismos neuronales en tiempo real, para explorar varios aspectos del problema "grounding" - esto es, cómo la sintaxis y la semántica del lenguaje puede ser aprendida a través de la interacción simulada del tiempo real con otra información sensorial que contiene una dimensión temporal (Dyer, 1988, p.15)

En este sentido, los nuevos modelos de autoconfiguración de la arquitectura de la red, algunos de ellos híbridos (como el de Fletcher (1991), basado en la Máquina de Boltzmann y en la inferencia lógica) intentan salvar algunos de estos problemas, como, por ejemplo, la ausencia de una semántica clara.

Sin embargo, un area interesante en la que los sistemas conexionistas deben probar su utilidad es el uso de conocimiento a largo plazo en tareas de corto plazo. Cualquier almacenamiento a largo plazo que un sistema pueda tener, necesita un modo de almacenar temporalmente o incrementar la accesibilidad de porciones de la información almacenada que son de relevancia inmediata para el procesamiento.

Una alternativa atrayente ha sido la nueva arquitectura conexionista de Levy y Bairaktaris (1991), que está dirigida a producir una herramienta flexible para el modelamiento de la interacción entre memoria a corto y largo plazo. El modelo es capaz de almacenar incrementalmente varios items desde la memoria a largo plazo en una memoria a corto plazo. El modelo propuesto combina dos arquitecturas de red diferentes: Memoria Asociativa Bidireccional (BAM) y Mean Field Theory (MFT) que sirven respectivamente como almacenamiento a corto y largo plazo. Las propiedades de un sistema BAM se corresponden con todos los principales criterios de diseño de un almacenamiento a corto plazo incremental. Cuando se aumenta con Randomized Internal Representations (RIR) (Bairaktaris, 1991) un sistema BAM puede servir como una memoria auto-asociativa que soporta representaciones hidden y tiene una capacidad y habilidad ampliada para almacenar patrones correlacionados. Los sistemas MFT puede ser poderosos auto-asociadores

capaces de almacenar grandes cantidades de patrones correlacionados (Peterson y Hartman, 1989) ya que pueden utilizar unidades hidden. La interacción entre los dos sistemas está establecida por medio de una representación hidden común -ésta es desarrollada por el algoritmo de aprendizaje MFT y utilizada por el sistema BAM para expandir la dimensionalidad de sus datos y aumentar su capacidad.

Introducen un método donde la información entrante puede ser utilizada para evocar un patrón del almacenamiento a largo plazo (LTS) que puede entonces ser almacenado o "indexado" en un mecanismo de almacenamiento a corto plazo (STS).

EL STS necesita sólo tener una capacidad modesta y quizás habilidades representacionales menos poderosas que el LTS. Sin embargo, si queremos modelar cómo es integrada la información evocada sucesivamente desde el LTS, necesitamos un STS que pueda almacenar patrones incrementalmente. Un método simple de hacer esto sería utilizar una red que pueda ser entrenada utilizando un algoritmo de aprendizaje "one-shot" (regla de Hebb).

Proponen modelar el LTS utilizando un autoasociador con unidades hidden entrenado utilizando el algoritmo de aprendizaje del MFT (Peterson y Anderson, 1989; Hinton, 1989). Su componente STS será implementado utilizando una variación de BAM (Kosko, 1988; Bairaktaris, 1991).

El modelo podría ser utilizado plausiblemente para alguna aplicación que requiera que un número limitado de items de información derivado de un LTS sea hecho temporalmente más accesible almacenándolo incrementalmente en un STS. Los fenómenos posibles que pueden ser modelados de este modo incluyen el almacenamiento temporal de antecedentes posibles para una futura anáfora, los esquemas para los caracteres o sucesos en una narración o alguna fuente de datos que provenga de una tarea donde los items a ser recordados reclutan asociaciones desde la memoria a largo plazo (por ejemplo, Stenning, Sheperd y Levy, 1988). Podrían sugerir que este tipo de modelo parecería especialmente útil para el modelamiento de fenómenos de memoria a corto plazo que requieren acceso a un almacenamiento a largo plazo.

Aunque no solucionan el problema de cómo una memoria a largo plazo representacionalmente poderosa puede ser aumentada incrementalmente (Ratcliff, 1990), la combinación de dos arquitecturas de red versátiles crea una herramienta de modelamiento útil. MFT y la multi-capa BAM son complementarios -el primero siendo poderoso representacionalmente y teniendo una gran capacidad, mientras que el segundo tiene una capacidad más modesta pero es capaz de ser aumentado de modo incremental utilizando el aprendizaje one-shot. Su combinación

muestra una gran esperanza para modelar fenómenos donde la información a corto y largo plazo interactúan.

5.- CONCLUSION.

Como mantiene Varela (1988): "El significado de una palabra en un lenguaje natural es quizá un buen ejemplo de todos los items que habitan nuestro mundo natural: hay que conocer todo el idioma para percibir el significado múltiple de una palabra, que a la vez condiciona el significado de todas las demás. La categorización de cualquier aspecto del mundo natural en que vivimos 'no' tiene límites precisos: no se puede expresar como un dominio a partir del cual elaboramos un mapa".

Siguiendo a Pollack (1988, p.18), uno debería imaginar el procesamiento de alto nivel tomando lugar en las representaciones como un todo, más que excavar ('digging') en su subestructura.

Por ejemplo, los niños jóvenes tienen menos probabilidad de extraer inferencias que ocasiona el discurso -incluyendo, probablemente, inferencias de instanciación- ya que todavía tienen que adquirir un sofisticado conocimiento y habilidad de metacompreensión y metamemoria (Brow, 1975). Otra razón puede ser su ausencia de comprensión de ciertas formas lingüísticas complejas (Spiro, Bruce, y Brewer, 1980, p.340).

La competencia de los niños al utilizar y comprender palabras importantes pero comunes mejora desde la temprana infancia a través de los años de la escuela primaria. Sólo es razonable suponer que alguna de estas mejoras es atribuible a la adquisición de distinciones más finas en los significados de las palabras (por supuesto, es obvio que durante este periodo los niños también aprenderán nuevas palabras y conceptos). Pero, además, hay cambios concurrentes en el funcionamiento del lenguaje. Los niños son capaces incrementalmente de utilizar palabras de un modo despersonalizado y descontextualizado.

La recuperación y su inversa, el olvido, son procesos activos en los que la información en la memoria se recupera y evalúa con respecto al contexto de recuperación y que, a veces, este contexto puede hacer más o menos accesible la información en este almacén. Los procesos de familiaridad y búsqueda en la MLP, así como los procesos de interferencia y construcción, nos muestran el carácter flexible y cambiante de la información en este almacén para acomodarse a las exigencias del ambiente (Ruiz-Vargas, 1991, p. 201; Patel, 1991).

Es razonable asumir que muchas tareas cognitivas que son realizadas con extrema eficiencia tales como la comprensión del lenguaje (por ejemplo, comprensión de diálogo y historias) tienden a suponer sólo un pequeño número de entidades (se refiere a conceptos individuales o abstractos) distintas a un tiempo. Durante el discurso normal tenemos que tratar quizás con tres o cuatro entidades distintas a un tiempo, pero una estimación razonable del máximo número de entidades distintas que podemos tratar a un tiempo es alrededor de siete (Miller, 1956).

Una representación distinta de cada argumento y predicado argumento junto con una codificación explícita de la dependencia inferencial entre argumentos predicado parece esencial si el sistema está esperando aplicar múltiples reglas en paralelo y representar un gran número de ligamientos ('bindings') dinámicos que pueden resultar desde las aplicaciones de estas reglas. En particular, la necesidad de paralelismo de reglas al nivel-conocimiento ha dejado atrás las representaciones puramente distribuidas donde los predicados y los argumentos están representados como patrones hacia un conjunto 'común' de nodos (Hinton, 1981; Touretzky y Hinton, 1988).

En términos de Hinton (1988), sería interesante ver los procesos conexionistas que son sensibles a la estructura mientras se utiliza simultáneamente el tipo de asociación de patrón dependiente del contenido por las cuales las redes conexionistas son renombradas. Esta es la promesa que ha quedado abierta por las representaciones conexionistas implícitamente estructuradas, y es una promesa que conduciría a ideas radicalmente nuevas sobre el procesamiento del lenguaje natural.

6.- NOTAS.

1.- Conseguir dependencias puramente acíclicas no siempre es trivial. Sin embargo, un modo de suprimir dependencias cíclicas es adoptar una descomposición del conocimiento 'bien-granulado' ('fine-grained') para reducir la relación entre el número de dependencias y el número de 'términos' (conceptos, propiedades, rasgos, microrrasgos,...) en la base de conocimiento. Otro modo de eliminar las dependencias cíclicas es identificar restricciones apropiadas en la estructura conceptual que excluyan ciertos tipos de dependencias cíclicas.

2.- Esta noción no es nueva y subyace a las redes semánticas, lenguajes frame, scripts, esquemas, restricciones, o cualquier modo de describir un 'chunk' de conocimiento. La idea de 'vividness' (Levesque, 1988) es un caso especial de esta noción general.

3.- El reconocimiento puede ser visto como una forma muy general de correspondencia de patrones ('pattern matching'); y, las preguntas a la red que combinan reconocimiento y herencia realizan una forma generalizada de 'compleción de patrones' [véase Shastri, 1988, pp. 342-343].

4.- Un modo usual alrededor de este problema de amplitud fija son los modelos híbridos (Waltz y Pollack, 1985; Berg, 1987; Hendler, 1987; Lehnert, 1987). Son modos de diseñar un mecanismo de pila utilizando primitivos conexionistas. Ninguno de estos enfoques son aprendidos, aunque una técnica de aprendizaje robusta debe ser capaz de inducirlos.

7.- BIBLIOGRAFIA.

- Chalmers, D.J. (1990). Syntactic Transformations on Distributed Representations. *Connection Science*, Vol. 2, Nos. 1 y 2.
- Cohen, B. y Murphy, G.L. (1984). Models of Concepts. *Cognitive Science*, Vol. 8, 27-58.
- Dyer, M.G. (1988). Symbolic NeuroEngineering for Natural Language Processing: A Multilevel Research Approach. Technical Report UCLA-AI-88-14.
- Elman, J.L. (1991). Incremental learning, or The importance of starting small. CRL Technical Report 9101. University of California, San Diego.
- Elman, J.L. Representation and structure in connectionist models. University of California, San Diego.
- Feldman, J.A. (1988). Connectionist Representation of Concepts .
En 'Connectionist Models and their Implications', Waltz, D. & Feldman, J. (eds.), Cap. 13, 341-363.
- Feldman, J.A. (1989). Neural Representation of Conceptual Knowledge. En *Neural Connections, Mental Computation*. L. Nadel, L.A. Cooper, P. Cullicover, y R.M. Harnish (eds.). The MIT Press, Cambridge, MA.
- Fletcher, P. (1991). A Self-configuring Network. *Connection Science*, Vol. 3, No. 1, pp. 35-60.

- French, R.M. (1991). Using Semi-Distributed Representations to Overcome Catastrophic Forgetting in Connectionist Networks. CRCC Technical Report 51-1991. Submitted to Cognitive Science Society Conference 1991.
- Hinton, G.E., McClelland, J.L., y, Rumelhart, D.E. (1986). Distributed Representations. In D.E. Rumelhart, J.L. McClelland, & the PDP research group (Eds.), Parallel distributed processing: Explorations in the microstructure of cognition. Volume I. Cambridge, MA: Bradford Books.
- Lachter, J., y, Bever, T.G. (1988). The relation between linguistic structure and associative theories of language learning -A constructive critique of some connectionist learning models. *Cognition* 28, 195-247.
- Levy, J., y, Bairaktaris, D. (1991). A Model of the Interaction Between Long and Short Term Memory. HCRC Edinburgh University.
- Massaro, D.W. (1988). Some Criticisms of Connectionist Models of Human Performance. *Journal of Memory and Language* 27, 213-234.
- McClelland, J.L. (1988). Parallel distributed processing: implications for cognitions and development. Report AIP-47. Department of Psychology. Carnegie Mellon University, Pittsburgh.
- McCloskey, M., y, Cohen, N.J. (1989). Catastrophic interference in connectionist networks: The sequential learning problem. In G.H. Bower (Ed.), *The psychology of learning and motivation*. New York: Academic Press.
- Mozer, M.C., y, Smolensky, P. (1989). Using Relevance to Reduce network Size Automatically. *Connection Science*, Vol. 1, Nº 1.
- Nagy, W., y, Gentner, D. (1990). Semantic Constraints on Lexical Categories. *Language and Cognitive Processes*, Vol.5, Nº3, 169-201.
- Oaksford, M., Chater, N., y, Stenning, K. (1989). Connectionism, Classical Cognitive Science and Experimental Psychology. Research Paper EUCCS/RP-29. Centre for Cognitive Science, University of Edinburgh.

- Patel, M.J., y, Schnepf, U. (1991). Concept Formation as Emergent Phenomena. Cognitive Science Research Paper No 196, University of Sussex.
- Peterson, C. (1991). Mean Field Theory Neural Networks for Feature Recognition, Content Addressable Memory and Optimization. Connection Science, Vol. 3, No. 1, pp. 3-33.
- Peterson, C., y, Hartman, E. (1989). Explorations of the Mean Field Theory Learning Algorithm. Neural Networks, Vol. 2, pp. 475-494.
- Plunkett, K., y, Marchman, V. (1989). Pattern Association in Back Propagation Network: Implications for Child Language Acquisition. Report 8902. Center for Research in Language, C-008. University of California, San Diego.
- Pollack, J.P. (1987). On Connectionist Models of Natural Language Processing. PhD. Department of Computer Science, University of Illinois at Urbana-Champaign. MCCA-87-100. Computing Research Laboratory, New Mexico State University.
- Pollack, J. (1988). Recursive Auto-Associative Memory: Devising Compositional Distributed Representations. MCCA-88-124. Computing Research Laboratory, New Mexico State University.
- Ramsey, W. Connectionism and the representations of concepts.
- Ratcliff, R. (1990). Connectionist Models of Recognition Memory: Constraints Imposed by Learning and Forgetting Functions. Psychological Review, Vol. 97, Nº 2, 285-308.
- Seidenberg, M.S., y, McClelland, J.L. (1989). A Distributed, Developmental Model of Word Recognition and Naming.
- Schneider, W. (1987). Connectionism: Is it a paradigm shift for psychology?. Behavior Research Methods, Instruments, & Computers, 19 (2), 73-83.
- Shastri, L. (1988). A Connectionist Approach to Knowledge Representation and Limited Inference. Cognitive Science 12, 331-392.
- Shastri, L. (1989). THE RELEVANCE TO CONNECTIONISM TO AI: A Representation and Reasoning Perspective. MS-CIS-8905. Department of Computer and Information Science. University of Pennsylvania.

- Shastri, L. (1990). Connectionism and the computational effectiveness of reasoning. *Theoretical Linguistics*.
- Shastri, L., y, Ajjanagadde, V. (1989a). A Connectionist System for Rule Based Reasoning with Multi-Place Predicates and Variables. MS-CIS-89-06. Computer and Information Science Department, University of Pennsylvania.
- Shastri, L., y, Ajjanagadde, V. (1989b). From simple associations to systematic reasoning: A connectionist representation of rules, variables and dynamic bindings. Technical Report: MS-CIS-90-05. University of Pennsylvania.
- Shastri, L., y, Feldman, J.A. (1986). Semantic Nets, Neural Nets, and Routines. In *Advances in Cognitive Science*, (Ed.) N. Sharkey, Ellis Harwood Limited/John Wiley & Sons, Chichester, UK.
- Smolensky, P. (1988). On the Proper Treatment of Connectionism. *The Behavioral and Brain Sciences*, 11, 1-74.
- St. John, M.F., y, McClelland, J.L. (1988). Learning and applying contextual constraints in sentence comprehension. (AIP Technical Report). Pittsburgh, PA: Carnegie Mellon University, Departments of Computer Science and Psychology, and University of Pittsburgh, Learning Research and Development Center.
- Tversky, B., y, Hemenway, K. (1984). Objects, Parts, and Categories. *J.E.P.: General*, Vol. 113, Nº 2.
- Varela, F.J. (1988). *Cognitive Science. A Cartography of Current Ideas*. editorial Gedisa. Barcelona (1990).
- Walker, S. F. (1990). A Brief History of Connectionism and its Psychological Implications. *AI & Society*, Vol. 4, Nº 1, 17-38.

