

# Inteligencia y Robótica Corporizada

Bruno Lara, and Jorge Hermosillo  
Facultad de Ciencias  
Universidad Autónoma del Estado de Morelos  
Av. Universidad 1001, Col. Chamilpa  
Cuernavaca, Mexico  
{bruno.lara, jhermosillo}@uaem.mx

8 de junio de 2011

## Resumen

La Inteligencia Artificial surge como parte de las ciencias cognitivas en un momento en el que la inteligencia y los procesos cognitivos se suponían consistir en un procesamiento lineal y unidireccional de información. Es sólo en las últimas décadas que esta área, junto con algunas otras de las ciencias cognitivas, tiene un cambio de dirección, creando nuevos paradigmas y escuelas de pensamiento. Dentro de las escuelas más importantes está la que insiste en que una condición necesaria para la inteligencia es que los agentes se desarrollen dentro de un medio ambiente. Es sólo a través de la interacción sensori-motriz del agente con su entorno que se desarrollan las capacidades cognitivas que conocemos. Esta es la razón por la que ahora los robots o agentes artificiales autónomos se han convertido en una pieza clave para tratar de desentrañar el misterio que encierra la inteligencia natural, siendo al mismo tiempo, candidatos ideales en la búsqueda de inteligencia artificial. La investigación presentada en este trabajo está enmarcada en lo que ahora se conoce como Robótica Corporizada. En este trabajo se presentan algunos resultados seleccionados de las investigaciones que hemos llevado a cabo en nuestro laboratorio para tratar de acercarnos a agentes artificiales autónomos con signos de inteligencia y que representan la base para la producción de comportamiento coherente.

## 1. Introducción

La investigación reportada en este artículo tiene dos objetivos generales y concurrentes. El primero es el desarrollo de agentes artificiales capaces de interactuar con su entorno mediante modelos cognitivos. Nos interesa estudiar estos modelos para investigar su capacidad de proveer a los agentes con las herramientas necesarias para producir comportamiento coherente. En segundo lugar, esperamos que el estudio e implementación de estos modelos coadyuve en la comprensión de los procesos que subyacen en el comportamiento inteligente de agentes naturales.

Esta investigación está fundamentada en la importancia de predicciones y acciones como parte de los procesos del sistema cognitivo (Sección 2.1). La investigación está enmarcada en el campo de la *cognición corporizada* (embedded cognition), la cual representa una nueva visión de la Inteligencia Artificial [1], [2].

La cognición corporizada tiene como principio básico que los agentes tienen que tener un cuerpo e interactuar activamente con su entorno. Es a través de esta interacción que los agentes aprenden y entienden su entorno. La motivación de este enfoque surge de una revisión crítica de los paradigmas que marcaban la pauta de la investigación en Inteligencia Artificial hasta hace un par de décadas.

### 1.1. Vieja Inteligencia Artificial

Una visión ampliamente aceptada de la cognición explica la conducta como el resultado de una línea directa, unidireccional, de procesamiento de información. Entradas de datos sensoriales crean una representación que se traduce en una acción motriz. Las acciones se consideran reacciones, respuestas a estímulos, y la mayor parte del comportamiento observado es considerado una consecuencia del mecanismo innato de estímulo y respuesta disponible al individuo ([3]).

Este marco, conocido como *la metáfora del procesamiento de información*, considera a los procesos de percepción como módulos independientes que reciben, modifican y pasan la información. Esta información era concebida como representaciones sensoriales formadas por los estímulos recibidos y manipulados por los diferentes procesos cognitivos.

Este marco proveyó a los investigadores en las ciencias cognitivas, con la oportunidad de considerar y trabajar en módulos aislados con habilidades de manipulación y procesamiento especializadas ([4], [5]). La inteligencia artificial buscaba sistemas artificiales capaces de manipular el tipo correcto de representaciones usando el conjunto correcto de reglas.

Las ciencias cognitivas también se encontraron siguiendo estas hipótesis acerca del funcionamiento del cerebro y la mente. Estas ideas estaban agrupadas alrededor de los principios del cognitivismo, afirmando que las funciones centrales de la mente podían explicarse en términos de manipulación de símbolos de acuerdo a reglas específicas ([6]).

En Inteligencia Artificial y Robótica, los agentes implementados con este enfoque caen en el conocido problema de la cimentación de símbolos. Este prob-

lema, presentado por Steven Harnard ([7]), expone que los símbolos *otorgados o implementados* en los agentes carecen del vínculo hacia sus referentes necesario para establecer categorías entre los objetos del mundo([8]).

## 1.2. Nueva Inteligencia Artificial

Un enfoque nuevo en la Inteligencia Artificial considera la entrada de datos sensoriales y la acción motriz de un agente como parte del mismo proceso cognitivo. Entre otros, los puntos de vista ecologistas, defendidos por Gibson [9], sugieren un vínculo directo entre acción y percepción. La importancia del cuerpo del agente y su relación dinámica con el entorno es central en este enfoque.

Para las nuevas escuelas, las situaciones sensoriales también se consideran como consecuencias de acciones. El enfoque del proceso lineal de información ha dado su lugar a nuevos marcos de acuerdo a los cuales el flujo de información ya no es una trayectoria en una sola dirección. Cualquier acción realizada por un agente sobre su entorno tiene efectos (efectos de acción) y son la razón principal para la conducta. Representaciones que codifican las consecuencias ambientales y corporales de un movimiento se asocian con representaciones motrices que codifican este movimiento ([10]).

Estas ideas han recibido mucha atención recientemente en el campo de la psicología cognitiva. Un marco general se basa en conceptos ideomotrices del control de acciones. Estos puntos de vista enfatizan el papel que juegan estados internos, tales como metas o intenciones, para la realización de acciones, despreciando a diferentes niveles las condiciones sensoriales externas.

Sólo recientemente se ha valorado la idea de que la anticipación de acciones y/o los estados sensoriales pueden influenciar la conducta. Ahora se considera que la anticipación juega un papel importante en la coordinación, planeación y realización de la conducta ([11]). La planeación y el control de acciones se vuelven anticipatorios cuando están gobernados por las situaciones sensoriales deseadas o los efectos deseados de las acciones.

## 2. Modelos Internos

Los elementos centrales en estos procesos son los modelos internos. Un modelo interno es un mecanismo neuronal que imita las características de entrada/salida, o su inverso, del aparato sensorio-motor.

Dentro de los modelos internos más estudiados en el campo de la nueva Inteligencia Artificial encontramos a los modelos inversos y a los modelos directos. Éstos, provenientes de la teoría de control clásica, nos permiten modelar comportamientos sencillos y básicos de agentes naturales. En las últimas décadas, estos modelos han tenido una gran acogida en la comunidad de las ciencias cognitivas, desde las neurociencias ([12], [13]) y la filosofía ([14], [15]), hasta la robótica ([16], [17], [18],[19]).

Un modelo inverso es un *controlador* que, dada un situación sensorial en un tiempo  $t$  y una situación sensorial deseada para el tiempo  $t + 1$  provee al agente

con el comando matriz  $M_t$  necesario para alcanzar ese estado.

Inversamente, un modelo directo es un modelo interno que incorpora conocimiento acerca de cambios sensoriales producidos por acciones autogeneradas de un agente. Esto es, dada una situación sensorial  $S_t$  y un comando motor  $M_t$  (una acción planeada o real) el modelo directo predice la siguiente situación sensorial  $S_{t+1}$ . Los modelos directos proveen una alternativa a los enfoques clásicos mencionados en la Sección 1.1. Möller [20] sugirió los modelos directos como una posibilidad de integrar percepción visual y generación de acción.

En el ámbito de agentes artificiales autónomos, la anticipación y los modelos directos se pueden usar como base para la conducta coherente. Como se mencionó en la Sección 1, los agentes autónomos interactúan con su entorno de manera directa. Una necesidad básica para que ellos encaren su mundo es predecir lo que está sucediendo. Un agente anticipatorio, aprendiendo y usando un modelo directo, deberá tener suficiente información para formar estrategias de planeación que eviten situaciones no deseadas, reaccionando a tiempo a los peligros de su entorno.

Las predicciones de los agentes se basan en los datos de entrada del modelo directo y se caracterizan por la asociación entre diferentes tipos de estímulos. Estas asociaciones pueden considerarse un evento compuesto por el comando matriz y las situaciones sensoriales (reales y deseadas) [21].

## 2.1. Modelado de procesos cognitivos

En nuestra investigación consideramos como la unidad fundamental de la cognición un ciclo sensori-motriz ([22]). Es consecuencia lógica que nuestros modelos necesiten estar *albergados* en cuerpos, por lo que hacemos uso de agentes autónomos artificiales, robots. Los trabajos presentados en este artículo intentan proveer a agentes artificiales con herramientas necesarias para predecir situaciones no deseadas.

En general, los modelos que se implementan en los robots producen comportamientos sencillos y básicos de agentes naturales. Por principio, se busca que estos modelos no hagan uso de representaciones sensoriales, de tal forma que sólo se valgan de las capacidades y características sensorimotrices del agente. Sin embargo, y como se explicará más adelante, es interesante explorar modelos que tienen la posibilidad de tomar en cuenta ciertas hipótesis y representaciones de más alto nivel, que permiten proponer alguna explicación de ciertos procesos cognitivos que se pueden dar en tareas más complejas. En todos los casos reportados, excepto uno, los agentes hacen uso de modelos adquiridos mediante la interacción de éstos con el medio en el que se desenvuelven.

## 3. Implementaciones

En los experimentos aquí descritos se usan dos robots. El primero es un robot simulado que se desarrolla en un ambiente de dos dimensiones y que cuenta con una cámara lineal omnidireccional y un arreglo de parachoques binarios. El

segundo robot es tanto simulado como real y es un Pioneer 3-DX que cuenta con un arreglo de sonares distribuidos como se muestra en la Fig. 1. Estos emiten lecturas de distancia a los objetos mas cercanos hasta una distancia de 5 metros. El robot real cuenta tambien con una camara web montada en la parte frontal con la cual puede tomar imagenes bidimensionales de su entorno.

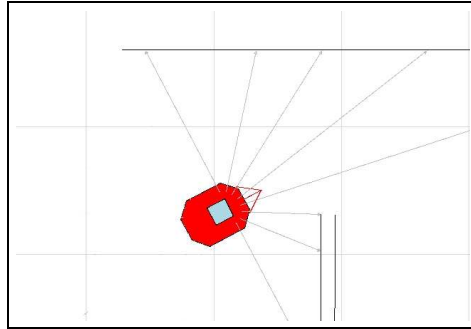


Figura 1: Distribucion de los sonares en el Pioneer P3-DX

### 3.1. Cámara lineal

Para este caso de estudio, el modelo directo se obtiene entrenando una red neuronal artificial con datos que vienen de un agente simulado, la red es validada utilizando trayectorias no vistas durante el entrenamiento. El sistema completo se implementa en el agente para resolver la tarea de buscar una fuente de luz evitando obstáculos en el ambiente ([23],[24]).

Se requiere un modelo que sea capaz de predecir información visual y los estados del parachoques simulado. La implementación toma la forma del modelo en la Figura 2, donde la situación sensorial actual esta compuesta por las imagenes visuales  $V$  a los tiempos  $t$ ,  $t + 1$   $t + 2$ . Se espera que esta forma en los datos de entrada provea al modelo la suficiente información para capturar la estructura temporal de los datos. La salida del modelo directo es la escena visual y el estado de los parachoques para el tiempo  $t + 3$ , esto es  $V_{t+3}$  y  $B_{t+3}$  respectivamente.




Figura 2: Modelo directo implementado

Para obtener un modelos *afinado*, esto es, capaz de proveer una predicción útil para el agente, se entrena una red con ejemplos de pares entrada/salida.

Cada una de las escenas visuales es extraída de una cámara lineal simulada y consta de una línea de píxeles que representa los  $90^\circ$  grados del frente del robot. Cada una de las situaciones táctiles,  $B$ , consta de 50 valores, esto es equivalente a un valor por cada píxel codificado, por lo que cada valor en el arreglo de  $B$  tiene una correspondencia espacial en los  $90^\circ$  representados en las imágenes. Es importante hacer notar que para esta salida la red se entrena con valores de 0 cuando no hay colisión y un valor de 1 cuando si la hay pero para los 50 valores, sin importar en donde fue la colisión, esto es, cuando existe una colisión la red deben aprender a predecir un valor de 1 para *todos* los valores.

Se espera que la red lleve a cabo dos tipos de predicción. Primero, una predicción de un paso (OSP), esto es, dados los valores para  $V_t$ ,  $V_{t+1}$  y  $V_{t+2}$  predecir los valores para  $V_{t+3}$  y  $B_{t+3}$ . Esto se puede considerar como la salida estándar de una red neuronal. En segundo lugar se espera que las redes lleven a cabo una predicción de largo plazo (LTP), esta consiste en usar la salida (predicción) del sistema como entrada a este mismo. El segundo tipo de predicción es comparable a una simulación interna de eventos. Una vez entrenada la red, la activación de las neuronas que predicen el estado de los parachoques no es binaria, su activación incrementa conforme el agente se acerca a un obstáculo. Mas importante aún, las neuronas que muestran un incremento en la activación son las que se encuentran en el lado del agente por el que los obstáculos se aproximan o en donde ocurren cambios significativos en el área visual.


Una vez entrenado, el modelo directo fue implementado en el agente simulado que se utilizó para recolectar los datos. Los datos que vienen de la cámara son preprocesados y alimentados a la red en línea, mientras el agente se mueve. El robot tiene la tarea de seguir una fuente de luz, evitando colisiones en un ambiente en donde existe un cierto número de obstáculos. La habilidad del agente de seguir la fuente de luz es completamente independiente del modelo directo, el sentido visual (la información proveniente de la cámara) y el sentido táctil (el parachoques).

La Figura 3 muestra al robot una vez que alcanza la fuente de luz, evitando un número de obstáculos. El robot lleva a cabo una trayectoria recta hasta que las neuronas, codificando los estados del parachoques, presentan alta activación. El robot lleva a cabo entonces una simulación interna que lo lleva a cambiar el curso de la trayectoria.

Este agente es capaz de predecir las consecuencias de sus propias acciones y al mismo tiempo de tomar decisiones necesarias para acciones futuras. El sistema realiza esto aprendiendo una asociación entre estímulos visuales y estímulos táctiles. Esta representación multimodal puede ser categorizada como un evento en el contexto que provee TEC [21].


Vale la pena notar que la decisión de cambiar curso tomada por el agente esta basada solamente en los valores presentados por las neuronas relacionadas a la predicción del estado de los parachoques, no en las neuronas relacionadas a la predicción visual. Interpretamos esto como que el agente toma una decisión basado en la predicción de una colisión futura, dada la estimulación táctil que recibiría si continuara en esa trayectoria.

Tomando en cuenta la definición del modelo directo, este provee a los agentes



*Figura 3: Robot siguiendo sobre la fuente de luz y despues de a haber evitado una serie de obstáculos en su trayectoria.*

con un sentido de agencia al dotarlos de la capacidad de saber si un cambio en el ambiente fue consecuencia de acciones propias o de factores externos. Una prueba de esta capacidad se ilustra en las Fig. 4, 5 y 6, donde observamos, para los tres casos, un agente que se desplaza en un ambiente. Despues de un número de pasos (6) los obstaculos son cambiados de posición. El modelo directo reporta un error significativo cuando se registra este cambio en el ambiente, la situación sensorial predicha o esperada es distinta a la real, lo cual resulta en un error significativo (Fig. 7).



*Figura 4: Experimento 1. El obstaculo en el centro se desplaza hacia abajo alejandose del robot.*

La misma red, una vez entrenada se implementa en un robot real Pioneer 3D-X, haciendo uso de una camara al frente de este, observamos el mismo comportamiento. El robot es capaz de deambular por nuestro laboratorio evitando situaciones no deseadas.




Figura 5: Experimento 2. Los dos obstáculos superiores se desplazan hacia abajo alejándose del robot.




Figura 6: Experimento 3. El obstáculo en el centro se acerca al robot.

### 3.2. Sonares

Usando los sonares del robot no se necesitan imágenes de tres tiempos consecutivos para capturar la estructura espacial del entorno. Un modelo directo que usa esta modalidad sensorial se podría ver de la forma ilustrada en la Fig. 8.

Un rearrreglo de las entradas y salidas nos permite visualizar al modelo directo como nodo de un árbol. Dada una situación sensorial, en este caso, una lectura de los sonares, el modelo directo simula cualquiera de los movimientos con los que ha sido entrenado, en este caso moverse hacia la izquierda, derecha o el frente (Fig 9).

La repetición de estas simulaciones internas provee al agente con un árbol de posibles situaciones sensoriales. Una vez construido este árbol, el agente puede evaluar de acuerdo a algún criterio los posibles caminos que lo lleve desde su posición inicial, la raíz del árbol, hasta una situación deseada. Como se ve en la Fig. 10, para cada nivel del árbol, existe un movimiento que es *mejor* que los otros dos, característica que deberá ser aprendida también de manera directa por el agente. Una situación candidato, es aquella que mantiene al agente mas




Figura 7: Error Cuadratico (SSE) entre la predicción de la red y los valores reales.




Figura 8: Modelo directo usando sonares.

lejos de los obstáculos, ocasionando una trayectoria libre de colisiones.

Escoger el *mejor* movimiento a seguir para cada nivel del árbol, produce un camino ideal, como se puede ver en la Fig 10.

#### 4. Acoplamiento Modelo Directo - Modelo Inverso

El acoplamiento de modelos internos ha sido propuesto en algunos trabajos [25], [26] como un mecanismo plausible para explicar la capacidad del ser humano para generar comportamientos motrices precisos y apropiados bajo distintas e inciertas condiciones ambientales.

La idea es que el Sistema Nervioso Central (SNC) introduce retrasos en las señales sensoriales y motoras que son compensados por un mecanismo de anticipación sensorial (modelo directo) acoplado con un sistema de control motor (modelo inverso) que permite una ejecución de movimientos que se "ajusta" una vez que se retroalimentan las señales sensoriales reaférentes.

En los trabajos citados, este acoplamiento de un modelo directo con un modelo inverso constituye un módulo de procesamiento. La ventaja de considerar una




Figura 9: Modelo directo como nodo.

arquitectura modular del sistema motor (control del comportamiento) es que es posible explicar distintos comportamientos como la configuración de distintos módulos adaptados a diferentes circunstancias y dinámicas que se aprenden a través del tiempo.

Como parte de nuestros trabajos de investigación se comenzó a explorar el acoplamiento de un modelo directo con un modelo inverso utilizando dos técnicas de modelado distintas, por su naturaleza y por su filosofía.

En las secciones anteriores, se ha discutido la implementación de un modelo directo mediante el uso de redes neuronales. En la siguiente sección se introduce la técnica probabilista para implementar un modelo inverso que se acopla con un modelo directo de manera a realizar una tarea de navegación sencilla.

#### 4.1. Modelado Probabilista de la Cognición

A diferencia de los modelos conexionistas (redes neuronales), el modelado probabilístico de la cognición sigue una estrategia que comienza por plantear principios abstractos que permiten a un agente resolver los problemas de su entorno, emulando funciones cognitivas de la mente, tratando después de hacer que estos principios abstractos converjan en procesos psicológicos y neuronales. La ventaja de este enfoque consiste en proponer una teoría matemática robusta para modelar procesos de inducción: muchos procesos cognitivos como la adquisición de un concepto o de un modelo causal requieren de conjeturas inciertas, a partir de información parcial o contaminada.

La teoría de la probabilidad provee una solución al problema de la inducción indicando la forma en que un agente que aprende debe revisar sus grados de creencia sobre un conjunto de hipótesis, a la luz de información proporcionada por datos de observación del mundo. Esta solución está dada por el Teorema de Bayes de donde las técnicas de modelado adquieren su nombre.

El uso de modelos probabilistas de la cognición permite explorar un amplio rango de hipótesis sobre cómo se resuelven problemas inductivos y sobre las representaciones que pueden estar asociadas a esas soluciones. La hipótesis es que las funciones cognitivas, como la percepción, el aprendizaje, el razonamiento, y la decisión, pueden describirse como formas de inferencia probabilista, lo que necesariamente implica una fuerte caracterización del problema inductivo

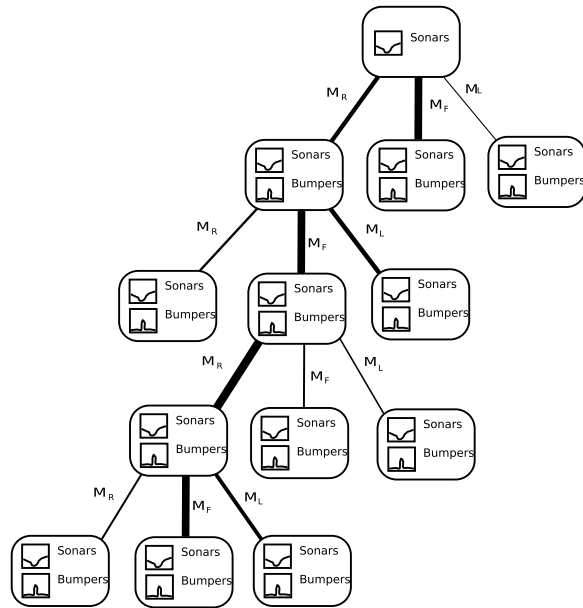


Figura 10: Construcción de un árbol.

a resolver, obligando a especificar las hipótesis a considerar y su relación con datos observables.

En el ámbito de la robótica cognitiva, las funciones cognitivas se abstraen mediante modelos probabilistas o bayesianos, que se estructuran en función del conocimiento a priori sobre el problema y de la interacción entre el robot y su entorno.

Una característica del modelado probabilista, es que el método permite elevar el nivel de estructuración y explorar distintas formas de representación de la solución a un problema, a costa de elevar el número de hipótesis sobre su solución (*inductive bias* en inglés). Si bien esta es una crítica fuerte a esta técnica, una ventaja indiscutible es que permite modelar muchas funciones cognitivas de alto nivel [27].

## 4.2. Modelado Híbrido

Como parte de nuestro trabajo de investigación, hemos comenzado a explorar la combinación de modelos conexionistas y probabilistas, tratando de obtener lo mejor de ambos métodos, con el fin de plantear nuevos modelos cognitivos para realizar tareas robóticas cada vez más complejas.

Un primer resultado de este trabajo se expone a continuación.

### 4.3. Control Bayesiano

Nuestro robot es un Pioneer P3-DX equipado con 8 sonares al frente, cubriendo un área de  $180^0$ . Cada sensor  $i$  proporciona una distancia  $D^i$  al obstáculo más cercano (ver Figura 1). Además, el robot es controlado en velocidad  $V$  y desviación angular  $\delta\theta$ . De esta forma, definimos la situación motora o acción actual (presente) por la variable  $M_t^* := (V, \delta\theta)$ . Definimos también, la situación sensorial actual reportada por el sensor  $i$  como el valor mismo de la variable  $D^i$ . Llamamos  $D_d^i$  y  $M_t'$  la situación sensorial deseada (futura) y el comando motor deseado (i.e. el comando motor que conduce a la situación  $D_d^i$ ) respectivamente.

El propósito es modelar el comportamiento siguiente: Entre más lejos se encuentre el robot de un obstáculo, más la situación sensorial deseada  $D_d^i$  debe producir un comando motor que mantenga inalterado el curso de la trayectoria nominal. Por el contrario, cuanto más cerca se encuentre el robot de un obstáculo, cuanto más la situación sensorial deseada  $D_d^i$  debe producir un comando motor seguro que evite el obstáculo desviándose de la trayectoria nominal. Este problema se traduce en encontrar una asociación funcional entre la situación sensorial actual  $D^i$  y el comando motor actual  $M_t^*$  que conduzcan a la situación sensorial deseada  $D_d^i$ , mediante la aplicación del comando motor deseado  $M_t' := (V', \delta\theta')$ .

En nuestro marco teórico, esto se logra mediante el acoplamiento de modelos internos. Por un lado, el modelo directo predice situaciones sensoriales futuras ( $D_d^i$ ) a partir de situaciones sensoriales y acciones actuales ( $D^i$  y  $M_t^*$ ). Por otra parte, el modelo inverso permite generar comandos motores deseados ( $M_t'$ ) a partir de situaciones sensoriales deseadas ( $D_d^i$ ). La solución propuesta consiste en utilizar una red neuronal para el modelo directo y una red bayesiana para el modelo inverso de manera a producir el comportamiento deseado (Fig. 11).

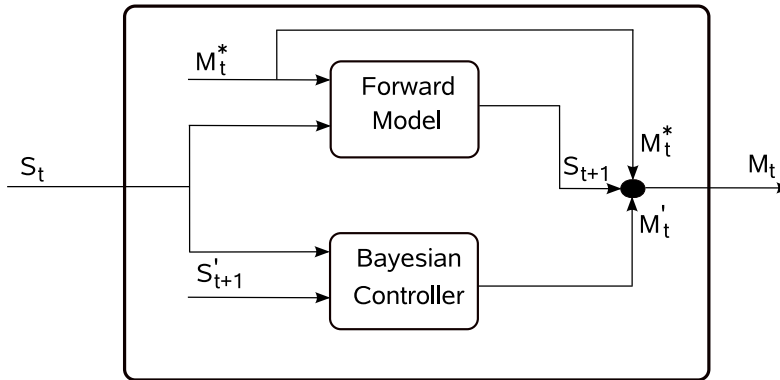


Figura 11: Modelo híbrido propuesto [28].

## 5. Discusión

Desde su surgimiento como una ciencia que busca la creación de máquinas inteligentes, la Inteligencia Artificial había seguido las pautas del estudio de la cognición humana marcadas por las escuelas y paradigmas existentes.

A partir de la década de los ochentas, la Inteligencia Artificial comenzó a replantear sus principios. Una de las consecuencias más visibles es que en nuestros días la investigación en esta área se lleva a cabo mediante el uso de Agentes Artificiales Autónomos (robots). Ahora se sigue como principio que para lograr obtener máquinas inteligentes, se necesita estudiar la cognición desde un punto de vista corporizado, esto es, se necesita de agentes que interactúen con su ambiente que se desarrollen y aprendan a través de su interacción con éste.

Un modelo que ha cobrado importancia es el llamado modelo directo. Mediante su implementación en agentes, tanto simulados como reales, hemos demostrado su importancia en la producción de comportamientos coherentes. Explotando sus capacidades, los agentes logran anticipar situaciones no deseadas.

Un tema muy interesante para explorarse es el sentido de agencia que los modelos directos le proveen a los agentes. Según algunos autores ([14]) esta capacidad debería sentar las bases para la conciencia al otorgar a los agentes el sentido de autoría de sus acciones.

Por otra parte, el acoplamiento Modelo Directo - Modelo Inverso (*md-mi*), como el reportado en [25], [26], permite entender un proceso sensori-motor muy eficaz que consiste en alcanzar una situación sensorial deseada en forma efectiva (es decir, con los elementos de precisión y rapidez adecuados para que el agente logre su objetivo).

Este modelo de acoplamiento posee una funcionalidad “puramente mecánica”, en el sentido de que el acoplamiento sirve para ajustar de manera rápida y fina el movimiento (control motor), mediante un ciclo de control que emite un comando motor que cesa cuando la diferencia entre la situación sensorial deseada y la situación sensorial actual se reduce a cero. Durante este ciclo, el modelo directo provee una predicción de la situación sensorial futura, dados la situación sensorial actual y el comando motor que emite el modelo inverso. La función de anticipación del modelo directo es crucial para la función de ajuste de la velocidad y la precisión del comando motor del modelo inverso.

La importancia del acoplamiento logrado en nuestros trabajos de investigación radica en dos aspectos. Por un lado, se están combinando dos técnicas de modelado que son distintas por su naturaleza y su filosofía. En efecto, la red neuronal no prejuzga sobre la estructura de la solución al problema de construir un modelo directo para la predicción del estado del mundo, lo que permite que esta estructura emerja como consecuencia de la interacción del robot con su entorno (aprendizaje supervisado). La red bayesiana, por el contrario, utiliza conocimiento a priori que se ha empleado para estructurar una solución al problema de navegar en forma segura (es decir, evitando los obstáculos).

Si bien la alternativa de un aprendizaje del modelo inverso por la red bayesiana a partir de datos experimentales (es decir, mediante la interacción del robot con su entorno) hubiese sido igualmente realizable, lo que nuestro experimento per-

mite demostrar es que la utilización del conocimiento a priori en el modelo bayesiano permite elevar el nivel de abstracción, lo que en nuestra opinión, abre nuevas posibilidades para el modelado de funciones cognitivas de más alto nivel mediante la conjunción de ambos enfoques.

Por otro lado, este acoplamiento se distingue del acoplamiento de Wolpert et. al. ([25] y [26]) en que el modelo inverso posee una funcionalidad adicional. Ésta consiste en decidir si la predicción del modelo directo es “riesgosa”, en cuyo caso, en lugar de emitir un comando motor que permita alcanzar el estado sensorial futuro (es decir, el estado sensorial anticipado por el modelo directo como consecuencia del comando motor actual) emite un comando motor distinto (uno para el cuál la predicción del modelo directo arroje una situación sensorial “segura”).

Bajo ciertas consideraciones aún por dilucidar, el acoplamiento que proponemos podría explicar ciertos comportamientos de alto nivel (comportamientos que implican cierto nivel de decisión) por ejemplo: un comportamiento tendiente a evitar un obstáculo puede conducir a la necesidad de re-planear una trayectoria para alcanzar un objetivo (la situación sensorial deseada), lo que conlleva necesariamente a una nueva forma de alcanzarlo; esto es, un acoplamiento que permita llegar a la situación deseada a partir de la nueva situación de partida.

## Referencias

- [1] R. Pfeifer and C. Scheier, *Understanding Intelligence*. Cambridge, MA: MIT Press, 1999.
- [2] M. Wilson, “Six views of embodied cognition,” *Psychonomic Bulletin & Review*, vol. 9(4), pp. 625–636, 2002.
- [3] M. Witkowski, “Anticipatory learning: the animat as a discovery engine,” in *Adaptive Behaviour in anticipatory learning systems (ABiALS’02)*, B. M. V., P. Gerard, and S. O., Eds., Edinburgh, Scotland, 2002.
- [4] R. Pfeifer and C. Scheier, “From perception to action: The right direction?” in *From Perception to Action*, P. Gaussier and J.-D. Nicoud, Eds. Los Alamitos, CA: IEEE Computer Society Press, 1994, pp. 1–11.
- [5] R. A. Brooks, “Intelligence without representation,” *Artificial Intelligence*, vol. 47, pp. 139–159, 1991.
- [6] D. M. L. Anderson, “Embodied cognition: A field guide,” *Artificial Intelligence*, vol. 149, no. 1, pp. 91–130, September 2003. [Online]. Available: <http://cogprints.org/3949/>
- [7] S. Harnad, “The symbol grounding problem,” *Physica D*, vol. 42, pp. 335–346, 1990. [Online]. Available: <http://cogprints.org/615/>

- [8] D. Rodriguez, J. Hermosillo, and B. Lara, "Meaning in artificial agents: The symbol grounding problem revisited," *Minds and Machines*, Submitted.
- [9] J. J. Gibson, *The ecological approach to visual perception*. Boston: Houghton Mifflin, 1979.
- [10] G. Knoblich and W. Prinz, "Linking perception and action: An ideomotor approach," in *Higher-order motor disorders*, H.-J. Freund, M. Jeannerod, M. Hallett, and R. C. Leiguarda, Eds. Oxford, UK: Oxford University Press, 2005.
- [11] M. V. Butz, O. Sigaud, and P. Gerard, "Internal models and anticipations in adaptive learning systems," in *Adaptive Behaviour in anticipatory learning systems (ABiALS'02)*, P. Butz M. V., Gerard and S. O., Eds., Edinburgh, Scotland, 2002.
- [12] S. J. Blakemore, D. Wolpert, and C. Frith, "Why can't you tickle yourself?" *Neuroreport*, vol. 11, pp. 11–16, 2000.
- [13] Z. G. DM Wolpert and M. Jordan, "An internal model for sensorimotor integration," *Science*, vol. 269, no. 5232, pp. 1880 – 1882, 1995. [Online]. Available: <http://www.sciencemag.org/content/269/5232/1880.abstract?sid=23569266-2c7e-4593-9b42-7e93a1a3d71b>
- [14] J. Kiverstein, "Could a robot have a subjective point of view?" *Journal of Consciousness Studies*, vol. 14, no. 7, pp. 127–139, 2007.
- [15] G. Hesslow, "Must machines be zombies? internal simulation as a mechanism for machine consciousness," 1999.
- [16] M. Kawato, "Internal models for motor control and trajectory planning," *Current Opinion in Neurobiology*, vol. 9, pp. 718–727, 1999.
- [17] M. I. Jordan and D. E. Rumelhart, "Forward models: Supervised learning with a distal teacher," *Cognitive Science*, vol. 16, pp. 307–354, 1992.
- [18] H. Hoffmann and R. Moeller, "Action selection and mental transformation based on a chain of forward models," in *Proc. of the 8th Int. Conference on the Simulation of Adaptive Behavior*. Cambridge, MA: MIT Press, 2004, pp. 213–222.
- [19] B. Lara and J. M. Rendon, "Prediction of undesired situations based on multi-modal representations," vol. 1. Los Alamitos, CA, USA: IEEE Computer Society, 2006, pp. 131–136.
- [20] R. Möller, "Perception through anticipation. A behavior-based approach to visual perception," in *Understanding Representation in the Cognitive Sciences*, A. Riegler, A. von Stein, and M. Peschl, Eds. New York: Kluwer Academic Publishers, 1999, pp. 169–176.

- [21] B. Hommel, J. Müsseler, G. Aschersleben, and W. Prinz, “The theory of event coding (TEC): A framework for perception and action planning,” *Behavioral and Brain Sciences*, vol. 24, pp. 849–937, 2001.
- [22] M. Lungarella, G. Metta, R. Pfeifer, and G. Sandini, “Developmental robotics: a survey,” *Connection Science*, vol. 15, pp. 151–190, 2003. [Online]. Available: <http://www.informaworld.com/10.1080/09540090310001655110>
- [23] B. Lara, J. M. Rendon, and M. Capistran, “Forward models and the prediction of undesired situations,” *Research in Computing Science*, vol. 21, pp. 161–170, 2006.
- [24] B. Lara, J. M. Rendon, and M. Capistran, “Prediction of multi-modal sensory situations, a forward model approach,” in *Proceedings of the 4th IEEE Latin America Robotics Symposium*, vol. 1, 2007.
- [25] D. M. Wolpert, R. C. Miall, and M. Kawato, “Internal models in the cerebellum,” *Trends in Cognitive Sciences*, vol. 2, no. 9, pp. 338 – 347, 1998. [Online]. Available: <http://www.sciencedirect.com/science/article/B6VH9-3TX4M94-6/2/96461cc0e36e558776bfbfd846fd225cf>
- [26] D. M. Wolpert and M. Kawato, “Multiple paired forward and inverse models for motor control,” *Neural Networks*, vol. 11, pp. 1317–1329, 1998.
- [27] T. L. Griffiths, N. Chater, C. Kemp, A. Perfors, and J. B. Tenenbaum, “Probabilistic models of cognition: exploring representations and inductive biases,” *Trends in Cognitive Sciences*, vol. 14, no. 8, pp. 357–364, 2010.
- [28] B. Lara and J. Hermosillo, “Cognitive hybrid control of an autonomous agent,” in *Proceedings of the 2008 Electronics, Robotics and Automotive Mechanics Conference*. Washington, DC, USA: IEEE Computer Society, 2008, pp. 526–531. [Online]. Available: <http://portal.acm.org/citation.cfm?id=1440458.1440751>