

Predicción de Situaciones no Deseadas Basada en Representaciones Multimodales

Bruno Lara, Juan M. Rendon, *Member, IEEE*, y Marcos A. Capistran

Resumen—La investigación presentada en este artículo esta fundamentada en la importancia que los conceptos de predicción y acción juegan en el proceso perceptual de un sistema cognitivo. Para lograr esto se utilizan los modelos directos como una herramienta cognitiva básica. Se deja interactuar una gente artificial con su entorno, dicho agente esta equipado con un modelo directo que deberá utilizar para predecir situaciones no deseadas. El modelo directo se implementa como una red neuronal artificial, entrenada con datos provenientes del agente simulado. La red es probada y después implementada en el agente simulado para que resuelva una tarea de evasión de obstáculos mientras sigue una fuente de luz. El sistema entrenado aprende exitosamente a predecir una representación sensorial multimodal, formada por estímulos visuales y táctiles. Los resultados aquí presentados son muy alentadores y representan una base sólida para futura investigación sobre el uso y ventajas que pueden proporcionar modelos cognitivos en agentes autónomos artificiales.

Palabras Clave—Modelos directos, Cognición, Acción, Percepción, Redes Neuronales.

I. INTRODUCCIÓN

EL objetivo central de la investigación reportada en este artículo es el desarrollo de agentes artificiales capaces de interactuar con su entorno mediante modelos cognitivos. Nos interesa estudiar estos modelos para averiguar su capacidad para proveer a los agentes con las herramientas necesarias para interactuar con su entorno.

Esta investigación esta fundamentada en la importancia de predicciones y acciones como parte del proceso perceptual del sistema cognitivo (Sección B). La investigación esta en marcada en el campo de la cognición embebida, la cual representa una nueva visión de inteligencia artificial [1], [2]. La cognición embebida 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 alrededor.

El comportamiento del agente presentado en este artículo es el resultado de la necesidad del agente de resolver un problema en su propio mundo. El modelo cognitivo es entrenado y después examinado a través de la interacción del agente con su entorno. Igualmente, la examinación cualitativa de las decisiones que el agente toma están basadas en necesidades de la gente que surgen dentro de este entorno propio. Por estas razones nosotros argumentamos que el

agente esta cimentado es su entorno [3]

A. Visiones clásicas de Percepción y Acción

Una visión ampliamente aceptada de cognición explica la conducta como el resultado de una línea directa, unidireccional, reprocesamiento de información. Entradas de datos sensoriales crean una representación sensorial que a su vez se traduce en una acción motriz. Las acciones se consideran como reacciones, respuestas a estímulos. La mayor parte del comportamiento observado es considerado una consecuencia del mecanismo innato de estímulo y respuesta disponible al individuo [4]. Este marco, conocido como la metáfora del proceso de información, considera a los procesos de percepción como módulos que reciben, modifican y pasan la información disponible en el entorno.

Este marco provee a los investigadores en las ciencias cognitivas, inteligencia artificial y la robótica, con la oportunidad de considerar y trabajaren módulos aislados con habilidades especializadas [5], [6].

Estos enfoques de cognición tienen varios problemas. Primeramente, algunas conductas se desarrollan y se aprenden mejor cuando un agente interactúa dinámicamente con su entorno [7]. Segundo, la complejidad para programar módulos para una conducta específica aumenta dramáticamente conforme se incrementa el número de conductas.

El problema mejor conocido es la pregunta del homúnculo. Una vez que se forma una representación sensorial hay la necesidad que alguien o algo interprete esa representación y que lleva a cabo la acción requerida. Este problema se presenta nuevamente cuando el homúnculo requiere la interpretación de su propia representación sensorial.

Además, los agentes implementados con este enfoque caen en el conocido problema decimentación, el cual implica el hecho de que el agente es ajeno al entorno con el que interactúa, puesto que no evolucionó o aprendió a través de interactuar con él [3].

B. Anticipación y Selección de Acción

Un enfoque nuevo en las ideas con respecto al tema de percepción considera la entrada de datos sensoriales y la acción motriz (salida de datos) como parte del mismo proceso cognitivo.

Estas ideas han recibido mucha atención recientemente en el campote 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, paralarealización de acciones, despreciando a diferentes niveles las condiciones sensoriales externas.

Solo recientemente se ha valorado la idea de que la

Bruno Lara trabaja en la Facultad de Ciencias de la Universidad Autónoma del Estado de Morelos, México. (email: bruno.lara@uaem.mx).

Marcos A. Capistran trabaja en el Centro de Investigación en Matemáticas, Guanajuato, México.(email:marcos@cimat.mx).

Juan M.Rendon trabaja en la Facultad de Ciencias de la Universidad Autónoma del Estado de Morelos, México.(email:rendon@uaem.mx).

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 [8]. 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.

Entre otros, los puntos de vista ecologistas, defendidos por Gibson [9], sugieren un vínculo directo entre acción y percepción. La importancia del cuerpo de la gente y su relación dinámica con el entorno es central en este enfoque. Un marco más innovativo y radical ha sido propuesto por Hommel et. Al [10]: La teoría de codificación de eventos (TEC) la cual está "... basada en la noción central de que percepción, atención, intención y acción, comparten, u operan, en un dominio de representación común" [10].

TEC vincula percepción y acción funcionalmente. Esta vinculación y su coordinación provee las bases para la conducta adaptativa [10].

Dentro de este marco, las representaciones sensoriales también se consideran como consecuencias de acciones. 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 [11]. La planeación y el control de acciones se vuelven anticipatorios cuando esta gobernado por las situaciones sensoriales deseadas o los efectos deseados de las acciones.

C. Modelos Directos

Un equivalente computacional son los modelos directos. Usados principalmente en el campo de control motriz, 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 intentada o real) el modelo directo predice la siguiente situación sensorial S_{t+1} .

Los modelos delanteros proveen una alternativa a los enfoques clásicos mencionados en la Sección A. Möller [12] 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 conducta coherente. Como se mencionó en la Sección I 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 ser capaz entonces de tener suficiente información para formar estrategias de planeación que eviten situaciones no deseadas y de reaccionar a tiempo a los peligros de su entorno. Dearden et. Al [13] han presentado resultados muy interesantes: un robot aprende un modelo delantero que imita exitosamente las acciones presentadas a su sistema visual. Otras implementaciones de enfoques cognitivos se discuten en la Sección IV.

El trabajo presentado en este artículo intenta proveer un

agente artificial con las herramientas necesarias para predecir situaciones no deseadas. La predicción del agente se basa en los datos de entrada del modelo directo, esta predicción se caracteriza por la asociación entre los estímulos visual y táctil. Esta asociación se puede considerar un evento compuesto por el comando motriz y las situaciones sensoriales (reales y deseadas) [10].

II. EL MODELO PROPUESTO

El modelo directo se obtiene entrenando una red neuronal artificial con datos que vienen del 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.

A. Entorno y Recolección de Datos

Usando un simulador (Fig.1), se coloca a un robot en una arena con obstáculos cuyo tamaño varía entre 25 y 50 píxeles. En la figura el robot se mueve hacia adelante de izquierda a derecha.




Fig. 1 Vista del mundo virtual del robot.

El robot tiene un diámetro de 30 píxeles y está equipado con una cámara lineal, omnidireccional en blanco y negro. Esta cámara produce imágenes de 360° del entorno del robot pero solo de un píxel de ancho. Asimismo, el robot cuenta con un parachoques simulado, esto es un sensor binario que indica si el robot ha chocado con un objeto en cualquiera de sus lados. El robot se mueve en línea recta en la arena, tomando imágenes instantáneas del entorno. Cada 20 píxeles se graba una nueva imagen. La figura 2 muestra una trayectoria de 80 pasos o 1600 píxeles.



Fig. 2 Una trayectoria completa del robot con duración de 80 pasos.

En la imagen el eje x representa la dimensión espacial de la imagen, esto es, los 360 grados de la vista del robot y el eje y representa la dimensión temporal con su origen en la parte inferior de la imagen. El frente del robot está localizado en medio de la imagen en la dirección espacial. En la primera imagen instantánea, los obstáculos se pueden ver juntos, cerca entre sí y de un tamaño relativamente pequeño. Conforme el robot se mueve hacia adelante, los obstáculos crecen y se

alejando del centro del robot hasta que quedan detrás de él, (i.e. lejos a la izquierda y a la derecha de la imagen).

Los obstáculos son situados aleatoriamente a la derecha, izquierda y enfrente de la trayectoria del robot. La tarea del robot es predecir si puede efectuar una trayectoria de 1600 píxeles libre de colisiones. Las figuras 3 y 4 muestran trayectorias donde una colisión ocurre durante el desplazamiento del robot, obligándolo a detenerse. Conforme el robot se acerca a los obstáculos estos crecen en la imagen, los obstáculos están situados en el área central de la imagen puesto que esta área representa el frente del robot.




Fig. 3 Trayectoria del robot de 62 pasos con una colisión del lado izquierdo.



Fig. 4 Trayectoria del robot de 50 pasos con una colisión frontal.

B. Procesamiento de Datos e Implementación del Modelo Directo

Antes de ser usada en el sistema la información visual es preprocesada. Originalmente, las imágenes que salen de la cámara del robot tienen un tamaño de 1000x1 píxeles, cada trayectoria tiene diferente longitud ya que cuando el agente choca con un obstáculo deja de grabar imágenes. Las trayectorias son preprocesadas como sigue:

- Extracción de la sección frontal de la imagen. Dado que el sistema requiere predecir colisiones en la parte frontal del robot, la información visual relevante para esta tarea es la situada en el frente de la gente. Una sección equivalente a 90 grados (250 píxeles) de la parte frontal es extraída de la imagen total.
- Filtrado. Un filtro de paso bajo se aplica a la dimensión espacial de las imágenes. Esto funciona aplicando una transformada de Fourier a la imagen unidimensional. Las amplitudes de los coeficientes de Fourier son multiplicadas por un factor:

$$f = \frac{1}{1 + (\frac{k}{w})^{2n}} \tag{1}$$

con los valores de $w=0,25$ para la amplitud y $n=0,1$ para el orden. La inversa de la transformada de Fourier es aplicada al resultado. Esto se hace para deshacernos de información redundante de alta frecuencia.

- Mapeo Foveal en el dominio espacial. Este mapeo consiste en un submuestreo ponderado de la imagen. Entre mas lejos se encuentre un píxel del centro de la imagen este sea menos significativo. Los píxeles en el

centro de la imagen permanecen casi sin cambios. El submuestreo se lleva a cabo con una máscara de promedio.

Los efectos de aplicar los algoritmos de preprocesado a la imagen que se muestra en la Figura 2 se pueden ver en la Figura 5.



Fig. 5 90° frontal es después del filtrado (imagen izquierda) y después de la fovealización (imagen derecha).

Se requiere un sistema que sea capaz de predecir información visual y los estados del parachoques simulado. Este sistema puede ser implementado como un modelo directo de la forma ilustrada en la Figura 6, donde la situación sensorial actual esta compuesta por las imágenes visuales V a los tiempos $t, t+1, t+2$. Se espera que esta forma de la 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.




Fig. 6 Modelo directo implementado

El sistema lleva a cabo una predicción local y simétrica. Esto es, cada unidad de predicción o modelo directo toma como entrada una sección de los estímulos visuales y predice solo el píxel central de esa sección. En las orillas de la imagen esto no es posible, por lo que la ventana de información de entradas e va recorriendo usando la información disponible.

Dado que el tamaño final de las imágenes de 50 píxeles, el sistema consiste de 50 redes, perceptrones multicapa entrenados con retropropagación fuerte del error (resilient back propagation). Cada red tiene por entrada 45 unidades (15 píxeles para cada tiempo), 10 unidades en la capa oculta y 2 unidades en la capa de salida, una para el píxel predecido y una para el valor predecido del parachoques (valor de 0 cuando no existe colisión y 1 en caso contrario).

Se prepararon patrones de entrenamiento para cada red consistentes de diferentes imágenes (46000 patrones) conformados por una mezcla de diferentes trayectorias con y sin colisiones al final. Es importante hacer notar que cada una de las 50 redes es entrenada con el mismo valor de parachoques, esto es, cuando existe una colisión todas las redes deben aprender a predecir un valor de 1.

III. EXPERIMENTOS

Después de entrenar las redes 6000 ciclos de entrenamiento por lote (todos los patrones son presentados una vez antes de que se lleven a cabo los cambios en los parámetros libres de la

red) se lleva a cabo un proceso de prueba en el que se presenta a la red patrones (trayectorias) que no fueron presentados durante el entrenamiento.

Se espera que las redes lleven 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. Este segundo tipo de predicción es comparable a una simulación interna de eventos.

La activación de las neuronas de salida 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 redes que muestran un incremento en la activación de estas neuronas 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.

Para probar al sistema se definen dos umbrales. El primero se utiliza para considerar si el agente ha chocado con un obstáculo o no y consiste en que si 5 o mas neuronas de salida prediciendo una colisión presentan una actividad mayor a 0.5 esto es una colisión. El segundo umbral es para satisfacer la necesidad del agente de tener que usar la predicción de largo plazo. Cuando 3 o mas de estas mismas neuronas presentan una actividad mayor a 0.3 durante la predicción de un solo paso, se dispara la predicción de largo plazo para simular internamente el resto de la trayectoria.

El sistema es probado en 30 diferentes trayectorias. El sistema siempre desencadena la predicción de largo plazo cuando existe una colisión en el futuro. De la misma manera, nunca lo hace cuando se le presenta una trayectoria libre de obstáculos.

La salida visual de dos corridas típicas del sistema se pueden ver en las Figuras 7 y 8. La Fig7 muestra una trayectoria con una colisión en el lado izquierdo del robot, el sistema desencadena la predicción de largo plazo 2 pasos antes de que la colisión suceda. En el mundo del agente esto significa 40 píxeles o mas de una vez su propio tamaño de 30 píxeles. El segundo ejemplo muestra el comportamiento del sistema cuando se le presenta una colisión en el lado derecho, la LTP es desencadenada 3 pasos antes de la colisión.




Fig. 7 Trayectoria con una colisión del lado izquierdo




Fig. 8 Trayectoria con una colisión del lado derecho

Es importante hacer notar que las Figuras 3 y 4 muestran colisiones antes del preprocesamiento de las imágenes. Las Figuras 7 y 8 muestran trayectorias con colisiones después del preprocesado. El proceso de fovealización tiene el efecto de estirar la región central de la imagen real. Es por esta razón que en la Figura 8 el obstáculo parece estar muy lejos del centro de la imagen y por lo tanto del robot cuando en realidad no lo está. Nosotros sabemos que ha existido una colisión gracias a que conocemos los datos, sin embargo, el sistema detecta la colisión correctamente únicamente basándose en la activación de las unidades de salida que predicen los valores del parachoques.

La activación del arreglo completo de las unidades de salida que predicen los valores del parachoques puede verse en la Figura 9. Estos valores son los que presenta el sistema al final de una predicción de largo paso para tres diferentes tipos de colisiones.

Se puede observar que las neuronas que presentan mayor activación son las que están localizadas en el lado del agente donde la colisión va a ocurrir. En el caso de la colisión en el centro, la activación es mas alta en las regiones del campo visual donde ocurren cambios que indican que el obstáculo se aproxima.




Fig. 9 Activación de las neuronas de salida que predicen el estado de los parachoques en el último paso de una predicción de largo plazo.

A. Implementación

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 luzes completamente independiente del modelo directo, el sentido visual (la información proveniente de la cámara) y el sentido táctil (el parachoques). Una situación típica del robot

se puede ver en la Figura 10. El robot, la fuente de luz y un número de obstáculos aparecen en distintas posiciones del ambiente simulado.




Fig. 10 Simulador del robot, incluyendo obstáculos y una fuente de luz.

Para probar el modelo directo se definen tres comportamientos:

- Seguir fuente de luz. Esto hace que el robot gire hacia donde ésta se encuentra y se dirija a ella directamente.
- Predicción. Si se detecta alta activación en las neuronas de salida que predicen el estado del parachoques el robot se detiene y lleva a cabo una simulación interna que le permitirá decidir si en el futuro existirá una colisión. Para este comportamiento se utilizan los mismos umbrales arriba mencionados.
- Evitar obstáculos. En caso de que la simulación interna prediga que existe una posible colisión, el robot da un giro antes de volver al primer comportamiento. Ya que sabemos que la activación de las neuronas codificando la predicción de los estados del parachoques proporcionan información con respecto a la localización de los obstáculos, esta información se utiliza para hacer decidir al robot hacia donde girar.

La Figura 11 muestra al robot tratando de alcanzar la fuente de luz, pasando por 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.

Es importante hacer notar que el robot solo puede predecir situaciones sensoriales cuando el comando motriz ha sido constante durante al menos 3 pasos. Esto significa que una vez que el robot da un giro, ya se a buscando la luz o evitando un obstáculo, el robot necesita dar tres pasos con comando motriz constante antes de poder predecir otra vez.

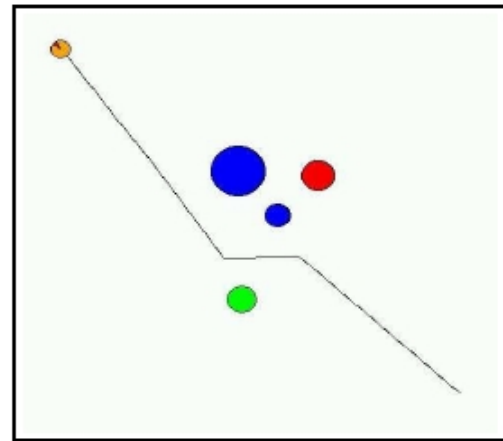


Fig. 11 Robot siguiendo una fuente de luz y evitando una serie de obstáculos en su trayectoria.

IV. CONCLUSIONES Y DISCUSION

Los experimentos presentados demuestran que tanto el concepto de anticipación como los modelos directos proveen a los agentes artificiales de estrategias útiles para moverse en su entorno. El agente presentado aquí 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 [10].

Es interesante observar el comportamiento emergente mostrado por este sistema. Las neuronas de salida que codifican los estados del parachoques proveen mas información de la esperada. Los resultados se pueden extender fácilmente a problemas que requieren que el agente sepa de que parte del entorno se aproximan los obstáculos, tal y como lo han demostrado los experimentos.

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.

El sistema presentado aquí difiere de otros trabajos en robótica que utilizan modelos directos en aspectos importantes. Hoffman et. Al [14] presentaron una cadena de modelos directos que provee al agente con la capacidad de seleccionar diferentes acciones para alcanzar una meta deseada y para llevar a cabo transformaciones mentales o internas. La diferencia principal con este sistema es que el modelo directo presentado aquí lleva a cabo la predicción del mismo evento (colisión) utilizando dos modalidades sensoriales (táctil y visual). La entrada visual a nuestro modelo directo esta completamente cimentada, en términos de que no se le proporciona ningún tipo de información acerca de la distancia a objetos. El sistema aprende a estimar distancia a través de la interacción con su entorno, asociando entrada visual y experiencia táctil. Esta asociación creemos es la mas

importante aportación de este trabajo.

Una forma de anticipación fue presentada por Ziemke et. Al [15], sin embargo sus resultados para predicción de largo plazo están restringidos por el ambiente en el que los agentes evolucionaron. En nuestro sistema el modelo es capaz de resolver diferentes escenarios, llevando a cabo las necesarias predicciones y reaccionando a tiempo a los obstáculos en su camino.

V. TRABAJO A FUTURO

Aunque la tarea presentada aquí puede ser resuelta por diferentes modelos, incluso algunos mas sencillos, este modelo presenta la ventaja de anticipación. La implementación de tareas mas complejas en el ambiente del robot deberá probar que un agente anticipador es capaz de evitar problemas típicos en los que un agente puramente reactivo fallaría, tales como esquinas y situaciones de callejones sin salida.

Un uso extendido del sistema presentado aquí podrá incluir comportamientos en los que es necesario el entendimiento de los conceptos de *ego-movimiento* y sus consecuencias. El sistema tal como esta deberá ser capaz de diferenciar por un lado, los cambios del ambiente que son consecuencia de sus propias acciones (*ego-movimiento*) y por otro lado, los cambios en el ambiente provocados por otros agentes y sus acciones respectivas.

Hasta el momento la dinámica interna de las redes no se ha investigado. Se espera que la activación de las neuronas en las capas ocultas presenten patrones de activación interesantes, tales como detección de contornos y detectores de movimiento. La representación multisensorial de estímulo (visual y táctil) deberá estar presente también en esta dinámica. Como esta propuesto por TEC [10] las neuronas en las capas ocultas de las redes deberán también compartir recursos al codificar acciones y percepción multisensorial.

BIBLIOGRAFIA

- [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] T. Ziemke, "Rethinking grounding," in *Understanding Representation in the Cognitive Sciences*, A. Riegler, M. Peschl, and A. Von Stein, Eds. New York: Kluwer Academia Publishers, 1999, pp. 177-190.
- [4] 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.
- [5] 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.
- [6] R. A. Brooks, "Intelligence without representation," *Artificial Intelligence*, vol. 47, pp. 139-159, 1991.
- [7] J. J. Bryson, "Modularity and specialized learning: Reexamining behaviour-based artificial intelligence," in *Adaptive Behaviour in anticipatory learning systems (ABiALS'02)*, P. Butz M. V., Gerard and S. O., Eds., Edinburgh, Scotland, 2002.
- [8] 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. M. Young, *The Technical Writers Handbook*. Mill Valley, CA: University Science, 1989.

- [9] J. J. Gibson, *The ecological approach to visual perception*. Boston: Houghton Mifflin, 1979.
- [10] 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.
- [11] G. Knoblich and W. Prinz, "Linking perception and action: An ideomotor approach," in *Higher-order motor disorders*, H.-J. Freund, M. Jean-nerod, M. Hallett, and R. C. Leiguarda, Eds. Oxford, UK: Oxford University Press, 2005.
- [12] 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 Academia Publishers, 1999, pp. 169-176.
- [13] A. Dearden and Y. Demiris, "Learning forward models for robots," in *Int. Joint Conferences on Artificial Intelligence*, Edinburgh, 2005, p. 1440.
- [14] 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.
- [15] T. Ziemke, D. A. Jirnhed, and G. Hesslow, "Internal simulation of perception: a minimal neuro-robotic model," *Neurocomputing*, vol. 68, pp. 85-104, 2005.



Bruno Lara Nació en la ciudad de México el 25 de Julio de 1972. Terminó la carrera de Ingeniería Electromecánica en el Tecnológico de Toluca en 1995. Recibió el grado de Doctor en King's Collage London en el 2000, en el área de Mecatronica. Llevo a cabo una estancia posdoctoral en el Theori Labor de la Universidad Friedrich Schiller en Jena, Alemania en el área de Robótica Evolutiva. Realizo una segunda estancia posdoctoral en el Max Planck Institute for Psychology Research en el área de Robótica Cognitiva. Desde 2005 es profesor asociado en la Facultad de Ciencias de la Universidad Autónoma del Estado de Morelos en Cuernavaca, México. Sus intereses de investigación incluyen Robótica Cognitiva, Robótica Evolutiva e Inteligencia Artificial.

Juan Manuel Rendón-Mancha Obtuvo su doctorado en computación en la Universidad Paris 5 en Francia en el año 2002. Actualmente es profesor asociado en la Facultad de Ciencias de la Universidad Autónoma del Estado de Morelos en Cuernavaca, México. Sus líneas de investigación son visión tridimensional multicámara y procesamiento de imágenes. Es miembro de la IEEE.

Marcos Capistrán Nació en Cuernavaca, México el 18 de marzo de 1970. Terminó su Licenciatura en Matemáticas en la Universidad Nacional Autónoma de México en 1996. En el 2003 se doctoro en el área de Matemáticas en el Instituto Courant de la Universidad de Nueva Cork bajo la supervisión del Prof. Yu Chen. Desde el 2003 es profesor asociado en la Facultad de Ciencias de la Universidad Autónoma del Estado de Morelos en Cuernavaca, México. Sus intereses de investigación incluyen Análisis Numérico y Problemas Inversos.