



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS
INSTITUTO DE INVESTIGACIÓN EN CIENCIAS BÁSICAS Y APLICADAS
CENTRO DE INVESTIGACIÓN EN CIENCIAS

**Cimentación del contexto
en la robótica cognitiva corporizada**

T E S I S
QUE PARA OBTENER EL GRADO DE
DOCTOR EN CIENCIAS

PRESENTA:
DIANA VALENZO MACÍAS

DIRECTOR DE TESIS
DR. BRUNO LARA GUZMÁN

CUERNAVACA, MORELOS

12 de junio de 2023

Jurado Examinador de Tesis

- Dr. Bruno Lara Guzmán, CInC-UAEM
- Dr. Jorge Hermosillo Valadez, CInC-UAEM
- Dr. Markus Franziskus Müller, CInC-UAEM
- Dr. Juan Manuel Rendón Mancha, CInC-UAEM
- Dra. Ma. de la Cruz Bernarda Téllez Alanís, CITPSI-UAEM
- Dr. Ángel Eugenio Tovar y Romo, Facultad de Psicología-UNAM
- Dr. Alejandro Vázquez del Mercado Hernández, Facultad de Filosofía y Letras-UNAM

RESUMEN

Cimentación del contexto en la robótica cognitiva corporizada

DIANA VALENZO MACÍAS

Este proyecto proporciona una interpretación de la noción de contexto para la robótica cognitiva y propone un modelo teórico que considera el procesamiento del contexto para la autonomía y flexibilidad conductual de agentes biológicos y artificiales. Se considera que el contexto refiere a todos los elementos de una situación, externos e internos en relación con el agente, que tienen poder predictivo sobre el comportamiento (Turner 1998). A partir del contexto global, se establecieron tres tipos de contexto de acuerdo a la fuente de origen de cada elemento: el contexto del agente, del entorno y de la tarea. Se identificaron elementos contextuales de cada tipo de contexto centrales para la autonomía y flexibilidad conductual. Se exploró cómo estos elementos han sido modelados dentro de la robótica cognitiva con la finalidad de introducir una nueva hipótesis sobre la interacción de dichos elementos a partir de la propuesta de un modelo teórico. La interacción de los elementos centrales en el modelo permite a los agentes: 1) seleccionar tareas relevantes para sí mismos en función de sus necesidades actuales, o para aprender y dominar su entorno a través de la exploración, 2) planear y realizar una tarea, así como monitorear continuamente su desempeño y 3) abandonar una tarea en caso de que su ejecución no sea la esperada. El seguimiento del error predictivo, la diferencia entre las predicciones sensoriomotoras y la información sensorial entrante, está en el centro de la flexibilidad conductual durante los ciclos de acción situados. El monitoreo de la dinámica del error predictivo y su comparación con la tasa esperada de reducción del error, indica al agente su desempeño global en la ejecución de la tarea. La sensibilidad al desempeño evoca emociones que funcionan como elemento impulsor de la conducta autónoma. El modelo es corporizado, afectivo y situado, mediante el procesamiento de los elementos contextuales centrales del agente y del entorno. Además, es cimentado en el procesamiento del contexto de la tarea y los ciclos de acción situados asociados durante la ejecución de la tarea.

ABSTRACT

Grounding context in Embodied Cognitive Robotics

DIANA VALENZO MACÍAS

This research provides an interpretation of the notion of context for cognitive robotics and proposes a theoretical model that considers context processing for the autonomy and behavioral flexibility of biological and artificial agents. It is considered that the context refers to all the elements of a situation, external and internal in relation to the agent, that have predictive power on behavior (Turner, 1998). Starting from the global context, three types of context were established according to the source of origin of each element: agent-related, environmental and task-related context. Contextual elements of each type of context central to autonomy and behavioral flexibility were identified. It was explored how these elements have been modeled within cognitive robotics in order to introduce a new hypothesis on the interaction of these elements through the proposal of a theoretical model. The interaction of core elements in the model allows agents to: 1) select relevant tasks for themselves based on their current needs, or to learn and master their environment through exploration, 2) plan and perform a task, as well as continuously monitor their performance and 3) abandon a task in case its execution is not as expected. Tracking predictive error, the difference between sensorimotor predictions and incoming sensory information, is at the core of behavioral flexibility during situated action cycles. The monitoring of the predictive error dynamics and its comparison with the expected rate of error reduction, indicates to the agent its global performance in the execution of the task. Performance sensitivity evokes emotions that function as a driver of autonomous behavior. The model is embodied, affective and situated, through the processing of the core contextual elements of the agent and the environment. Additionally, it is grounded in the processing of the task-related context and the associated situated action cycles during task execution.

Dedicatoria

A mis seres amados: a mis padres, porque gracias a ellos toda esta historia ha sido posible, en especial a tí, madre hermosa, por todo el amor y apoyo que me has brindado en cada momento. A ti, hermano, que con tu ejemplo y charlas me motivas a continuar creciendo. A mi compañero de vida, Federico, por estar a mi lado en todo este proceso y brindarme tanto amor.

Agradecimientos

- Al Dr. Bruno Lara Guzmán, por mostrarme con su ejemplo la importancia del amor al conocimiento y a la realización personal y por brindarme todo su apoyo siempre que lo necesité.
- A la Dra. Alejandra Ciria, por inspirarme a querer saber y comprender más y a maravillarme de mi propio mundo interno.
- A mis compañeros del laboratorio, por siempre apoyarme y hacerme sentir dentro de una gran familia.

Esta tesis fue financiada por el Consejo Nacional de Ciencia y Tecnología (CONACYT). Beca número 517333.

Índice general

CAPÍTULO

1. Introducción	1
1.1. Preguntas de investigación	4
1.2. Hipótesis	4
1.3. Objetivo general	5
1.4. Objetivos particulares	5
1.5. Enfoque del proyecto	5
1.6. Estructura de la tesis	7
1.7. Publicación	8
2. Rol del contexto en la flexibilidad conductual	9
3. Contexto del agente	13
3.1. Necesidades fisiológicas	13
3.1.1. Modelado de necesidades fisiológicas en agentes artificiales	14
3.2. Emociones	17
3.2.1. Modelado de emociones en agentes artificiales	19
3.3. Motivación intrínseca	21
3.3.1. Modelado de la motivación intrínseca en agentes artificiales	23
4. Contexto del entorno	27
4.1. Configuración espacial del entorno	29
4.1.1. Modelado de interacción de agentes artifi- ciales con el entorno	31
5. Contexto de la tarea	37
5.1. Postura corporal	38
5.1.1. Esquema corporal y modelos internos	42
5.1.2. Modelado del esquema corporal en agentes artificiales	43
5.2. Espacio peripersonal	48

5.2.1. Modelado del espacio peripersonal en agentes artificiales	49
5.3. Configuración del cuerpo y objeto situados	51
5.3.1. Modelado de configuración del cuerpo y objetos en agentes artificiales	52
5.4. Contexto del agente y la tarea integrados	57
5.4.1. Arquitectura DARWIN	57
5.4.2. Arquitectura MACSi	60
5.4.3. Lingüística y contexto en la arquitectura ERA	61
6. Modelo de interacción de los tres tipos de contexto	65
6.1. Modelo interaccionista de los tres tipos de contexto .	68
7. Discusión y conclusiones	77
Appendices	81
A. Categorización de investigaciones de acuerdo al contexto estudiado	83

Índice de figuras

2.1.	Contexto del agente, del entorno y de la tarea.	10
5.1.	Modelos internos: modelo directo e inverso.	43
5.2.	Modelos internos acoplados.	43
5.3.	Mapa de propiocepción	45
5.4.	Modelos internos basados en propiocepción	46
5.5.	Autoencoder variacional multimodal	46
5.6.	Arquitectura computacional SOIMA	48
5.7.	Descripción del efecto de empujar	54
5.8.	Affordances de herramientas	55
5.9.	Arquitectura DARWIN	59
5.10.	Exploración autónoma y guiada	62
5.11.	Arquitectura ERA	63
6.1.	Modelo interaccionista de tres contextos	70

CAPÍTULO 1

Introducción

La robótica cognitiva corporizada pretende comprender los mecanismos subyacentes a los procesos cognitivos, al mismo tiempo que busca diseñar agentes artificiales cognitivos capaces de interactuar de forma autónoma y efectiva con el entorno (Lara y cols., 2018; Mohan, Morasso, Sandini, y Kasderidis, 2013). Este campo de investigación se inspira en las neurociencias, la psicología cognitiva y la filosofía de la mente, entre otras áreas, para diseñar modelos computacionales de procesos cognitivos que se estudian en agentes artificiales (Pfeifer y Scheier, 2001). En la actualidad, los agentes artificiales son capaces de simular procesos de percepción y acción que les permiten interactuar de forma autónoma con el entorno y aprender a manipular diferentes objetos y herramientas a través de su propia experiencia, mediante acciones como alcanzar, agarrar y empujar (Abdulazeez y Faizi, 2021; Jamone y cols., 2016; Min, Luo, Zhu, Bi, y cols., 2016; Vernon, Metta, y Sandini, 2007). Sin embargo, estas tareas se aprenden generalmente en condiciones controladas y estableciendo parámetros fijos, lo que restringe fuertemente la capacidad de los agentes artificiales para adaptarse a las demandas de entornos dinámicos y no estructurados¹ (Min y cols., 2016).

En este sentido, uno de los grandes retos de la robótica cognitiva es diseñar agentes artificiales autónomos que generen comportamientos apropiados de acuerdo al entorno específico en el que se encuentren. Un enfoque prometedor para lograr esta autonomía y efectividad de interacción con el entorno es el intento de comprender los mecanismos subyacentes de la flexibilidad conductual que los agentes biológicos exhiben de manera natural y espontánea al cambiar de comportamiento y poder adaptarse eficientemente a entornos dinámicos. Se entiende por flexibilidad conductual a la habilidad de los agentes para elegir la tarea apropiada en un momento determinado y cambiar de estrategia de acuerdo a lo que dicte la situación (Lea, Chow, Leaver, y McLaren, 2020; Ragozzino, 2007).

¹Dentro de la robótica cognitiva, los entornos no estructurados son aquellos entornos que no han sido modificados previamente para simplificar la ejecución de una tarea por parte de un robot (Brock, Park, y Toussaint, 2016).

Uno de los factores esenciales que intervienen en la flexibilidad conductual es el procesamiento del contexto. Para responder a las condiciones cambiantes, los agentes deben orquestar sus demandas internas junto con los factores ambientales, aquellos que son de relevancia para el mismo agente y que inducen afecto para guiar e iniciar el comportamiento (Barsalou, 2020). Tomando todo esto, y para efectos de este trabajo, se considera **contexto** a todos los elementos internos y externos de una situación que tienen poder predictivo sobre el comportamiento de los agentes (Turner, 1998). De esta manera, al procesar los elementos contextuales en un momento determinado, los agentes son capaces de elegir la tarea apropiada de acuerdo a la situación actual.

El procesamiento del contexto modula la conducta en diferentes niveles de organización jerárquica (Maren, Phan, y Liberzon, 2013). En primer lugar, el procesamiento del contexto es fundamental para que los agentes biológicos y artificiales prioricen metas y seleccionen las tareas apropiadas de acuerdo a una situación particular. En segundo lugar, identificar el contexto resulta esencial para la planeación y ejecución de cada tarea bajo condiciones particulares. Por ejemplo, la secuencia sensorimotora necesaria para agarrar un vaso dependerá de si el vaso se encuentra boca arriba o boca abajo (Rosenbaum, Herbort, Van der Wel, y Weiss, 2014). En consonancia con esto, se ha sugerido que el cerebro es un sistema dependiente del contexto, ya que todas las entradas que procesa - tanto internas, como externas - están relacionadas con el contexto en el que ocurren (Nikolić, 2010)². Por lo tanto, la adquisición de información sobre el contexto por parte de los agentes biológicos y artificiales es esencial para su flexibilidad y adaptabilidad conductual (Baker y Mizumori, 2017).

Este proyecto de investigación tiene como objetivo analizar el rol del contexto en la flexibilidad conductual y en la planeación y ejecución de acciones en agentes biológicos y artificiales. La estrategia adoptada para el análisis del contexto consiste en establecer y explorar tres componentes principales del contexto global: el contexto del agente, el contexto del entorno y el

²En este proyecto acotamos el estudio del papel del contexto en la flexibilidad conductual de agentes biológicos que poseen cerebro. Otros agentes biológicos sin sistema nervioso también exhiben respuestas apropiadas de acuerdo al contexto. Por ejemplo, las bacterias modulan sus procesos de acuerdo a la concentración de ciertos nutrientes o sustancias tóxicas en el entorno, o de acuerdo a la concentración de iones en su interior. Asimismo, se ha propuesto incluso que la memoria molecular es un componente esencial de la vía de la quimiotaxis (Vladimirov y Sourjik, 2009). Sin embargo, esta discusión está fuera del alcance de este proyecto.

contexto de la tarea. La exploración de cada tipo de contexto consiste en identificar los elementos centrales de cada uno de ellos involucrados en la flexibilidad conductual y la planeación de acciones dirigidas a objetivos.

Por un lado, este proyecto explora el rol predictivo de cada elemento contextual central en la modulación de la conducta. Sumado a ello, la interacción del contexto del agente, del entorno y de la tarea se aborda mediante un modelo teórico que integra sus elementos centrales dentro de los mecanismos de control de un agente artificial. Un aspecto relevante del modelo es que considera esencial el monitoreo de la dinámica del error predictivo para cambiar de tareas y adaptarse de manera flexible a las circunstancias cambiantes. De esta manera, el modelo integra los elementos contextuales esenciales para que un agente artificial seleccione, planifique y ejecute de manera autónoma la tarea apropiada, permitiendo un ciclo continuo de selección de acciones.

Identificar diferentes tipos de contextos es posible porque, si bien existen innumerables factores que impactan el comportamiento, todos ellos provienen de tres fuentes principales: el estado del agente, las condiciones ambientales y las características de la tarea en la que los agentes participan en un momento determinado (Cohen, 1995). Dentro de la robótica cognitiva corporizada, Pfeifer y Bongard (2006) consideraron los mismos componentes dentro de su conjunto de principios de diseño para agentes artificiales. Específicamente, el principio de los tres componentes establece que un agente inteligente debe tener un diseño de agente específico, un nicho ecológico definido y una tarea definida.

El contexto está involucrado en todos los aspectos cognitivos, conductuales y perceptuales de los agentes biológicos y artificiales. Desde una perspectiva que enfatiza la corporización para el desarrollo de la cognición, la flexibilidad conductual podría lograrse cuando se basa en el monitoreo constante del contexto, permitiendo a los agentes cambiar de estrategia para adaptarse de manera flexible a circunstancias cambiantes. En este sentido, el modelado del contexto es fundamental para estudiar el acoplamiento estructural entre los agentes y su entorno.

Aunque el contexto es un concepto muy utilizado, sigue siendo un concepto difícil de definir y comprender. Actualmente no existe un consenso sobre la noción de contexto dentro de la robótica cognitiva. Para tener una idea más clara al respecto, consideremos el trabajo de Bazire y Brézillon

(2005), quienes realizaron un análisis de diferentes definiciones de contexto provenientes de dominios distintos de las ciencias cognitivas, con el fin de identificar los principales componentes relacionados con este concepto. Los autores concluyeron que las 150 definiciones de contexto que identificaron pueden analizarse en términos de algunos parámetros como: restricción, influencia, comportamiento, naturaleza, estructura y sistema. El estudio destaca que no existe un consenso sobre si el contexto es externo o interno, si se refiere a un conjunto de información o procesos, si el contexto es de naturaleza dinámica y/o estática, y si se refiere a un simple conjunto de fenómenos o una red organizada. Sin embargo, en realidad existe un consenso sobre el contexto como un conjunto de restricciones que influyen en el comportamiento de un sistema. En este sentido, este proyecto pretende brindar una aportación en el estudio del contexto proporcionando una interpretación de la noción de contexto para la robótica cognitiva y proponiendo un modelo que considera el procesamiento y relevancia del contexto para la autonomía y flexibilidad conductual de agentes biológicos y artificiales.

Por otro lado, este estudio también pretende contribuir al desarrollo de las ciencias cognitivas. Un desafío para la cognición cimentada es comprender la cognición en profundidad dentro del contexto de los ciclos de acción situados. La investigación desarrollada en el presente trabajo nos permite sugerir que a través del monitoreo constante de los elementos centrales de los tres tipos de contexto principales, junto con el monitoreo de la dinámica del error predictivo, los agentes artificiales determinarían de manera autónoma las tareas que les son relevantes en cada situación específica.

1.1. Preguntas de investigación

- ¿Qué papel juega el contexto en la elección de una tarea?
- ¿Cuál es la importancia del contexto y la tarea en la planificación de una acción para lograr un objetivo específico?

1.2. Hipótesis

- El contexto del agente y del entorno determinan la tarea, por lo que aprender y actualizar las predicciones sobre las consecuencias sensoriales de las acciones en un contexto global específico optimizará la

conducta de un agente artificial al brindar flexibilidad en la elección de la tarea.

- Las asociaciones multimodales aprendidas dentro de un contexto específico indicarán la secuencia de acciones necesarias para lograr un objetivo final, el cual es dependiente de la tarea y de su contexto.

1.3. Objetivo general

Proponer un modelo teórico que integre el contexto y la tarea en los mecanismos de control de un agente artificial.

1.4. Objetivos particulares

- Proveer a la robótica cognitiva un análisis sobre el contexto:
 - Establecer una definición de trabajo de contexto
 - Establecer una clasificación de los tipos de contexto
 - Identificar elementos contextuales de cada tipo de contexto que resultan esenciales para la autonomía y flexibilidad conductual
- Revisar alcances y limitaciones del modelado del contexto dentro de la robótica cognitiva bajo las definiciones propuestas
- Establecer una relación plausible de los elementos contextuales esenciales para la autonomía y flexibilidad conductual dentro de un modelo teórico

1.5. Enfoque del proyecto

Este proyecto está enmarcado dentro de la robótica cognitiva, un campo de investigación que busca comprender la cognición biológica mediante la recreación de procesos cognitivos en agentes artificiales (Asada y cols., 2009; Krichmar, 2012; Lara y cols., 2018). Además de interesarse en el estudio de la cognición, este campo de estudio posee el objetivo de dotar con capacidades cognitivas básicas a dichos agentes para que sean capaces de interactuar en un mundo complejo de manera autónoma y flexible (Pfeifer y Scheier, 2001). Inspirada en teorías y modelos propuestos en áreas como la psicología cognitiva, las neurociencias y la filosofía de la mente, la robótica cognitiva se

centra en el estudio de modelos computacionales biológicamente plausibles en agentes artificiales. Su enfoque metodológico se conoce como sintético o constructivo debido a que permite diseñar, implementar, evaluar y reimplementar los modelos en los agentes artificiales para refinar y estudiar dichos modelos (Asada, MacDorman, Ishiguro, y Kuniyoshi, 2001).

En este campo de estudio, el marco teórico de la cognición corporizada y la cognición cimentada proporcionan las bases epistemológicas y metodológicas para el modelado computacional de procesos cognitivos en agentes artificiales. Ambas teorías enfatizan la importancia de la interacción del agente con su entorno para la emergencia de las habilidades cognitivas (Barsalou, 2008; Foglia y Wilson, 2013; Wilson, 2002). A partir de dicha interacción el agente desarrollaría capacidades como el control sensorimotor, considerado un prerrequisito fundamental para el desarrollo cognitivo.

En contraste con la visión tradicional de la cognición, que describe a la mente como un ordenador que puede realizar el procesamiento de la información independientemente del cuerpo y de las conexiones con el entorno, la cognición corporizada enfatiza que los estados corporales y las modalidades sensoriales para la percepción y la acción subyacen al procesamiento de la información, y que el cuerpo contribuye a varios aspectos de los fenómenos mentales (Foglia y Wilson, 2013). De manera paralela, la cognición cimentada rechaza los puntos de vista tradicionales de que la cognición involucra computación sobre símbolos amodales en un sistema modular, independiente de los sistemas modales del cerebro para la percepción, la acción y la introspección. En cambio, la cognición cimentada propone que las simulaciones modales, los estados corporales y la acción situada subyacen a la cognición.

Para los fines de este proyecto la cognición cimentada se entiende como en Barsalou (2020), esto es, un enfoque general que incorpora la cognición corporizada, embebida, enactiva y extendida en una perspectiva más amplia. De acuerdo con lo anterior, la cognición, el afecto y el comportamiento emergen del cuerpo estando embebido en entornos que extienden la cognición, a medida que los agentes realizan acciones situadas que reflejan sus estados cognitivos y afectivos actuales (Barsalou, 2020). Por lo tanto, la interacción con el entorno se considera un aspecto crucial para la estructuración y emergencia de habilidades cognitivas en agentes artificiales (Cangelosi, Bongard, Fischer, y Nolfi, 2015; Pezzulo y cols., 2013; Spivey y cols., 2011). Siguiendo esta misma línea, la metodología sintética de la robótica cognitiva

considera a los agentes artificiales como herramientas útiles para explorar principalmente modelos de cognición corporizados, embebidos y cimentados.

Sumado a ello, la cognición situada también juega un papel importante dentro de la robótica cognitiva. La cognición situada enfatiza que el procesamiento cognitivo tiene lugar en un entorno del mundo real, e inherentemente involucra a la percepción y a la acción (Pezzulo y cols., 2013; Roth y Jor-net, 2013). En este sentido, el procesamiento cognitivo es dependiente de las limitaciones actuales y las demandas de la tarea en la que un agente participa en un momento determinado, de las entradas y salidas relevantes para dicha tarea. Cuando se realiza un proceso cognitivo, sigue llegando información perceptual que afecta al procesamiento, y se continúa ejecutando actividad motriz que afecta al ambiente en formas relevantes para la tarea (Wilson, 2002). En este sentido, moverse por una habitación tratando de imaginar dónde deben ir acomodados los muebles son actividades cognitivas que están situadas. Otro ejemplo se halla en la cognición numérica, cuando los giros de la cabeza sesgan el generador aleatorio interno del cerebro. De manera intuitiva, la generación de números aleatorios parece involucrar procesos cognitivos abstractos independientes de cualquier conexión directa con el cuerpo o el espacio. Sin embargo, una manipulación sensoriomotora de bajo nivel en humanos, como girar la cabeza a la derecha o hacia la izquierda, influye sistemáticamente en el comportamiento y parece afectar de manera predecible la aparente espontaneidad de las elecciones numéricas “aleatorias” (Hubbard, Piazza, Pinel, y Dehaene, 2005; Loetscher, Schwarz, Schubiger, y Brugger, 2008).

En conjunto, la cognición cimentada y la cognición situada constituyen un marco teórico de referencia para la robótica cognitiva, incluyendo al paradigma de la cognición corporizada, que enfatizan la importancia de la interacción del agente con su entorno para la estructuración y emergencia de las habilidades cognitivas (Wilson, 2002).

1.6. Estructura de la tesis

Los siguientes capítulos están estructurados de esta manera: en el capítulo 2 se introduce la noción del contexto del agente, del entorno y de la tarea y se aborda de manera general el papel de cada uno de ellos en la flexibilidad conductual de los agentes. Posteriormente, en los capítulos 3, 4 y 5 el contexto del agente, del entorno y de la tarea se exploran con más detalle

a través de sus elementos centrales, respectivamente. Al mismo tiempo, se revisan algunas implementaciones representativas de robótica cognitiva que abordan dichos elementos. En el capítulo [6](#) se explora la interacción de los tres tipos de contexto en la flexibilidad conductual a través de un modelo teórico que relaciona los elementos centrales de cada tipo de contexto. Finalmente, el capítulo [7](#) presenta las conclusiones del presente proyecto. Para el resto del documento, cuando se lee “agentes biológicos” se hace referencia a organismos vivos, “agentes artificiales” refiere a implementaciones y robots artificiales situados y, cuando se lee “agentes” se refiere a ambos.

1.7. Publicación

El artículo publicado derivado del proyecto de esta tesis es:

- Valenzo, D., Ciria, A., Schillaci, G., & Lara, B. (2022). Grounding Context in Embodied Cognitive Robotics. *Frontiers in Neurorobotics*, 16.

Rol del contexto en la flexibilidad conductual

El comportamiento flexible está modulado por innumerables factores asociados con la constitución del agente y la estructura del entorno (Palmer, Barnett, Copado, Gardezy, y Kristan Jr, 2014). Los agentes deben orquestrar constantemente elementos tanto internos como externos para acoplarse adecuadamente con el entorno y poder sobrevivir. Aquellos elementos que tienen poder predictivo sobre la conducta de un agente constituyen el contexto (Turner, 1998). En este sentido, la detección de elementos contextuales asociados tanto a su propio estado como al entorno permite a los agentes establecer objetivos de forma autónoma y seleccionar las tareas apropiadas para lograr dichos objetivos de acuerdo a la situación.

Dado que los elementos contextuales tienen su origen en el agente y el entorno, es posible establecer dos subcomponentes del contexto global de acuerdo a la fuente de donde procedan: el contexto del agente y el contexto del entorno. El contexto del agente se refiere a los factores físicos, fisiológicos y psicofisiológicos asociados con el estado de un agente que tienen un impacto en la conducta. Se caracteriza por abarcar elementos como las necesidades fisiológicas, las emociones, la motivación intrínseca, así como los aspectos posturales y morfológicos del cuerpo, entre otros. A su vez, el contexto del entorno se relaciona con las características del entorno específico en el que se encuentra el agente, como la configuración espacial del cuerpo y los objetos en el entorno, así como sus propiedades relacionales. Es así que, cuando un agente debe seleccionar una tarea, será siempre en función de ambos contextos.

Por otro lado, es posible distinguir un tercer tipo de contexto que integra elementos del contexto del agente y del entorno en una interacción constante durante los ciclos de acción sensorimotora de un agente. Al seleccionar una tarea específica, ciertos elementos del agente y del entorno se vuelven relevantes para lograr el objetivo específico de la tarea, estos elementos constituyen el contexto de la tarea (Martin y cols., 2013). El contexto de la

tarea está constituido por todos aquellos factores tanto del agente como del entorno que inciden en la planeación y ejecución de la secuencia de acciones dirigidas para lograr el objetivo de la tarea. Es importante distinguir entre la tarea y el contexto de la tarea. En este proyecto, la tarea refiere a la secuencia de estados sensorimotores ordenados temporalmente que conlleva a un objetivo específico (por ejemplo, agarrar un vaso) (Khatib y cols., 2009). Por otro lado, el contexto de la tarea engloba a todos aquellos elementos relevantes para poder lograr el objetivo de la tarea. Así, este contexto se caracteriza por elementos que cambian dinámicamente durante la ejecución de la tarea, como el cuerpo espacial situado y la configuración del objeto (percibido a través de la exterocepción), la postura corporal del agente (percibida a través de la propiocepción), e incluso el área alrededor del agente en la que los objetos se pueden agarrar y manipular, conocido como espacio peripersonal.



Figura 2.1: Contexto del agente, del entorno y de la tarea.

La dinámica del contexto de la tarea difiere de la dinámica exhibida por el contexto del agente y del entorno, dado que su naturaleza es función de la tarea seleccionada. En este sentido, el contexto de la tarea se redefiniría cada vez que el agente cambia de tarea, incluso estando en un mismo entorno con un estado interno del agente constante. Por otro lado, este contexto tiene una dinámica más rápida en comparación con los otros dos tipos de contexto aún cuando la tarea no cambie. Es decir, cada vez que el agente mueve un objeto dentro del espacio de la tarea o cambia la posición de

sus extremidades, el contexto de la tarea se actualizará para considerar estos cambios en la planeación y ejecución de las acciones dirigidas a objetivos.

Desde una perspectiva que enfatiza la corporización para el desarrollo de la cognición, la flexibilidad conductual se lograría cuando el agente monitorea constantemente su propio contexto interno (contexto del agente), el contexto del entorno que le rodea y el contexto de la tarea que se encuentra realizando en un momento determinado (Figura 2.1). Este monitoreo se produce a través de los sistemas sensoriales disponibles para el agente: exteroceptivo, interoceptivo y propioceptivo. Dadas las propiedades intrínsecas de los sistemas sensoriales, cada uno está más estrechamente vinculado al procesamiento de alguno de los tres diferentes contextos.

El procesamiento del contexto del agente está fuertemente ligado a la interocepción y la propiocepción. En primer lugar, las señales interoceptivas permiten la percepción de los estados fisiológicos internos del cuerpo (Schulz y Vögele, 2015). Dichos estados fisiológicos, como el hambre, juegan un papel esencial en la determinación y selección de la tarea apropiada que un agente debe realizar en un momento dado para sobrevivir. Así, la información contextual adquirida a través de la interocepción modularía la conducta para favorecer el mantenimiento y la autorregulación de los estados internos de los agentes, necesarios para mantenerlos vivos.

En segundo lugar, las señales propioceptivas informan sobre la postura corporal, así como sobre los cambios de posición del cuerpo durante el movimiento, la velocidad y la fuerza aplicada asociada (Tuthill y Azim, 2018). Dado que la propiocepción está fuertemente ligada al control del movimiento, los elementos contextuales adquiridos a través de esta modalidad también están asociados a los mecanismos de planeación de la secuencia de acciones relacionadas con la tarea. Por lo tanto, la propiocepción está estrechamente vinculada tanto al contexto del agente como al contexto de la tarea.

Por otro lado, la exterocepción permite el procesamiento del contexto del entorno. A través de las modalidades sensoriales visual, auditiva, táctil,

¹Como se ha aclarado previamente, los agentes biológicos sin sistema nervioso también exhiben respuestas apropiadas de acuerdo al contexto, ya que tienen su propio mecanismo para sentir las condiciones internas y externas, como el caso de las bacterias que modulan sus procesos de acuerdo a la concentración de ciertos nutrientes o de acuerdo a la concentración de iones en su interior. Sin embargo, esta discusión está fuera del alcance de este proyecto.

olfativa y gustativa, la exterocepción captura información sobre los estímulos externos al cuerpo e informa al agente sobre los cambios que ocurren en el entorno en el que se encuentra (Wade, 2019). Percibir y procesar el contexto del entorno permite determinar la tarea que mejor satisface los requisitos o necesidades internos del agente de acuerdo con los recursos externos disponibles y la configuración de este contexto.

La exterocepción también proporciona información sobre los agentes embebidos en su entorno. Los agentes pueden obtener información indirecta sobre sus cuerpos con diferentes modalidades sensoriales exteroceptivas, como la visión. Esto es fundamental para integrar información tanto del agente situado en el entorno como de la tarea que se está ejecutando para orientar la acción a través de la percepción (Kozak y Corneil, 2021). Por lo tanto, la exterocepción también se asocia directamente con el contexto de la tarea, ya que también ayuda a determinar la secuencia de acciones que deben ejecutarse.

A través de sus sistemas sensoriales, los agentes procesan información directa o indirecta sobre los tres tipos de contexto. Sin embargo, los elementos que constituyen cada uno de ellos pueden ser innumerables, complejos y diversos en naturaleza. Debido a lo anterior, el procesamiento de todos los elementos contextuales en agentes artificiales no es computacionalmente trivial (Brooks y Mataric, 1993; Connelland Mahadevan, 1993). Para desarrollar agentes artificiales que exhiban una mayor flexibilidad conductual es crucial distinguir los elementos esenciales de cada tipo de contexto que permitan a los agentes artificiales autorregular su estado interno mientras interactúan de manera autónoma y efectiva con el entorno.

En las secciones 3, 4 y 5 sugerimos elementos centrales del contexto del agente, del entorno y de la tarea, respectivamente, que juegan un papel fundamental para la interacción del agente con el entorno de una manera flexible y autónoma. Se aborda el papel predictivo de estos elementos en el comportamiento de agentes biológicos y cómo se han modelado en agentes artificiales dentro de la robótica cognitiva. Posteriormente, en la sección 6 se aborda la interacción del contexto del agente, del entorno y de la tarea mediante un modelo teórico que integra los elementos contextuales centrales de cada uno de ellos dentro de los mecanismos de control de un agente artificial.

CAPÍTULO 3

Contexto del agente

El contexto del agente se refiere a todos aquellos elementos que tienen poder predictivo en la conducta y están asociados con la estructura física, fisiológica y psicofisiológica de un agente. Los mecanismos de motivación intrínseca, así como las emociones, son actores clave. Todos estos elementos modulan el comportamiento en diferentes niveles jerárquicos de organización. En un nivel superior, el contexto del agente modula el comportamiento al establecer metas específicas que son una prioridad para que el agente se mantenga vivo durante su acoplamiento con el entorno.

Las necesidades fisiológicas, la motivación intrínseca y las emociones son elementos contextuales que tienen un fuerte impacto en este nivel de organización conductual y se abordarán en esta sección. El contexto del agente restringe el conjunto de posibilidades de tareas apropiadas para lograr el objetivo interno específico. En un nivel jerárquico inferior, la postura corporal y el espacio peripersonal, juegan un papel fundamental en la planeación y ejecución de acciones dirigidas a objetivos. Estos elementos contextuales caen en la superposición del contexto del agente y el contexto de la tarea así que se abordarán como elementos del contexto de la tarea.

3.1. Necesidades fisiológicas

Las necesidades fisiológicas como el hambre, la sed o el sueño, son sensaciones evocadas por estados internos del agente que indican una falta de químicos, nutrientes, energía o condiciones internas necesarias para la supervivencia (Taormina y Gao, 2013). Cuando las señales interoceptivas indican una necesidad fisiológica, ésta debe regularse para mantener la estabilidad u homeostasis del agente (Strigo y Craig, 2016). Las necesidades fisiológicas están asociadas con estados motivacionales que constituyen impulsos de acción relacionados con la supervivencia (Maslow, 1958). Por ejemplo, cuando un animal tiene hambre, varios tipos de neuronas hipotalámicas señalan esta necesidad fisiológica e impulsan una tarea específica que permitiría satisfacer la necesidad detectada, como la búsqueda de alimento (Schulkin y

(Sterling, 2019).

La capacidad de detectar sus propias necesidades fisiológicas permite a los agentes modular su comportamiento para satisfacer la insuficiencia de sus recursos internos y restablecer su equilibrio a través de la acción (Ramirez-Pedraza y Ramos, 2021). Activar tareas que mantengan la homeostasis es fundamental para asegurar la supervivencia del agente. Por lo tanto, las necesidades fisiológicas son un elemento contextual central que aumenta la probabilidad de mantenerse con vida seleccionando la acción adecuada.

3.1.1. Modelado de necesidades fisiológicas en agentes artificiales

Al igual que los agentes biológicos, los agentes artificiales deben cumplir ciertos requisitos para funcionar correctamente y poder interactuar eficazmente con el medio ambiente. Ellos deben tener cierto nivel de energía, integridad en sus sensores y mantener una temperatura óptima para el correcto funcionamiento de sus motores. Para mantener el estado interno de los agentes artificiales en condiciones adecuadas, algunos estudios se han centrado en el modelado de sistemas homeostáticos (Kelkar, 2021; Man y Damasio, 2019; Stradner, Hamann, Schmickl, y Crailsheim, 2009; Yoshida, 2017). Generalmente, el agente puede permanecer dentro de una zona de viabilidad, definida como el conjunto de posibles estados en los que el funcionamiento del sistema no se ve comprometido (Müller y Tamura, 2013). Esto dota a los agentes artificiales de la capacidad de activar tareas que ayudarían a regular su propio estado cuando sus niveles internos exceden un límite predeterminado.

Algunos modelos han utilizado un controlador de producción de hormonas, que forman parte de un marco más amplio que incluye redes neuronales artificiales. Cualquier variación en el entorno externo o en el estado interno desencadena la producción de una hormona. A su vez, los niveles de hormonas alteran el estado interno impulsando las acciones de las redes neuronales mediante la estimulación de las neuronas objetivo para que realicen una determinada tarea. Esto se logra afectando los pesos de entrada en la RNA. Una vez que se ha completado la tarea, el controlador de producción de hormonas recibe una señal de retroalimentación negativa que detiene la producción y liberación de la hormona (Vargas y cols., 2005).

Por ejemplo, (Moioli, Vargas, y Husbands, 2009) abordaron la coordina-

ción de tres tareas acopladas pero diferentes en un robot móvil: explorar el entorno evitando obstáculos, buscar una fuente de luz cuando la fatiga es alta y buscar una raya negra en la arena cuando la batería está baja. Usan tres GasNet no espaciales (NSGasNet), que son redes neuronales recurrentes artificiales en tiempo discreto derivadas del modelo GasNet original. Cada red neuronal es evolucionada previamente por separado para realizar una tarea específica. Posteriormente, la salida de las redes neuronales es modulada por los niveles de dos hormonas simuladas asociadas con los niveles de fatiga y hambre, respectivamente. Los niveles de las dos hormonas, junto con el estímulo ambiental externo, son responsables de determinar la coordinación coherente del comportamiento del agente.

La homeostasis se ha modelado junto con el control alostático para lograr consistencia y equilibrio en la satisfacción de los impulsos del agente a través del cambio de comportamiento. Normalmente, estos modelos permiten al agente la flexibilidad para modular la activación de tareas relacionadas con la exploración del entorno (tareas de navegación) y aquellas tareas asociadas con la regulación del estado interno (recarga de batería). El escenario mínimo de múltiples tareas para la selección de acciones se conoce como el problema de dos recursos (2RP, por sus siglas en inglés) (Spier y McFarland, 1997). Esto le permite al agente seleccionar en qué tarea participar y evitar casos de conflicto. De esta manera, los agentes pueden exhibir un comportamiento cíclico junto con cambios tanto internos como externos.

Se ha implementado una estrategia similar para coordinar la selección de tareas en agentes humanoides¹ durante la interacción humano-robot. En el marco propuesto por Vouloutsi, Lallée, y Verschure (2013), el comportamiento del agente está guiado por sus impulsos y objetivos internos para satisfacer sus necesidades. La arquitectura Distributive Adaptive Control (DAC) que sugieren consta de cuatro capas acopladas: soma, reactiva, adaptativa y contextual. Específicamente, la capa reactiva se modela en términos de un proceso alostático en el que los estímulos están conectados con acciones específicas. En su modelo, tres estados principales definen cada impulso: bajo homeostasis, homeostasis y sobre homeostasis. Cuando el agente encuentra el estímulo apropiado para satisfacer sus necesidades se dice que una pulsión está en homeostasis; a su vez, la ausencia de un estímulo corresponde a un estado de una pulsión bajo homeostasis mientras que la presencia de un estímulo extenso corresponde a un estado de sobrehomeostasis. Su modelo permite al agente seleccionar una tarea cuando dos impulsos deben

¹Robots con estructura externa parecida a un humano

satisfacerse al mismo tiempo y se contradicen entre sí (por ejemplo, cuando la energía y el juego deben satisfacerse) mediante la asignación de prioridad para satisfacer necesidades. Sin embargo, en esta propuesta no se considera el aprendizaje del agente mediante su interacción con el entorno ya que las habilidades son preprogramadas.

Los estudios asociados a la regulación energética autónoma no suelen abordarse de forma aislada. Generalmente, la regulación energética se estudia en conjunto con los mecanismos asociados a la motivación y las emociones. [Kirtay y cols. \(2019\)](#) implementaron un marco de aprendizaje por refuerzo (RL², por sus siglas en inglés) libre de modelo para argumentar que la emoción puede considerarse como un fenómeno emergente de un mecanismo de regulación de energía neurocomputacional de un agente cognitivo en una tarea de toma de decisiones. Este mecanismo genera una señal de recompensa interna para minimizar el consumo de energía neuronal de una secuencia de acciones. En su enfoque, cada acción desencadena un proceso de recuperación de la memoria visual en el que las acciones para explorar el entorno son movimientos del cuello y los ojos para dirigir la mirada. Según los autores, los mecanismos computacionales de atajo sobre los procesos cognitivos para facilitar la economía energética dan lugar a las emociones.

En otro trabajo, [Lewis y Canamero \(2016\)](#) estudiaron el papel que juega el placer en la selección de acciones relacionadas o no con la satisfacción de necesidades fisiológicas. Toman como base un modelo previo que considera el papel de las hormonas del placer como recompensa en el mantenimiento de la homeostasis en un proceso de RL ([Cos, Canamero, Hayes, y Gillies \(2013\)](#)). En su experimento, el agente debe sobrevivir en su entorno para implementar un simple 2RP. Curiosamente, evalúan los efectos de diferentes tipos de placeres y muestran que el placer, incluido el placer no relacionado con la satisfacción de la necesidad fisiológica, tiene valor para el manejo homeostático en términos de mejora de la viabilidad y mayor flexibilidad en la conducta adaptativa.

De acuerdo a [McFarland \(2009\)](#), uno de los niveles centrales de autonomía de los agentes artificiales está relacionado con la energía. Generalmente, los agentes artificiales actuales operan con baterías que deben ser reemplazadas o recargadas por el usuario. Sin embargo, los robots de carga

²Algoritmo computacional que aprenden una política que maximiza el rendimiento a largo plazo del agente (cantidad de recompensa) por el desempeño de una tarea ([Sutton y Barto \(2018\)](#)).

automática tendrían otro nivel de autonomía energética. Hay algunos trabajos iniciales centrados en la creación de agentes genuinamente autónomos energéticamente. Por ejemplo, el agente artificial EcoBot-II fue diseñado para regular de manera autónoma su energía al convertir la biomasa de insectos sin refinar en energía útil utilizando celdas de combustible microbianas integradas con cátodos de oxígeno (Ieropoulos, Melhuish, Greenman, y Horsfield, 2005).

Además, el trabajo descrito por Lowe et al. (2010) aborda la autonomía de la motivación energética desde una perspectiva de robótica evolutiva. En su estudio, la información fisiológica se genera mediante un metabolismo artificial simulado como un lote de células de combustible microbianas. Su modelo para integrar información sobre el medio ambiente y las necesidades internas está determinado por una interfaz de visión activa E-GasNet. La base del comportamiento de acuerdo con las limitaciones metabólicas artificiales permitió la evolución del comportamiento sensorial anticipatorio en la forma de una simple visión activa pan/tilt (inclinación y rotación).

Los estudios presentados muestran cómo las limitaciones metabólicas y fisiológicas impactan no solo en la actividad sensoriomotora, sino también en los mecanismos emocionales y motivacionales. Además, permiten la aparición de un comportamiento anticipatorio adaptativo y trayectorias motoras energéticamente eficientes de acuerdo con las necesidades de los agentes artificiales. Las necesidades fisiológicas están vinculadas con la regulación energética en términos del nivel de carga de la batería de los agentes. Sin embargo, pocos estudios abordan otras necesidades fisiológicas en agentes artificiales, como la integridad de los motores o la temperatura de funcionamiento óptima. Abordar dichos parámetros dentro de las necesidades que los agentes deben satisfacer incrementaría el nivel de autorregulación del agente artificial, logrando una mayor autonomía en ellos.

3.2. Emociones

No existe un consenso claro sobre la definición de emoción, en parte, porque se puede definir con base en su dominio afectivo, así como a sus aspectos conductuales que orientan cómo los agentes actúan y responden al entorno (Soudry, Lemogne, Malinvaud, Consoli, y Bonfils, 2011). Sin embargo, el componente fisiológico de las emociones resulta clave para su definición, incluyendo las necesidades fisiológicas y su correspondiente valencia negativa o

positiva, las cuales están fuertemente relacionadas con las experiencias emocionales. Se ha planteado la hipótesis de que las emociones evolucionaron para impulsar conductas que promueven la autorregulación y los procesos homeostáticos, lo que explica por qué una experiencia emocional depende, en parte, del procesamiento de señales interoceptivas (Pace-Schott y cols., 2019). Algunas emociones básicas, como el miedo, la ira, el disgusto, la tristeza, la felicidad y la sorpresa, podrían haberse desarrollado durante el curso de la evolución y estar al servicio de estrategias adaptativas (Ekman, 1992, 2016).

En general, las emociones pueden definirse como respuestas multifacéticas de todo el cuerpo que implican cambios coordinados en los dominios de la experiencia subjetiva, el comportamiento y la fisiología periférica (Mauss, Bunge, y Gross, 2007). Las emociones organizan rápidamente las respuestas de diferentes sistemas biológicos, incluida la expresión facial, el tono muscular somático, el tono de voz, la actividad del sistema nervioso autónomo y la actividad endocrina para producir un entorno corporal óptimo para una respuesta eficaz a la tarea (Rolls, 2000). El papel de estos fenómenos psicofisiológicos de corta duración de estados de sensaciones características abarca un sistema de respuesta conductual coordinado, jerarquías conductuales cambiantes, comunicación y vinculación social, procesamiento cognitivo de atajo y facilitación del almacenamiento y evocación de recuerdos (Dolan, 2002; Mulligan y Scherer, 2012; Phelps, 2006; Tyng, Amin, Saad, y Malik, 2017).

Las emociones representan modos eficientes de adaptación a las cambiantes demandas internas o ambientales. Este es el motivo por el que las emociones se consideran estados biológicos funcionales, permitiendo flexibilidad en las decisiones conductuales e incluso provocando la interrupción de una conducta cuando se produce un cambio ambiental repentino (Adolphs, 2017). En este sentido, los comportamientos asociados a los estados emocionales son altamente dependientes del contexto. Así, las emociones regulan la conducta al asociar la situación con estados emocionales de valencia positiva o negativa (Coifman y Bonanno, 2010).

En este sentido, las emociones funcionan como un elemento contextual central, proporcionando información directa relacionada con el agente, regulando la selección de tareas benéficas para el este, así como la interrupción de la tarea en curso cuando sea necesario. El agente puede establecer su posición ante el mundo, acercándose a ciertos objetos, tareas e ideas, y

alejándose de los demás. En general, las emociones expresan una valoración de una relación o interacción del agente con el entorno que implica un tipo particular de daño o beneficio (Griffiths y Scarantino, 2005). Junto con las necesidades fisiológicas y la motivación intrínseca, las emociones impulsan a los agentes a comportarse de una manera que aumenta su potencial para sobrevivir y prosperar (Lazarus y Lazarus, 1991).

3.2.1. Modelado de emociones en agentes artificiales

El modelado computacional de las emociones constituye un área de creciente interés en la investigación de la robótica cognitiva (Breazeal y Brooks, 2005; Ziemke y Lowe, 2009). Los estudios asociados con las emociones artificiales se pueden dividir en términos generales en aquellos que se centran en su papel en la modulación y organización del comportamiento y los que se centran en la interacción humano-robot (Arbib y Fellous, 2004). En este trabajo, la atención se centra principalmente en modelos que destacan el papel de las emociones en la toma de decisiones para la selección de tareas.

El modelado de emociones se ha explorado en el control de agentes multitarea (Ghayoumi y Bansal, 2016; Kowalczyk y Czubenko, 2010). En estos enfoques, los agentes artificiales generalmente aprenden algunas tareas predefinidas y luego encuentran la coordinación de alto nivel de estos comportamientos. Algunos estudios han asociado las emociones del agente con la utilidad esperada de cada comportamiento. Desde esta perspectiva, las emociones artificiales se pueden considerar como desencadenantes de secuencias de acciones conductuales de acuerdo con algún valor. Cuanto mayor sea el valor, mayor será la probabilidad de que se seleccione una tarea en un momento. Este tipo de enfoques se han implementado para interrumpir la conducta y seleccionar las secuencias apropiadas de acciones en tareas como la navegación y la exploración (Lee-Johnson y Carnegie, 2009).

Generalmente, los estados emocionales se utilizan para impulsar el RL (Moerland, Broekens, y Jonker, 2018). Por ejemplo, (Gadano y Hallam, 2001) propusieron un modelo en el que las emociones aportan un valor de refuerzo y determinan las situaciones en las que reevaluar decisiones en un robot móvil. El robot debe mantener su energía, evitar colisiones y moverse por un entorno cerrado similar a un laberinto. Las emociones abordadas fueron felicidad, tristeza, miedo e ira. Los autores implementaron su modelo de emociones utilizando una red neuronal artificial recurrente (RANN, por sus siglas en inglés) en la que las emociones influyen en la percepción del estado

del mundo. A su vez, este modelo se integró en una arquitectura de RL. La intensidad de cada emoción está asociada con el estado interno del agente, determinado por el hambre o la deficiencia energética, la temperatura del motor, la proximidad a los obstáculos, por nombrar algunos.

En [Marinier y Laird \(2008\)](#), los autores utilizaron la arquitectura cognitiva SOAR como base para la integración de un módulo de emoción. SOAR proviene de State, Operator And Result (Estado, operador y Resultado) que modela la representación de la resolución de problemas como la aplicación de un operador a un estado para obtener un resultado. En su propuesta, los sentimientos sirven como señal de recompensa para un robot móvil de cuatro ruedas. El sistema de emociones permite al robot evaluar a qué estímulos atender (repentinos, relevantes, agradables) así como decidir qué hacer con el estímulo atendido. El agente aprende a comportarse de una manera que se siente bien y evita sentirse mal. Acoplado a una tarea, el agente aprende que completar la tarea lo hace sentir bien. Curiosamente, sus resultados indican que los agentes con emociones aprenden muy rápido en relación con los robots con RL estándar. Argumentan que esto se debe a que sus agentes artificiales obtienen señales de recompensa en cada ciclo de decisión y, por lo tanto, obtienen retroalimentación intermedia sobre cómo lo están haciendo. Por otro lado, cuando se usa RL estándar, el agente solo obtiene retroalimentación de recompensa al final y, por lo tanto, esa información tarda más en propagarse a acciones anteriores.

En otro estudio, [Daglarli, Temeltas, y Yesiloglu \(2009\)](#) proporcionan una solución útil para la gestión de tareas con múltiples objetivos en un agente móvil. En su modelo, las emociones artificiales y un sistema motivacional constituyen el nivel de control más alto de una arquitectura de control de robot autónomo. Por un lado, el módulo de motivación asigna coeficientes de ganancia de comportamiento que proporcionan un aumento o disminución del impacto del comportamiento. A su vez, las emociones determinan secuencias de comportamientos para la planeación de acciones a largo plazo de acuerdo con las probabilidades de transición de los estados emocionales y conductuales. Los autores consideran un modelo de Markov oculto para los procesos de transición conductual y emocional. En su enfoque, las emociones están constituidas por secuencias conductuales que son desencadenadas por un evento conductual.

Por su parte, [Jitviriyaya, Koike, y Hayashi \(2015\)](#) propusieron un modelo de selección conductual-emocional basado en un mapa autoorganizado o

SOM (Self-organizing map, por sus siglas en inglés) y un modelo de Markov de espacio de estado estocástico discreto. En su propuesta, el agente artificial determina el comportamiento y la expresión emocional más adecuados según las situaciones tanto internas como externas. Como primer paso, el agente reconoce la situación externa y determina su motivación. A su vez, se utiliza un módulo de cognición para agrupar los estímulos de entrada (la motivación intrínseca y la situación externa) en un SOM. Posteriormente, el robot calcula los factores afectivos y conductuales. Específicamente, el sistema de selección conductual-emocional se implementa con un modelo de Markov. Las emociones básicas que se simulan en este trabajo son la normalidad, la esperanza, la felicidad, la tristeza, el miedo y el disgusto.

Algunos enfoques han adoptado un enfoque evolutivo para modelar las emociones en agentes artificiales. [Parisi y Petrosino \(2010\)](#) sugirieron que agregar un circuito emocional a la red neuronal que controla el comportamiento de un agente conduce a mejores decisiones motivacionales y, por lo tanto, a una mayor aptitud. En su estudio, los agentes se simulaban en cinco escenarios diferentes. Las posibilidades son que necesiten comer y beber, comer y volar lejos de un depredador, comer y encontrar un compañero de apareamiento, comer y cuidar a su descendencia, o comer y descansar para recuperarse del daño físico. Curiosamente, sus resultados muestran que los robots cuya red neuronal incluye un circuito emocional se comportan con mayor eficacia que los robots que no poseen un circuito emocional. Otros enfoques que utilizan redes neuronales artificiales para la modulación emocional de varios procesos se enfocan en aumentar o disminuir la eficiencia sináptica de poblaciones específicas de neuronas involucradas en estos procesos ([Belkaid, Cuperlier, y Gaussier, 2018](#)). En general, las emociones artificiales han ofrecido un enfoque elegante para la autonomía y la flexibilidad de comportamiento en agentes artificiales, proporcionando una forma unificadora de abordar diferentes problemas de control en agentes multitarea.

3.3. Motivación intrínseca

La motivación intrínseca podría definirse como un deseo o interés natural en llevar a cabo conductas específicas solo por el placer y la satisfacción derivados al realizar la actividad más que por algún incentivo, recompensa o presión externa ([Daddaoua, Lopes, y Gottlieb, 2016](#); [Oudeyer y Kaplan, 2008](#); [Ryan y Deci, 2000](#); [Sansone y Harackiewicz, 2000](#)). Esta tendencia

natural o inclinación de los agentes a explorar y dominar sus capacidades y dominar el entorno se lleva a cabo mediante diversas conductas como la exploración, la manipulación, la curiosidad y el juego (Reiss, 2004; Ryan y Deci, 2000; Stagnitti, 2004). Los comportamientos intrínsecamente motivados permiten a los agentes adquirir conocimiento sobre sí mismos y su mundo para interactuar de manera efectiva con el entorno, siendo crucial para el desarrollo cognitivo abierto (Deci, 1975).

Los agentes se esfuerzan por dominarse a sí mismos y a su entorno y por sentirse agentes causales. Los comportamientos intrínsecamente motivados resultan esenciales para que un agente adquiriera la competencia necesaria para la autonomía (Perry, Hogan, Marlin, y cols., 2000). White (1959) llamó a esta necesidad psicológica intrínseca de interactuar eficazmente con el entorno motivación o dominio. En este sentido, la cantidad de interacción efectiva o el grado de control que los agentes pueden tener sobre los objetos externos, las tareas, ellos mismos e incluso sobre otros agentes motiva su comportamiento en una tendencia natural (Deci, 1975).

Se ha argumentado que la motivación intrínseca está asociada con un mecanismo crucial para satisfacer necesidades distintas de las fisiológicas. En este sentido, mientras las necesidades fisiológicas estarían asociadas a la activación de tareas de mantenimiento para la supervivencia, la motivación intrínseca llevaría a los agentes a un compromiso activo con su entorno, buscando tareas interesantes y aprendiendo a través de estas interacciones. Se ha observado que las situaciones más motivadoras son aquellas con un nivel intermedio de novedad, entre situaciones ya conocidas y situaciones completamente nuevas (Berlyne, 1960). Como resultado, los agentes parecen buscar algunas formas de optimización entre situaciones completamente inciertas y completamente ciertas.

Cuando un agente realiza una tarea, se experimenta una emoción con un valor positivo o negativo como resultado de lo bien o mal que lo está haciendo para lograr su objetivo asociado. Recientemente, se ha sugerido que el monitoreo de la dinámica del error predictivo a lo largo del tiempo es un mecanismo de autorregulación que está detrás de la motivación intrínseca (Schillaci y cols., 2020). En cuanto al desempeño en una tarea, una experiencia emocional positiva está vinculada a una disminución continua del error predictivo, y una experiencia emocional negativa a un aumento continuo del error a lo largo del tiempo (O'Reilly, 2020; Schillaci y cols., 2020). Este mecanismo puede ayudar a explicar cómo los agentes seleccionan sus

objetivos, así como por qué la curiosidad y el juego son comportamientos fundamentales para el desarrollo en agentes (Kiverstein, Miller, y Rietveld, 2019).

La motivación intrínseca implica un ciclo continuo de búsqueda de objetivos óptimos y tareas interesantes que evocan emociones con valencia positiva. Este impulso interno proporciona un estímulo para el dominio de esas tareas y metas a lo largo del tiempo. Por lo tanto, la motivación intrínseca es un elemento contextual esencial para aprender y fomentar la interacción con el entorno, permitiendo la selección de tareas novedosas e interesantes en un contexto del entorno dado.

3.3.1. Modelado de la motivación intrínseca en agentes artificiales

Los algoritmos de motivación intrínseca en robótica cognitiva han demostrado ser herramientas prometedoras para permitir el aprendizaje, la adaptabilidad y los comportamientos impulsados por la curiosidad en agentes artificiales (Gordon, 2020; Schillaci y cols., 2020). Modelar la motivación intrínseca ha permitido dotar a los agentes de la flexibilidad para seleccionar de forma autónoma la tarea que van a realizar en cada momento (Oudeyer, 2018). La tendencia a sentirse atraído intrínsecamente por la novedad se ha utilizado a menudo como un ejemplo de motivación intrínseca para guiar la exploración (Huang y Weng, 2002; Oudeyer, Kaplan, y Hafner, 2007). Este enfoque se ha implementado para adquirir una ganancia de información óptima de los objetos novedosos o interesantes para crear un modelo más preciso del mundo a través de una exploración curiosa basada en una recompensa intrínseca inversamente proporcional a la previsibilidad del entorno (Schmidhuber, 1991).

Las implementaciones de motivación intrínseca en robótica utilizan modelos basados en conocimiento. En estos modelos, el interés de una acción o evento surge de la comparación entre los valores sensoriomotorepredichos, basados en un modelo interno directo, y los valores reales obtenidos mediante los sensores del agente (Oudeyer y Kaplan, 2008). Las situaciones interesantes son aquellas en las que el error predictivo es mayor. Por tanto, la recompensa intrínseca por cada evento destacado es proporcional al error predictivo de ese evento según el modelo aprendido. Esto permite a los agentes artificiales seleccionar de forma autónoma comportamientos de exploración dirigidos a objetivos impulsados por la curiosidad e impulsa la

exploración hacia los objetivos asociados con la cantidad óptima de error predictivo reducible (Schillaci y cols., 2020).

Por ejemplo, Marsland, Nehmzow, y Shapiro (2000) propusieron un filtro detector de novedad que utiliza un SOM que permite al agente evaluar la novedad de cada exploración de los sonares mientras explora el entorno. Las características del entorno son agrupadas en el SOM. Además, todas las neuronas del SOM están conectadas a una única neurona de salida. Las conexiones a esta neurona de salida representan el proceso de habituación de las neuronas biológicas, registrando el número de veces que se ha disparado cada neurona ganadora. La salida recibida de una neurona ganadora se reduce con la cantidad de veces que se dispara. Esto permite que el agente reconozca características nuevas o inusuales del entorno y olvide características que se repiten con el tiempo.

Por otro lado, los modelos basados en competencia proporcionan otra medida de interés, dado que son las propiedades del proceso de logro las que determinan el nivel de interés de una tarea asociada (Oudeyer y Kaplan, 2008). Los agentes prestan poca atención a aquellas tareas que ya están resueltas o no resueltas, para las que el progreso del aprendizaje se mantiene pequeño (Colas, Fournier, Chetouani, Sigaud, y Oudeyer, 2019). Así, los agentes son capaces de realizar tareas asociadas con situaciones sorprendentes o novedosas y pueden cambiar de forma autónoma eventos o tareas cuando su modelo de ese evento haya mejorado. De esta manera, el comportamiento está motivado por un sistema de recompensa intrínseco que favorece el desarrollo de una competencia amplia en lugar de estar dirigido a objetivos más específicos dirigidos externamente.

Luciw, Graziano, Ring, y Schmidhuber (2011) exploraron un sistema de curiosidad artificial para aprender activamente los sistemas cognitivos y de percepción durante una tarea de exploración. Su propuesta se basa en RL y se ocupa de observaciones visuales ruidosas de alta dimensión. El agente construye una representación interna de su mundo a través de la exploración. La activación perceptual se asigna luego, a través de una función de valor, a una distribución sobre las acciones del agente. Su señal de recompensa se modifica para contener dos componentes distintos: un componente intrínseco y uno externo. El componente externo es la señal de recompensa en RL clásico, mientras que la señal de recompensa intrínseca se basa en la medida de interés que se utiliza como un sistema de motivación para acelerar el aprendizaje. La medida del interés asigna valores bajos a patrones ya

conocidos y patrones que no se pueden aprender, y valores altos a patrones no conocidos, pero que pueden descubrirse. El modelo asigna valores para maximizar las recompensas externas e intrínsecas combinadas mediante una iteración de la política de mínimos cuadrados con el modelo interno directo de un agente.

La motivación intrínseca se ha utilizado para el aprendizaje autónomo de habilidades progresivamente más complejas y organizadas jerárquicamente. [Barto, Singh, y Chentanez \(2004\)](#) propusieron una estrategia para explorar el espacio de tareas donde cada decisión implica la ejecución de una tarea extendida temporalmente. Generalmente, estos enfoques utilizan el progreso del aprendizaje para guiar intrínsecamente la selección de objetivos. Esto genera agentes motivados para dominar un conjunto de tareas impulsadas por el progreso del aprendizaje de cada una de ellas. En estos modelos, el progreso del aprendizaje genera recompensas intrínsecas, que a su vez determinan la selección de acciones en un momento dado.

La mayoría de las implementaciones de motivación intrínseca utilizan el marco computacional de RL dada su inspiración en los sistemas de recompensa del cerebro ([Eschmann, 2021](#)). Los algoritmos de RL abordan el desafío de cómo un agente artificial puede aprender a aproximarse a una estrategia de comportamiento óptima, generalmente llamada política, mientras interactúa directamente con su entorno. De esta manera, el criterio de optimalidad de un problema es definir una función de recompensa primaria, una solución aproximada se ve como la habilidad de controlar de manera experta el sistema dado ([Sutton y Barto, 2018](#)).

Generalmente, la motivación intrínseca se ha centrado en la exploración y manipulación de objetos. [Hart y Grupen \(2013\)](#) proponen que una única función de motivación intrínseca para el descubrimiento de posibilidades de acción puede guiar el aprendizaje a largo plazo en agentes artificiales. Usando el marco de trabajo de RL, su función recompensa el descubrimiento de tareas como encontrar, agarrar y colocar objetos simples. La motivación intrínseca también se ha utilizado para mejorar el modelo del estado corporal y el espacio de acción del agente ([Frank, Leitner, Stollenga, Förster, y Schmidhuber, 2014](#)). Esto se logra guiando la exploración de estados y acciones utilizando recompensas intrínsecas. Estos enfoques abordan procesos de más bajo nivel³ como la planeación. En este caso de RL, el espacio de

³Se entiende por procesos cognitivos de alto nivel el lenguaje, el razonamiento, las funciones ejecutivas, resolución de problemas, entre otros. De acuerdo a la cognición

configuración se divide como parte de la estrategia de aprendizaje en varios problemas de RL débilmente acoplados con recompensas intrínsecas para guiar la exploración (Frank y cols., 2014).

Aunque los modelos de motivación intrínseca son útiles para que los agentes dirijan de manera autónoma su aprendizaje e interacción con el entorno, todavía no pueden explicar lo que hace interesantes muchas formas de exploración o manipulación. En este sentido, Singh, Lewis, Barto, y Sorg (2010) consideran una perspectiva evolutiva para definir un nuevo marco de recompensa óptima que capture la presión para diseñar buenas funciones de recompensa primaria que conduzcan al éxito evolutivo en todos los entornos. En su estudio, los autores muestran que tanto la motivación intrínseca como la extrínseca pueden entenderse como propiedades emergentes de las funciones de recompensa seleccionadas porque aumentan la aptitud de los agentes de aprendizaje en alguna distribución de entornos.

En general, la motivación intrínseca permite a los agentes artificiales modular la exploración del entorno y la selección de tareas de forma no aleatoria. Esto hace que el aprendizaje sea más eficiente, al permitir la selección de nuevas tareas y objetivos con la capacidad óptima para la reducción del error predictivo.

corporizada, dichos procesos se fundamentan en procesos de bajo nivel, que involucran a la percepción, la planeación motriz, entre otros.

CAPÍTULO 4

Contexto del entorno

El contexto del entorno se refiere al estado del entorno que rodea a un agente en un momento dado, lo que afecta la forma en que se procesa cada entrada sensorial (Nikolić, 2010). En general, la información contextual del entorno está relacionada con las características del terreno, el clima y la iluminación, así como con todas las entidades u objetos en una escena (Bloisi, Nardi, Riccio, y Trapani, 2016). Sin embargo, la disposición de los objetos y el cuerpo bajo una configuración espacial específica es un factor clave para determinar el contexto del entorno.

Generalmente, el entorno muestra ciertas regularidades. Cada escena contiene objetos específicos que aparecen con cierta probabilidad, y las relaciones espaciales entre estos elementos también se presentan bajo configuraciones típicas (Bar, 2004). La configuración típica de objetos específicos en cada escena permite distinguir diferentes tipos de contextos del entorno. En este sentido, identificar la configuración espacial del entorno y la configuración espacial de los objetos activa un marco contextual específico que integra información sobre la identidad de los objetos y sus ubicaciones (Gronau, Neta, y Bar, 2008).

En su famoso estudio cognitivo, (Biederman, Mezzanotte, y Rabinowitz, 1982) caracterizaron la organización de objetos en escenas del mundo real estableciendo cinco clases de relaciones entre un objeto y su entorno. Dichas relaciones son:

- Soporte. Los objetos tienden a descansar sobre superficies en lugar de flotar.
- Interposición. Los objetos interrumpen su fondo, ocluyen parte de la escena.
- Probabilidad. Los objetos tienden a encontrarse en algunas escenas más que en otras.
- Posición. Los objetos a menudo se encuentran en algunas posiciones con mayor probabilidad que en otras.

- Tamaño familiar. Los objetos tienen un conjunto limitado de relaciones de tamaño dentro de ellos.

Los hallazgos de [Biederman y cols. \(1982\)](#) dan un indicio sobre la información que los agentes representan sobre las escenas.

La atención se despliega para procesar la orientación, la ubicación y la configuración general de los objetos en el entorno, priorizando aquellas regiones relevantes para las acciones corporales ([Reed y Hartley, 2021](#)). El contexto del entorno restringe las tareas que un agente puede seleccionar en un momento dado a través de las posibilidades de acción que proporcionan los objetos en una situación. De acuerdo a ([Gibson, 2014](#)), una *affordance* se refiere a las posibilidades de acción que existen en virtud de una relación entre las propiedades del entorno y un agente. Los objetos por sí mismos no proporcionan posibilidades de acción, necesitan estar situados en un contexto para destacar como relevantes, permitiendo interacciones dependientes del contexto.

En este sentido, cada contexto del entorno ofrece un campo de posibilidades a los agentes según los objetos típicos presentes en él ([Rietveld, Denys, y Van Westen, 2018](#); [Withagen, De Poel, Araújo, y Pepping, 2012](#)). El contexto del entorno tiene un impacto predictivo sobre el comportamiento del agente, al permitir que se tomen determinadas acciones y restringir otras. Además, la configuración de los objetos espaciales tiene poder predictivo en la secuencia sensoriomotora necesaria para interactuar con ellos. Una teoría corporizada de la atención espacial en un contexto situado es aquella que ajusta dinámicamente las posibilidades del cuerpo, el entorno actual y los objetivos del agente que percibe ([Reed y Hartley, 2021](#)).

Por lo tanto, la configuración espacial del entorno, así como la configuración del cuerpo y de los objetos son elementos contextuales centrales para la selección y planeación de tareas en cualquier situación. La configuración espacial de los objetos es también un elemento fundamental del contexto relacionado con la tarea dado su papel esencial en los mecanismos de planeación y ejecución de la tarea seleccionada y se abordará en la sección [5](#). Como se mencionó anteriormente, la información sobre el contexto del entorno puede adquirirse por exterocepción. Aquí, solo se discutirá el procesamiento visual de la configuración espacial del entorno en agentes biológicos.

4.1. Configuración espacial del entorno

Algunos estudios han sugerido que el contexto semántico de una escena podría extraerse lo suficientemente temprano como para afectar la percepción de los objetos individuales en ella. Es ampliamente aceptado que el reconocimiento visual de escenas es un proceso rápido, automático y confiable (Greene y Oliva, 2009; Kaiser, Häberle, y Cichy, 2020; M. X. Lowe, Rajsic, Ferber, y Walther, 2018; Oliva, 2005). Por ejemplo, Thorpe, Fize, y Marlot (1996) han indicado que el procesamiento visual de escenas naturales complejas puede realizarse en menos de 150 ms. Para explicar este fenómeno, las teorías de la percepción visual han sugerido una estrategia de procesamiento basada en frecuencias espaciales (Aghajari, Vinke, y Ling, 2020; Kauffmann, Ramanoël, y Peyrin, 2014). Se ha sugerido que las neuronas dentro de la corteza visual temprana son selectivas para las estadísticas básicas de imágenes, incluida la frecuencia espacial. Se cree que estas neuronas actúan como filtros de paso de banda, con la ventana de sensibilidad de frecuencia espacial que varía en el campo visual y en las áreas visuales. La selectividad de frecuencia espacial es una propiedad distintiva de las neuronas visuocorticales tempranas (Aghajari y cols., 2020).

De acuerdo a esta postura, frecuencias espaciales específicas transmitirían información específica sobre la aparición de un estímulo (Q. Zhang y Li, 2020). Las frecuencias espaciales altas (HSF, por sus siglas en inglés) representan cambios espaciales abruptos en la información visual, como los bordes, y generalmente corresponden a información de configuración y detalles finos. Por otro lado, las frecuencias espaciales bajas (LSF, por sus siglas en inglés) representan información global sobre el estímulo (Kauffmann y cols., 2014). Como afirman Bar y Aminoff (2003), una versión de imagen borrosa parcialmente analizada de la entrada visual se proyecta rápidamente desde las áreas visuales tempranas hacia la corteza prefrontal. En este sentido, las LSF en la imagen pueden proporcionar información burda de las escenas y podrían alcanzar áreas de alto orden rápidamente al transmitir información a través de “atajos” anatómicos. Mientras tanto, las HSF pueden transmitir detalles finos de la imagen más lentamente (Kauffmann y cols., 2017; Kihara y Takeda, 2010; Petras, Ten Oever, Jacobs, y Goffaux, 2019).

Se ha sugerido que la representación borrosa del contexto del entorno puede activar expectativas o predicciones sobre las interpretaciones más probables de la imagen de entrada, que a su vez podría retroproyectarse hacia

atrás como una suposición inicial de la corteza temporal para integrarse con el procesamiento ascendente. De esta manera, el procesamiento rápido de información burda sobre el contexto del entorno desencadenaría el proceso de generar predicciones en niveles superiores (Bar, 2007). Desde esta perspectiva, se activaría una correspondencia entre una entrada novedosa y una representación existente similar a la entrada almacenada en la memoria. Entonces, las representaciones asociadas con esa representación similar se traducirían en predicciones. En este sentido, los procesos *top-down*, de arriba hacia abajo, pueden facilitar el reconocimiento al limitar el número de representaciones de objetos que podrían considerarse de acuerdo con la experiencia del agente (Bar, 2004).

Se ha propuesto que la representación del contexto de los distintos entornos o escenas podría almacenarse en estructuras de memoria llamadas marcos de contexto. Algunos estudios han sugerido que las representaciones asociativas integran información sobre la identidad de los objetos y sus ubicaciones (Gronau y cols., 2008). Estas estructuras reunirían información sobre la identidad de los objetos que tienen más probabilidades de aparecer en una escena específica, así como sobre las probables relaciones espaciales entre estos objetos (Bar, 2004; Gronau y cols., 2008). El conocimiento asociativo basado en la ubicación mejora la detección y el reconocimiento de objetos en una escena (Bar y Ullman, 1996). Al mismo tiempo, la detección de objetos que violan estas relaciones es menos precisa y más lenta que cuando esos mismos objetos están en relación normal con su entorno (Biederman y cols., 1982). Sin embargo, investigaciones más recientes proponen que los objetos que producen un alto error predictivo se detectan más rápidamente (Spaak, Peelen, y de Lange, 2020).

Los marcos de contexto implican fuertemente una representación global unificada de información asociativa basada en la identidad y la ubicación. De acuerdo con eso, Brady, Konkle, y Alvarez (2011) argumentan que los elementos individuales no se representan independientemente de otros elementos en la misma escena y que la memoria de trabajo visual almacena información más allá del nivel de los elementos individuales. De acuerdo a estos autores, cada escena podría tener múltiples niveles de estructura, desde el nivel de representaciones de características hasta elementos individuales y el nivel de grupos o conjuntos de objetos. Cada representación de escena permite simulaciones con respecto a la categoría específica del contexto activada en apoyo de la acción situada (Barsalou, 2020).

Asimismo, [Bar y Aminoff \(2003\)](#) han sugerido que los objetos podrían agruparse de distintas maneras de acuerdo con las características consideradas en algún dominio. Por ejemplo, los elementos pueden organizarse de acuerdo con sus características físicas en la vía visual ventral, mientras que las relaciones contextuales entre los objetos podrían codificarse en la corteza parahippocampal mientras que las relaciones semánticas en la corteza prefrontal.

Además, algunos estudios han sugerido que los agentes representan el conocimiento sobre dónde se usa típicamente un objeto junto con información sobre cómo se usa el objeto. [Peelen y Caramazza \(2012\)](#) proporcionaron evidencia, basada en resonancia magnética funcional en humanos, acerca de que las representaciones de objetos en los lóbulos temporales anteriores transmitirían información sobre dónde y cómo se usa típicamente un objeto. En este sentido, la información sobre los objetos, como dónde se usan típicamente y cómo se usan, estaría fuertemente relacionada con las propiedades motoras asociadas con esos objetos. No está del todo claro cómo se almacenan e integran estas asociaciones contextuales en el cerebro. Sin embargo, la mayor parte de la evidencia apoya a una organización por características o atributos que se distribuyen a través de múltiples regiones del cerebro.

A través de su interacción con el entorno, los agentes extraen regularidades sobre las posibilidades de acción que ofrecen los diferentes contextos del entorno según los objetos presentes en ellos. Esto favorece su acoplamiento estructural con el mundo, generando un campo de posibilidades relevantes para cada contexto del entorno particular. Una vez que los agentes han aprendido las regularidades sobre este acoplamiento, el procesamiento rápido del contexto les permitirá generar predicciones sobre posibles interpretaciones de la situación, simular situaciones y actuar de acuerdo a lo que dicte el contexto del entorno, seleccionando la estrategia o tarea adecuada en cada situación teniendo en cuenta también el contexto del agente.

4.1.1. Modelado de interacción de agentes artificiales con el entorno

Dentro de la robótica cognitiva, el modelado de la interacción del agente con su entorno se suele abordar desde enfoques distintos. Por un lado, se encuentran los estudios que se centran en la navegación del entorno. Por otro lado, están aquellos relacionados con la planeación de acciones realizadas con objetos específicos dentro de una región limitada del espacio, como

puede ser la superficie de una mesa. Generalmente, para la implementación de algoritmos computacionales de control de navegación se usan agentes artificiales con ruedas que le sirven para desplazarse por el entorno y no suelen contar con efectores que les permitan manipular objetos. Mientras tanto, la planeación de acciones requiere plataformas con al menos un brazo robótico. El estudio de la planeación de acciones durante la interacción con objetos está inspirado en las *affordances* o posibilidades de acción que el ambiente ofrece al agente, concepto introducido por James Jerome Gibson en 1966 (Gibson, 1966, 1977, 2014). La robótica cognitiva modela las *affordances* como la relación entre una acción, un objeto único y un efecto de la acción. Normalmente, en estos estudios el agente no se desplaza por el entorno y simplemente aprende a establecer la relación entre sus acciones y las consecuencias de desplazamiento que éstas causan sobre los objetos con los que interactúa. Por su naturaleza, este tipo de implementaciones serán abordadas como parte del contexto de la tarea (sección 5) ya que involucra la planeación y ejecución de una tarea. Sin embargo, es importante mencionar que algunos algoritmos computacionales para el aprendizaje de las *affordances* toman en cuenta un contexto ambiental constante e invariable de manera implícita debido a que el modelado solo considera la relación entre una acción, un objeto único y un efecto de la acción (Kammer, Schack, Tscherepanow, y Nagai, 2011). Un factor del entorno que tiende a ser ignorado en este tipo de modelos es la superficie sobre la cual se realiza la tarea. Esta consideración es importante debido al hecho de que si el material de la superficie cambia entonces el comportamiento del objeto y el efecto también se modificaría.

Desde una perspectiva corporizada, esto restringe fuertemente la interacción que los agentes artificiales pueden tener con el entorno y, por lo tanto, la flexibilidad conductual que pueden adquirir durante el proceso de aprendizaje. Sin embargo, existen algunos estudios que consideran el contexto del entorno para acoplar la navegación y la manipulación al mismo tiempo (Sisbot y cols., 2005). Este tipo de estudios son los que serán abordados a continuación. En su mayoría, estos estudios dotan a los agentes artificiales de habilidades pre-establecidas para que puedan realizar diversas tareas en entornos domésticos. El conocimiento de los agentes generalmente incluye bases de datos de objetos que no necesitan aprender. Además, los agentes especifican y conocen de antemano los pasos necesarios para lograr los objetivos.

Por ejemplo, Blomqvist y cols. (2020) presentaron un sistema de manipulación móvil con capacidad de percepción, ubicación, navegación, planeación

motora y agarre. El principal interés de su proyecto es generar aplicaciones robóticas capaces de realizar tareas en entornos interiores no estructurados. El agente artificial que usan es conocido como RoyalYumi, un robot ABB YuMi que está montado sobre una base móvil omnidireccional y puede navegar usando un mapa global pre-construido en 3D de su entorno. Además, el agente usa sensores para construir una cuadrícula de ocupación para la navegación. El agente es capaz de ubicarse en el entorno mediante un algoritmo en línea que se utiliza para estimar su posición en el mapa global. Durante la navegación, el agente puede detectar objetos a través de un sistema de visión basado en RGB, utilizando una red neuronal preentrenada con una base de datos de diferentes objetos. Una vez que se identifica el objeto relacionado con la tarea, el agente extrae información sobre su posición en el espacio para agarrarlo. Una vez calculada la posición del objeto de interés, se reconstruye en detalle la geometría 3D de la escena local. Posteriormente, se utilizan algoritmos de detección de pose de agarre para generar y clasificar un conjunto de posibles tipos de agarre. Finalmente, se planifica y ejecuta una trayectoria a la posición de agarre elegida, se cierra la pinza y se recupera el objeto de la mesa. Estas acciones permiten al agente navegar en un laboratorio, encontrar un objeto en una de las mesas circundantes, tomarlo y dejarlo caer en otro lugar.

A su vez, [Asfour y cols. \(2006\)](#) están interesados en el desarrollo de agentes humanoides que coexistan de forma segura con los humanos y realicen diversas tareas. Los autores presentaron un robot humanoide denominado ARMAR III enfocado en la realización de tareas en escenarios domésticos. Su arquitectura de control presenta una organización jerárquica de tres niveles: planeación de tareas, sincronización y coordinación, y nivel de ejecución llamado nivel de actor-sensor. En el enfoque propuesto, cada tarea se descompone en subtareas que representan secuencias de acciones. Cada subtarea contiene la información necesaria para la ejecución, como los parámetros de los objetos, así como información espacial sobre el entorno. El nivel más alto relacionado con la representación de tareas es el nivel de planeación. Este nivel especifica las subtareas que el agente debe realizar para lograr un objetivo. Este componente también es responsable de la gestión de recursos y habilidades. El nivel de coordinación de la tarea activa acciones secuencialmente o en paralelo para el nivel de ejecución. Por otro lado, el nivel de ejecución se basa en la teoría de control para ejecutar comandos de control específicos. Este nivel utiliza modelos activos locales específicos sobre el entorno y los objetos. Al principio, los modelos activos se inicializan mediante modelos globales, que integran información del en-

torno, que contiene la base de datos de los objetos, tareas y habilidades del agente. El modelo global corresponde a la memoria a largo plazo, mientras que los modelos activos corresponden a la memoria a corto plazo del agente. Los modelos activos pueden actualizarse y reorganizarse para actualizar las estrategias operativas. La arquitectura puede detectar errores, mismos que se utilizan como retroalimentación para el nivel de coordinación de la tarea. La plataforma robótica aún está en desarrollo y recientemente se introdujo una nueva versión, que es capaz de colaboración bimanual y comprensión del lenguaje natural (Asfour y cols., 2019).

Desde otra perspectiva, Puigbo, Pumarola, Angulo, y Tellez (2015) dotaron a un agente artificial REEM de un conjunto de ciertas habilidades predefinidas como la navegación, el agarre de objetos, así como el reconocimiento de objetos y personas. El objetivo principal de este estudio fue proporcionar a los robots de servicio una arquitectura de control que les permitiera generar y ejecutar sus propios planes para lograr un objetivo. Su estrategia consistió en implementar una arquitectura cognitiva previamente descrita llamada estado, operador y resultado (SOAR, por sus siglas en inglés) como parte de su enfoque (Laird, Kinkade, Mohan, y Xu, 2012; Laird, Newell, y Rosenbloom, 1986). SOAR actúa como el razonador del agente artificial al seleccionar las acciones que deben realizarse para lograr un objetivo. El sistema de control propuesto se compone de cuatro módulos principales. Como primer paso, se envía un comando vocal al robot que se traduce a texto mediante un sistema automático de reconocimiento de voz. Posteriormente, el módulo extractor semántico divide el texto recibido en estructuras gramaticales, a partir de las cuales se genera el objetivo. El objetivo se compila en el módulo razonador y se envía como entrada a la arquitectura cognitiva SOAR. Finalmente, las acciones sugeridas por SOAR se traducen como activaciones de habilidades en los nodos de acción. El robot tiene información sobre el entorno en cinco categorías: 1) un mapa del entorno donde el agente realiza las tareas, 2) una ontología que contiene todas las acciones, nombres de objetos, personas y lugares, 3) una base de datos de modelos 2D/3D de objetos que el agente puede reconocer y captar, 4) una base de datos de rostros que el robot puede reconocer y 5) una base de datos con el conocimiento actual del estado del mundo, el agente, los objetos y las personas. La información disponible para el agente le permite manipular un objeto, navegar por una habitación e interactuar con personas.

Los agentes artificiales descritos en esta sección son capaces de navegar por el entorno y realizar tareas de manipulación de objetos. Sin embargo,

la información sobre el contexto del entorno en el que interactúan está predefinida por el programador y no es adquirida a través de la exploración y el aprendizaje autónomo de dichos agentes. En algunos casos, los agentes pueden planear secuencias de acciones. Sin embargo, las habilidades que exhiben tampoco se adquieren a través de la experiencia. A pesar de las limitaciones, está claro que considerar el contexto del entorno amplía las habilidades que puede exhibir un agente artificial.

Contexto de la tarea

Los agentes interactúan con diferentes objetos a través de tareas de manipulación, como agarrar, jalar, o empujar. Cada tarea sensoriomotora implica una secuencia temporalmente ordenada de estados sensoriomotores que conduce a un objetivo específico (Grafton, Hazeltine, y Ivry, 1998). Para planear y ejecutar eficazmente una tarea, los agentes deben adquirir información relevante sobre ellos mismos y sobre los objetos involucrados en la tarea. Los elementos relevantes para lograr el objetivo de la tarea constituyen el contexto de la tarea. Los elementos centrales para la planeación y ejecución de una tarea sugeridos en este proyecto son la postura corporal, el espacio peripersonal y el cuerpo situado junto con la configuración espacial del objeto involucrado en la tarea. Es importante resaltar que todos estos elementos cambian dinámicamente durante la ejecución de la tarea.

Como un ejemplo, al agarrar un objeto, la información sobre su posición y orientación es crucial para adaptar con precisión la secuencia sensoriomotora (Baltaretu, Monaco, Velji-Ibrahim, Luabeya, y Crawford, 2020; Chen y cols., 2014). Dada una determinada configuración del objeto, es posible predecir la secuencia de acciones que realizará un agente para lograr un objetivo específico. Por ejemplo, el tipo de agarre utilizado para levantar un vaso dependería de si el objeto está boca abajo o en posición vertical sobre una mesa (Rosenbaum y cols., 2014). Además, si la tarea implica la interacción con dos o más objetos, la relación espacial entre dichos elementos se vuelve relevante para planear la tarea.

Para ejecutar eficazmente una tarea sensoriomotora, no sólo es fundamental adquirir información sobre la configuración del objeto, sino también información sobre la configuración del propio cuerpo del agente en un momento dado (Sarlegna y Sainburg, 2009). En el ejemplo de levantar un vaso de la mesa, la secuencia sensoriomotora también dependerá de la posición inicial del cuerpo. Esta información se puede adquirir directamente a través de la propiocepción o indirectamente a través de información exteroceptiva entrante, como la visión, que proporciona información sobre la configuración

del cuerpo situado dentro del contexto del entorno.

Planear las secuencias sensoriomotoras de una tarea implica que el agente tiene que predecir las consecuencias sensoriomotoras resultado de sus acciones. Así, durante la ejecución de las secuencias sensoriomotoras planeadas, el error predictivo resultante (la diferencia entre las consecuencias sensoriales predichas y la entrada sensorial entrante) permite ajustar dinámicamente las secuencias sensoriomotoras planeadas de acuerdo con el cuerpo y la configuración del objeto situados. En conjunto, la configuración del cuerpo del agente y la configuración de los objetos relevantes para la tarea en cualquier momento específico, determinarían la secuencia sensorial que permitiría al agente alcanzar el objetivo de la tarea (Rosenbaum y cols., 2014).

La postura corporal de un agente y su espacio peripersonal combinados, determinan la ubicación de un objetivo en relación con la posición de una extremidad, como el brazo. El control efectivo del cuerpo para evitar o manipular objetos requiere una representación neuronal integrada del cuerpo y el espacio alrededor del cuerpo. En este sentido, la postura corporal y el espacio peripersonal son propiedades emergentes de redes interdependientes de centros corticales y subcorticales. Cada centro procesa información multisensorial en un marco de referencia adecuado a la parte del cuerpo sobre la que recibe información, y con la que se van a dar respuestas (Holmes y Spence, 2004). A continuación se abordan cada uno de los elementos contextuales centrales para planear y ejecutar la tarea.

5.1. Postura corporal

Antes de poder interactuar eficientemente con su entorno, los agentes biológicos deben distinguir su cuerpo del resto del mundo así como aprender a controlarlo. Los agentes necesitan adquirir información sobre la posición de su cuerpo en el espacio para guiar sus movimientos y ser capaces de mover sus extremidades de una configuración a otra de manera precisa. Esta información sobre su propio cuerpo es adquirida mediante sus modalidades sensoriomotoras. Los agentes adquieren y procesan información sobre la posición de sus extremidades en el espacio a través de diferentes modalidades sensoriales, como la propiocepción y la visión (Grigg, 1994; Montell, 2019; Saunders y Knill, 2003; Sherrington, 1907).

La propiocepción¹ es una modalidad sensorial que procesa información sobre la posición y la fuerza ejercida en cada parte del cuerpo (Montell, 2019; Sherrington, 1907). Al mismo tiempo, los agentes pueden usar la visión para conocer la posición de sus extremidades en el espacio y utilizar esta información para guiar sus movimientos (Saunders y Knill, 2003). En situaciones normales, los agentes integran la propiocepción y la información visual para realizar movimientos del brazo dirigidos a objetivos (Limanowski y Friston, 2020; Sober y Sabes, 2005). Incluso, desde la psicología ecológica se ha propuesto que el agente extrae información sobre sí mismo (sobre su tamaño, por ejemplo) mediante el procesamiento del flujo óptico a través de la deformación de las líneas y su invarianza (Blau y Wagman, 2022).

El cerebro integra la información del cuerpo recibida a través de los sentidos en una representación neuronal multimodal conocida como esquema corporal (Carruthers, 2008; Head y Holmes, 1911; Hoffmann, Lanillos, Jamone, Pitti, y Somogyi, 2020; Morasso, Casadio, Mohan, Rea, y Zenzeiri, 2015). Este modelo permite monitorear constantemente la configuración espacial del cuerpo y permite al agente desencadenar la planeación y ejecución de movimientos dirigidos a objetivos (Schillaci, Hafner, y Lara, 2016). Al realizar movimientos dirigidos a un objetivo, los agentes deben integrar información intrínseca sobre la posición del cuerpo y cómo esto se relaciona con las coordenadas espaciales extrínsecas de los objetos en el mundo (Sainburg, Lateiner, Latash, y Bagesteiro, 2003).

Básicamente, el esquema corporal integra información del sistema visual, la propiocepción, la audición, el sistema vestibular, la detección táctil y el aparato motor para mantener actualizada la representación de las posiciones de las diferentes partes del cuerpo en el espacio, con la finalidad de poder preparar un movimiento (Carruthers, 2008). Aunque se ha afirmado que existe más de una representación corporal en el cerebro, el esquema corporal se ha relacionado fuertemente con las representaciones sensoriomotoras del contexto espacial del cuerpo necesario para guiar las acciones de los agentes (De Vignemont, 2010).

La representación del cuerpo puede existir en un conjunto de marcos de referencia diferentes, como los marcos de referencia centrados en el cuerpo o los ojos. De acuerdo a Holmes y Spence (2004), un marco de referencia

¹Los propioceptores se encuentran en casi todos los animales móviles, desde la mosca de la fruta *Drosophila melanogaster* hasta los cachalotes (Mamiya, Gurung, y Tuthill, 2018).

centrado en el cuerpo representa la superficie del cuerpo topográficamente y podría existir en la corteza somatosensorial primaria y en varias otras áreas del cerebro, como la corteza somatosensorial secundaria, el putamen, la corteza premotora y la corteza motora primaria. Asimismo, los autores proponen que las señales visuales sobre la ubicación de las partes del cuerpo podrían dirigirse a la parte relevante de dicha representación somatotópica para transmitir el espacio visual alrededor de las partes individuales del cuerpo. Alternativamente, un marco de referencia centrado en el ojo podría estimar la ubicación de diferentes partes del cuerpo con respecto a un mapa retinotópico en la corteza visual. Sin embargo, aún no queda claro cómo las representaciones desde diferentes marcos de referencia son integradas.

Se han sugerido modelos internos como el mecanismo para codificar el esquema corporal (Wolpert, Ghahramani, y Flanagan, 2001; Wolpert, Ghahramani, y Jordan, 1995). Se han propuesto dos modelos internos: modelo directo e inverso. El modelo directo o predictor, predice la siguiente situación sensorial o estado del agente dada una acción y una situación sensorial actual (Kawato y cols., 2003; Miall y Wolpert, 1996; Tanaka, Ishikawa, Lee, y Kakei, 2020). El modelo inverso o controlador, genera un comando motor apropiado para cambiar del estado sensorial actual a un estado sensorial deseado. Estos modelos permiten a los agentes establecer una relación causal entre sus intenciones y acciones, así como anticipar los efectos generados por sus acciones (Wolpert y Kawato, 1998). Los modelos internos integran la configuración espacial del cuerpo y la información motora para controlar los movimientos y planear acciones (McNamee y Wolpert, 2019). Esta asociación permitiría a los agentes generar planes motores de acuerdo con su postura corporal actual para lograr un objetivo específico. La postura corporal de un agente constituye un elemento central del contexto de la tarea dado su papel determinante en la planeación y ejecución de una acción (Zimmermann, Meulenbroek, y de Lange, 2012).

Con respecto a la formación del esquema corporal, se ha sugerido que éste se desarrolla a través de la interacción con el propio cuerpo inmediatamente después del nacimiento o incluso antes, dentro del útero (Berlucchi y Aglioti, 1997; Joseph, 2000). Se ha reportado que los bebés a la edad de 2 a 3 meses pasan tiempo considerable observándose y tocando sus diferentes partes del cuerpo. De acuerdo a Rochat (1998), estas observaciones sugieren que los infantes calibran su información visual y propioceptiva mediante un proceso de balbuceo, en el que aprenden las redundancias temporales e intermodales. Durante este proceso, los bebés producen movimientos aleatorios

que involucran cambios en su situación sensorial, definida como una configuración del cuerpo del agente en un momento específico, así como toda la información que se puede percibir en ese contexto a través de los diferentes canales sensoriales. De esta manera, el agente puede establecer asociaciones entre situaciones sensoriales y movimientos a través del balbuceo motor.

El esquema corporal tiene la propiedad de ser plástico con el tiempo (Llorens y cols., 2017). Para controlar de manera eficiente las acciones, ya sea con el cuerpo o mediante herramientas manuales, el cerebro necesita codificar, actualizar y almacenar las propiedades del efector, incluido su tamaño y forma, así como su ubicación en el espacio. Esta información del esquema corporal se combina con el estado del mundo para construir un plan motor apropiado. Se ha reportado que dicha representación corporal responde a períodos más cortos de actividad que implican el uso de objetos y herramientas. De acuerdo con esto, Ramachandran, Blakeslee, y Shah (2013) sugieren que la representación de esquema corporal no está restringida al cuerpo e incluso puede involucrar objetos inanimados. En su famoso experimento, Iriki, Tanaka, y Iwamura (1996) entrenaron a monos macacos para acercar objetos distantes utilizando una herramienta mientras registraban la actividad neuronal del giro postcentral caudal, el cual integra señales somatosensoriales y visuales. Una gran cantidad de neuronas bimodales² parecían codificar el esquema de la mano. Sin embargo, durante el uso de la herramienta, sus campos receptivos visuales se alteraron para incluir toda la longitud de la herramienta. De acuerdo a los autores, estos hallazgos pueden representar correlatos neurales del esquema modificado de la mano en la que se incorporó la herramienta. Adicionalmente, se ha reportado que la propiocepción es fundamental para la plasticidad del esquema corporal durante el uso de herramientas. De acuerdo a Cardinali, Brozzoli, Luauté, Roy, y Farnè (2016), los hallazgos de un estudio de caso de un paciente desaferentado del miembro superior derecho sugieren que las herramientas no pueden incorporarse completa y rápidamente cuando solo se dispone de información visual para guiar el movimiento.

Los agentes biológicos adquieren información acerca de la configuración de su cuerpo en el espacio por medio del esquema corporal. Esta representación corporal integra información de diferentes canales sensoriales en una representación multimodal del cerebro para mantener actualizada la infor-

²Las neuronas bimodales integran información visual y táctil y se activan solo cuando un estímulo cae dentro del espacio peripersonal (Ürsino, Zavaglia, Magosso, Serino, y di Pellegrino, 2007).

mación contextual del cuerpo en el espacio a cada momento. Además, el esquema corporal se forma durante el desarrollo y tiene la propiedad de ser plástico con el tiempo. Existe abundante evidencia acerca del esquema corporal, no obstante, todavía queda por explorar los mecanismos que permiten la integración multimodal de diferentes marcos de referencia para construir este.

5.1.1. Esquema corporal y modelos internos

Para guiar los movimientos a través del espacio, el cerebro debe monitorear constantemente las posiciones de las extremidades y hacer predicciones sobre sus posiciones futuras. Se ha propuesto que las asociaciones entre situaciones sensoriales y el movimiento para cambiar de una configuración corporal a otra se llevan a cabo mediante modelos internos dentro del cerebro (Wolpert y cols., 2001). Estos modelos integran información sensorial y motora que involucra el esquema corporal de forma natural creando una representación multimodal (De Vignemont, 2010). Diversos estudios sobre el desarrollo cognitivo en humanos sugieren que el sistema nervioso central simula internamente conductas dinámicas del sistema motor mediante el uso de modelos internos para planear, controlar y aprender acciones (Blakemore, Wolpert, y Frith, 2000; Kawato, 1999; Wolpert y cols., 1995).

Básicamente, existen dos modelos internos: el modelo directo y el modelo inverso (Figura 5.1). El modelo directo predice la siguiente situación sensorial ($St+1$) o estado del agente dada una acción o comando motor (M) y una situación sensorial actual (St); este modelo también se conoce como predictor. Por otro lado, el modelo inverso o controlador genera un comando motor M necesario para cambiar de una situación sensorial actual St a otra situación sensorial deseada $St+1$. Desarrollar los modelos internos es básicamente establecer una relación causal entre los movimientos y los estados sensoriales. Asimismo, aprender los patrones espacio-temporales que relacionan a las diversas modalidades, las acciones y configuraciones corporales permite a los agentes distinguir su propio cuerpo del entorno y controlar sus movimientos de manera eficiente en el mundo.

El modelo directo y el modelo inverso pueden estar acoplados (Figura 5.2). Su acoplamiento permitiría predecir varios estados futuros o acciones para tener información del sistema a largo plazo (Jordan y Rumelhart, 1992). Este modelo de predicción de varios pasos generaría una serie o se-

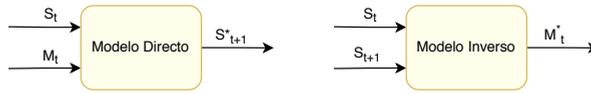


Figura 5.1: Modelos internos: modelo directo e inverso.

cuencia de estados antes de ejecutarlos, otorgándole a un agente la posibilidad de anticipar, predecir y planear conductas motoras basándose en simulaciones internas (Schillaci, Lara, y Hafner, 2012). Los modelos mixtos o acoplados han causado gran interés y se han estudiado extensivamente en el campo de las neurociencias (Kawato, 1999; Wolpert y Kawato, 1998). De acuerdo a la postura de la teoría de la cognición cimentada, estas representaciones se adquieren durante la experiencia y pueden ser re-activadas, generando simulaciones internas durante los procesos de percepción y acción.

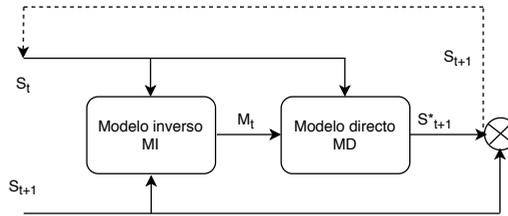


Figura 5.2: Modelos internos acoplados.

Los modelos internos forman parte de una de las principales teorías para el aprendizaje y el control motor dentro de las ciencias cognitivas. Asimismo, las representaciones multimodales, el esquema corporal y la simulación interna son considerados fundamentales para la planeación de acciones y para interactuar de manera eficiente con el entorno.

5.1.2. Modelado del esquema corporal en agentes artificiales

Al igual que los bebés, los agentes artificiales pueden adquirir un esquema corporal, una estrategia común es el balbuceo motor (Houbre, Angleraud, y Pieters, 2020). Durante este proceso, los agentes realizan movimientos aleatorios que a su vez provocan cambios en su situación sensorial. De esta manera, los cambios en las situaciones sensoriales y los movimientos que las

causan se asocian. Además, aprender los patrones espacio-temporales que relacionan sus modalidades sensoriomotoras y su configuración corporal permite al agente distinguir entre su propio cuerpo y el entorno (Diez-Valencia, Ohashi, Lanillos, y Cheng, 2019).

En la robótica cognitiva, los modelos internos son un enfoque típico para permitir que los agentes adquieran las representaciones sensoriomotoras necesarias para la predicción y la generación de acciones (Dearden y Demiris, 2005). Sin embargo, las herramientas computacionales para codificar el contexto espacial del cuerpo del agente, la situación sensorial, los movimientos así como los enfoques para mapear asociaciones entre ellos varían considerablemente (Nguyen, Hoffmann, Pattacini, y Metta, 2019; Schillaci y cols., 2016).

Por ejemplo, Gama y Hoffmann (2019) estudian la adquisición de esquemas corporales en robots humanoídes para construir representaciones propioceptivas similares a mapas, parecidas a representaciones somatotópicas dentro del cerebro. En su enfoque, los ángulos articulares del robot se consideran entradas propioceptivas y se obtienen a partir de diferentes configuraciones corporales. La información propioceptiva sirve como entrada a un SOM modificado (Figura 5.3). La activación de neuronas en los mapas codifica una articulación o una combinación de dos o tres de ellas, como campos receptivos de neuronas en la corteza somatosensorial (Krubitzer, Huffman, Disbrow, y Recanzone, 2004). Utilizando un enfoque similar, este algoritmo también se ha implementado para representar la superficie de la piel del robot iCub (Hoffmann, Straka, Farkaš, Vavrečka, y Metta, 2017).

En un enfoque diferente, T. Zhang y cols. (2018) implementaron una red neuronal autocodificadora o *autoencoder* para modelar la propiocepción en un robot humanoide PKU-HR6.0, que es del tamaño de un niño de 3,93 kg de peso y 59,50 cm de altura. La red neuronal *autoencoder* que implementan realiza un proceso de reconstrucción de entrada, codificando una entrada de alta dimensión en capas de dimensiones inferiores y luego realiza el proceso inverso para reconstruir la entrada. Curiosamente, dicho estudio no considera los ángulos de articulación directamente como información propioceptiva, como se suele hacer. Los autores consideran dos características de la propiocepción: 1) el valor exacto de los ángulos articulares es desconocido para los agentes biológicos, solo está disponible una aproximación y 2) la propiocepción debe ser capaz de representar estados corporales. Siguiendo esta

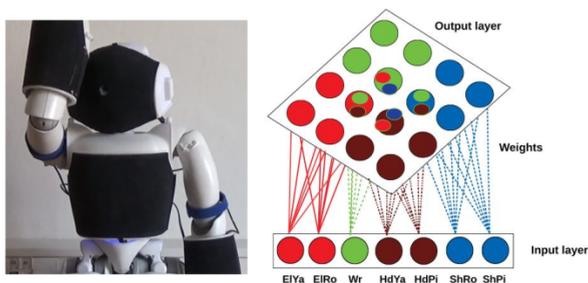


Figura 5.3: A la izquierda se observa al robot nao tocando su propio cuerpo. A la derecha se muestra un esquema de los campos receptivos superpuestos en la capa de salida obtenidos mediante el algoritmo MRF-SOM. Figura tomada del trabajo reportado por [Gama y Hoffmann \(2019\)](#).

idea, la configuración conjunta es la entrada a la red y la capa oculta se considera la propiocepción del agente artificial (Figura [5.4](#)). En este estudio se enfocan en dotar al agente con la capacidad de controlar su brazo mediante el aprendizaje de los modelos internos que asocian los ángulos de la articulación del brazo y la postura de la mano, en un espacio libre de objetos.

Por otro lado, utilizando un autocodificador variacional multimodal (VAE, por sus siglas en inglés), [Zambelli, Cully, y Demiris \(2020\)](#) propusieron un sistema que permite a un robot humanoide iCub aprender representaciones de sus capacidades sensoriomotoras considerando la configuración espacial de su cuerpo. En este marco, el VAE multimodal está formado por múltiples codificadores y decodificadores, uno para cada modalidad sensorial como propiocepción, visión, tacto, auditiva y motora. El modelo aprendido puede reconstruir el estado multimodal del robot, incluidos los datos propioceptivos, visuales, táctiles, de sonido y de comandos del motor, a partir de información parcial.

Desde un enfoque distinto, [Escobar-Juárez, Schillaci, Hermosillo-Valadez, y Lara-Guzmán \(2016\)](#) dotaron a un agente artificial con la capacidad de ejecutar movimientos sacádicos para enfocar un estímulo en la fovea así como para realizar una tarea de coordinación mano-ojo mediante representaciones multimodales. En este estudio se propone la Arquitectura de Modelos Internos Autoorganizados (SOIMA, por sus siglas en inglés), una red de mapas autoorganizados interconectados con pesos hebbianos. SOIMA proporciona modelos acoplados inversos y directos que permiten

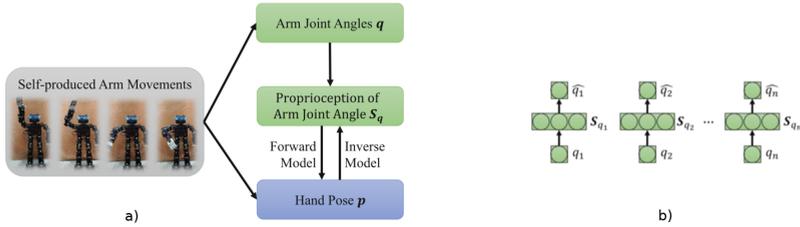


Figura 5.4: Arquitectura propuesta para modelos internos basados en propiocepción. a) Flujo de información del modelo directo e inverso de la arquitectura b) esquema representativo de la estructura de los *autoencoders* para codificar propiocepción en cada articulación. Figura tomada de T. Zhang y cols. (2018).

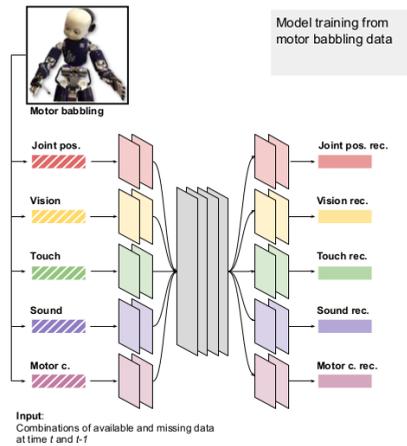


Figura 5.5: Descripción general de la arquitectura propuesta por Zambelli y cols. (2020). El modelo aprendido puede reconstruir el estado multimodal del robot, incluidos los datos propioceptivos, visuales, táctiles, de sonido y de comandos del motor, a partir de información parcial.

asociaciones multimodales de información sensorial y motora (Figura 5.10).

En los estudios anteriores, una vez aprendido, el esquema corporal no es adaptable o alterable como ha sido reportado que ocurre en agentes biológicos (Iriki y cols., 1996). Considerando la flexibilidad de las representaciones corporales, Nabeshima, Kuniyoshi, y Lungarella (2006) propusieron un modelo de adaptación del esquema corporal biológicamente inspirado. Su enfoque se basa en una fase de integración temporal en la que el robot alcanza y toca un objeto con la mano y aprende a integrar temporalmente información visual y táctil en una memoria asociativa. Si la información visual recordada es consistente con la información visual obtenida actualmente, entonces la ubicación del contacto visual se considera como la ubicación en la mano donde se originó la sensación táctil. Por otro lado, si el contacto visual no ocurre en la mano del robot, sino en la herramienta, entonces el robot no puede usar adecuadamente la herramienta con el controlador de trayectoria manual actual, lo que induce al sistema a aprender un nuevo controlador cinemático para la herramienta. En su modelo, la memoria global se compone de dos memorias asociativas: una red neuronal de compuerta para asociar la información de dirección de aproximación al objetivo detectada visualmente con información táctil y una red neuronal no monótona que asocia señales táctiles con la distancia entre la mano y el objetivo. Curiosamente, los autores sugieren que el uso de herramientas depende de la unificación coherente de los aspectos espaciales y temporales de la información multimodal. Por lo tanto, su modelo se basa en la integración temporal de la visión, el tacto y la información propioceptiva.

Los algoritmos de aprendizaje han demostrado ser herramientas computacionales útiles para crear representaciones multimodales como el esquema corporal en robótica cognitiva (Hoffmann y cols., 2010; Morasso y Mohan, 2021). Desde mapas propioceptivos hasta representaciones multimodales que implican la integración de diferentes modalidades, como la visión y la información táctil, estos estudios han buscado dotar a los agentes artificiales de la capacidad de adquirir de forma autónoma información contextual sobre sus propios cuerpos. Las modalidades más exploradas en robótica cognitiva han sido la propiocepción y la visión, sin embargo, existe un interés creciente en involucrar otras modalidades para dotar a los agentes artificiales de una mayor flexibilidad conductual (Dahiya, Mittendorfer, Valle, Cheng, y Lumelsky, 2013; Pugach, Pitti, Tolochko, y Gaussier, 2019; Zenha, Vicente, Jamone, y Bernardino, 2018).

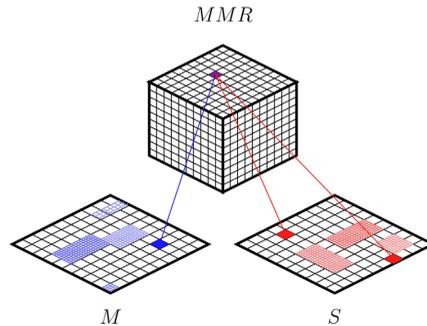


Figura 5.6: SOIMA: *Self-Organized Internal Models Architecture*. Arquitectura basada en SOMs que codifica esquemas sensorimotrices formando tripletas, como se ilustra en la imagen. Figura tomada de Escobar-Juárez y cols. (2016).

5.2. Espacio peripersonal

El espacio peripersonal se puede definir funcionalmente como la distancia a la que un objeto puede ser alcanzado por la mano del agente sin mover el tronco (Cardinali, Brozzoli, y Farnè, 2009). En otras palabras puede entenderse como el espacio de alcance de un agente (Serino, 2019). Se ha sugerido que el espacio peripersonal actúa como una interfaz entre el cuerpo del agente y el entorno (Makin, Holmes, y Ehrsson, 2008; Noel, Bertoni, y Serino, 2020). Aunque los agentes biológicos perciben el espacio como algo continuo y unificado, el espacio peripersonal cercano incluye diferentes representaciones espaciales, como las representaciones espaciales alrededor de las manos y la cara (Farnè, Demattè, y Làdavas, 2005). Además, el procesamiento del espacio peripersonal se caracteriza por un alto grado de integración multisensorial, principalmente entre información visual y somatosensorial (táctil y propioceptiva) (Bertoni, Magosso, y Serino, 2021; Cardinali y cols., 2009). La característica más relevante de las neuronas peripersonales multimodales es que sus respuestas evocadas visualmente están moduladas por la distancia entre el objeto visual y el campo receptivo táctil. De esta forma, la información visual se puede codificar centrada en la parte del cuerpo que contiene el campo receptivo táctil (Cardinali y cols., 2009). Dicho mapa daría la ubicación del estímulo visual en relación con la superficie del cuerpo en coordenadas somatotópicas. Curiosamente, la integración multimodal en el espacio peripersonal apoya la existencia, en los humanos, de sistemas

visuales-táctiles que codifican el espacio peripersonal, como se describe en los monos (Farnè y cols., 2005; Làdavias y Farnè, 2004).

El espacio peripersonal es fundamental para orientar el movimiento en cualquier momento (Graziano, 1999). Por un lado, existe evidencia sobre la participación del espacio peripersonal en la orientación de los movimientos defensivos involuntarios para protección. Esta región del espacio se conocía como zona de fuga y correspondería a un margen de seguridad alrededor del cuerpo de un agente (Dosey y Meisels, 1969). En este sentido, algunas evidencias muestran que la estimulación eléctrica de áreas multimodales en el cerebro, específicamente la corteza precentral, la corteza motora primaria y premotora, evoca un patrón complejo de movimientos de manos y brazos en los monos. Estos movimientos son similares a las reacciones de evitación o defensivas, como retirar la mano, girar la cabeza o levantar la mano como para defender la cabeza (Graziano, Taylor, y Moore, 2002). Por otro lado, el procesamiento del espacio peripersonal permite determinar, una vez determinado el objetivo del agente, si la tarea puede ejecutarse en el lugar en el que se encuentra o si es necesario desplazarse por el entorno considerando los objetos accesibles para el agente en el espacio peripersonal en un momento específico.

Los agentes biológicos adquieren información sobre las características de su espacio peripersonal para lograr orientar y dirigir su movimiento en cualquier momento (Graziano, 1999). Esta región permite determinar las tareas posibles de ejecutar sin la necesidad de desplazamiento del agente, dependiendo de los objetos que se encuentren dentro de su límite. A su vez, posibilita al agente para decidir si es necesario desplazarse por el entorno para acceder a los objetos que le permitirían satisfacer una necesidad o motivación específica. En este sentido, el procesamiento del espacio peripersonal resulta fundamental para la flexibilidad conductual y se considera un elemento central del contexto del agente, dado que permite la toma de decisiones e informa sobre la región espacial accesible relacionada con el cuerpo donde se puede llevar a cabo la planeación y ejecución de una tarea específica.

5.2.1. Modelado del espacio peripersonal en agentes artificiales

En la robótica cognitiva del desarrollo se han intentado diversos enfoques sintéticos que tienen como objetivo comprender el proceso de adquisición

de representaciones del cuerpo y visuoespaciales en humanos. En concreto, se ha modelado el espacio peripersonal centrado en diferentes partes del cuerpo. [Fuke, Ogino, y Asada \(2009\)](#) propusieron un modelo que permite a un agente adquirir una representación espacial peripersonal centrada en la cabeza utilizando un SOM con aprendizaje hebbiano. Su modelo está inspirado en la representación facial en neuronas bimodales que se encuentran en la región intraparietal ventral adyacente del cerebro, que codifica la ubicación del estímulo visual a través de la referencia centrada en la cabeza y conecta las sensaciones visuales con las sensaciones táctiles ([Sereno y Huang, 2006](#)). Estas neuronas se han asociado con la capacidad de evitar que los objetos se muevan hacia la cara como un mecanismo de protección o una retirada defensiva ([Graziano y Cooke, 2006](#)). En su modelo, [Fuke y cols. \(2009\)](#) utilizan información propioceptiva del brazo como referencia, de modo que cuando el agente mueve su brazo frente a su rostro se activa el SOM y se produce el aprendizaje. Así, su agente simulado aprende la asociación entre la representación táctil del rostro y la representación visuoespacial aprendida. De esta manera, el agente adquiere una forma de percepción en la que el espacio circundante se codifica en un marco de referencia centrado en la cabeza.

[Juett y Kuipers \(2019\)](#) propusieron un modelo para recrear el proceso de aprendizaje del espacio peripersonal en los bebés. Los autores estudiaron la asociación entre la información propioceptiva del brazo y la percepción visual de la mano y las pinzas del agente. En su trabajo, el espacio peripersonal se modela mediante gráficos. Los nodos del gráfico representan el estado del brazo y los bordes corresponden a movimientos seguros; a su vez, los caminos representan trayectorias seguras de una pose a otra. En su propuesta, una acción de alcance surge como una forma confiable de golpear y mover un objeto en el entorno. Por otro lado, cuando un objeto es agarrado accidentalmente debido al reflejo de prensión palmar innato, y se mueve el objeto junto con la mano, se genera una acción de agarre³. El proceso de aprendizaje está modulado por un mecanismo de motivación intrínseca. A través del aprendizaje del espacio peripersonal, el agente es capaz de alcanzar y agarrar objetos basándose en una exploración no guiada.

En [Nguyen y cols. \(2019\)](#), los autores modelaron la integración de infor-

³este estudio se inspira en cómo es que los bebés realizan acciones de alcance y agarre, y se menciona que la acción de agarre involucra mayor grado de complejidad que la acción de alcance y que en el agarre interviene el reflejo de prensión palmar innato, que se activa como consecuencia de una estimulación táctil

mación visual, propioceptiva y táctil en un robot humanoide para desarrollar comportamientos de alcance. Para ello, se implementó una red neuronal profunda que recibe como entrada imágenes de las cámaras del agente y la posición de la cabeza, mientras que la salida es la posición del brazo y la información táctil de la mano y el antebrazo. La red puede predecir las configuraciones del brazo de un alcance exitoso, junto con información sobre la parte del cuerpo que entraría en contacto con los objetos.

Por otro lado, [Jamone, Natale, Hashimoto, Sandini, y Takanishi \(2012\)](#) dotaron a un agente de la capacidad de aprender una representación de su propio espacio alcanzable utilizando su experiencia motora. El mapa del espacio peripersonal que propusieron utiliza un marco de referencia centrado en la mirada y fijo en el ojo. En este sentido, la posición de un punto en el espacio se puede codificar con la configuración motora de la cabeza y los ojos del agente. Sus mapas se implementan utilizando una red neuronal de regresión de proyección ponderada localmente (locally weighted projection regression neural network). Después de aprender, el agente es capaz de estimar la accesibilidad de un objeto detectado visualmente, incluso antes de iniciar el movimiento de alcance. Junto a la información sobre la configuración del cuerpo, el espacio peripersonal permite a los agentes artificiales percibir el espacio que les rodea para llevar a cabo procesos de planeación, ejecución, alcance y manipulación.

5.3. Configuración del cuerpo y objeto situados

Los agentes biológicos procesan la disposición espacial de los objetos de manera rápida y eficiente. Durante la ejecución de una tarea, es necesario construir continuamente un mapa visual de la posición corporal espacial actual percibida en relación con la disposición espacial de los objetos. Esta información exteroceptiva complementa la postura corporal percibida a través de la propiocepción para guiar y ajustar las secuencias sensoriomotoras dentro del espacio peripersonal del agente. Aquí, la memoria de trabajo visual juega un papel central en la planeación de la acción.

La memoria de trabajo visual y los mecanismos de atención están acoplados por medio de la acción que se está ejecutando. Un plan de acción guía la recuperación de las representaciones apropiadas de la memoria sensorial, y cuando los resultados esperados de la acción son exitosos, las representacio-

nes se consolidan robustamente, lo que lleva a una recuperación más rápida en el futuro (Olivers y Roelfsema, 2020). Así, el contenido de la memoria de trabajo visual está al servicio de la conducta futura, de tal manera que la codificación de acciones se produce en respuesta a esas memorias visuales de objetos relevantes relacionados con las acciones anticipadas (Boettcher, Gresch, Nobre, y van Ede, 2021).

Un ejemplo revelador es la ejecución de acciones de agarre complejas (Van Polanen y Davare, 2015). Se ha establecido que la información espacial de un objeto interactúa con la información de sus propiedades físicas para controlar los movimientos de la mano orientados al objeto. A su vez, esta configuración espacial del objeto debe asociarse con información sobre la configuración del cuerpo para mapear la información espacial de los objetos en coordenadas corporales (Bertoni y cols., 2021; Colby, 1998; Graziano y Gross, 1998). Así, la configuración del cuerpo y el objeto situados son elementos contextuales de la tarea que cambian dinámicamente durante la ejecución de las secuencias sensoriomotoras planeadas.

Las tareas están constituidas por una secuencia de acciones. Los planes de acción requieren memoria de trabajo para anticipar y encadenar múltiples pasos, así como el uso de mecanismos de atención que son guiados por la retroalimentación recurrente situada para aprender los acoplamientos de acción sensorial apropiados (Olivers y Roelfsema, 2020). En este sentido, dado que no se puede conocer de antemano toda la información para la planeación de secuencias sensoriomotoras, la atención selectiva a la información relevante durante el flujo de acción influye en los planes de acción posteriores (Reed y Hartley, 2021). El ciclo de acción situado tiene resultados particulares que potencialmente cambian el contexto del agente y el contexto del entorno, y estos cambios también pueden desencadenar más iteraciones del ciclo (Barsalou, 2020).

5.3.1. Modelado de configuración del cuerpo y objetos en agentes artificiales

Muchos estudios han adoptado el enfoque de “aprender haciendo” en robótica cognitiva, considerando específicamente el aprendizaje sobre los efectos y consecuencias de las acciones autogeneradas por los agentes. Por ejemplo, Fitzpatrick, Metta, Natale, Rao, y Sandini (2003) mostraron cómo los robots aprenden el efecto de acciones de empuje sobre objetos, deslizándolos en diferentes direcciones. En cada prueba, el objeto se colocó

directamente frente al robot dentro del espacio de tareas. Luego, el agente ejecutó acciones de empuje desde cualquiera de las cuatro posiciones iniciales diferentes. Durante cada ensayo, se monitorearon dos variables, la información propioceptiva inicial de la posición de la mano y en el momento del contacto y la dirección del desplazamiento retiniano del objeto.

En otro estudio, (Högman, Björkman, Maki, y Kragic, 2015) dotaron a un sistema robótico de la capacidad de aprender diferentes categorías de objetos a través de una tarea de empuje. Los autores definen categorías como relaciones acción-efecto o contingencias sensoriomotoras, modelando los efectos en una representación centrada en el objeto en lugar de considerar una representación más estática que incluyera las propiedades físicas de los objetos. La tarea de empuje se parametrizó utilizando la posición y la velocidad al realizar dicha acción. Las contingencias se modelan como funciones específicas del objeto de la forma $f\Delta : a \rightarrow \Delta(s, s')$ donde a denota a la acción y $\Delta(s, s')$ corresponde al cambio sensorial causado por la acción. A través de la interacción, la plataforma robótica aprende las características de traslación y rotación de los objetos al aplicar ciertas acciones sobre ellos y adquiere dicho conocimiento con cierto grado de confianza a partir de las observaciones repetidas de pares de acción-efecto. La traslación se calcula como la distancia euclidiana del cambio de posición y la rotación se obtiene a través del ángulo diedro entre los planos inicial y final (Figura 5.7). El contexto del objeto se considera como una representación probabilística, donde la distribución del efecto e dada la acción a se aprende como una probabilidad $p(e|a)$. Esta propuesta está inspirada en el modelo MOSAIC (Haruno, Wolpert, y Kawato, 2001) y proporciona una funcionalidad para clasificar objetos y sus categorías resultantes, asociando cada clase de objeto con un módulo específico. Cada módulo representa una categoría de objeto que contiene el modelo directo junto con el modelo de probabilidad. Durante los experimentos, la posición inicial de los objetos es la misma en cada prueba, cambiando únicamente el punto desde donde el robot empujará el objeto. En este estudio, la posición inicial y final, así como la orientación se modelan de manera implícita, únicamente el cambio entre ellos se considera explícitamente en el modelo.

Desde otra perspectiva, algunos estudios se han centrado en abordar las *affordances* que ofrecen las herramientas a los agentes artificiales. En este caso, el aprendizaje corresponde a encontrar una asociación entre un conjunto de características que describen a las herramientas y los efectos que éstas

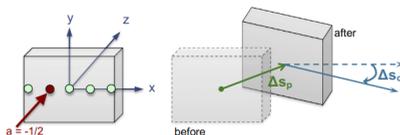


Figura 5.7: Descripción del efecto de empujar mediante el cálculo de la traslación y rotación de un objeto. Figura tomada del estudio de [Högman y cols. \(2015\)](#).

pueden lograr a través de acciones sobre un objeto. [Mar, Tikhanoft, y Natale \(2018\)](#) propusieron un enfoque que permite a los agentes artificiales aprender el uso de herramientas a través de la interacción, así como generalizar este conocimiento entre herramientas similares basándose en su geometría 3D. Durante la fase de entrenamiento, el robot iCub realiza un conjunto de acciones de arrastre utilizando una gran cantidad de herramientas agarradas en diferentes orientaciones, ya sea hacia la derecha, de manera frontal o hacia la izquierda. Cada prueba comenzó colocando una herramienta en la mano del agente artificial. Después de agarrar la herramienta, el iCub detectó automáticamente la pose de la herramienta que se le había dado. Posteriormente, el agente realizó una serie de acciones exploratorias para poder descubrir el *affordance* correspondiente a cada posición de la herramienta. El arrastre fue ejecutado hacia diferentes direcciones y su efecto fue obtenido a partir del desplazamiento del objeto calculando la distancia euclidiana. Las *affordances* de las herramientas fueron aprendidas usando una regresión de la posición de la herramienta y el vector de acción-efecto de cada prueba en sus respectivos mapas autoorganizables (SOMs).

En este sentido, un modelo regresor GRNN es entrenado para aprender la asociación entre las coordenadas de las neuronas de las características de la herramienta en el SOM de la pose de la herramienta y las coordenadas de las neuronas relacionadas con el vector de *affordances* en el SOM de las *affordances* (Figura [5.8](#)). En la fase de predicción, la coordenada del SOM de las herramientas es activada de acuerdo a la herramienta usada y dicha coordenada es usada como entrada al modelo regresor para obtener un estimado de la coordenada de la neurona asociada con dicha entrada en el SOM de las *affordances*. En este estudio, la posición inicial del objeto que es arrastrado en todas las pruebas permanece constante y no es considerado explícitamente en el modelo.

Ciertamente, entender los efectos de las acciones, en otras palabras, el

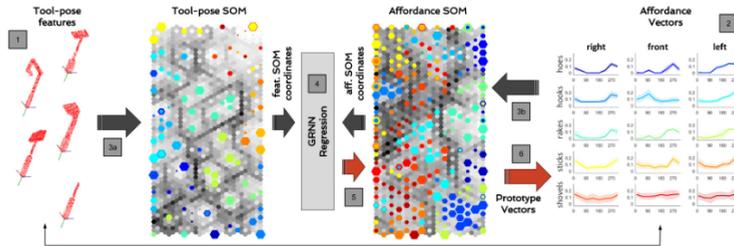


Figura 5.8: Diagrama para aprender y predecir las *affordances* relacionadas con la posición de las herramientas. Figura tomada del estudio de [Mar y cols. \(2018\)](#).

cambio de contexto de la tarea, es esencial para la planeación y ejecución de tareas. [Paus, Huang, y Asfour \(2020\)](#) muestran que la predicción del efecto de una acción de empuje permite la realización de tareas de manipulación dirigidas a objetivos deseados a través de la evaluación de diferentes empujes y sus posibles efectos. En su estudio, el robot ARMAR-6 aprende modelos internos que involucran objetos, así como las relaciones espaciales entre ellos. Las escenas percibidas por el agente artificial se representan como gráficos centrados en objetos, mientras que el modelo interno predice cambios en las configuraciones de los objetos de la escena debido a las acciones de empuje. Las propiedades del objeto son almacenadas en los nodos del gráfico, mientras que los bordes contienen información espacial relativa entre pares de objetos. Para formular un problema de optimización en estos gráficos de escena, los investigadores usaron redes de gráficos, que proporcionan bloques de construcción de aprendizaje de máquina que usan gráficos como entrada y salida. Como primer paso, el método propuesto en este estudio transforma los objetos de entrada a un sistema de coordenadas local y crea un gráfico a partir de ellas. Después de eso, el modelo interno se usa para predecir un gráfico de salida, a partir del cual pueden extraerse las configuraciones de los objetos después de realizar la acción. Este estudio considera la posición inicial y final de los objetos explícitamente en el modelo y también tiene en cuenta la relación espacial entre pares de objetos en una escena.

Utilizar los conocimientos previos es fundamental para realizar diferentes tareas en situaciones y contextos nuevos. [Khazatsky, Nair, Jing, y Levine \(2021\)](#) desarrollaron un sistema controlado situado para un aprendizaje por refuerzo condicionado por objetivos auto-supervisado y eficiente. Se entrenó

un robot con varias experiencias previas de trayectorias en diferentes tareas y contextos y se probó en nuevos entornos y tareas mediante el muestreo de objetivos de un modelo de *affordance* visuomotor. Después de entrenar las posibilidades o *affordances*, el robot se probó en nuevos entornos que contenían objetos distractores y otros objetos que permitían una interacción, como abrir o cerrar un cajón, recoger un objeto o colocar un objeto en una olla. Es importante destacar que estos objetos que permitieron una interacción no se habían visto anteriormente pero tenían características similares relacionadas con lo que ofrecen (por ejemplo, un cajón con un tipo de asa diferente). En este trabajo, el aprendizaje requirió generalización en términos de *affordances* visuales y sus comportamientos asociados durante las interacciones en línea para recopilar más datos y mejorar constantemente la política⁴ asociada. Como consecuencia, la política de agarre se generaliza a agarrar objetos y el aprendizaje continuo de nuevas tareas es más rápido, ya que se beneficia del aumento de los conocimientos previos. Este método de aprendizaje de *affordance* visuomotor (VAL) permite el aprendizaje autónomo en línea de tareas en nuevos contextos, lo que destaca la relevancia de utilizar conocimientos previos de otros contextos y sus posibilidades relacionadas para un aprendizaje escalable y continuo.

Las *affordances* tienen en cuenta el cambio en la configuración espacial del objeto ocasionado por una acción. Sin embargo, la representación de este cambio puede variar drásticamente entre los estudios reportados. Mientras que algunos enfoques representan el efecto de la acción considerando únicamente la dirección del movimiento del objeto, otros consideran su desplazamiento. Además, algunos estudios tienen en cuenta tanto el desplazamiento como la rotación de los objetos dada una acción. Sin embargo, la posición inicial de los objetos es constante y no se modela explícitamente en esos estudios, tampoco se consideran la posición final ni la orientación. Con respecto a los objetos, algunos de ellos consideran diferentes elementos pero presentan de manera aislada a uno por cada prueba. Asimismo, en el aprendizaje de *affordances* de herramientas no se considera la relación espacial entre la herramienta y el objeto a manipular, enfocándose únicamente en el desplazamiento logrado del objeto. Mientras tanto, sólo unos pocos estudios consideran más de un objeto en la escena y representan las

⁴Generalmente, dentro de la robótica cognitiva se usa el término política para referirse al mapeo o asociación de los estados percibidos del entorno con las acciones que se deben tomar cuando se está en esos estados. En este sentido, una política define la forma de comportarse del agente en un momento dado. En el caso más simple, una política es una función que toma como entrada un estado s y devuelve una acción a

interacciones espaciales objeto-objeto de manera explícita, como en el caso del estudio de [Paus y cols. \(2020\)](#). Sin embargo, el enfoque de aprendizaje de affordances objeto-objeto está tomando cada vez más auge dentro de la robótica cognitiva ([Mo, Qin, Xiang, Su, y Guibas, 2022](#); [Moldovan, Moreno, Van Otterlo, Santos-Victor, y De Raedt, 2012](#); [Sun, Ren, y Lin, 2014](#)).

5.4. Contexto del agente y la tarea integrados

Los modelos que han sido presentados en la subsección [5](#) generalmente se consideran como elementos o bloques de algoritmos para arquitecturas cognitivas computacionales más complejas. El diseño de arquitecturas cognitivas es un área de investigación amplia y activa dentro de la robótica cognitiva que se interesa por el diseño e implementación de modelos de cognición a nivel de sistema ([Lieto, Bhatt, Oltramari, y Vernon, 2018](#)). Una arquitectura involucra aspectos de un agente cognitivo que son constantes en el tiempo y a través de diferentes dominios: memoria de corto y largo plazo que almacenan contenido sobre la experiencia del agente, que puede ser sobre creencias, objetivos y conocimientos; así como la representación de elementos o bloques y su organización en la estructura, además de los procesos funcionales que operan entre éstos ([Langley, Laird, y Rogers \(2009\)](#)). Estas arquitecturas se han probado en diferentes tareas cognitivas que implican razonamiento, percepción, ejecución de acciones, entre otras. A continuación se presentan diferentes arquitecturas cognitivas computacionales que muestran de qué manera, tanto el contexto del agente como el contexto de la tarea pueden modelarse de manera entrelazada, describiendo cómo los objetos, las acciones y el cuerpo se fusionan en una sola arquitectura.

5.4.1. Arquitectura DARWIN

La arquitectura DARWIN es un modelo computacional inspirado en el cerebro diseñado para desarrollar capacidades de aprendizaje y razonamiento en agentes artificiales ([Mohan y cols., 2013](#)).

Esta arquitectura tiene la propiedad de representar conceptos de objetos y permite al agente artificial planificar acciones con ellos teniendo en cuenta el contexto de la tarea y del cuerpo del agente. DARWIN posee una estructura jerárquica que promueve los flujos de información de arriba hacia abajo o *top-down* y de abajo hacia arriba o *bottom-up*, permitiendo el flujo de información de las capas de mayor jerarquía a las de menor nivel y viceversa (Figura [5.9](#)). Asimismo, tiene la propiedad de segregación funcional y también de integración global entre las capas de información. En la

Estudio	Objetivo	# Objeto	efecto (Δ Contexto tarea)	Relación espacial objetos
Fitzpatrick y cols. (2003)	Aprender sobre objetos	1	Dirección de desplazamiento	No
Högman y cols. (2015)	Categorización	1	Desplazamiento, orientación	No
Mar y cols. (2018)	Uso de herramientas	2	Desplazamiento	Orientación, desplazamiento
Paus y cols. (2020)	Planeación	1 a 5	Cambio de posición	Posición relativa

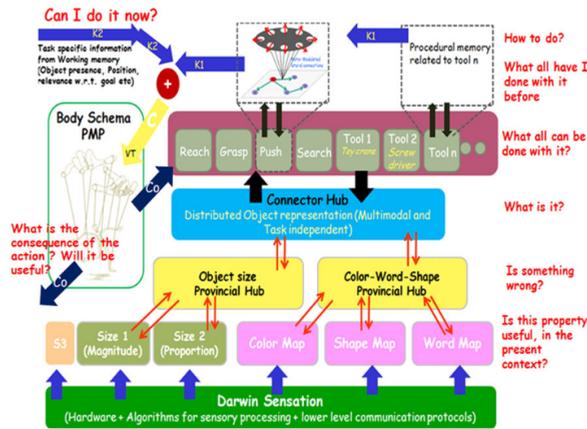


Figura 5.9: Conectividad y flujos de información en la arquitectura DARWIN. Figura tomada del estudio de [Mohan y cols. \(2013\)](#).

parte inferior de la arquitectura se encuentra la capa sensorial, que incluye los sensores y los protocolos y algoritmos de comunicación de nivel inferior para analizar las propiedades de los objetos, como su color, forma y tamaño.

La información proveniente de la capa sensorial se proyecta a la capa 1, compuesta por un conjunto de mapas autoorganizables en crecimiento encargados de representar las propiedades de los objetos a nivel conceptual. Esta información se procesa por separado en cada SOM, razón por la cual los autores los denominan SOMs específicos de propiedad. De tal forma que existen dos SOMs que representan el tamaño, uno para la magnitud y el segundo para la proporción. Además, hay un mapa SOM para el color, otro para representar la forma del objeto y un mapa asociado con el nombre del mismo, respectivamente. La información de los objetos también considera señales contextuales en términos de la orientación de los objetos en relación con el marco de referencia del agente.

Las representaciones más altas en la jerarquía se vuelven multimodales y hay una mayor integración de la información en cada capa ascendente. Por ejemplo, ambos mapas relacionados con el tamaño están integrados en un mapa denominado centro provincial o *provincial hub* representando el tamaño del objeto. A su vez, los mapas correspondientes al color, la forma

y el nombre del objeto se integran en un mapa denominado centro provincial de color-palabra-forma. Los mapas hub tienen el propósito de facilitar la integración multimodal así como permitir la activación vía *top-down* y *cross-modal* entre distintos mapas específicos de propiedad de menor jerarquía. Al mismo tiempo, los dos *provincial hubs* de tamaño y el de color-palabra-forma se integran en el *connector hub*, que es la representación multimodal de mayor jerarquía correspondiente a las propiedades físicas de los objetos.

Desde una perspectiva corporizada, las acciones están mediadas por el cuerpo y al mismo tiempo están dirigidas hacia los objetos. Teniendo en cuenta lo anterior, las capas de percepción de los objetos están conectadas con las acciones y con el esquema corporal del agente a través de la jerarquía de la arquitectura DARWIN. Es interesante notar que la representación de la acción está separada en *affordances* en un nivel abstracto de la acción mientras que la memoria procedimental está relacionada con la ejecución de la acción. El hub conector que representa al objeto en su nivel más abstracto y más alto en la jerarquía de la arquitectura está asociado con la representación de la acción más abstracta, que consiste en neuronas individuales que codifican diferentes acciones como alcanzar, agarrar o empujar. Estas neuronas individuales activan sucesivamente la memoria procedimental, la cual es responsable de generar la acción correspondiente. Simultáneamente, la memoria procedimental se conecta con el esquema corporal del agente, que genera los comandos motores necesarios para lograr el plan de acción o la trayectoria creada por la memoria procedimental. Los comandos motores se generan mediante modelos inversos.

La actividad neuronal entre el objeto y las acciones se aprende a través de la exploración activa del agente artificial con los objetos de su entorno. De esta forma, un objeto puede ser agarrado, alcanzado o moverse de una manera específica y el repertorio motor incrementará progresivamente al interactuar con diferentes objetos y realizando diferentes acciones con éstos. A pesar de que el agente es capaz de interactuar con múltiples objetos en el espacio de tarea, DARWIN no considera las relaciones espaciales objeto-objeto explícitamente en su arquitectura, únicamente considera la orientación y posición de objetos de manera aislada.

5.4.2. Arquitectura MACSi

Con la finalidad de abordar el aprendizaje activo de objetos en el robot iCub, Ivaldi y cols. (2013) propusieron la arquitectura cognitiva MACSi. Su

enfoque está inspirado en el acoplamiento de la visión y la manipulación en bebés para adquirir representaciones de objetos. En este sentido, la representación visual de los objetos se construye de forma incremental a través de la exploración activa del robot, combinando la guía social de un maestro humano con la motivación intrínseca del agente. La arquitectura consiste en un sistema integrado de módulos cognitivos, perceptivos, de aprendizaje y de control. El sistema perceptual del agente artificial combina varios canales sensoriales, como los sensores de visión, propiocepción y RGB-D para detectar a los cuidadores, los objetos y la mano del robot a través del módulo relacionado con el aprendizaje y reconocimiento de objetos. El método de categorización de objetos se basa en la información mutua entre los datos visuales y propioceptivos, así como en estadísticas sobre el movimiento de las entidades físicas.

Los módulos perceptivos y cognitivos están conectados al robot a través de un módulo de acción, encargado de controlar el habla, las expresiones faciales y los movimientos de la parte superior del cuerpo del agente. Asimismo, los módulos perceptivos también se comunican con el conocimiento episódico del robot, que almacena la información perceptiva procesada, como los objetos en la escena, su posición y orientación, las personas que interactúan con el robot, su ubicación y la tarea actual. La arquitectura incluye un proceso de toma de decisiones basado en la motivación intrínseca, que combina la enseñanza social con la exploración activa del agente. Este mecanismo se compone de dos niveles de procesamiento: 1) nivel de exploración de estrategia y espacio de tareas, el cual decide activamente qué tarea u objeto manipular y qué estrategia realizar, y 2) nivel de exploración del espacio de posibles estados que genera diferentes muestras de estados y tareas para mejorar la estimación del modelo.

5.4.3. Lingüística y contexto en la arquitectura ERA

De manera interesante, el contexto espacial de los objetos ha sido útil en el aprendizaje de asociaciones auditivas y visuales. En su estudio, [A. Morse, Belpaeme, Cangelosi, y Smith \(2010\)](#) llevaron a cabo una replicación de experimentos de desarrollo cognitivo usando un robot iCub para mostrar que las señales espaciales son suficientes para asociar etiquetas verbales con objetos, destacando el papel de la configuración del cuerpo y las ubicaciones espaciales en el aprendizaje de los nombres de los elementos. En una serie de experimentos [Smith y Samuelson \(2010\)](#) presentaron en repetidas ocasiones

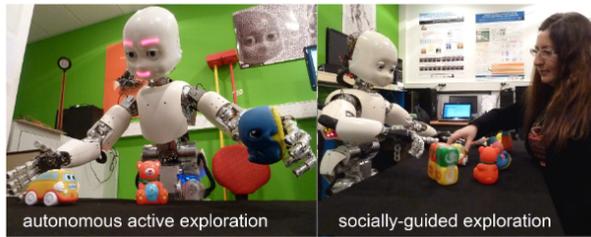


Figura 5.10: El robot humanoide iCub interactuando con los objetos a través de exploración autónoma y exploración guiada por un humano. Figura tomada del estudio de [Ivaldi y cols. \(2013\)](#).

dos objetos diferentes a su vez a niños de entre 18 y 24 meses de edad. Uno de los objetos se mostraba constantemente a la izquierda, mientras que el otro se presentaba a la derecha. Después de dos presentaciones de cada objeto la atención de los infantes fue dirigida hacia uno de los lugares de presentación ahora vacío mientras se presentaba la etiqueta verbal “modi”. Finalmente, a los niños se les presentaron ambos objetos en otra ubicación y se les pidió que encontraran el “modi”. La mayoría de ellos seleccionó el objeto espacialmente correlacionado a pesar de que el nombre se presentó en ausencia de cualquiera de los objetos.

La arquitectura computacional propuesta por [A. Morse y cols. \(2010\)](#) para replicar este experimento se conoce como Arquitectura Epigenética Robótica (ERA, por sus siglas en inglés). Este modelo consiste en una jerarquía homogénea en el cual la unidad básica está formada por la asociación estructurada de múltiples SOMs ([A. F. Morse, De Greeff, Belpeame, y Cangelosi, 2010](#)). Cada SOM recibe entradas de una modalidad sensorial específica y, por lo general, se preestabiliza en cierto grado utilizando entradas aleatorias distribuidas en los rangos apropiados para esos dominios de entrada (Figura [5.11](#)). La arquitectura incluye SOMs especiales “hub” que integran información de otros mapas de representación información de más bajo nivel. El mapa hub permite la propagación de la activación de una modalidad a otra, mismas que se encuentran conectadas a través de dicho mapa. El mapa hub para la replicación del experimento corresponde a la configuración del cuerpo del agente artificial y utiliza los ángulos de las articulaciones del robot como entrada a otro SOM [A. Morse y cols. \(2010\)](#). Específicamente, el mapa del cuerpo codifica dos grados de libertad de la cabeza y dos de los ojos. La información vinculada mediante el mapa hub

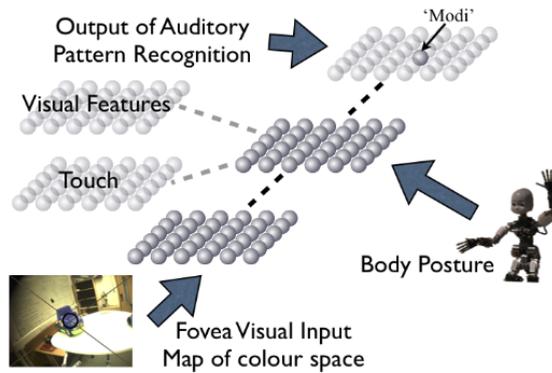


Figura 5.11: Arquitectura general de ERA compuesta por SOMs integrados mediante aprendizaje hebbiano. Imagen tomada del estudio de [A. Morse y cols. \(2010\)](#).

de postura corporal corresponde a la modalidad visual y auditiva. La actividad de los mapas que representan el color y las palabras auditivas está asociada con la configuración del cuerpo a través de aprendizaje hebbiano en tiempo real. Debido a que los mapas están asociados en función de las experiencias del robot, se generan fuertes conexiones entre objetos que generalmente se detectan en ubicaciones espaciales particulares y en posturas corporales similares. En consecuencia, cuando se escucha la palabra “modi” se asocia con una configuración de cuerpo particular. Finalmente, cuando se le pide al robot que encuentre el “modi”, la actividad en el nodo de palabra “modi” se propaga hacia la configuración del cuerpo asociada y, por lo tanto, al nodo del mapa de color asociado con esa postura. De acuerdo a los autores, los resultados de los experimentos de los niños y el desempeño del modelo computacional sugieren la hipótesis acreca que la postura corporal es fundamental para la asociación temprana entre nombres y objetos. Los resultados de estos experimentos desafían la hipótesis popular de que los nombres están vinculados a lo que se atiende en el momento en el que se encuentra el nombre.

Modelo de interacción de los tres tipos de contexto

Los agentes biológicos aprenden a realizar la tarea apropiada de acuerdo al contexto en el que se encuentran a través de una interacción constante con su entorno. Son capaces de detectar regularidades sobre la información contextual a través de la experiencia y aprenden a establecer asociaciones entre las tareas y los cambios que generan en su propio estado interno así como en el estado del entorno a través de la ejecución de dichas tareas. En otras palabras, aprenden regularidades sobre la dinámica del contexto del agente, del entorno y de la tarea durante su interacción con el mundo. Se ha sugerido que esta asociación está codificada por diferentes mecanismos, como la descarga corolaria¹ o la predicción de las consecuencias sensoriales de la acción y el uso de una copia eferente para hacerlo, que caen bajo la noción de lo que se conoce como modelos internos (Kawato y cols., 2003; McNamee y Wolpert, 2019; Wolpert y cols., 1995).

Los modelos internos se adquieren a través de la interacción constante con el entorno, permitiendo establecer asociaciones entre las tareas y los cambios que generan tanto en su estado como en el estado del entorno en cada momento. Estas interacciones se dan bajo circunstancias particulares y, por lo tanto, las asociaciones adquiridas mediante los modelos internos son siempre dependientes del contexto, tanto del agente, como del entorno y de la tarea particular que se esté realizando. De esta manera, los agentes aprenden a lograr sus objetivos anticipando las consecuencias sensoriales de

¹Nuestros movimientos pueden obstaculizar nuestra capacidad de sentir el mundo. Los movimientos pueden inducir información sensorial (por ejemplo, cuando golpeas algo) que es indistinguible de la información causada por agentes externos (por ejemplo, cuando algo te golpea). Es fundamental para los sistemas nerviosos poder diferenciar entre estos dos escenarios. Una estrategia es enviar copias de comandos de movimiento a estructuras sensoriales. Estas señales se denominan descargas corolarias. La combinación de la información recibida de los receptores sensoriales y la copia motora que indica cómo un movimiento podría influir en la señal de entrada permite que un animal en movimiento resuelva la confusión en la información sensorial (Crapse y Sommer, 2008).

sus acciones en contextos específicos. Los modelos internos se adquieren a través de la interacción constante con el entorno y, por lo tanto, siempre dependen del contexto.

Los modelos internos generan predicciones sobre las consecuencias sensoriales más probables de las acciones autogeneradas. La diferencia entre una predicción generada y la entrada sensorial entrante se conoce como error predictivo, mismo que los agentes siempre intentan minimizar. El error predictivo se puede minimizar utilizando dos estrategias: actualizando el modelo interno para generar mejores predicciones o cumpliendo predicciones a través de la acción para igualar los estados sensoriomotores esperados (Clark, 2015; Friston, Mattout, y Kilner, 2011). Además, recientemente se ha llamado la atención sobre la importancia del monitoreo del error predictivo a lo largo del tiempo al ejecutar una tarea. Por lo tanto, los agentes también aprenden la tasa asociada de cómo se reduce el error predictivo durante la ejecución de una tarea. Esta tasa puede entenderse como cambios en la velocidad de reducción del error predictivo, en la medida en que informa qué tan bien o mal está realizando una tarea un agente. Se cree que este monitoreo de la dinámica del error predictivo juega un papel central en las emociones y el bienestar de los agentes (Hesp y cols., 2021; Joffily y Coricelli, 2013; Kiverstein y cols., 2019; Nave, Deane, Miller, y Clark, 2020; Van de Cruys, 2017).

La valencia positiva y negativa experimentada mientras actuamos está directamente relacionada con el éxito del comportamiento seleccionado en la reducción del error predictivo con respecto a la tasa esperada. Adicionalmente, debido a que la dinámica del error predictivo está fuertemente relacionada con las emociones, se ha sugerido que el monitoreo de la tasa de reducción del error puede ser concebido como un mecanismo de autorregulación para guiar el comportamiento en agentes artificiales (Schillaci y cols., 2020). Por lo tanto, un agente artificial puede estar intrínsecamente motivado para seleccionar de forma autónoma un objetivo asociado con un error predictivo reducible óptimo. La capacidad de monitorear la reducción de la tasa del error al realizar la tarea permite a un agente “decidir” de manera autónoma si debe continuar con la tarea cuando se está logrando el objetivo perseguido, o si debe abandonarla cuando no se logra ningún progreso en ella. En ambos escenarios, al lograr una meta o al abandonarla, el agente artificial estará intrínsecamente motivado para seleccionar otra meta que le permita aprender.

A continuación, en la sección [6.1](#) se presenta un modelo teórico de interacción de los tres tipos de contexto. En los capítulos 3, 4 y 5 se identificaron y abordaron los elementos del contexto del agente, del entorno y de la tarea, respectivamente, que se consideran fundamentales para la autonomía y flexibilidad conductual de los agentes. El modelo integra dichos elementos contextuales, así como los modelos internos y el procesamiento de la dinámica del error predictivo, descrito en esta sección.

Este modelo surge a partir del análisis del papel del contexto en la flexibilidad conductual de los agentes biológicos y artificiales. Como ha sido mencionado previamente, los estudios e implementaciones dentro de la robótica cognitiva están enfocados en el proceso cognitivo de interés y, aunque lo consideran implícitamente, generalmente pierden de vista el rol del contexto de manera general. Dentro de la literatura se encuentran, por un lado, los estudios centrados en la navegación del entorno en los cuales el contexto del entorno toma vital importancia para el desplazamiento apropiado del agente artificial. Sin embargo, estos enfoques generalmente consideran pocos o ningún elemento contextual involucrado en la planeación y ejecución de tareas de manipulación de objetos pues su único objetivo es la navegación. Por otro lado, están aquellos estudios centrados en la interacción de los agentes artificiales con objetos en los que el contexto de la tarea tiene mayor peso, perdiendo de vista otros elementos esenciales tanto del contexto del agente como del entorno para la selección de tareas. Mientras tanto, están aquellos modelos que consideran ambos enfoques. Sin embargo, generalmente estos modelos dotan a los agentes artificiales con habilidades pre-establecidas para que sean capaces de realizar diversas tareas en entornos no estructurados.

En este sentido, los estudios que consideran algunos elementos contextuales centrales para la autonomía y flexibilidad conductual dejan de lado otros elementos, como es el caso de los estudios centrados en la regulación de la conducta mediante las necesidades fisiológicas, en los que solo en algunas ocasiones consideran a las emociones o la motivación intrínseca como parte de los mecanismos de control. Dadas estas observaciones, el modelo propuesto en este proyecto busca relacionar los elementos centrales de los tres tipos de contexto en un solo mecanismo de regulación para la conducta de los agentes artificiales. El modelo toma en cuenta los elementos contextuales centrales descritos en los capítulos anteriores, así como los modelos internos y el procesamiento de la dinámica del error predictivo. Se propone una relación plausible que permitiría a los agentes artificiales seleccionar, planear y ejecutar la tarea apropiada y cambiar de estrategia de acuerdo a

lo que dicte el contexto global.

6.1. Modelo interaccionista de los tres tipos de contexto

A continuación, la interacción del contexto del agente, del entorno y de la tarea para la flexibilidad conductual se analiza en un modelo teórico (Figura 6.1) que integra los elementos contextuales centrales abordados en los capítulos anteriores. Además, el modelo propuesto considera la tasa esperada de reducción del error predictivo y su seguimiento como elementos clave para la toma de decisiones sobre la tarea más adecuada en el contexto percibido. Antes de presentar el modelo teórico es importante mencionar que con esta propuesta también se pretende contribuir a las discusiones en torno al problema del marco, originado dentro de la Inteligencia Artificial al pretender construir sistemas artificiales capaces de imitar la cognición y conducta flexible humana.

El problema del marco cuestiona cómo piensan y actúan los sistemas de manera que sean adaptativamente sensibles a la relevancia de acuerdo al contexto (McCarthy y Hayes, 1981). En este sentido, el problema del marco es una invitación a pensar cómo un sistema puramente mecanicista puede lograr planear y ejecutar una acción apropiada y flexible dentro de un contexto específico en un mundo en el que además el número de contextos potenciales es indeterminado. Se ha propuesto que esto depende, por un lado, de poder crear un sistema que almacene información y que pueda acceder a la información correcta y relevante en el tiempo apropiado. Por otro lado, ese sistema debe reconocer la información que resulta relevante dada la tarea que atiende. La pregunta es: ¿cómo se diseña un sistema artificial capaz de reconocer los rasgos relevantes del entorno y de acceder a la información necesaria para poder actuar de manera inmediata dada una determinada tarea?.

Dado que los agentes biológicos aprenden a realizar la tarea apropiada de acuerdo al contexto en el que se encuentran a través de su interacción constante con el entorno, el modelo interaccionista de los tres tipos de contexto enfatiza la importancia de procesar y monitorear constantemente el contexto del agente, del entorno y de la tarea para poder dotar a agentes artificiales con autonomía y flexibilidad conductual. Sugerimos que el mo-

delo teórico presentado aquí es una primera aproximación para cimentar el contexto en agentes artificiales. Este modelo de interacción propuesto es una representación idealizada de los diferentes elementos contextuales. En la operación real, al igual que con otras propuestas, como en Barsalou (2020), uno o más elementos podrían omitirse, además, la secuencia podría ser diferente a la descrita aquí. Sin embargo, durante el modelado de los diferentes elementos es importante tener en cuenta que la flexibilidad alcanzada por el agente artificial dependerá del número de elementos contextuales involucrados en su control motor.

La Figura 6.1 muestra el modelo propuesto que contiene los tres tipos de contexto y la interacción de sus elementos contextuales centrales para la selección de tareas, su planeación y ejecución, así como para el cambio de tareas cuando sea necesario. El contexto del agente, del entorno y de la tarea se muestran en recuadros de color azul, verde y amarillo, respectivamente. En el recuadro de cada contexto se indica la principal fuente de información sensorial por la que es percibido. Para el contexto del agente, la interocepción y la propiocepción son claves para proporcionar un contexto afectivo y corporizado. La exterocepción es central para percibir el contexto del entorno de una manera situada y, finalmente, juntas, la propiocepción, la interocepción y la exterocepción, son fundamentales para cimentar el contexto de la tarea durante la ejecución de la misma.

Al percibir los tres tipos de contexto y sus elementos centrales, los agentes artificiales se comportarán de acuerdo con las condiciones contextuales cambiantes. Los agentes artificiales serán capaces de gestionar las necesidades fisiológicas internas y los impulsos intrínsecos del aprendizaje, ambos asociados con las emociones, junto con los factores ambientales percibidos situados. Esto significa que los agentes artificiales serán más propensos a volverse competentes para seleccionar de manera autónoma las tareas que son auto-relevantes para mantener su “existencia”, así como las tareas que promueven el aprendizaje, de una manera sensible al contexto.

Se ha sugerido que la minimización del error predictivo es en sí misma gratificante (Friston, Samothrakis, y Montague, 2012). La toma de decisiones basada en recompensas se reemplaza por el uso de conocimientos previos para evitar estados sorprendentes de supervivencia, que es una condición suficiente para impulsar la minimización del error predictivo. En el modelo, las necesidades fisiológicas son fundamentales para determinar qué acción debe priorizarse para mantener el agente activo. Cuando se experimenta una

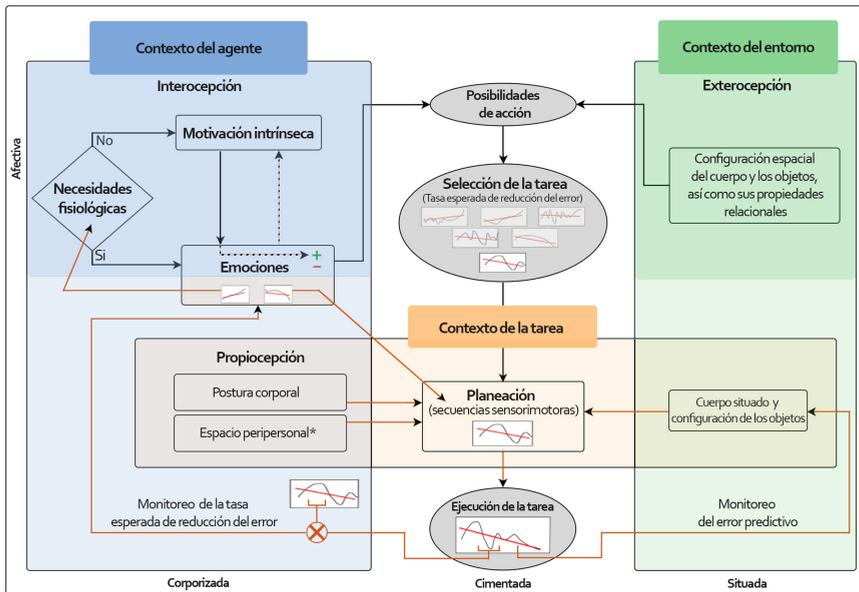


Figura 6.1: Modelo interaccionista de los tres tipos de contexto. Se propone una interacción plausible de los elementos contextuales centrales del contexto del agente, del entorno y de la tarea para la selección y ejecución de la tarea apropiada.

necesidad fisiológica, la emoción positiva o negativa asociada, junto con el contexto del entorno, dan lugar a las posibilidades de acción relevantes con las que el agente puede interactuar. La selección de la mejor tarea se basa en su tasa esperada de reducción del error asociada. Esta tasa se aprende y se actualiza constantemente durante los ciclos de acción situados, estando directamente relacionada con la competencia actual del agente para lograr el resultado deseado (para una implementación, ver Schillaci y cols. (2016)).

Las oportunidades más eficientes para mejorar la interacción con el entorno provienen de seleccionar aquellas posibilidades relevantes que no son ni demasiado complejas ni demasiado simples para el agente (Kidd, Piantadosi, y Aslin, 2012). De esta manera, cuando no hay necesidades fisiológicas, la motivación intrínseca lleva al agente a explorar su entorno, provocando emociones positivas relacionadas con conductas impulsadas por la curiosidad. En este caso, la selección de tareas ocurre de manera similar, el contexto del entorno y sus posibilidades actuales, es decir, el campo de las posibilidades relevantes (Rietveld, 2008), permiten al agente seleccionar una tarea, teniendo en cuenta su tasa esperada de reducción del error. Una vez seleccionada la tarea, ya sea para el mantenimiento y la autorregulación o para la exploración y manipulación del entorno, surge el contexto de la tarea. Aquí, la información sensorial recopilada de los tres tipos de contexto se vuelve relevante para la ejecución de la tarea seleccionada. Como se observa en la Figura 6.1, el contexto de la tarea, representado en amarillo, se superpone con el contexto del entorno y con el contexto del agente enfatizando que el contexto de la tarea involucra elementos tanto del agente como del entorno para poder modular la flexibilidad del agente de acuerdo a las condiciones internas y externas.

Además, el modelo muestra dos temporalidades diferentes en la velocidad a la que ocurren los cambios sensoriales. Primero, se produce una baja tasa de cambios sensoriales mientras se procesan y representan las propiedades generales de los contextos para la selección de tareas (contexto del agente en azul intenso; contexto del entorno en verde intenso). Este ciclo lento está representado en el modelo por flechas negras que interactúan con los elementos contextuales centrales para la selección y planeación de tareas. En segundo lugar, cuando surge el contexto de la tarea, se produce una tasa rápida de cambios sensoriales en el entorno mientras se ejecuta la secuencia sensoriomotora planificada de la tarea (azul claro, verde claro y amarillo). Este ciclo rápido está representado en el modelo por flechas naranjas que interactúan con los elementos contextuales centrales durante la ejecución de

la tarea.

Al respecto, (Marchi, 2020) sugirió que la línea que distingue cognición y percepción puede establecerse considerando los niveles funcionales de la jerarquía de procesamiento. Los niveles cognitivos, los niveles más altos de la jerarquía, realizan funciones más abstractas y generales para representar el conocimiento general sobre las propiedades contextuales, y no son tan susceptibles a los rápidos cambios sensoriales que ocurren en el entorno. Por el contrario, los niveles perceptivos, los niveles inferiores de la jerarquía, se encuentran en estrecha proximidad espacio-temporal a los detectores sensoriales y son muy sensibles a los cambios sensoriales rápidos en el entorno producto de acciones a corto plazo (p. ej., agarrar, dar un paso). En este sentido, el modelo propuesto considera el criterio de sensibilidad propuesto por Marchi (2020), de tal manera que la cognición está representada por el bucle lento para la representación contextual y la selección de tareas, y la percepción está representada por el bucle rápido, que se ve radicalmente afectado por cambios sensoriales rápidos que ocurren durante la ejecución de la tarea.

Además, en el bucle rápido de percepción, se producen en paralelo dos tipos de monitoreo del error predictivo, el monitoreo del error predictivo y el monitoreo de la tasa esperada de reducción del error. Para el seguimiento del error predictivo, las consecuencias sensoriomotoras predichas de las acciones se comparan con la entrada sensoriomotora real para la estimación del error predictivo. El bucle rápido de percepción se produce cuando la configuración del cuerpo y el objeto situados cambia a medida que avanza la ejecución de la tarea, lo que permite realizar correcciones cuando sea necesario. Esto se puede considerar como el ciclo de control rápido de la ejecución de la tarea, que involucra tanto el modelo inverso como el modelo directo (representados en el solapamiento amarillo-azul y el solapamiento amarillo-verde, respectivamente). Para el monitoreo de la tasa esperada de reducción del error, a medida que se ejecuta la tarea, la tasa de reducción del error en la dinámica de error predictivo supervisada se compara con la tasa esperada de reducción del error. En otras palabras, el error predictivo acumulado a lo largo del tiempo al ejecutar la tarea permite una comparación directa entre la tasa esperada de reducción del error asociada a la tarea y la dinámica del error predictivo real.

El monitoreo de la dinámica del error predictivo a lo largo del tiempo y su comparación con la tasa esperada de reducción del error indican

qué tan bueno o malo es el agente en la realización de la tarea. Se cree que la minimización del error predictivo y su relación con la tasa esperada de reducción del error está en el centro de las emociones y la valencia de las acciones de los agentes (Hesp y cols., 2021; Kiverstein y cols., 2019). Cuando ocurre una tasa de reducción del error más rápida de lo esperado, se producen emociones positivas, lo que motiva al agente a continuar con la tarea. Una sensación de bien hecho, también actualiza la tasa esperada de reducción del error para esa tarea en particular en ese contexto particular.

Una tasa de minimización del error real que sea más lenta que la esperada puede desencadenar un abandono de la tarea. Esta diferencia tendrá una valencia negativa y devolverá al sistema al ciclo lento mediante el seguimiento de sus necesidades fisiológicas actuales, así como de los otros elementos contextuales centrales del agente y del entorno para seleccionar una tarea diferente. Esto también puede ocurrir cuando el agente no es capaz de minimizar el error predictivo. Cuando la diferencia entre la tasa esperada de reducción del error y la tasa real no es muy grande, el agente puede continuar con la ejecución de la tarea. Sin embargo, la comparación también tiene un valor emocional. Una tasa de reducción positiva es un estímulo para continuar como está, mientras que una tasa negativa puede verse como una advertencia o como una señal de un cambio necesario en la forma en que se planea y ejecuta la tarea. En el modelo, este proceso se representa con una flecha naranja que desciende del producto de la emoción experimentada de la diferencia entre la tasa esperada de reducción del error y la tasa real, lo que permite correcciones a las secuencias sensoriomotoras planeadas restantes.

Es importante resaltar la pregunta abierta con respecto al tamaño óptimo de la ventana de tiempo en la que se debe monitorear la dinámica del error predictivo. Diferentes ventanas de tiempo de monitoreo del error predictivo, desde muy breves hasta relativamente largas, producen diferentes patrones de experiencia emocional, así como una sensibilidad diferente a cambios significativos en la tasa de reducción del error (Carver y Scheier, 1990). Recientemente, se ha sugerido que el tamaño de esta ventana de tiempo debería cambiar dinámicamente de acuerdo con “qué tan bien o mal van las cosas” con respecto al progreso esperado (Schillaci y cols., 2020). Por lo tanto, cuando la tasa del error disminuye constantemente, lo que significa que el agente lo está haciendo bien en la ejecución de la tarea, la necesidad de monitoreo del error disminuye. Por el contrario, si aumenta el error predictivo, se debe realizar una evaluación más cuidadosa.

En implementaciones computacionales, menos monitoreo implica la liberación de recursos. En este sentido, en el modelo propuesto, la ventana de tiempo por la cual se monitorean las dinámicas del error predictivo podría cambiar dinámicamente en base a las emociones experimentadas producto de las diferencias entre la tasa esperada de reducción del error y la tasa de reducción del error real. Además, aquí se sugiere que la ventana de tiempo también puede verse influenciada por el nivel de familiaridad del contexto del entorno percibido. Cuando un agente se familiariza con un contexto particular, aumenta la confianza o la precisión relacionada con las posibilidades de acción relevantes (Friston, FitzGerald, Rigoli, Schwartenbeck, y Pezzulo, 2017; Friston y cols., 2017). Por lo tanto, en un contexto del entorno familiar, es muy probable que las tareas que tienden a seleccionarse conduzcan a resultados preferidos (valor pragmático) y, como consecuencia, la tasa esperada de reducción del error sea muy rápida. En este escenario, la experiencia previa guía la recuperación de representaciones sólidamente consolidadas para la planeación de acciones que conducirán al resultado esperado (Olivers y Roelfsema, 2020). Dado el valor pragmático de una tarea seleccionada en un contexto familiar, se hace más grande la ventana de tiempo mediante la cual se monitorea la dinámica del error predictivo. Es decir, se monitorea con menor frecuencia. Por el contrario, en contextos de entornos nuevos o desconocidos, los resultados de un conjunto de posibles tareas tienden a ser inciertos. En consecuencia, las tareas que pueden seleccionarse en un contexto del entorno novedoso tienden a ser de exploración y aprendizaje (valor epistémico). Por tanto, su tasa esperada de reducción del error asociada es baja. Como consecuencia, la ventana de tiempo por la cual se monitorea la dinámica del error predictivo se hace menor hasta que se gana más experiencia y se consolidan los acoplamientos entre las acciones y la información sensorial apropiados. En otras palabras, se necesita monitorear el error predictivo con mayor frecuencia.

Finalmente, en línea con Barsalou (2020), el modelo interaccionista de contextos presentado aquí ofrece un enfoque cimentado de la percepción, la cognición y el comportamiento. Los ciclos de acción situados en el contexto del entorno son cimentados en la tarea que se está ejecutando. Un aspecto central del modelo es el procesamiento de las necesidades fisiológicas, así como el monitoreo constante de la dinámica del error predictivo, que son la base de los estados emocionales. Una interacción óptima con el entorno lo proporciona el equilibrio experimentado al actuar en una situación particular para reducir la tensión afectiva (desequilibrio) (Rietveld, 2008). Por lo

tanto, una situación mejora al responder a las posibilidades o *affordances* relevantes que potencialmente pueden generar la experiencia del equilibrio. Además, el modelo propuesto destaca el papel particular de los diferentes sistemas sensoriales como la interocepción, la propiocepción y la exterocepción en los procesos cognitivos asociados con la modulación del comportamiento.

Desde esta perspectiva, los procesos cognitivos y perceptuales no solo ocurren en el cerebro, sino que se distribuyen en el acoplamiento dinámico, lleno de afectividad, entre el cerebro, el cuerpo y el entorno. Así, el modelo interaccionista de contextos es entonces:

- a) corporizado en el procesamiento de las necesidades fisiológicas de los agentes, su morfología y sus capacidades sensoriomotoras,
- b) afectivo, ya que los agentes actúan para mejorar la interacción sensible al contexto en un campo dinámico de posibilidades relevantes,
- c) situado en el contexto del entorno, la configuración actual del cuerpo y el objeto que, en conjunto, hacen que las posibilidades relevantes se destaquen para la selección y planeación de tareas, y finalmente,
- d) cimentado en los ciclos de acción situadas durante la ejecución de la tarea que desencadenan el procesamiento de procesos sensoriales multimodales rápidos, así como los dos tipos de monitoreo del error predictivo que ocurren en paralelo.

Discusión y conclusiones

El procesamiento del contexto juega un papel esencial en la autonomía y la flexibilidad del comportamiento de los agentes biológicos y artificiales. Esencialmente, el contexto está involucrado en todos los aspectos cognitivos, perceptuales y conductuales de los agentes. En este sentido, dotar a los agentes artificiales de la capacidad de procesar el contexto en el que se encuentran les permitiría priorizar metas y tareas importantes para su autorregulación interna y promover su aprendizaje y dominio del entorno. Esto hace que el contexto y su procesamiento sean un elemento clave para la investigación en robótica cognitiva corporizada. La gran mayoría de los estudios en la robótica cognitiva consideran uno o más elementos contextuales, sin embargo, rara vez se aborda el contexto explícitamente. Existe consenso en que el contexto actúa como un conjunto de restricciones que influyen en el comportamiento de un agente, pero la discusión está abierta a cuál es la noción de contexto más adecuada para la robótica cognitiva.

Dada la relevancia del contexto no solo en la autonomía y flexibilidad del comportamiento, sino en la cognición en general, este trabajo tiene como objetivo motivar la discusión sobre el procesamiento del contexto dentro de la investigación de robótica cognitiva. En este proyecto, el contexto engloba todos aquellos elementos tanto del agente como del entorno que tienen un impacto en el comportamiento. La esencia del contexto es compleja dada la naturaleza diversa de sus componentes. Para abordar el contexto global, se ha hecho una distinción, analizando el contexto como contexto del agente, del entorno y de la tarea. El contexto del agente se caracteriza por elementos como las necesidades fisiológicas, las emociones, la motivación intrínseca, así como los aspectos morfológicos del cuerpo. El contexto del entorno se relaciona con las características del entorno específico en el que se sitúa el agente, como la configuración espacial del cuerpo y los objetos del entorno, así como sus propiedades relacionales. Finalmente, el contexto de la tarea se caracteriza por elementos que cambian dinámicamente durante la ejecución de una tarea, como el cuerpo espacial situado y la configuración del objeto (percebido a través de la exterocepción), la postura corporal

del agente (percibida a través de la propiocepción) y su espacio peripersonal.

Para cada tipo de contexto, sus elementos centrales se analizan por separado y se describen varias implementaciones dentro de la robótica cognitiva, representativas de cada elemento central. Generalmente, cada estudio se enfoca en diferentes procesos cognitivos y existe una variedad de herramientas matemáticas y computacionales para sus implementaciones. En este proyecto se propone que el establecimiento del contexto del agente, del entorno y de la tarea permite una rápida identificación de los elementos considerados en cada estudio, independientemente del proceso modelado o las herramientas utilizadas. En este sentido, la clasificación de implementaciones que aquí se hace, según los elementos contextuales centrales, puede arrojar luz sobre los alcances y limitaciones del estudio del contexto. Al mismo tiempo, se pueden enmarcar más investigaciones utilizando esta clasificación como guía hacia un comportamiento más autónomo y flexible en agentes artificiales. Este artículo destaca el papel del contexto como concepto unificador para la investigación en robótica cognitiva corporizada.

Este proyecto permitió explorar y comprender cómo los tres contextos y sus elementos centrales deberían interactuar para proporcionar flexibilidad conductual en agentes biológicos y artificiales. Además, se propone un modelo que integra estos elementos contextuales centrales considerando sus interacciones y sus diferentes temporalidades durante la selección y ejecución de tareas. El modelo da gran importancia a la función del monitoreo de la dinámica del error predictivo, así como a la tasa esperada de reducción del error. El contexto del agente corporizado y afectivo, junto con el contexto del entorno situado, dan lugar a un campo de *affordances*. La selección de tareas se realiza en el campo de las *affordances* relevantes de acuerdo con la tasa esperada de reducción del error predictivo para cada tarea. El monitoreo de la dinámica del error predictivo permite realizar correcciones en línea de la secuencia sensoriomotora planeada, comparando las predicciones con la información sensorial entrante. Todo esto ocurre en la cimentación del contexto de la tarea durante los ciclos de acción situados del agente. El monitoreo del error predictivo a lo largo del tiempo, a medida que se ejecuta la tarea, y su comparación con la tasa esperada de reducción del error permite que un agente sea sensible a su desempeño. Esta sensibilidad indica si es apropiado continuar con la ejecución, cuando los resultados son positivos y “se siente bien”, o cambiar de tarea de manera autónoma, cuando las cosas no ocurren como se esperaba y la tarea se vuelve “frustrante”⁴. Finalmente, el modelo también incluye dos resoluciones temporales, una más lenta para

la cognición y otra más rápida para la percepción y los ciclos de acción situados.

El modelo que se propone como parte de este proyecto es corporizado, afectivo y situado, mediante el procesamiento de los elementos contextuales centrales relacionados con el agente y el entorno. Además, es cimentado en el procesamiento del contexto de la tarea y los ciclos de acción situados durante la ejecución de la tarea. El modelo propuesto enfatiza cómo los agentes artificiales deben procesar los elementos contextuales centrales del contexto del agente y del entorno para dar lugar al contexto de la tarea, permitiendo a los agentes seleccionar de manera autónoma una tarea, llevar a cabo su planeación, ejecución y monitoreo para flexibilidad de comportamiento. El modelado del contexto es fundamental para estudiar el acoplamiento estructural entre los agentes y su entorno. El modelo aquí presentado pretende contribuir en esta dirección, así como en aclarar la noción de contexto para la flexibilidad conductual, no solo en agentes artificiales, sino también en agentes biológicos.

Finalmente, para trabajos futuros se propone a la SOIMA como posible arquitectura para implementar y probar el modelo teórico de interacción de los tres contextos. La SOIMA es una arquitectura cognitiva computacional codificada mediante una red de mapas auto-organizados que permite modelar esquemas sensorio-motores multimodales mediante modelos internos acoplados (Escobar-Juárez y cols., 2016). Asimismo, dicha arquitectura exhibe características de escalabilidad que posibilitaría generar una implementación que considere los distintos tipos de contexto en capas de procesamiento de mayor a menor jerarquía.

Por otro lado, el modelo propuesto considera los elementos contextuales centrales para la ejecución de tareas sensorimotoras involucradas en la manipulación de objetos. Sin embargo, más adelante este modelo podría escalarse para considerar factores contextuales involucrados en la selección de tareas de mayor complejidad, como aquellas asociadas en el estudio de la comunicación y la socialización con otros agentes artificiales.

Appendices

APÉNDICE A

**Categorización de
investigaciones de acuerdo al
contexto estudiado**

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Kirtay y cols. (2019)	Contexto del agente	Necesidades físicas	Cambio de tareas	Búsqueda visual	Aprendizaje por refuerzo
Lewis y Canamero (2016)	Contexto del agente	Necesidades físicas	Cambio de tareas	Pasearse por un entorno	Aprendizaje por refuerzo
R. Lowe y cols. (2010)	Contexto del agente	Necesidades físicas	Cambio de tareas	Navegación	Algoritmos evolutivos
Vargas y cols. (2005)	Contexto del agente	Necesidades físicas	Cambio de tareas	Navegación	Redes neuronales artificiales
Vouloutsi y cols. (2013)	Contexto del agente	Necesidades físicas	Cambio de tareas	Interacción robot-humano	Redes neuronales artificiales
Barto y cols. (2004)	Contexto del agente	Motivación intrínseca	Selección de evento a explorar en el entorno guiada por la sorpresa	Exploración de entorno y aprendizaje de eventos	Aprendizaje por refuerzo
Colas y cols. (2019)	Contexto del agente	Motivación intrínseca	Selección y aprendizaje de objetivos impulsado por la curiosidad	Tareas de manipulación	Aprendizaje por refuerzo
Frank y cols. (2014)	Contexto del agente	Motivación intrínseca	Aprendizaje impulsado por la curiosidad	Aprendizaje de control de brazo	Aprendizaje por refuerzo

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Hart y Grupen (2013)	Contexto del agente	Motivación intrínseca	Descubrimiento y aprendizaje de posibilidades de acción o <i>affordances</i>	Tareas de manipulación	Aprendizaje por refuerzo
Huang y Weng (2002)	Contexto del agente	Motivación intrínseca	Selección de acción	Navegación	Aprendizaje por refuerzo
Luciw y cols. (2011)	Contexto del agente	Motivación intrínseca	Selección de acción	Navegación y exploración	Aprendizaje por refuerzo
Marsland y cols. (2000)	Contexto del agente	Motivación intrínseca	Reconocimiento y aprendizaje de características novedosas del entorno	Navegación y exploración	Mapa autoorganizado
Gadanh y Hamlam (2001)	Contexto del agente	Emociones	Detección de eventos relevantes en una tarea de aprendizaje y selección de tarea	Explorar el entorno y adquirir energía de fuentes de alimento, en forma de luz	Aprendizaje por refuerzo

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Dagliarli y cols. (2009)	Contexto del agente	Emociones	Selección de secuencia de conductas	Evasión de obstáculos mientras se dirige hacia la meta	Red neuronal Q-SOM
Jitviyira y cols. (2015)	Contexto del agente	Emociones	Selección de acción	Conductas de manipulación o de evasión de un objeto	Mapa autoorganizado
marinier2008emotions Marinier y Laird (2008)	Contexto del agente	Emociones	Aprendizaje de tareas que lo hacen sentir bien. Emociones como señales de recompensa al completar una tarea	Navegar por un laberinto de un solo corredor	Aprendizaje por refuerzo
Parisi y Petrosino (2010)	Contexto del agente	Emociones	Decidir qué motivación intentar satisfacer mediante su conducta en un momento dado	Tarea de supervivencia en un entorno simulado	Algoritmos evolutivos

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Hoffmann y cols. (2017)	Contexto del agente	Configuración espacial del cuerpo	Aprendizaje de modelo de sí mismo	Representación de piel artificial	Mapa autoorganizado modificado
Gama y Hoffmann (2019)	Contexto del agente	Configuración espacial del cuerpo	Aprendizaje de modelo de sí mismo	Representación de configuración de cuerpo mediante proiocepción	Mapa autoorganizado modificado
T. Zhang y cols. (2018)	Contexto del agente	Configuración espacial del cuerpo	Planeación y ejecución del movimiento	Control motor de brazo	Autoencoder
Metta, Sandini, y Konczak (1999)	Contexto del agente	Configuración espacial del cuerpo	Planeación y ejecución de movimiento guiado por visión	Alcance de objeto guiado visualmente	Tabla de búsqueda
Sturn, Plagemann, y Burghard (2009)	Contexto del agente	Configuración espacial del cuerpo	Planeación y ejecución de movimiento guiado por visión	Control motor guiado visualmente	Redes bayesianas

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Saegusa, Metta, Sandini, y Sakka (2009)	Contexto del agente	Configuración espacial del cuerpo	Planeación y ejecución de movimiento guiado por visión	Control motor guiado visualmente	Perceptrón multicaapa
Escobar-Ináñez y cols. (2016)	Contexto del agente	Configuración espacial del cuerpo	Control sacádico y planeación y ejecución de movimiento guiado por visión	Control motor guiado visualmente	Mapa autorganizado
Nabeshima y cols. (2006)	Contexto del agente	Configuración espacial del cuerpo	Extensión de alcance de objetos mediante el uso de herramientas	Alcanzar y tocar un objeto distante visualmente sobresaliente con su mano y/o con una herramienta	Redes neuronales artificiales
Zambelli y cols. (2020)	Contexto del agente	Configuración espacial del cuerpo	Planeación y ejecución de movimiento guiado por visión, imitación	Tocar un piano de juguete	Autoencoder variacional

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Chinellato, Antonelli, Grzyb, y Del Pobil (2011)	Contexto del agente	Espacio personal	Aprendizaje visomotor del espacio personal para alcanzar objetos	Mirar y alcanzar diferentes objetivos visuales	Redes RBF (por sus siglas en inglés, Radial basis function)
Fuke y cols. (2009)	Contexto del agente	Espacio personal	Aprendizaje de espacio peripersonal centrado en la cara para ubicar estímulos visuales y asociarlo con información táctil	Mover mano frente a la cara	Mapas autoorganizados y aprendizaje hebbiano
Goerick, Werhsing, Mikhailova, y Dunn (2005)	Contexto del agente	Espacio personal	Reconocimiento de objetos	Distinguir objetos que se encuentran dentro del espacio peripersonal	Redes jerárquicas

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Holthaus y Wachsmuth (2012)	Contexto del agente	Espacio personal	Apoyar decisiones que dependen de la distancia y de los objetos presentes	Interacción humano-robot en espacio de tareas con objetos	Modelos de escena articulada
Jamone y cols. (2012)	Contexto del agente	Espacio personal	Aprendizaje de alcance de objeto	Alcanzar un cubo rojo colocado frente al robot con la mano derecha	Redes Neuronales LWPR (por sus siglas en inglés, locally weighted projection regression)
Juett y Kuipers (2019)	Contexto del agente	Espacio personal	Aprendizaje de alcance y agarrar de manera confiable de objetos	Alcance y agarrar	Mapeo estructurado en grafos
Nguyen y cols. (2019)	Contexto del agente	Espacio personal	Aprendizaje de alcance de objeto	Alcance de objeto	Aprendizaje profundo

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Roncane, Hoffmann, Pattacini, y Metta (2015)	Contexto del agente	Espacio personal	Predicción de contacto con objetos sobre la piel artificial	Alcance y evasión de objeto	Estimación de probabilidad frecuentista
Fitzpatrick y cols. (2003)	Contexto de la tarea	Configuración espacial de la tarea	Desplazamiento de un objeto hacia una dirección deseada	Empuje de un objeto, con múltiples objetos en el espacio de tarea	Mapeo topográfico
Högman y cols. (2015)	Contexto de la tarea	Configuración espacial de la tarea	Desplazamiento de un objeto hacia una dirección deseada	Empuje de un objeto	Modelos de regresión de procesos gaussianos
Mar y cols. (2018)	Contexto de la tarea	Configuración espacial de la tarea	Desplazamiento de un objeto hacia una dirección deseada usando herramientas	Empuje de un objeto con diferentes herramientas	Mapa autoorganizado

Estudio	Tipo de contexto	Elemento contextual	Flexibilidad conductual	Tarea	Herramienta computacional
Paus y cols. (2020)	Contexto de la tarea	Configuración espacial de la tarea	Desplazamiento secuencial de múltiples objetos hacia una dirección deseada	Empuje de un objeto con múltiples objetos en el espacio de tareas	Redes Gráficas
Blomqvist y cols. (2020)	Contexto del entorno	Configuración espacial del entorno	Cambio de ubicación de objetos por el entorno	Navegación por un entorno de oficina y manipulación de objetos	Mapeo visual-inercial y sistema de localización
Puigbo y cols. (2015)	Contexto del entorno	Configuración espacial del entorno	Ejecución de tareas específicas por el usuario en entorno similar al de una casa	Recibir un comando y realizar las acciones necesarias para lograr el objetivo	Mapeo del entorno asociado con base de datos de las acciones predefinidas y estímulos reconocibles
Tapus y Siegart (2005)	Contexto del entorno	Configuración espacial del entorno	Adquisición y actualización del mapa global del lugar	Navegación por un edificio	Mapeo topológico mediante grafo de lugares

Referencias

- Abdulazeez, A. M., y Faizi, F. S. (2021). Vision-based mobile robot controllers: A scientific review. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(6), 1563–1580.
- Adolphs, R. (2017). How should neuroscience study emotions? by distinguishing emotion states, concepts, and experiences. *Social cognitive and affective neuroscience*, 12(1), 24–31.
- Aghajari, S., Vinke, L. N., y Ling, S. (2020). Population spatial frequency tuning in human early visual cortex. *Journal of neurophysiology*, 123(2), 773–785.
- Arbib, M. A., y Fellous, J.-M. (2004). Emotions: from brain to robot. *Trends in cognitive sciences*, 8(12), 554–561.
- Asada, M., Hosoda, K., Kuniyoshi, Y., Ishiguro, H., Inui, T., Yoshikawa, Y., ... Yoshida, C. (2009). Cognitive developmental robotics: A survey. *IEEE transactions on autonomous mental development*, 1(1), 12–34.
- Asada, M., MacDorman, K. F., Ishiguro, H., y Kuniyoshi, Y. (2001). Cognitive developmental robotics as a new paradigm for the design of humanoid robots. *Robotics and Autonomous systems*, 37(2-3), 185–193.
- Asfour, T., Regenstein, K., Azad, P., Schroder, J., Bierbaum, A., Vahrenkamp, N., y Dillmann, R. (2006). Armar-iii: An integrated humanoid platform for sensory-motor control. En *2006 6th ieee-ras international conference on humanoid robots* (pp. 169–175).
- Asfour, T., Waechter, M., Kaul, L., Rader, S., Weiner, P., Ottenhaus, S., ... Paus, F. (2019). Armar-6: A high-performance humanoid for human-robot collaboration in real-world scenarios. *IEEE Robotics & Automation Magazine*, 26(4), 108–121.
- Baker, P. M., y Mizumori, S. J. (2017). Control of behavioral flexibility by the lateral habenula. *Pharmacology Biochemistry and Behavior*, 162, 62–68.
- Baltaretu, B. R., Monaco, S., Velji-Ibrahim, J., Luabeya, G. N., y Crawford, J. D. (2020). Parietal cortex integrates saccade and object orientation signals to update grasp plans. *Journal of Neuroscience*, 40(23), 4525–4535.
- Bar, M. (2004). Visual objects in context. *Nature Reviews Neuroscience*, 5(8), 617–629.
- Bar, M. (2007). The proactive brain: using analogies and associations to generate predictions. *Trends in cognitive sciences*, 11(7), 280–289.

- Bar, M., y Aminoff, E. (2003). Cortical analysis of visual context. *Neuron*, 38(2), 347–358.
- Bar, M., y Ullman, S. (1996). Spatial context in recognition. *Perception*, 25(3), 343–352.
- Barsalou, L. W. (2008). Grounded cognition. *Annu. Rev. Psychol.*, 59, 617–645.
- Barsalou, L. W. (2020). Challenges and opportunities for grounding cognition. *Journal of Cognition*, 3(1).
- Barto, A. G., Singh, S., y Chentanez, N. (2004). Intrinsically motivated learning of hierarchical collections of skills. En *Proceedings of the 3rd international conference on development and learning* (pp. 112–19).
- Bazire, M., y Brézillon, P. (2005). Understanding context before using it. En *International and interdisciplinary conference on modeling and using context* (pp. 29–40).
- Belkaid, M., Cuperlier, N., y Gaussier, P. (2018). Autonomous cognitive robots need emotional modulations: Introducing the emodul model. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 49(1), 206–215.
- Berlucchi, G., y Aglioti, S. (1997). The body in the brain: neural bases of corporeal awareness. *Trends in neurosciences*, 20(12), 560–564.
- Berlyne, D. E. (1960). Conflict, arousal, and curiosity.
- Bertoni, T., Magosso, E., y Serino, A. (2021). From statistical regularities in multisensory inputs to peripersonal space representation and body ownership: Insights from a neural network model. *European Journal of Neuroscience*, 53(2), 611–636.
- Biederman, I., Mezzanotte, R. J., y Rabinowitz, J. C. (1982). Scene perception: Detecting and judging objects undergoing relational violations. *Cognitive psychology*, 14(2), 143–177.
- Blakemore, S.-J., Wolpert, D., y Frith, C. (2000). Why can't you tickle yourself? *Neuroreport*, 11(11), R11–R16.
- Blau, J. J., y Wagman, J. B. (2022). *Introduction to ecological psychology: A lawful approach to perceiving, acting, and cognizing*. Taylor & Francis.
- Bloisi, D. D., Nardi, D., Riccio, F., y Trapani, F. (2016). Context in robotics and information fusion. En *Context-enhanced information fusion* (pp. 675–699). Springer.
- Blomqvist, K., Breyer, M., Cramariuc, A., Förster, J., Grinvald, M., Tschopp, F., . . . Siegwart, R. (2020). Go fetch: Mobile manipulation in unstructured environments. *arXiv preprint arXiv:2004.00899*.
- Boettcher, S. E., Gresch, D., Nobre, A. C., y van Ede, F. (2021). Output planning at the input stage in visual working memory. *Science*

- advances*, 7(13), eabe8212.
- Brady, T. F., Konkle, T., y Alvarez, G. A. (2011). A review of visual memory capacity: Beyond individual items and toward structured representations. *Journal of vision*, 11(5), 4–4.
- Breazeal, C., y Brooks, R. (2005). Robot emotion: A functional perspective. *Who needs emotions*, 271–310.
- Brock, O., Park, J., y Toussaint, M. (2016). Mobility and manipulation. *Springer Handbook of Robotics*, 1007–1036.
- Cangelosi, A., Bongard, J., Fischer, M. H., y Nolfi, S. (2015). Embodied intelligence. En *Springer handbook of computational intelligence* (pp. 697–714). Springer.
- Cardinali, L., Brozzoli, C., y Farne, A. (2009). Peripersonal space and body schema: two labels for the same concept? *Brain topography*, 21(3), 252–260.
- Cardinali, L., Brozzoli, C., Luauté, J., Roy, A. C., y Farnè, A. (2016). Proprioception is necessary for body schema plasticity: evidence from a deafferented patient. *Frontiers in human neuroscience*, 10, 272.
- Carruthers, G. (2008). Types of body representation and the sense of embodiment. *Consciousness and cognition*, 17(4), 1302–1316.
- Carver, C. S., y Scheier, M. F. (1990). Origins and functions of positive and negative affect: a control-process view. *Psychological review*, 97(1), 19.
- Chen, Y., Monaco, S., Byrne, P., Yan, X., Henriques, D. Y., y Crawford, J. D. (2014). Allocentric versus egocentric representation of remembered reach targets in human cortex. *Journal of Neuroscience*, 34(37), 12515–12526.
- Chinellato, E., Antonelli, M., Grzyb, B. J., y Del Pobil, A. P. (2011). Implicit sensorimotor mapping of the peripersonal space by gazing and reaching. *IEEE Transactions on Autonomous Mental Development*, 3(1), 43–53.
- Clark, A. (2015). *Surfing uncertainty: Prediction, action, and the embodied mind*. Oxford University Press.
- Cohen, P. R. (1995). *Empirical methods for artificial intelligence* (Vol. 139). MIT press Cambridge, MA.
- Coifman, K. G., y Bonanno, G. A. (2010). When distress does not become depression: Emotion context sensitivity and adjustment to bereavement. *Journal of abnormal psychology*, 119(3), 479.
- Colas, C., Fournier, P., Chetouani, M., Sigaud, O., y Oudeyer, P.-Y. (2019). Curious: intrinsically motivated modular multi-goal reinforcement learning. En *International conference on machine learning* (pp.

- 1331–1340).
- Colby, C. L. (1998). Action-oriented spatial reference frames in cortex. *Neuron*, *20*(1), 15–24.
- Cos, I., Canamero, L., Hayes, G. M., y Gillies, A. (2013). Hedonic value: Enhancing adaptation for motivated agents. *Adaptive Behavior*, *21*(6), 465–483.
- Crapse, T. B., y Sommer, M. A. (2008). Corollary discharge across the animal kingdom. *Nature Reviews Neuroscience*, *9*(8), 587–600.
- Daddaoua, N., Lopes, M., y Gottlieb, J. (2016). Intrinsically motivated oculomotor exploration guided by uncertainty reduction and conditioned reinforcement in non-human primates. *Scientific reports*, *6*(1), 1–15.
- Daglarli, E., Temeltas, H., y Yesiloglu, M. (2009). Behavioral task processing for cognitive robots using artificial emotions. *Neurocomputing*, *72*(13–15), 2835–2844.
- Dahiya, R. S., Mittendorfer, P., Valle, M., Cheng, G., y Lumelsky, V. J. (2013). Directions toward effective utilization of tactile skin: A review. *IEEE Sensors Journal*, *13*(11), 4121–4138.
- Dearden, A., y Demiris, Y. (2005). Learning forward models for robots. En *Ijcai* (Vol. 5, p. 1440).
- Deci, E. L. (1975). The intrinsic motivation of behavior. En *Intrinsic motivation* (pp. 93–125). Springer.
- De Vignemont, F. (2010). Body schema and body image—pros and cons. *Neuropsychologia*, *48*(3), 669–680.
- Diez-Valencia, G., Ohashi, T., Lanillos, P., y Cheng, G. (2019). Sensorimotor learning for artificial body perception. *arXiv preprint arXiv:1901.09792*.
- Dolan, R. J. (2002). Emotion, cognition, and behavior. *science*, *298*(5596), 1191–1194.
- Dosey, M. A., y Meisels, M. (1969). Personal space and self-protection. *Journal of personality and social psychology*, *11*(2), 93.
- Ekman, P. (1992). An argument for basic emotions. *Cognition & emotion*, *6*(3–4), 169–200.
- Ekman, P. (2016). What scientists who study emotion agree about. *Perspectives on psychological science*, *11*(1), 31–34.
- Eschmann, J. (2021). Reward function design in reinforcement learning. *Reinforcement Learning Algorithms: Analysis and Applications*, 25–33.
- Escobar-Juárez, E., Schillaci, G., Hermosillo-Valadez, J., y Lara-Guzmán, B. (2016). A self-organized internal models architecture for coding sensory–motor schemes. *Frontiers in Robotics and AI*, *3*, 22.

- Farnè, A., Demattè, M. L., y Làdavas, E. (2005). Neuropsychological evidence of modular organization of the near peripersonal space. *Neurology*, *65*(11), 1754–1758.
- Fitzpatrick, P., Metta, G., Natale, L., Rao, S., y Sandini, G. (2003). Learning about objects through action-initial steps towards artificial cognition. En *2003 ieee international conference on robotics and automation (cat. no. 03ch37422)* (Vol. 3, pp. 3140–3145).
- Foglia, L., y Wilson, R. A. (2013). Embodied cognition. *Wiley Interdisciplinary Reviews: Cognitive Science*, *4*(3), 319–325.
- Frank, M., Leitner, J., Stollenga, M., Förster, A., y Schmidhuber, J. (2014). Curiosity driven reinforcement learning for motion planning on humanoids. *Frontiers in neurorobotics*, *7*, 25.
- Friston, K., FitzGerald, T., Rigoli, F., Schwartenbeck, P., y Pezzulo, G. (2017). Active inference: a process theory. *Neural computation*, *29*(1), 1–49.
- Friston, K., Mattout, J., y Kilner, J. (2011). Action understanding and active inference. *Biological cybernetics*, *104*(1), 137–160.
- Friston, K., Samothrakis, S., y Montague, R. (2012). Active inference and agency: optimal control without cost functions. *Biological cybernetics*, *106*(8), 523–541.
- Fuke, S., Ogino, M., y Asada, M. (2009). Acquisition of the head-centered peri-personal spatial representation found in vip neuron. *IEEE Transactions on Autonomous Mental Development*, *1*(2), 131–140.
- Gadanho, S. C., y Hallam, J. (2001). Emotion-triggered learning in autonomous robot control. *Cybernetics & Systems*, *32*(5), 531–559.
- Gama, F., y Hoffmann, M. (2019). The homunculus for proprioception: Toward learning the representation of a humanoid robot’s joint space using self-organizing maps. *arXiv preprint arXiv:1909.02295*.
- Ghayoumi, M., y Bansal, A. K. (2016). Multimodal architecture for emotion in robots using deep learning. En *2016 future technologies conference (ftc)* (pp. 901–907).
- Gibson, J. (1966). The senses considered as perceptual systems.
- Gibson, J. (1977). The concept of affordances. *Perceiving, acting, and knowing*, *1*.
- Gibson, J. (2014). *The ecological approach to visual perception: classic edition*. Psychology press.
- Goerick, C., Wersing, H., Mikhailova, I., y Dunn, M. (2005). Peripersonal space and object recognition for humanoids. En *5th ieee-ras international conference on humanoid robots, 2005*. (pp. 387–392).

- Gordon, G. (2020). Infant-inspired intrinsically motivated curious robots. *Current Opinion in Behavioral Sciences*, 35, 28–34.
- Grafton, S. T., Hazeltine, E., y Ivry, R. B. (1998). Abstract and effector-specific representations of motor sequences identified with pet. *Journal of Neuroscience*, 18(22), 9420–9428.
- Graziano, M. S. (1999). Where is my arm? the relative role of vision and proprioception in the neuronal representation of limb position. *Proceedings of the National Academy of Sciences*, 96(18), 10418–10421.
- Graziano, M. S., y Cooke, D. F. (2006). Parieto-frontal interactions, personal space, and defensive behavior. *Neuropsychologia*, 44(6), 845–859.
- Graziano, M. S., y Gross, C. G. (1998). Spatial maps for the control of movement. *Current opinion in neurobiology*, 8(2), 195–201.
- Graziano, M. S., Taylor, C. S., y Moore, T. (2002). Complex movements evoked by microstimulation of precentral cortex. *Neuron*, 34(5), 841–851.
- Greene, M. R., y Oliva, A. (2009). The briefest of glances: The time course of natural scene understanding. *Psychological Science*, 20(4), 464–472.
- Griffiths, P. E., y Scarantino, A. (2005). Emotions in the wild: The situated perspective on emotion.
- Grigg, P. (1994). Peripheral neural mechanisms in proprioception. *Journal of Sport Rehabilitation*, 3(1), 2–17.
- Gronau, N., Neta, M., y Bar, M. (2008). Integrated contextual representation for objects' identities and their locations. *Journal of cognitive neuroscience*, 20(3), 371–388.
- Hart, S., y Grupen, R. (2013). Intrinsically motivated affordance discovery and modeling. En *Intrinsically motivated learning in natural and artificial systems* (pp. 279–300). Springer.
- Haruno, M., Wolpert, D. M., y Kawato, M. (2001). Mosaic model for sensorimotor learning and control. *Neural computation*, 13(10), 2201–2220.
- Head, H., y Holmes, G. (1911). Sensory disturbances from cerebral lesions. *Brain*, 34(2-3), 102–254.
- Hesp, C., Smith, R., Parr, T., Allen, M., Friston, K. J., y Ramstead, M. J. (2021). Deeply felt affect: The emergence of valence in deep active inference. *Neural computation*, 33(2), 398–446.
- Hoffmann, M., Lanillos, P., Jamone, L., Pitti, A., y Somogyi, E. (2020). Body representations, peripersonal space, and the self: humans, animals, robots. *Frontiers in Neurobotics*, 14, 35.
- Hoffmann, M., Marques, H., Arieta, A., Sumioka, H., Lungarella, M., y Pfeifer, R. (2010). Body schema in robotics: a review. *IEEE Transactions*

- on Autonomous Mental Development*, 2(4), 304–324.
- Hoffmann, M., Straka, Z., Farkaš, I., Vavrečka, M., y Metta, G. (2017). Robotic homunculus: Learning of artificial skin representation in a humanoid robot motivated by primary somatosensory cortex. *IEEE Transactions on Cognitive and Developmental Systems*, 10(2), 163–176.
- Högman, V., Björkman, M., Maki, A., y Kragic, D. (2015). A sensorimotor learning framework for object categorization. *IEEE Transactions on Cognitive and Developmental Systems*, 8(1), 15–25.
- Holmes, N. P., y Spence, C. (2004). The body schema and multisensory representation (s) of peripersonal space. *Cognitive processing*, 5, 94–105.
- Holthaus, P., y Wachsmuth, S. (2012). Active peripersonal space for more intuitive hri. En *2012 12th ieee-ras international conference on humanoid robots (humanoids 2012)* (pp. 508–513).
- Houbre, Q., Angleraud, A., y Pieters, R. (2020). Balancing exploration and exploitation: A neurally inspired mechanism to learn sensorimotor contingencies. En *International workshop on human-friendly robotics* (pp. 59–73).
- Huang, X., y Weng, J. (2002). Novelty and reinforcement learning in the value system of developmental robots.
- Hubbard, E. M., Piazza, M., Pinel, P., y Dehaene, S. (2005). Interactions between number and space in parietal cortex. *Nature Reviews Neuroscience*, 6(6), 435–448.
- Ieropoulos, I., Melhuish, C., Greenman, J., y Horsfield, I. (2005). Ecobot-ii: An artificial agent with a natural metabolism. *International Journal of Advanced Robotic Systems*, 2(4), 31.
- Iriki, A., Tanaka, M., y Iwamura, Y. (1996). Coding of modified body schema during tool use by macaque postcentral neurones. *Neuroreport*, 7(14), 2325–2330.
- Ivaldi, S., Lyubova, N., Droniou, A., Padois, V., Filliat, D., Oudeyer, P.-Y., ... others (2013). Object learning through active exploration. *IEEE Transactions on Autonomous Mental Development*, 6(1), 56–72.
- Jamone, L., Natale, L., Hashimoto, K., Sandini, G., y Takanishi, A. (2012). Learning the reachable space of a humanoid robot: a bio-inspired approach. En *2012 4th ieee ras & embs international conference on biomedical robotics and biomechatronics (biorob)* (pp. 1148–1154).
- Jamone, L., Ugur, E., Cangelosi, A., Fadiga, L., Bernardino, A., Piater, J., y Santos-Victor, J. (2016). Affordances in psychology, neuroscience, and robotics: A survey. *IEEE Transactions on Cognitive and Deve-*

- lopmental Systems*, 10(1), 4–25.
- Jitviriyā, W., Koike, M., y Hayashi, E. (2015). Behavior selection system based on emotional variations. En *2015 24th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)* (pp. 462–467).
- Joffily, M., y Coricelli, G. (2013). Emotional valence and the free-energy principle. *PLoS computational biology*, 9(6), e1003094.
- Jordan, M. I., y Rumelhart, D. E. (1992). Forward models: Supervised learning with a distal teacher. *Cognitive science*, 16(3), 307–354.
- Joseph, R. (2000). Fetal brain behavior and cognitive development. *Developmental review*, 20(1), 81–98.
- Juett, J., y Kuipers, B. (2019). Learning and acting in peripersonal space: moving, reaching, and grasping. *Frontiers in Neurobotics*, 13, 4.
- Kaiser, D., Häberle, G., y Cichy, R. M. (2020). Cortical sensitivity to natural scene structure. *Human brain mapping*, 41(5), 1286–1295.
- Kammer, M., Schack, T., Tscherepanow, M., y Nagai, Y. (2011). From affordances to situated affordances in robotics—why context is important. En *Frontiers in computational neuroscience (conference abstract: IEEE ICDL-EPIROB 2011)* (Vol. 5).
- Kauffmann, L., Ramanoël, S., y Peyrin, C. (2014). The neural bases of spatial frequency processing during scene perception. *Frontiers in integrative neuroscience*, 8, 37.
- Kauffmann, L., Roux-Sibilon, A., Beffara, B., Mermillod, M., Guyader, N., y Peyrin, C. (2017). How does information from low and high spatial frequencies interact during scene categorization? *Visual Cognition*, 25(9-10), 853–867.
- Kawato, M. (1999). Internal models for motor control and trajectory planning. *Current opinion in neurobiology*, 9(6), 718–727.
- Kawato, M., Kuroda, T., Imamizu, H., Nakano, E., Miyauchi, S., y Yoshioka, T. (2003). Internal forward models in the cerebellum: fMRI study on grip force and load force coupling. *Progress in brain research*, 142, 171–188.
- Kelkar, A. (2021). Cognitive homeostatic agents. *arXiv preprint arXiv:2103.03359*.
- Khatib, O., Demircan, E., De Sapio, V., Sentis, L., Besier, T., y Delp, S. (2009). Robotics-based synthesis of human motion. *Journal of physiology-Paris*, 103(3-5), 211–219.
- Khazatsky, A., Nair, A., Jing, D., y Levine, S. (2021). What can I do here? learning new skills by imagining visual affordances. *arXiv preprint arXiv:2106.00671*.

- Kidd, C., Piantadosi, S. T., y Aslin, R. N. (2012). The goldilocks effect: Human infants allocate attention to visual sequences that are neither too simple nor too complex. *PloS one*, 7(5), e36399.
- Kihara, K., y Takeda, Y. (2010). Time course of the integration of spatial frequency-based information in natural scenes. *Vision research*, 50(21), 2158–2162.
- Kirtay, M., Vannucci, L., Albanese, U., Laschi, C., Oztop, E., y Falotico, E. (2019). Emotion as an emergent phenomenon of the neurocomputational energy regulation mechanism of a cognitive agent in a decision-making task. *Adaptive Behavior*, 1059712319880649.
- Kiverstein, J., Miller, M., y Rietveld, E. (2019). The feeling of grip: novelty, error dynamics, and the predictive brain. *Synthese*, 196(7), 2847–2869.
- Kowalczyk, Z., y Czubenko, M. (2010). Model of human psychology for controlling autonomous robots. En *2010 15th international conference on methods and models in automation and robotics* (pp. 31–36).
- Kozak, R. A., y Corneil, B. D. (2021). High contrast, moving targets in an emerging target paradigm promote fast visuomotor responses during visually guided reaching. *Journal of Neurophysiology*.
- Krichmar, J. L. (2012). Design principles for biologically inspired cognitive robotics. *Biologically Inspired Cognitive Architectures*, 1, 73–81.
- Krubitzer, L., Huffman, K. J., Disbrow, E., y Recanzone, G. (2004). Organization of area 3a in macaque monkeys: contributions to the cortical phenotype. *Journal of Comparative Neurology*, 471(1), 97–111.
- Làdavas, E., y Farnè, A. (2004). Neuropsychological evidence of integrated multisensory representation of space in humans.
- Laird, J. E., Kinkade, K. R., Mohan, S., y Xu, J. Z. (2012). Cognitive robotics using the soar cognitive architecture. En *Workshops at the twenty-sixth aai conference on artificial intelligence*.
- Laird, J. E., Newell, A., y Rosenbloom, P. S. (1986). *Soar: An architecture for general intelligence*. (Inf. Téc.). STANFORD UNIV CA DEPT OF COMPUTER SCIENCE.
- Langley, P., Laird, J. E., y Rogers, S. (2009). Cognitive architectures: Research issues and challenges. *Cognitive Systems Research*, 10(2), 141–160.
- Lara, B., Astorga, D., Mendoza-Bock, E., Pardo, M., Escobar, E., y Ciria, A. (2018). Embodied cognitive robotics and the learning of sensorimotor schemes. *Adaptive Behavior*, 26(5), 225–238.
- Lazarus, R. S., y Lazarus, R. S. (1991). *Emotion and adaptation*. Oxford University Press on Demand.

- Lea, S. E., Chow, P. K., Leaver, L. A., y McLaren, I. P. (2020). Behavioral flexibility: a review, a model, and some exploratory tests. *Learning & behavior*, 1–15.
- Lee-Johnson, C. P., y Carnegie, D. A. (2009). Mobile robot navigation modulated by artificial emotions. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 40(2), 469–480.
- Lewis, M., y Canamero, L. (2016). Hedonic quality or reward? a study of basic pleasure in homeostasis and decision making of a motivated autonomous robot. *Adaptive Behavior*, 24(5), 267–291.
- Lieto, A., Bhatt, M., Oltramari, A., y Vernon, D. (2018). *The role of cognitive architectures in general artificial intelligence*. Elsevier.
- Limanowski, J., y Friston, K. (2020). Attentional modulation of vision versus proprioception during action. *Cerebral Cortex*, 30(3), 1637–1648.
- Llorens, R., Borrego, A., Palomo, P., Cebolla, A., Noé, E., i Badia, S. B., y Baños, R. (2017). Body schema plasticity after stroke: subjective and neurophysiological correlates of the rubber hand illusion. *Neuropsychologia*, 96, 61–69.
- Loetscher, T., Schwarz, U., Schubiger, M., y Brugger, P. (2008). Head turns bias the brain’s internal random generator. *Current Biology*, 18(2), R60–R62.
- Lowe, M. X., Rajsic, J., Ferber, S., y Walther, D. B. (2018). Discriminating scene categories from brain activity within 100 milliseconds. *Cortex*, 106, 275–287.
- Lowe, R., Montebelli, A., Ieropoulos, I., Greenman, J., Melhuish, C., y Ziemke, T. (2010). Grounding motivation in energy autonomy—a study of artificial metabolism constrained robot dynamics. En *Alife* (pp. 725–732).
- Luciw, M., Graziano, V., Ring, M., y Schmidhuber, J. (2011). Artificial curiosity with planning for autonomous perceptual and cognitive development. En *2011 IEEE International Conference on Development and Learning (ICDL)* (Vol. 2, pp. 1–8).
- Makin, T. R., Holmes, N. P., y Ehrsson, H. H. (2008). On the other hand: dummy hands and peripersonal space. *Behavioural brain research*, 191(1), 1–10.
- Mamiya, A., Gurung, P., y Tuthill, J. C. (2018). Neural coding of leg proprioception in drosophila. *Neuron*, 100(3), 636–650.
- Man, K., y Damasio, A. (2019). Homeostasis and soft robotics in the design of feeling machines. *Nature Machine Intelligence*, 1(10), 446–452.
- Mar, T., Tikhanoff, V., y Natale, L. (2018). What can i do with this tool?

- self-supervised learning of tool affordances from their 3-d geometry. *IEEE Transactions on Cognitive and Developmental Systems*, 10(3), 595–610.
- Marchi, F. (2020). The cognitive processing hierarchy. En *The attentional shaping of perceptual experience* (pp. 17–32). Springer.
- Maren, S., Phan, K. L., y Liberzon, I. (2013). The contextual brain: implications for fear conditioning, extinction and psychopathology. *Nature reviews neuroscience*, 14(6), 417–428.
- Marinier, R. P., y Laird, J. E. (2008). Emotion-driven reinforcement learning. En *Proceedings of the annual meeting of the cognitive science society* (Vol. 30).
- Marsland, S., Nehmzow, U., y Shapiro, J. (2000). A real-time novelty detector for a mobile robot. *arXiv preprint cs/0006006*.
- Martin, J., van Moorter, B., Revilla, E., Blanchard, P., Dray, S., Quenette, P.-Y., ... Swenson, J. E. (2013). Reciprocal modulation of internal and external factors determines individual movements. *Journal of Animal Ecology*, 82(2), 290–300.
- Maslow, A. H. (1958). A dynamic theory of human motivation.
- Mauss, I. B., Bunge, S. A., y Gross, J. J. (2007). Automatic emotion regulation. *Social and Personality Psychology Compass*, 1(1), 146–167.
- McCarthy, J., y Hayes, P. J. (1981). Some philosophical problems from the standpoint of artificial intelligence. En *Readings in artificial intelligence* (pp. 431–450). Elsevier.
- McFarland, D. (2009). *Guilty robots, happy dogs: the question of alien minds*. Oxford University Press.
- McNamee, D., y Wolpert, D. M. (2019). Internal models in biological control. *Annual review of control, robotics, and autonomous systems*, 2, 339–364.
- Metta, G., Sandini, G., y Konczak, J. (1999). A developmental approach to visually-guided reaching in artificial systems. *Neural networks*, 12(10), 1413–1427.
- Miall, R. C., y Wolpert, D. M. (1996). Forward models for physiological motor control. *Neural networks*, 9(8), 1265–1279.
- Min, H., Luo, R., Zhu, J., Bi, S., y cols. (2016). Affordance research in developmental robotics: A survey. *IEEE Transactions on Cognitive and Developmental Systems*, 8(4), 237–255.
- Mo, K., Qin, Y., Xiang, F., Su, H., y Guibas, L. (2022). O2o-afford: Annotation-free large-scale object-object affordance learning. En *Conference on robot learning* (pp. 1666–1677).

- Moerland, T. M., Broekens, J., y Jonker, C. M. (2018). Emotion in reinforcement learning agents and robots: a survey. *Machine Learning*, 107(2), 443–480.
- Mohan, V., Morasso, P., Sandini, G., y Kasperidis, S. (2013). Inference through embodied simulation in cognitive robots. *Cognitive Computation*, 5(3), 355–382.
- Moioli, R. C., Vargas, P. A., y Husbands, P. (2009). A multiple hormone approach to the homeostatic control of conflicting behaviours in an autonomous mobile robot. En *2009 IEEE Congress on Evolutionary Computation* (pp. 47–54).
- Moldovan, B., Moreno, P., Van Otterlo, M., Santos-Victor, J., y De Raedt, L. (2012). Learning relational affordance models for robots in multi-object manipulation tasks. En *2012 IEEE International Conference on Robotics and Automation* (pp. 4373–4378).
- Montell, C. (2019). Coordinated movement: Watching proprioception unfold. *Current Biology*, 29(6), R202–R205.
- Morasso, P., Casadio, M., Mohan, V., Rea, F., y Zenzeri, J. (2015). Revisiting the body-schema concept in the context of whole-body postural-focal dynamics. *Frontiers in human neuroscience*, 9, 83.
- Morasso, P., y Mohan, V. (2021). The body schema: neural simulation for covert and overt actions of embodied cognitive agents. *Current Opinion in Physiology*, 19, 219–225.
- Morse, A., Belpaeme, T., Cangelosi, A., y Smith, L. (2010). Thinking with your body: Modelling spatial biases in categorization using a real humanoid robot. En *Proceedings of the annual meeting of the cognitive science society* (Vol. 32).
- Morse, A. F., De Greeff, J., Belpaeme, T., y Cangelosi, A. (2010). Epigenetic robotics architecture (era). *IEEE Transactions on Autonomous Mental Development*, 2(4), 325–339.
- Müller, H., y Tamura, G. (2013). Dagstuhl seminar 13511 on software engineering for self-adaptive systems: Assurances december 16-19, 2013.
- Mulligan, K., y Scherer, K. R. (2012). Toward a working definition of emotion. *Emotion Review*, 4(4), 345–357.
- Nabeshima, C., Kuniyoshi, Y., y Lungarella, M. (2006). Adaptive body schema for robotic tool-use. *Advanced Robotics*, 20(10), 1105–1126.
- Nave, K., Deane, G., Miller, M., y Clark, A. (2020). Wilding the predictive brain. *Wiley Interdisciplinary Reviews: Cognitive Science*, 11(6), e1542.
- Nguyen, P. D., Hoffmann, M., Pattacini, U., y Metta, G. (2019). Reaching development through visuo-proprioceptive-tactile integration on a hu-

- manoid robot—a deep learning approach. En *2019 joint ieee 9th international conference on development and learning and epigenetic robotics (icdl-epirob)* (pp. 163–170).
- Nikolić, D. (2010). The brain is a context machine. *Review of psychology*, *17*(1), 33–38.
- Noel, J.-P., Bertoni, T., y Serino, A. (2020). Peri-personal space as an interface for self-environment interaction. *The World at Our Fingertips: A Multidisciplinary Exploration of Peripersonal Space*, 17.
- Oliva, A. (2005). Gist of the scene. En *Neurobiology of attention* (pp. 251–256). Elsevier.
- Olivers, C. N., y Roelfsema, P. R. (2020). Attention for action in visual working memory. *cortex*, *131*, 179–194.
- Oudeyer, P.-Y. (2018). Computational theories of curiosity-driven learning. *arXiv preprint arXiv:1802.10546*.
- Oudeyer, P.-Y., y Kaplan, F. (2008). How can we define intrinsic motivation? En *the 8th international conference on epigenetic robotics: Modeling cognitive development in robotic systems*.
- Oudeyer, P.-Y., Kaplan, F., y Hafner, V. V. (2007). Intrinsic motivation systems for autonomous mental development. *IEEE transactions on evolutionary computation*, *11*(2), 265–286.
- O'Reilly, R. C. (2020). Unraveling the mysteries of motivation. *Trends in cognitive sciences*, *24*(6), 425–434.
- Pace-Schott, E. F., Amole, M. C., Aue, T., Balconi, M., Bylsma, L. M., Critchley, H., ... others (2019). Physiological feelings. *Neuroscience & Biobehavioral Reviews*, *103*, 267–304.
- Palmer, C. R., Barnett, M. N., Copado, S., Gardezy, F., y Kristan Jr, W. B. (2014). Multiplexed modulation of behavioral choice. *Journal of Experimental Biology*, *217*(16), 2963–2973.
- Parisi, D., y Petrosino, G. (2010). Robots that have emotions. *Adaptive Behavior*, *18*(6), 453–469.
- Paus, F., Huang, T., y Asfour, T. (2020). Predicting pushing action effects on spatial object relations by learning internal prediction models. En *2020 ieee international conference on robotics and automation (icra)* (pp. 10584–10590).
- Peelen, M. V., y Caramazza, A. (2012). Conceptual object representations in human anterior temporal cortex. *Journal of Neuroscience*, *32*(45), 15728–15736.
- Perry, B., Hogan, L., Marlin, S., y cols. (2000). Curiosity, pleasure and play: A neurodevelopmental perspective. *Haaeyc Advocate*, *20*, 9–12.
- Petras, K., Ten Oever, S., Jacobs, C., y Goffaux, V. (2019). Coarse-to-fine

- information integration in human vision. *NeuroImage*, 186, 103–112.
- Pezzulo, G., Barsalou, L. W., Cangelosi, A., Fischer, M. H., McRae, K., y Spivey, M. (2013). Computational grounded cognition: a new alliance between grounded cognition and computational modeling. *Frontiers in psychology*, 3, 612.
- Pfeifer, R., y Bongard, J. (2006). *How the body shapes the way we think: a new view of intelligence*. MIT press.
- Pfeifer, R., y Scheier, C. (2001). *Understanding intelligence*. MIT press.
- Phelps, E. A. (2006). Emotion and cognition: insights from studies of the human amygdala. *Annu. Rev. Psychol.*, 57, 27–53.
- Pugach, G., Pitti, A., Tolochko, O., y Gaussier, P. (2019). Brain-inspired coding of robot body schema through visuo-motor integration of touched events. *Frontiers in neurorobotics*, 13, 5.
- Puigbo, J.-Y., Pumarola, A., Angulo, C., y Tellez, R. (2015). Using a cognitive architecture for general purpose service robot control. *Connection Science*, 27(2), 105–117.
- Ragozzino, M. E. (2007). The contribution of the medial prefrontal cortex, orbitofrontal cortex, and dorsomedial striatum to behavioral flexibility. *Annals of the New York academy of sciences*, 1121(1), 355–375.
- Ramachandran, V., Blakeslee, S., y Shah, N. (2013). *Phantoms in the brain: probing the mysteries of the human mind*. Tantor Media, Incorporated.
- Ramirez-Pedraza, R., y Ramos, F. (2021). Decision-making bioinspired model for target definition and “satisfactor” selection for physiological needs. *Cognitive Systems Research*, 66, 122–133.
- Reed, C. L., y Hartley, A. A. (2021). Embodied attention: Integrating the body and senses to act in the world. En *Handbook of embodied psychology* (pp. 265–290). Springer.
- Reiss, S. (2004). Multifaceted nature of intrinsic motivation: The theory of 16 basic desires. *Review of general psychology*, 8(3), 179–193.
- Rietveld, E. (2008). Situated normativity: The normative aspect of embodied cognition in unreflective action. *Mind*, 117(468), 973–1001.
- Rietveld, E., Denys, D., y Van Westen, M. (2018). Ecological-enactive cognition as engaging with a field of relevant affordances. *The Oxford handbook of 4E cognition*, 41.
- Rochat, P. (1998). Self-perception and action in infancy. *Experimental brain research*, 123(1-2), 102–109.
- Rolls, E. T. (2000). Precis of the brain and emotion. *Behavioral and brain sciences*, 23(2), 177–191.
- Roncione, A., Hoffmann, M., Pattacini, U., y Metta, G. (2015). Learning

- peripersonal space representation through artificial skin for avoidance and reaching with whole body surface. En *2015 ieee/rsj international conference on intelligent robots and systems (iros)* (pp. 3366–3373).
- Rosenbaum, D. A., Herbort, O., Van der Wel, R., y Weiss, D. J. (2014). What’s in a grasp. *Am. Sci*, *102*, 366–373.
- Roth, W.-M., y Jornet, A. (2013). Situated cognition. *Wiley Interdisciplinary Reviews: Cognitive Science*, *4*(5), 463–478.
- Ryan, R. M., y Deci, E. L. (2000). Intrinsic and extrinsic motivations: Classic definitions and new directions. *Contemporary educational psychology*, *25*(1), 54–67.
- Saegusa, R., Metta, G., Sandini, G., y Sakka, S. (2009). Active motor babbling for sensorimotor learning. En *2008 ieee international conference on robotics and biomimetics* (pp. 794–799).
- Sainburg, R. L., Lateiner, J. E., Latash, M. L., y Bagesteiro, L. B. (2003). Effects of altering initial position on movement direction and extent. *Journal of Neurophysiology*, *89*(1), 401–415.
- Sansone, C., y Harackiewicz, J. M. (2000). *Intrinsic and extrinsic motivation: The search for optimal motivation and performance*. Elsevier.
- Sarlegna, F. R., y Sainburg, R. L. (2009). The roles of vision and proprioception in the planning of reaching movements. *Progress in motor control*, 317–335.
- Saunders, J. A., y Knill, D. C. (2003). Humans use continuous visual feedback from the hand to control fast reaching movements. *Experimental brain research*, *152*(3), 341–352.
- Schillaci, G., Hafner, V. V., y Lara, B. (2016). Exploration behaviors, body representations, and simulation processes for the development of cognition in artificial agents. *Frontiers in Robotics and AI*, *3*, 39.
- Schillaci, G., Lara, B., y Hafner, V. V. (2012). Internal simulations for behaviour selection and recognition. En *International workshop on human behavior understanding* (pp. 148–160).
- Schillaci, G., Pico Villalpando, A., Hafner, V. V., Hanappe, P., Coliaux, D., y Wintz, T. (2020). Intrinsic motivation and episodic memories for robot exploration of high-dimensional sensory spaces. *Adaptive Behavior*, 1059712320922916.
- Schmidhuber, J. (1991). A possibility for implementing curiosity and boredom in model-building neural controllers. En *Proc. of the international conference on simulation of adaptive behavior: From animals to animats* (pp. 222–227).
- Schulkin, J., y Sterling, P. (2019). Allostasis: A brain-centered, predictive mode of physiological regulation. *Trends in Neurosciences*, *42*(10),

- 740–752.
- Schulz, A., y Vögele, C. (2015). Interoception and stress. *Frontiers in psychology*, 6, 993.
- Sereno, M. I., y Huang, R.-S. (2006). A human parietal face area contains aligned head-centered visual and tactile maps. *Nature neuroscience*, 9(10), 1337–1343.
- Serino, A. (2019). Peripersonal space (pps) as a multisensory interface between the individual and the environment, defining the space of the self. *Neuroscience & Biobehavioral Reviews*, 99, 138–159.
- Sherrington, C. S. (1907). On the proprioceptive system, especially in its reflex aspect. *Brain*, 29(4), 467–482.
- Singh, S., Lewis, R. L., Barto, A. G., y Sorg, J. (2010). Intrinsically motivated reinforcement learning: An evolutionary perspective. *IEEE Transactions on Autonomous Mental Development*, 2(2), 70–82.
- Sisbot, E. A., Alami, R., Siméon, T., Dautenhahn, K., Walters, M., y Woods, S. (2005). Navigation in the presence of humans. En *5th ieee-ras international conference on humanoid robots, 2005*. (pp. 181–188).
- Smith, L. B., y Samuelson, L. (2010). Objects in space and mind: from reaching to words. *Thinking Through Space: Spatial Foundations of Language and Cognition*.
- Sober, S. J., y Sabes, P. N. (2005). Flexible strategies for sensory integration during motor planning. *Nature neuroscience*, 8(4), 490–497.
- Soudry, Y., Lemogne, C., Malinvaud, D., Consoli, S.-M., y Bonfils, P. (2011). Olfactory system and emotion: common substrates. *European annals of otorhinolaryngology, head and neck diseases*, 128(1), 18–23.
- Spaak, E., Peelen, M. V., y de Lange, F. (2020). Scene context impairs perception of semantically congruent objects. *BioRxiv*.
- Spier, E., y McFarland, D. (1997). Possibly optimal decision-making under self-sufficiency and autonomy. *Journal of theoretical biology*, 189(3), 317–331.
- Spivey, M. J., McRae, K., Fischer, M. H., Cangelosi, A., Barsalou, L. W., y Pezzulo, G. (2011). The mechanics of embodiment: a dialog on embodiment and computational modeling. *Frontiers in Psychology*, 2.
- Stagnitti, K. (2004). Understanding play: The implications for play assessment. *Australian occupational therapy journal*, 51(1), 3–12.
- Stradner, J., Hamann, H., Schmickl, T., y Crailsheim, K. (2009). Analysis and implementation of an artificial homeostatic hormone system: A first case study in robotic hardware. En *2009 ieee/rsj international conference on intelligent robots and systems* (pp. 595–600).

- Strigo, I. A., y Craig, A. D. (2016). Interoception, homeostatic emotions and sympathovagal balance. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 371(1708), 20160010.
- Sturm, J., Plogemann, C., y Burgard, W. (2009). Body schema learning for robotic manipulators from visual self-perception. *Journal of Physiology-Paris*, 103(3-5), 220–231.
- Sun, Y., Ren, S., y Lin, Y. (2014). Object–object interaction affordance learning. *Robotics and Autonomous Systems*, 62(4), 487–496.
- Sutton, R. S., y Barto, A. G. (2018). *Reinforcement learning: An introduction*. MIT press.
- Tanaka, H., Ishikawa, T., Lee, J., y Kakei, S. (2020). The cerebro-cerebellum as a locus of forward model: a review. *Frontiers in systems neuroscience*, 14, 19.
- Taormina, R. J., y Gao, J. H. (2013). Maslow and the motivation hierarchy: Measuring satisfaction of the needs. *The American journal of psychology*, 126(2), 155–177.
- Tapus, A., y Siegwart, R. (2005). Incremental robot mapping with fingerprints of places. En *2005 ieee/rsj international conference on intelligent robots and systems* (pp. 2429–2434).
- Thorpe, S., Fize, D., y Marlot, C. (1996). Speed of processing in the human visual system. *nature*, 381(6582), 520–522.
- Turner, R. M. (1998). Context-mediated behavior for intelligent agents. *International Journal of Human-Computers Studies*, 48(3), 307–330.
- Tuthill, J. C., y Azim, E. (2018). Proprioception. *Current Biology*, 28(5), R194–R203.
- Tyng, C. M., Amin, H. U., Saad, M. N., y Malik, A. S. (2017). The influences of emotion on learning and memory. *Frontiers in psychology*, 8, 1454.
- Ursino, M., Zavaglia, M., Magosso, E., Serino, A., y di Pellegrino, G. (2007). A neural network model of multisensory representation of peripersonal space: effect of tool use. En *2007 29th annual international conference of the ieee engineering in medicine and biology society* (pp. 2735–2739).
- Van de Cruys, S. (2017). *Affective value in the predictive mind*. MIND Group; Frankfurt am Main.
- Van Polanen, V., y Davare, M. (2015). Interactions between dorsal and ventral streams for controlling skilled grasp. *Neuropsychologia*, 79, 186–191.
- Vargas, P., Muioli, R., de Castro, L. N., Timmis, J., Neal, M., y Von Zuben, F. J. (2005). Artificial homeostatic system: a novel approach. En *European conference on artificial life* (pp. 754–764).

- Vernon, D., Metta, G., y Sandini, G. (2007). A survey of artificial cognitive systems: Implications for the autonomous development of mental capabilities in computational agents. *IEEE transactions on evolutionary computation*, 11(2), 151–180.
- Vladimirov, N., y Sourjik, V. (2009). Chemotaxis: how bacteria use memory.
- Vouloutsi, V., Lallée, S., y Verschure, P. F. (2013). Modulating behaviors using allostatic control. En *Conference on biomimetic and biohybrid systems* (pp. 287–298).
- Wade, N. J. (2019). Microscopic anatomy of sensory receptors. *Journal of the History of the Neurosciences*, 28(3), 285–306.
- White, R. W. (1959). Motivation reconsidered: The concept of competence. *Psychological review*, 66(5), 297.
- Wilson, M. (2002). Six views of embodied cognition. *Psychonomic bulletin & review*, 9(4), 625–636.
- Withagen, R., De Poel, H. J., Araújo, D., y Pepping, G.-J. (2012). Affordances can invite behavior: Reconsidering the relationship between affordances and agency. *New Ideas in Psychology*, 30(2), 250–258.
- Wolpert, D. M., Ghahramani, Z., y Flanagan, J. R. (2001). Perspectives and problems in motor learning. *Trends in cognitive sciences*, 5(11), 487–494.
- Wolpert, D. M., Ghahramani, Z., y Jordan, M. I. (1995). An internal model for sensorimotor integration. *Science*, 269(5232), 1880–1882.
- Wolpert, D. M., y Kawato, M. (1998). Multiple paired forward and inverse models for motor control. *Neural networks*, 11(7-8), 1317–1329.
- Yoshida, N. (2017). Homeostatic agent for general environment. *Journal of Artificial General Intelligence*, 8(1), 1.
- Zambelli, M., Cully, A., y Demiris, Y. (2020). Multimodal representation models for prediction and control from partial information. *Robotics and Autonomous Systems*, 123, 103312.
- Zenha, R., Vicente, P., Jamone, L., y Bernardino, A. (2018). Incremental adaptation of a robot body schema based on touch events. En *2018 joint ieee 8th international conference on development and learning and epigenetic robotics (icdl-epirob)* (pp. 119–124).
- Zhang, Q., y Li, S. (2020). The roles of spatial frequency in category-level visual search of real-world scenes. *PsyCh journal*, 9(1), 44–55.
- Zhang, T., Hu, F., Deng, Y., Nie, M., Liu, T., Wu, X., y Luo, D. (2018). Self-developing proprioception-based robot internal models. En *International conference on intelligence science* (pp. 321–332).
- Ziemke, T., y Lowe, R. (2009). On the role of emotion in embodied cognitive

- architectures: From organisms to robots. *Cognitive computation*, 1(1), 104–117.
- Zimmermann, M., Meulenbroek, R. G., y de Lange, F. P. (2012). Motor planning is facilitated by adopting an action's goal posture: an fmri study. *Cerebral cortex*, 22(1), 122–131.

**DRA. LINA ANDREA RIVILLAS ACEVEDO
COORDINADORA DEL POSGRADO EN CIENCIAS
PRESENTE**

Atendiendo a la solicitud para emitir DICTAMEN sobre la revisión de la TESIS titulada: **Cimentación del contexto en la robótica cognitiva corporizada**, que presenta la alumna **Diana Valenzo Macías (10012792)** para obtener el título de **Doctor en Ciencias**.

Nos permitimos informarle que nuestro voto es:

NOMBRE	DICTAMEN	FIRMA
Dr. Markus Franziskus Müller CInC-UAEM	APROBADO	
Dr. Jorge Hermosillo Valadez CInC-UAEM	APROBADO	
Dr. Alejandro Vázquez del Mercado Hernández Facultad de Filosofía y Letras-UNAM	APROBADO	
Dr. Juan Manuel Rendón Mancha CInC-UAEM	APROBADO	
Dra. Ma. de la Cruz Bernarda Téllez Alanís CITPSI-UAEM	APROBADO	
Dr. Ángel Eugenio Tovar y Romo Facultad de Psicología- UNAM	APROBADO	
Dr. Bruno Lara Guzmán CInC-UAEM	APROBADO	



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

BRUNO LARA GUZMAN | Fecha:2023-06-07 18:20:31 | Firmante

oh9vvn9MWBa/Y+PIF5Mh0GchTfk8EdDvzzyBRbB+XF5oPUBi1hhOifdrX1vacJ+w3BILX2x1lvTrA6OU4RA2U5OrW//jhshTE3wFVt7w+ncX85fvJahFgoxPqrbePNs+qYKd6UzvSVr
gnwjHkr5uScjKhFhJPaS4xhlg8FWO8Geb3cgoCfe/DAR5WO/zJi80kjMZgf+ZSXiWfaK7vbu3OrdHIL1pPXxc70FTLXvNagDNYaKi5yJUoa5oKYQb3UdGHIO3gycDFOeDn/pGpkB+H
vvcemF0XQ6JmYsNPUXac+fMy1LJQN+0M93gjCsCkzMVO4ZbMuJ1cxFXDzQoB6aReQ==

JUAN MANUEL RENDON MANCHA | Fecha:2023-06-07 20:07:17 | Firmante

RUqVvK1LSYhhEgSKCtmyBVCbSCqmakJZJGcUzoAJ6O9eX8Wp+dj\$5HRpioLbgpPn8ZRaPlt9dqwbrx2p/hpnKEguRAelRDPHYQIBw06+mnxoWviduyrBaWCJLtidR5O/4ZJpR5
4+x9PG6keoAz19uuxLuNTamgRkdKc2Sq01OIDwzeRo1ELJRMhe1yThHzlg85ZT6zX/4hHSqyRrm6Jm7Hc/+EkDpVYyHANwQIDL9t1pkkyC49oWhjzFbk5kc2kC1Z8cuc5CF8K
2LWs7iY+CU61KOPrSnQyIVQuMuliVn2lm4ZwUjJsJfzVBZgF8nJ/WuCHNB/UsaFwrAME4AwOw==

ALEJANDRO VÁZQUEZ DEL MERCADO HERNÁNDEZ | Fecha:2023-06-08 00:25:22 | Firmante

XPPEZTd5Zn8DP2BkHvVz7m5lqv1PZkml/KV+1Recl5llChEnyBqojGtnZneNnTD8UQAglNPWJgPwoEcqBeNW60KWcl+5D8HjivUfChv/Bc9pGGcUWJhY1Jf6AKUSET1eKfl6nbnb
OBLjqFbH+yhUTDEWnxR0A8DX0EAbNhsBP/qxpDRoBmuo/ORkdUGhMUUVOhlaXApCNZyTaqSaQKruMg/61vO/C3aSrYK3dZJB8NOHBZ2D1Zn1J+4Vzy/KnEwLvdeTCpPJVk
aJlbamdVMLZNPFDWiewfybcNnncv/cVXZEksQnsXFO2P4L2zYHqjS2CQPmSCXgL31ouermaqA1A==

MARKUS FRANZISKUS MULLER | Fecha:2023-06-08 08:44:03 | Firmante

lwmXVyoCeN/blf0OzqQbXpHSGGIOrhYN6v57yS+zH1LWJQ2MYncsJ7NywSq1qa807Jz6b1gr9XTCgOXn9STKSByqGaYkcvWl0Kyxovet7QeAnS/n62VnWobq9KScjZ3oWKtrRP
mbP3vmltPNWpM9NbK1tYccKJccLtSacR89lgiWw5ztJMFv2USQG3JGmVqix/n78xGay1cLaj+RNSBtlNcrJQmjf3lv4ffG7oJv5yEpA97TyWENs3g5aWxNypFrpNakxMsCA+JblYI
mjx85z/0MkVqSiU2A6o2FBTPlLiUc5s+XWlG4UWjiaBIPvW++4vyAZKK095fiUblHETKIIQ==

JORGE HERMOSILLO VALADEZ | Fecha:2023-06-08 09:57:46 | Firmante

JYf1jEDIOwKGIiOj4advVtMFivWNbE2DB9XF5vsR7yFZwk+K8Q2oOZnls+psiGH2cfiUG9ieBpg0q+QgcoR0OojpRxxklpJCCbo9tBGL/Vstxn9gxYdkkXgaC8Bfk2rBtfeDRMuL8ja5
XiECllhLN7pYOMSGagtqxkkrer2O5OsljA2EGD7mhMxfHPIJZ68AEQTCAT9wTWweZrJD0eJzNONIXO5Z0qH0rznSirX+wZKDVMYDIDxLzFa5k4AtSKEzOGqiyWcElOg2EyDM
USPuiWyD64ayWtFphPKL07zsanYT7X374o4MLjz2l2UqqK077zj5/XMu/fs9Q==

ANGEL EUGENIO TOVAR Y ROMO | Fecha:2023-06-08 12:20:08 | Firmante

b7Up0u8TldU05So3uwrO+wcWYJ3vr1vHiMHMwSjR3XBvrZ7bZK4nbtgi0mmvR0wly1Zgi/z0quoNHcmoXmTZxa8s1llgxu/jHSv2e1+G22OFAFLGGTVE6WEiWebLweOprnw9sv
X20b3z35GyaoEwl3NZQx/vag4tQ588yFNUkorkjA3mDq3tKmRjXL282P/3COr61n5XQqpeO0khlx82TBdKuWJpkamGU1+7YfxtFm3YlyglLgYp9alNr9xGz5nj0EzFeGoeWH0vUuN
kjeZKANtMjD57uFVvuzngCV/Ro24LYJvRvqyW8cRIZ7gBhi1KuZ5FhLVfCTOR+/WnfUrQ==

MA DE LA CRUZ BERNARDA TELLEZ ALANIS | Fecha:2023-06-08 23:01:55 | Firmante

RHWFu0Uh1YeCA2oxGNX84xf7Ck46KY4u8PVwhS6r9/2cf0vE1pX9ThpWg7Vn738whM9c48l7ofxpg+L2/LO8f97vqFazgBjBwhNe5lIPn2smhpjau3he7QEUhV1/0OIFmpAoRa8i6
MsWcXEPRe6kPzzLioUF6+EppEucpJuYPIQKr/elrQdEyS64UQhV81ORn9iH8FxCVLS58aNNFicfshL4clYcH7SmXu1yrhwTL7EV+pJihibKDLzeH5Cfm2C0HlcWWWl9r6DrZvsP
QF6SZXUJadk5HIMXbwsfyv4gJwAzyw2/iuSJM5PJWjfu34IFu4QyzXM/qzO4Kz9LV/A==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



c0FStko9d

<https://efirma.uaem.mx/noRepudio/SxSN4k7TW6Ag4ZvTVvG2FBd4uSYeF7bO>

