

PEDECIBA Informática
Instituto de Computación – Facultad de Ingeniería
Universidad de la República
Montevideo, Uruguay

Tesis de Doctorado

en Informática

Localización robusta a través de interconexión
de neuronas grilla y neuronas de lugar

Gonzalo Tejera

2016

Localización robusta a través de interconexión
de neuronas grilla y neuronas de lugar
ISSN 0797-6410
Tesis de Doctorado en Informática
Reporte Técnico RT 16-01
PEDECIBA
Instituto de Computación – Facultad de Ingeniería
Universidad de la República.
Montevideo, Uruguay, 2015

PEDECIBA INFORMATICA

INSTITUTO DE COMPUTACION, FACULTAD DE INGENIERIA

UNIVERSIDAD DE LA REPUBLICA

MONTEVIDEO, URUGUAY

TESIS DE DOCTORADO EN INFORMATICA

Localización robusta a través de la interconexión de neuronas grilla y neuronas de lugar

Gonzalo Tejera
gtejera@fing.edu.uy

Directores: Dr. Héctor Cancela y Dr. Alfredo Weitzenfeld

Tribunal: Dr. Jesús Savage, Dra. Silvia S. C. Botelho (revisores), Dr. Javier Baliosian, Dr. Eduardo Mizraji y Dr. Alberto Pardo.

Montevideo, Uruguay - 2015

LOCALIZACIÓN ROBUSTA A TRAVÉS DE LA INTERCONEXIÓN DE NEURONAS GRILLA Y NEURONAS DE LUGAR

RESUMEN

Se ha demostrado que las neuronas grilla y de lugar juegan un rol importante en la cognición espacial de las ratas. Las neuronas grilla proporcionan un odómetro neuronal para la integración de trayectorias a partir de información propioceptiva. Por otro lado, las neuronas de lugar combinan información multimodal, alotética e idiotética, para formar una representación global de la localización en el espacio.

En este trabajo se presenta un módulo basado en neuronas grilla y su integración a un modelo de cognición espacial teniendo en cuenta estudios del comportamiento y la neurofisiología de las ratas. El disparo de las neuronas grilla es generado utilizando un modelo basado en la interferencia de múltiples osciladores. Además, se utiliza un lazo de realimentación desde el módulo de neuronas de lugar hacia las neuronas grilla, para tolerar el error acumulado a partir de la integración de la información propioceptiva. El modelo se evalúa en entornos robóticos simulados y reales, utilizando un protocolo de experimentación diseñado para ser utilizado con ratas, para estudiar las estrategias de localización espacial, y en un experimento de larga duración, para estudiar su tolerancia al error.

Palabras clave: cognición espacial, neuronas grilla, neuronas de lugar, hipocampo, corteza entorrinal, localización robótica

Índice general

1. Introducción	1
1.1. Biología y robots	2
1.2. Propósito de la Investigación	6
1.3. Publicaciones	7
1.4. Organización del Documento	8
2. Marco Teórico	9
2.1. Navegación	9
2.1.1. Introducción	9
2.1.2. Clasificación de los algoritmos de navegación	11
2.1.2.1. Navegación topológica	11
2.1.2.2. Navegación métrica	13
2.1.3. Asociación de Datos y Ambigüedad Perceptual	14
2.2. Memoria Espacial en Ratas	15
2.2.1. Áreas del cerebro	15
2.2.1.1. Características funcionales	15
2.2.1.2. Conexiones en sistema hipocampal	16
2.2.2. Integración de Trayectoria	17
2.2.3. Señales Visuales en la Navegación	19
2.2.4. Integrador de trayectorias y señales visuales	19
2.2.5. Mapas Cognitivos	20
2.3. Navegación bio-inspirada	21
2.3.1. Neuronas para la navegación	22
2.3.1.1. Neuronas de lugar	22
2.3.1.2. Neuronas de dirección de la cabeza	23
2.3.1.3. Neuronas grilla	24
2.3.1.4. Neuronas borde	25
2.3.1.5. Neuronas de aceleración y velocidad	26
2.3.1.6. Transformación de campos grilla a lugar	26
2.3.2. Escenarios para experimentación	27
2.3.2.1. Laberinto de brazos radiales (David Olton y Robert Samuelson)	27
2.3.2.2. Laberinto de agua (Richard Morris)	28
2.3.2.3. El laberinto de plataforma circular (Carol Barnes)	28
2.4. Trabajos Relacionados	29
2.4.1. El modelo de Burgess y colaboradores (1994)	30

2.4.2.	El modelo de Redish y Touretzky (1997)	30
2.4.3.	El modelo de Guazelli y colaboradores (1998)	31
2.4.4.	El modelo de Gaussier y colaboradores (2002)	31
2.4.5.	El modelo de Arleo y colaboradores (2004)	32
2.4.6.	El modelo de Milford y colaboradores (2006-2012)	33
2.4.7.	El modelo de Antonelo y Schrauwen (2009)	34
2.4.8.	El modelo de Koene y Prescott (2009)	34
2.4.9.	El modelo de Samu y colaboradores (2009)	35
2.4.10.	El modelo de Cheung y colaboradores (2012)	36
3.	Modelo de Cognición Espacial	39
3.1.	Presentación general del modelo	39
3.2.	Contexto Biológico	41
3.3.	Modelos de osciladores vs atractores	44
3.4.	Información kinestésica e integración de trayectorias	45
3.4.1.	Interferencia de ondas	46
3.4.2.	Grilla a partir de múltiples osciladores	47
3.4.2.1.	Relación entre el espaciado y la frecuencia de los osciladores	48
3.4.2.2.	Derivación de la ecuación de disparos grilla	49
3.4.3.	Módulo integrador de trayectorias	52
3.5.	Transformación grilla - lugar	55
3.6.	Procesamiento de Información Visual	58
3.7.	Representación y Reconocimiento de Lugares	59
3.8.	Mecanismo de realimentación	62
3.9.	Limitaciones del modelo	64
4.	Implementación del Modelo	65
4.1.	El Lenguaje de Simulación Neuronal	65
4.2.	Interfaz Modelo – Agente	66
4.2.1.	Mundo Virtual	68
4.2.1.1.	Entorno	68
4.2.1.2.	Robot	68
4.2.2.	Robot Real	70
4.3.	Configuración de los ensayos para un experimento	76
4.3.1.	Definición del entorno	76
4.3.2.	Definición del experimento	76
5.	Experimentos	79
5.1.	Introducción	79
5.2.	Setup del modelo	79
5.3.	Protocolo de Morris	83
5.3.1.	El laberinto	84
5.3.2.	Protocolo de experimentación	84
5.3.2.1.	Experimento 1	85
5.3.2.2.	Experimento 2	88
5.3.3.	Resultados de los experimentos	89

5.3.3.1.	Experimento 1	90
5.3.3.2.	Experimento 2	95
5.3.3.3.	Resultados con el robot	98
5.4.	Evaluación del integrador de trayectorias realimentado	98
5.4.1.	Error experimental	99
5.4.2.	Métrica utilizada y experimento realizado	101
5.4.3.	Resultados experimentales	102
5.4.3.1.	Utilizando el mínimo espaciado	102
5.4.3.2.	Evaluando distintos espaciados	111
5.4.3.3.	Discusión y conclusiones	116
6.	Discusión y Conclusiones	117
6.1.	Sobre los Resultados Experimentales	117
6.1.1.	Experimentos de Morris	118
6.1.2.	Experimentos de larga duración	118
6.2.	Sobre la Contribución de la Investigación	119
6.2.1.	Módulo integrador de trayectorias bio-inspirado	119
6.2.2.	Mecanismo de reset	119
6.2.3.	Aspectos de software	119
6.3.	Sobre las Líneas Futuras	120
6.3.1.	Expansión de los campos de lugar de las grilla	120
6.3.2.	Módulo de neuronas de dirección de la cabeza	120
6.3.3.	Módulo de aprendizaje	121
6.3.4.	Módulo del grafo del mundo	121
6.3.5.	Integración de información visual y de integración de trayectorias	121
6.3.6.	Integración de información de bordes	121
6.3.7.	Ejecutar el modelo en entornos no controlados	122
6.3.8.	Procesamiento de la información visual	122
6.3.9.	Mecanismo de remapeo	122
6.3.10.	Integración a ROS	123
	Bibliografía	124
	A. Parámetros del modelo	137

Índice de figuras

1.1. Interacción entre las Neurociencias y la Robótica.	2
1.2. Tortuga robótica.	3
1.3. Ejemplos de sensado y actuación con inspiración biológica.	5
1.4. Neurobot Darwin VIII.	6
2.1. Elementos de navegación. Los círculos representan los aspectos de navegación aislados y las intersecciones de los círculos representan los aspectos cuando éstos se resuelven en conjunto.	10
2.2. Ejemplos de marcas artificiales.	12
2.3. Ejemplo de mapa topológico con información para la navegación.	12
2.4. Ejemplo de mapa topológico con información para la navegación.	13
2.5. Ejemplo de navegación asociativa.	14
2.6. Cerebro de una rata.	16
2.7. Rutas en el sistema hipocampal.	17
2.8. Anatomía de la formación hipocampal.	20
2.9. Patrones de disparo espacial.	23
2.10. Patrones de disparo de una neurona grilla.	24
2.11. Red de neuronas grilla y de lugar.	26
2.12. Laberinto de brazos radiales de Olton.	28
2.13. Laberinto de agua de Morris.	29
2.14. Laberinto de plataforma circular de Barnes.	29
2.15. Arquitectura del modelo de Antonelo y Schrauwe.	35
2.16. Arquitectura del modelo de Koene y Prescott.	36
2.17. Arquitectura del modelo de Samu y colaboradores.	36
3.1. Arquitectura del modelo de cognición espacial.	40
3.2. Contexto biológico que subyace al modelo de cognición espacial.	42
3.3. Atractor continuo de neuronas HD.	45
3.4. Módulos de procesamiento de información kinestésica e integración de trayectorias, y su interacción.	46
3.5. Interferencia de dos ondas de igual amplitud y frecuencia.	47
3.6. Interferencia de ondas con igual amplitud y fase.	48
3.7. Gráficas con la variación de la frecuencia y el espaciado a través del eje dorsal - ventral.	49
3.8. Ejemplo de neuronas banda y su combinación.	52
3.9. Diagrama de neuronas incluidas en el módulo de integración de trayectorias.	53

3.10. La trayectoria de la rata en el escenario circular publicada por Hafting y Fyhn.	53
3.11. Campos grilla para distintas posiciones en eje ventral-dorsal.	54
3.12. Campos grilla para distintas direcciones preferidas de las neuronas banda.	54
3.13. Campos grilla para distintas fases espaciales.	55
3.14. Modulo integrador de trayectoria del modelo de cognición espacial.	57
3.15. El módulo de procesamiento de marcas del modelo de cognición espacial.	59
3.16. El módulo de representación de lugares del modelo de cognición espacial.	60
3.17. Ejemplo de grafo del mundo construido por el módulo WGL.	61
3.18. Interacción entre los módulos integración de trayectorias y representación de lugares.	62
3.19. Relación entre el módulo WGL y las neuronas grilla.	63
4.1. Diagrama de la interfase IRobot.	66
4.2. Entorno virtual de simulación.	69
4.3. Distribución del software entre el robot y el PC.	71
4.4. Imágenes locales tomadas con la webcam y su concatenación.	73
4.5. Interfaz gráfica con el modelo.	75
5.1. Ejemplos de laberintos de Morris.	79
5.2. Disparo grilla para diferentes orientaciones, y una misma fase y espaciado.	81
5.3. Disparos de lugar usando ecuación de Soldstad.	81
5.4. Relación y distribución de los campos de lugar en el entorno de Morris.	82
5.5. Características y elementos que forman el aparato diseñado por Morris.	84
5.6. El diagrama presenta las referencias cardinales dentro del escenario virtual.	86
5.7. Posición de la plataforma y el punto de partida de las ratas.	89
5.8. Latencia de escape para los 20 ensayos de entrenamientos del experimento 1.	90
5.9. Largo de los caminos para los ensayos 17 a 20 del experimento 1.	91
5.10. Trayectorias realizadas por las ratas del experimento 1.	92
5.11. Trayectorias realizadas por las ratas virtuales para el ensayo de Test A o B.	93
5.12. Porcentaje del tiempo en cada cuadrante.	93
5.13. Latencia para la etapa de test del experimento 1.	94
5.14. Distancias recorridas para la etapa de test del experimento 1.	94
5.15. Latencia los ensayos de entrenamiento 13-15.	96
5.16. Ensayos de test para el experimento 2.	96
5.17. Trayectorias realizadas para el primer ensayo de test del experimento 2.	97
5.18. Trayectorias realizadas por el robot en el experimento 1.	98
5.19. Agente, entorno y ruido.	99
5.20. El escenario circular y la posición de la cámara global.	102
5.21. Ejemplos de grafos del mundo generados para los experimentos de cierre de ciclo. . .	103
5.22. Gráfica del error acumulado inyectado al integrador de trayectorias.	104
5.23. Gráficas de errores de cierre de ciclo para el módulo DRL.	105
5.24. Gráfica de errores de cierre de ciclo con el módulo de neuronas grilla sin realimenta- ción.	106
5.25. Gráfica de errores de cierre de ciclo con el módulo de neuronas grilla con realimenta- ción.	107
5.26. Gráfica de errores de cierre de ciclo por factores de error inyectado.	108
5.27. Todas las gráficas de errores de cierre de ciclo.	109

5.28. Gráfica de errores de cierre de ciclo cuando el factor de espaciado es 1.	112
5.29. Gráfica de errores de cierre de ciclo cuando el factor de espaciado es 2.	113
5.30. Gráfica de errores de cierre de ciclo cuando el factor de espaciado es 3.	114
5.31. Gráfica de errores de cierre de ciclo multi escala sin realimentación.	115
5.32. Gráfica de errores de cierre de ciclo multi escala con realimentación.	115

Índice de cuadros

3.1. Ejemplos aproximados de período, frecuencia y espaciado.	50
4.1. Módulos NSL que componen el modelo de cognición espacial y su interacción.	67
4.2. Descripción de los métodos de IRobot.	68
4.3. Características del robot Khepera III+KoreBot II y sus periféricos.	71
4.4. Implementación la interfaz IRobot para el Khepera.	72
4.5. Hardware del robot utilizado para implementar la interfaz.	72
5.1. Variantes sobre la plataforma a la cual son sometidos los animales por grupos.	85
5.2. Resumen diario de los ensayos para el experimento 1.	85
5.3. Posición de los elementos en el entorno para el grupo Place.	87
5.4. Posición de la plataforma para las ocho ratas que componen el grupo <i>Place-Random</i>	87
5.5. Posiciones iniciales de la rata durante el Test A.	88
5.6. Posiciones iniciales de la rata durante el Test B.	88
5.7. Resumen diario de los ensayos para el experimento 2.	88
5.8. Cantidad de ratas, posiciones de partida y posiciones de la plataforma para los animales de los distintos grupos.	89
5.9. Cuadro característica de la cantidad de errores al cerrar el ciclo.	110
5.10. Relación entre factor de espaciado y espaciado.	111
A.1. Cantidad de ratas, posiciones de partida y posiciones de la plataforma para los animales de los distintos grupos.	137

Índice de algoritmos

4.1. Algoritmo para estabilizar imágenes	73
4.2. Algoritmo para encontrar una marca.	74
5.1. Algoritmo para determinar la magnitud del error sistemático del robot Khepera. . .	100

Capítulo 1

Introducción

A lo largo de la historia, el hombre ha intentado desarrollar máquinas y dispositivos capaces de imitar las funciones de los seres vivos. Muchos fueron los autómatas creados en la antigüedad que representaban figuras humanas o animales, en su mayoría realizados por artesanos relojeros. En general, estos autómatas construidos antiguamente no tenían una aplicación práctica y solamente servían como entretenimiento. Algunos de estos mecanismos funcionaban por medio de movimientos ascendentes de agua o aire pero también podían encontrarse otros que utilizaban palancas o contrapesos. Los primeros registros de esto tienen aproximadamente 2400 años y fueron llevados adelante por Arquitas de Tarento para la construcción de una máquina de madera capaz de volar utilizando poleas, aire comprimido y válvulas (Siciliano and Khatib, 2008).

En la actualidad la mayoría de los artefactos, y los robots en particular, son diseñados para una tarea particular en un determinado entorno. Por ejemplo, en las fábricas los manipuladores programables deben desarrollar piezas, realizar ensambles o manipular herramientas teniendo en cuenta el costo, la velocidad y la precisión. En contraste con éstos encontramos a los robots móviles que deben desempeñarse bajo incertidumbre y reaccionar en tiempo real adecuadamente a los cambios en un entorno dinámico. Si bien los resultados son prometedores, el desempeño y las cualidades de los robots móviles dista bastante de las soluciones propuestas por la naturaleza. En este sentido, los sistemas biológicos proporcionan una excepcional fuente de inspiración.

La evolución ha producido un abanico muy amplio de seres vivos móviles e inteligentes en la forma de organismos que van desde los insectos a los humanos, siendo éstos en general más flexibles y eficientes que los robots actuales. Esta diferencia ha llevado al estudio de los organismos vivos para desarrollar mejores robots, en algunos casos también se construyen robots para entender mejor a los organismos. Estos estudios eventualmente permiten el desarrollo de máquinas para el mundo real que posean alguna de las propiedades deseables de los organismos vivos, como ser adaptabilidad, robustez, versatilidad y agilidad.

El mundo biológico es inmensamente diverso y su riqueza se expresa, a menor escala, en los distintos tipos de robots que se han desarrollado con inspiración biológica. La inspiración biológica se puede sacar de muchos aspectos de los animales, incluyendo sus estrategias de comportamiento, el diseño de sus cuerpos y la organización de su sistema nervioso. Algunas especies que han sido usadas en alguno de estos sentidos son grillos, hormigas, arañas, abejas, gusanos, murciélagos, ranas, langostas, pulpos, peces, salamandras, serpientes, lagartijas, ratas, ratones, perros, monos y seres humanos (Tejera et al., 2009).

1.1. Biología y robots

Los inventores e ingenieros siempre han encontrado en la naturaleza una fuente inagotable de inspiración. Como se indicó antes, los primeros registros tienen unos 2.400 años, donde Arquitas de Tarento construyó una especie de paloma de madera, compensada por un peso suspendido de una polea, y puesto en marcha por aire comprimido al escapar de una válvula. En las últimas décadas la robótica ha estado estrechamente relacionada a las matemáticas, la mecánica, la electrónica y ciencias de la computación, dejando en un segundo plano a la biología. Por un lado, este enfoque sin duda solidificó las bases técnicas de la disciplina y permitió el desarrollo de un gran número de productos, especialmente en el campo de la robótica industrial. Por otra parte, sirvió para apreciar mejor la diferencia que aún separa a un robot de un animal, al menos cuando se busca autonomía y adaptación.

En 1948, Wiener definió el término Cibernética como el estudio del control y la comunicación en animales y máquinas. Tal enfoque fue utilizado por diversos investigadores llevando adelante criaturas que son tomadas en la actualidad como representativas para el desarrollo de robots autónomos. Esta tendencia se olvidó rápidamente y ya para los años 60 prácticamente se había perdido el interés que fundamentaba los trabajos científicos relacionados con la comparación entre las características estructurales y funcionales entre hombre y máquina. Únicamente importaba encontrar la manera en que las computadoras debían ser programadas para exhibir aspectos característicos de la inteligencia humana con el interés de mejorar el desempeño de las máquinas, sin importar los mecanismos por los que los humanos son inteligentes. En otras palabras, se perseguía el estudio de la Inteligencia Artificial, considerándola como un fin en sí misma (Arbib, 1989).

El enfoque defendido por la Inteligencia Artificial alude a la programación de las computadoras para mostrar “comportamientos inteligentes”, sin intentar correlacionar las estructuras del programa con estructuras cerebrales. Por otro lado, según la perspectiva de la Teoría del Cerebro, se utilizan la simulación por computadora y el análisis matemático para determinar cómo las interacciones entre los componentes del cerebro pueden sustentar funciones como la percepción, la memoria y la toma de decisiones. Dentro del campo de la Teoría del Cerebro se han desarrollado dos áreas de estudio diferentes pero interrelacionadas: la Neurociencia Computacional, que tiene como meta desarrollar modelos computacionales sobre la estructura y funcionamiento del cerebro para explicar datos biológicos; y la biorrobótica, que aprovecha el entendimiento del cerebro a través de los modelos computacionales para construir sistemas que posibiliten a los robots manifestar conductas inteligentes. El marco de referencia para estos estudios se presenta esquematizado en la Figura 1.1.

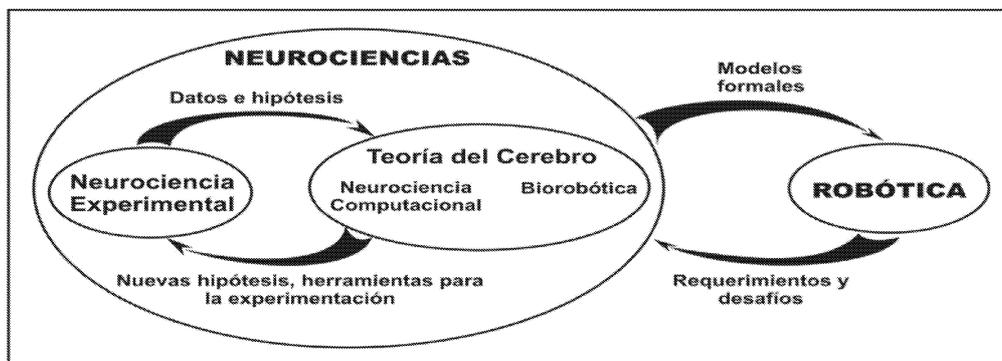


Figura 1.1 – Marco de referencia para la interacción entre las Neurociencias y la Robótica (Barrera, 2007).

Con el auge de los enfoques cibernéticos a finales de 1940 y principios de 1950, se construyen una amplia variedad de máquinas electromecánicas diseñadas para imitar los procesos biológicos. Tal vez el trabajo más conocido y relevante para la biorrobótica es el desarrollo de dos tortugas, Elsie y Elmer, llevado adelante por Grey Walter (Walter, 1961). Estas máquinas muestran un impresionante comportamiento basado únicamente en electrónica analógica con inspiración neuronal. La Figura 1.2 muestra una de las tortugas originales encontrada en 1995 por el Dr. Owen Holanda, de la Universidad de West of England.

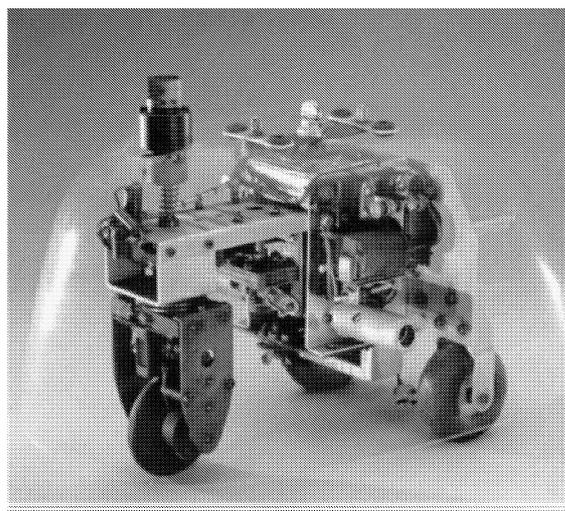


Figura 1.2 – Tortuga robótica (Elsie o Elmer). Fuente: Bristol Robotics Laboratory.

La inspiración a partir de la naturaleza no habría sido posible sin las sinergias generadas por los avances recientes en la biología, la tecnología y el desarrollo de nuevos materiales. Esto dio lugar al desarrollo de la biorrobótica que puede definirse como la intersección de la biología y la robótica. En ambos casos los sujetos de estudio obtienen información del entorno y se desempeñan en él utilizando sensores y actuadores, y requieren un sistema de control autónomo que posibilite el correcto desarrollo de tareas complejas en un mundo dinámico.

Con el fin de evitar la confusión, el término biorrobótica se utiliza para referirse a esta amplia intersección, reservando el término robótica con inspiración biológica para el trabajo cuyo objetivo principal es la aplicación de las ideas biológicas a los problemas tecnológicos, también llamado biomimética, y el término modelado biorrobótico para el trabajo cuyo objetivo principal es el uso de robots como una herramienta de modelado para abordar preguntas biológicas. Los términos inspiración biológica y biomimética, caracterizan respectivamente los extremos de un continuo en el cual en un extremo, los ingenieros tratan de reproducir algún resultado natural, pero no necesariamente su significado subyacente, mientras que en el otro extremo, buscan reproducir tanto el resultado como el significado. En este sentido, la robótica bio-inspirada tiende a adaptar al diseño tradicional algún principio abstraído de la observación de alguna criatura viviente, mientras que la robótica biomimética tiende a reemplazar las soluciones clásicas propuesta por la ingeniería por mecanismos o procesos tan detallados como sea posible de reproducir desde la observación de esta criatura. En la práctica, los trabajos caen en algún lugar entre estos dos extremos.

La robótica de inspiración biológica busca construir mejores robots, realizando un acercamiento a la biología en busca de inspiración con el objeto que la adopción de algunos de los principios del diseño animal dotará a los robots con similares características de flexibilidad y robustez. El éxito de

un proyecto de robótica de inspiración biológica no debe ser juzgado por su fidelidad a la biológica, debe ser evaluado por el grado en que el rendimiento del robot biológicamente inspirado mejora los enfoques tecnológicos utilizando las métricas que evalúan esa tecnología.

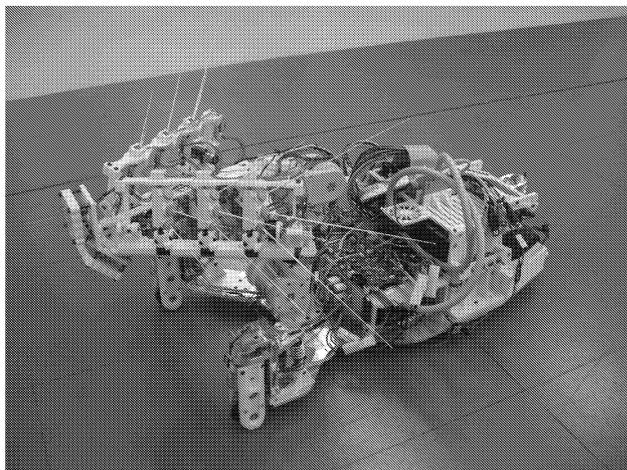
El desarrollo de modelos biológicos ha aumentado enormemente en los últimos años debido a los avances tanto en la tecnología como en la comprensión neuroetológica, permitiendo a biólogos, etólogos y neurocientíficos utilizar robots en vez de modelos puramente computacionales para el modelado de los sistemas vivos. La probabilidad de ser capaz de aplicar los resultados de vuelta a la biología por lo tanto aumentó, aún cuando este no era el objetivo primario al inicio del desarrollo del robot. La biorrobótica ha podido verificar, desarrollar y refutar teorías en varias áreas de la biología.

El desarrollo de modelos computacionales implica un trabajo interdisciplinario en el que prevalece el intercambio de conceptos entre teóricos y experimentalistas. El término Neurociencia Computacional proviene, precisamente, de la necesidad de emplear conceptos y metodologías computacionales para estudiar los datos neurocientíficos, considerando las hipótesis que sustentan la experimentación. La Robótica, por otro lado, puede considerar los modelos computacionales derivados de las Neurociencias en el diseño de robots, y realimentar su labor indicando los desafíos que interesa satisfacer para la construcción de robots autónomos. Cuando los modelos logran generar datos que pueden ser validados por los resultados experimentales, es factible que sean empleados por los neurocientíficos experimentalistas como herramientas para simular experimentos con robots que, de producir resultados interesantes, podrán guiar los siguientes experimentos que efectúen en la realidad. Posteriormente, los resultados empíricos, ya sea que coincidan o difieran de los derivados artificialmente, servirán a los neurocientíficos para plantear nuevas hipótesis o para ajustar las que se encuentran embebidas en los modelos desarrollados.

Los modelos biorrobóticos esperan comprender los mecanismos que determinan el comportamiento animal. Como tal, al igual que cualquier otro modelo biológico, los modelos biorrobóticos deben ser evaluados desde el punto de vista del comportamiento observado y los datos neurobiológicos, así como las hipótesis experimentales que pueda generar. Los mecanismos de comportamiento animal deben ser buscados no sólo en el sistema nervioso del animal, sino también en su cuerpo y el medio ambiente, y particularmente en la dinámica de la interacción entre estos tres componentes.

La Figura 1.3 presenta ejemplos de sensores y actuadores biológicamente inspirados, a) muestra una imagen del robot SCRATCHbot cuyo objetivo es centrarse en los estudios computacionales y etológicos del tacto activo en el sistema de bigote de rata (Pearson et al., 2010), y b) presenta el robot Stickybot el cual es una construcción de un geco que utiliza las hipótesis sobre estos animales respecto de la adherencia y capacidad para escalar superficies verticales. Los pies del robot geco están cubiertos por miles de pelos sintético hechos de un elastómero que asegura una gran superficie de contacto entre los pies y la pared (Santos et al., 2008). Además de la inspiración para el desarrollo de sensores y actuadores se han llevado adelante estudios sobre el control del robot basados en el sistema nervioso, esto dio lugar a los denominados neurobots. Los robots más representativos de este tipo son los de la familia Darwin desarrollados por el laboratorio de Gerald Edelman. La Figura 1.4 muestra el neurobot Darwin VIII, el cual inicia sin ningún tipo de conocimiento y aprende de su propia experiencia al interactuar con el ambiente. Las redes neuronales que controlan a los robots Darwin tiene cientos de miles de neuronas y las sinapsis superan el millón (Fleischer et al., 2007).

M. Franz y H. Mallot (M. and A., 2000), y B. Webb (Webb, 2001) realizan estudios del estado del arte pioneros en biorrobótica teniendo en cuenta los siguientes aspectos: movimiento, locomoción, navegación, orientación, manipulación, imitación y cooperación.



(a) Proyecto SCRATCHbot (Pearson et al., 2010).



(b) Proyecto Stickybot (Santos et al., 2008).

Figura 1.3 – Ejemplos de sensado y actuación con inspiración biológica.

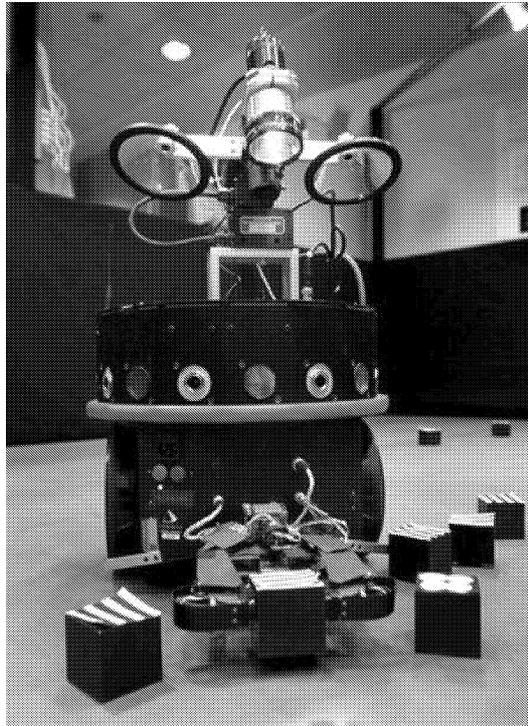


Figura 1.4 – Neurobot Darwin VIII (Fleischer et al., 2007).

1.2. Propósito de la Investigación

La supervivencia de muchas especies depende de su habilidad para representar y utilizar conocimiento espacial que resulta fundamental no sólo para escapar de situaciones peligrosas, sino también para regresar a lugares que proveen alimento y agua. Actualmente no hay duda que las ratas son capaces de generar una representación espacial del ambiente que exploran. Existe una gran cantidad de trabajo teórico y experimental al respecto, el cual considera las teorías neurocientíficas fundamentales del mapa cognitivo de Tolman (Tolman, 1948) y la que determina la ubicación de este mapa cognitivo en el hipocampo de O'Keefe y Nadel (O'Keefe and Nadel, 1978). Específicamente, se han abordado aspectos relacionados con las estrategias de aprendizaje que las ratas llevan a cabo, la información de entrada al mapa cognitivo, la exhibición de conductas orientadas a metas, la integración de trayectorias, y las regiones cerebrales involucradas en todos estos procesos, entre otros. Como resultado, han surgido valiosas hipótesis sobre los mecanismos que subyacen el aprendizaje y la memoria espacial, aunque no todas las respuestas están dadas.

El objetivo de la investigación que aquí se presenta consiste en identificar algunas de estas hipótesis y utilizarlas para modelar computacionalmente los siguientes aspectos: la integración de trayectorias, su integración a la información visual para la construcción del mapa cognitivo, y la calibración del integrador de trayectorias. Estos procesos que las ratas ejecutan de manera natural, constituyen grandes retos para la robótica, por lo que han sido varios los investigadores del área que han tomado inspiración en los animales para dotar a los robots de capacidades similares.

En el contexto de este trabajo se desarrolla un módulo de integración de trayectorias con inspiración biológica, integrado al modelo computacional de cognición espacial desarrollado por A. Barrera y A. Weitzenfeld (Barrera, 2007), y su desempeño es mostrado en un robot móvil autónomo. De

acuerdo con el marco de referencia ilustrado en la Figura 1.1, este estudio puede ubicarse en el ámbito de la Teoría del Cerebro, y sus metas impactan sobre la Neurociencia Experimental y la Robótica. En particular, el modelo formal incorpora hipótesis y datos empíricos relativos a la cognición espacial y navegación en ratas, esperando sugerir nuevas hipótesis neurocientíficas, promover el diseño de nuevos experimentos que permitan incrementar el entendimiento de la conducta de las ratas a partir de los resultados derivados de la experimentación con robots, y proveer a los neurocientíficos una herramienta para probar nuevas hipótesis con robots antes de hacerlo con ratas. Como ya ha ocurrido desde su desarrollo original, el modelo formal habrá de ser enriquecido continuamente para concretar y consolidar sus aportaciones a la Neurociencia Experimental.

1.3. Publicaciones

Esta sección enumera cuáles fueron las publicaciones realizadas en el contexto de la tesis indicando su principal cometido o aporte.

El primer trabajo relacionado a esta tesis fue una revisión de la bibliografía y de los proyectos de biorrobótica con especial atención en el uso de los roedores como objeto a modelar (Tejera et al., 2009). En él se remarca la gran cantidad de trabajos llevados adelante mostrando desde trabajos muy centrados en algún aspecto a trabajos que intentan abarcar globalmente el problema.

Luego de analizar el diseño y la implementación del modelo desarrollado por Barrera (Barrera, 2007) se evaluaron las posibilidades para su extensión y posibles mejoras a incorporar en los módulos que lo componen. Estos aspectos son presentados en los trabajos Weitzenfeld et al. (2012) y Tejera et al. (2013a).

Desde el punto de vista experimental se evalúa el modelo por primera vez en entornos abiertos, tomando como base los experimentos desarrollados y realizados por Morris (Morris, 1981), y se presentan los resultados en el artículo Barrera et al. (2014).

Los resultados preliminares del módulo integrador de trayectorias con inspiración biológica son presentados en el trabajo Tejera et al. (2013b), integrando por primera vez neuronas grillas basadas en interferencia de ondas con realimentación a un modelo de navegación. Luego se caracterizan los errores para el robot utilizado y se ajusta el modelo de ruido a él, dando lugar a la publicación del trabajo Tejera et al. (2015). A partir de los resultados de estos dos últimos trabajos se puede afirmar que el módulo de neuronas grillas realimentadas propuesto es robusto frente al error que tiene la información propioceptiva, posibilitando su uso en robots móviles y viabilizando este mecanismo en la biología.

Actualmente estamos trabajando para presentar en revista los resultados obtenidos en los experimentos realizados con distintas configuraciones de las neuronas grilla, usadas en el módulo integrador de trayectorias.

Si bien pueden encontrarse en la sección de referencias, con el propósito de visualizar en conjunto los trabajos, se presentan todos ellos a continuación.

G. Tejera, F. Benavides, and Casella S. Between rats and robots: A survey. In Universidad de Morón, editor, Anuales del VII Campeonato de Fútbol de Robots y Workshop de Sistemas Autónomos de Robots, pages 8–14, 2009.

A. Weitzenfeld, J. M. Fellous, A. Barrera, and G. Tejera. Allothetic and idiothetic sensor fusion in rat-inspired robot localization. In In Proceedings of SPIE, volume 8407, 2012.

G. Tejera, A. Barrera, J. M. Fellous, M. Llofriu, and A. Weitzenfeld. Spatial cognition: robot target localization in open arenas based on rat studies. In *In Proceedings of SPIE*, volume 8756, 2013a.

G. Tejera, A. Barrera, M. Llofriu, and A. Weitzenfeld. Solving uncertainty during robot navigation by integrating grid cell and place cell firing based on rat spatial cognition studies. In *Advanced Robotics (ICAR), 16th International Conference on*, pages 1–6, Nov 2013b.

Barrera A., Tejera G., Llofriu M., and Weitzenfeld A. Learning spatial localization: From rat studies to computational models of the hippocampus. *Spatial Cognition & Computation*, 15(1):27–59, 2014.

G. Tejera, M. Llofriu, A. Barrera, and A. Weitzenfeld. A spatial cognition model integrating grid cells and place cells. In *Neural Networks, International Joint Conference on*, pages 1–6, Jul 2015.

1.4. Organización del Documento

Al terminar este primer capítulo introductorio, el resto del documento queda organizado en diversas secciones temáticas. De esta forma, el segundo capítulo presenta los antecedentes de investigación en los que se enmarca el trabajo. En particular, se describen los mecanismos neurofisiológicos y conductuales que subyacen el aprendizaje y la memoria espacial en ratas, se plantea el estado del arte en los algoritmos de navegación aplicados a robots móviles, y se introducen algunos de los esfuerzos más importantes documentados en los últimos años acerca de modelos de cognición espacial y navegación en ratas aplicados a robots móviles.

El tercer capítulo presenta el modelo de cognición espacial y navegación en ratas propuesto por Barrera (Barrera, 2007), y las extensiones llevadas adelante en el contexto de este trabajo, explicando el contexto biológico que lo subyace, y describiendo detalladamente cada uno de los módulos funcionales que lo componen.

El cuarto capítulo discute los aspectos de implementación del modelo propuesto, involucra tanto el diseño de sus módulos, como la definición de las interfaces con el entorno, y las diferencias al trabajar con una rata virtual simulada o con el robot.

El quinto capítulo aborda los aspectos tenidos en cuenta durante la experimentación con ratas virtuales y robots. Así, una primera sección se enfoca en replicar los experimentos llevados adelante por Morris (Morris, 1981) para el estudio de aprendizaje de rutas. Luego, la segunda sección presenta un protocolo simple de experimentación para evaluar el rendimiento del integrador de trayectorias desarrollado en tareas de larga duración y su tolerancia al ruido.

Por último, el sexto capítulo se presenta la discusión final concerniente a los resultados experimentales obtenidos durante la investigación, sobre la contribución a los campos de la Robótica y de las Neurociencias, y a las líneas de investigación que serán abordadas próximamente.

Capítulo 2

Marco Teórico

Este capítulo presenta un panorama general de los aspectos teóricos que enmarcan el trabajo y que han sido estudiados con el fin de conocer e incorporar mejoras al modelo original de cognición espacial y navegación en ratas, así como la evaluación de los resultados con un robot móvil. El capítulo queda dividido en tres secciones. La primer sección presenta las generalidades del problema de navegación en robots, y las principales técnicas y herramientas utilizadas para resolverla, la segunda sección describe los mecanismos neurofisiológicos y conductuales que subyacen a la memoria espacial en ratas, y finalmente, la tercera sección introduce algunos de los esfuerzos más importantes documentados en los últimos años acerca de modelos de cognición espacial y navegación en ratas aplicados a robots móviles.

2.1. Navegación

2.1.1. Introducción

La navegación es una de las actividades más importantes y desafiantes que deben tenerse en cuenta al trabajar con un robot móvil (Murphy, 2000). Al trabajar en navegación todos los aspectos de la robótica están presentes: sensado, actuación, arquitectura de control, planificación, resolución de problemas, eficiencia computacional y hardware. La navegación es una colección de algoritmos que permiten resolver las dificultades que aparecen al tratar de responder a las siguientes preguntas:

- ¿A dónde debo ir? Este problema es usualmente determinado por un humano o el planificador de misión de la arquitectura de control del robot.
- ¿Cuál es la mejor forma de llegar? Este problema es denominado planificación de trayectorias y es el aspecto que ha recibido más atención dentro de la navegación.
- ¿Dónde he estado? Se refiere a la construcción de mapas, uno de los aspectos de la navegación que se ha pasado por alto en los primeros trabajos de navegación tomando fuerza su estudio en los últimos años. En entornos desconocidos es obligatorio construir mapas pero aún en entornos conocidos es posible mejorar el rendimiento, tanto si las cosas cambian como teniendo en cuenta aspectos del uso de los espacios de navegación.
- ¿Dónde estoy? El robot debe saber donde está para seguir un camino o construir un mapa. Este aspecto de la navegación se denomina localización.

Dada la complejidad y necesidad de la navegación como capacidad fundamental para los robots móviles, ésta ha sido estudiada desde 1960 sobre simuladores. Recién en 1990 la capacidad de sensado y procesamiento en el robot se hizo accesible. Por esta razón los primeros trabajos asumieron que el robot era capaz de localizarse de manera precisa y que los sensores proporcionaban una representación precisa del entorno, lo cual al trabajar con robots reales no ocurre debido a varias fuentes de incertidumbre. Los métodos más difundidos para lidiar con la incertidumbre en los sensores son en su naturaleza probabilísticos, si bien existen algunas alternativas basadas en modelos biológicos.

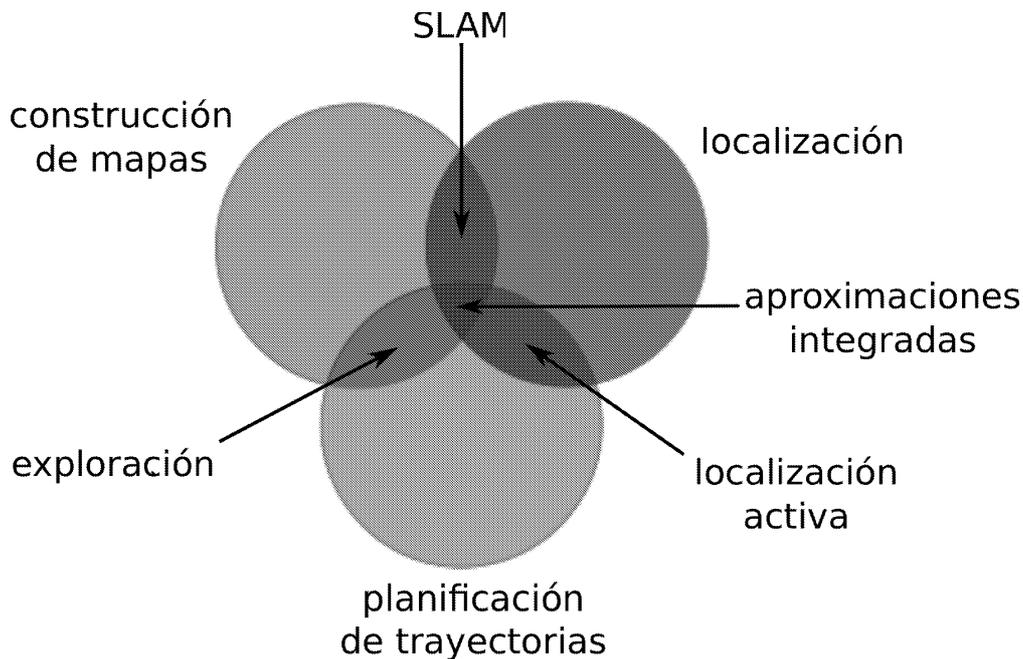


Figura 2.1 – Elementos de navegación. Los círculos representan los aspectos de navegación aislados y las intersecciones de los círculos representan los aspectos cuando éstos se resuelven en conjunto.

En la Figura 2.1 se pueden ver los problemas que conforman a la navegación y el nombre que recibe el problema cuando se resuelven algunos de estos aspectos simultáneamente. El objetivo de la exploración es cubrir todo el entorno en el menor tiempo posible. La exploración asume que el robot es capaz de localizarse, debiendo construir el mapa y planificar trayectorias para lograr su objetivo. En el caso de localización activa es posible tomar decisiones de movimiento con el objetivo de mejorar la eficiencia o la robustez de la localización.

La construcción de mapas y la localización están fuertemente relacionados y son auto-dependientes, lo que ha dado lugar a su estudio conjunto bajo el nombre de SLAM (simultaneous localization and mapping). La construcción de mapas introduce la necesidad de localizarse mientras el robot se mueve en el entorno. SLAM refiere al problema en el cual un robot móvil construye un mapa de su ambiente mientras simultáneamente se localiza dentro de dicho mapa (Hähnel et al., 2003). Desde hace tres décadas se han reportado un gran número de trabajos sobre los problemas involucrados en SLAM. Específicamente, se han propuesto diversos enfoques para construir mapas, como el topológico (Franz et al., 1997), el métrico (Moravec and Elfes, 1985), y enfoques híbridos que combinan los dos anteriores (Guivant et al., 2004; Kuipers et al., 2004; Folkesson and Christensen, 2004; Bosse et al., 2004; Zivkovic et al., 2005), e identificándose aspectos críticos para lograr implementaciones prácticas

y robustas de los algoritmos de SLAM, como la asociación de datos, y la ambigüedad perceptual. Las siguientes secciones describen los diversos enfoques de navegación, integración de trayectorias, y los desafíos relacionados con la asociación de datos y la ambigüedad perceptual.

2.1.2. Clasificación de los algoritmos de navegación

2.1.2.1. Navegación topológica

La navegación topológica suele integrarse de manera más simple y natural en robots con arquitecturas basadas en comportamientos (Arkin, 1998). De igual forma, las personas suelen dar un conjunto de indicaciones o rutas a realizar cuando responden a un pedido al respecto de alcanzar determinado punto de interés. Estas rutas no requieren de un mapa para ser llevadas adelante, pues la propia ruta incluye información para la navegación. Un ejemplo de este tipo de rutas podría ser:

- Subir las escaleras hasta el nivel de planta baja.
- Doblar a la derecha hacia bedelía.
- Volver a doblar a la derecha hacia el IMFIA, hasta el final del pasillo.
- Bajar dos pisos por las escaleras de material.
- Ingresar a las bandejas metálicas a través del puente metálico.
- Doblar a la derecha llegando al laboratorio ubicado sobre la mano derecha del corredor.

Utilizando su aparato sensorial, el agente debe ser capaz de extraer información para la navegación a partir de la ruta proporcionada para identificar elementos clave (p. ej. escalera y bedelía). Algunos de estos elementos son necesarios para controlar el comportamiento del agente y otros para poder seguir las instrucciones indicadas en la ruta.

Las representaciones de las rutas pueden tomar dos formas, relacionales o asociativas. Las técnicas relacionales son las más populares y se caracterizan por la utilización de un grafo como representación del mundo mientras que las asociativas ligan fuertemente el sensado a la navegación (Murphy, 2000).

La navegación topológica depende de la presencia de marcas. Una marca es una o varias características perceptualmente distintivas de un objeto o posición de interés. La Figura 2.2 presenta ejemplos de posibles marcas, en (a) se muestran los tipos de marcas usadas en el contexto de este trabajo mientras que en (b) se presentan marcas utilizadas en competencias de fútbol de la liga Robocup.

Las marcas son utilizadas en varios de los aspectos relacionados a la navegación. Si se encuentra una marca en el entorno y la marca existe en el mapa, el agente se localiza en el mapa. Si el agente planifica una trayectoria formada por un conjunto de segmentos, las marcas son utilizadas para generar la transición entre los segmentos. Si el agente encuentra una marca nueva puede agregarla a su memoria espacial para ampliar su mapa. Los gateway son un tipo especial de marca. Un gateway define oportunidades para cambiar la dirección de navegación. Es importante reconocer los gateway tanto para la localización como para la planificación de trayectorias y la construcción de mapas.

Los métodos relacionales utilizan un grafo para representar el mundo. Los nodos representan lugares representativos del entorno ya sea porque contienen marcas, gateways u objetivos. Las aristas representan caminos navegables entre dos nodos. A cada arista se le puede asociar información de navegación como ser la dirección de navegación (N, S, E y O), distancia, características del



(a) Imagen que muestra hojas de colores como marcas.



(b) Imagen que muestra cilindros como marcas (RoboCup, 2015).

Figura 2.2 – Ejemplos de marcas artificiales.

terreno a transitar y comportamientos que pueden usarse para realizar la transición. Las aristas son denominadas también estrategia de control local, cuando éstas indican el procedimiento para alcanzar el nodo siguiente desde el nodo actual. En la Figura 2.3 se muestra un grafo topológico donde las aristas incluyen información del comportamiento necesario para transitarla y a qué se debe prestar atención durante su ejecución.

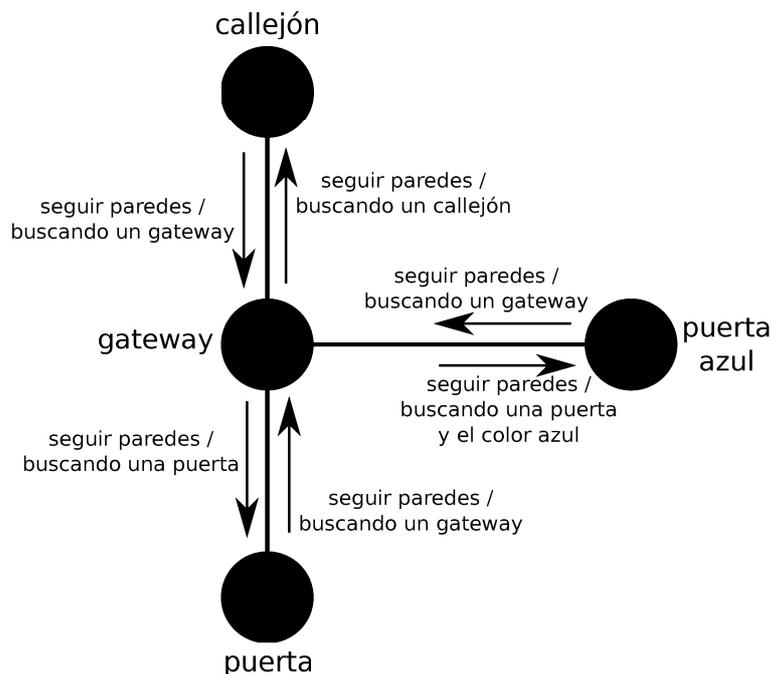


Figura 2.3 – Ejemplo de mapa topológico con información para la navegación. Adaptado del libro de Murphy (Murphy, 2000). Los nodos representan lugares representativos del entorno y las aristas representan caminos navegables entre dos nodos. Las aristas del grafo muestran el comportamiento que debe activarse para transitarla y a qué se debe prestar atención durante su ejecución.

Un lugar distintivo es un conjunto de marcas que el robot puede detectar desde un lugar cercano a ellas denominado vecindario. Los nodos pueden verse desde esta perspectiva como lugares distintivos, una vez que el agente alcanza la vecindad utiliza un algoritmos de búsqueda local para colocarse en el lugar de la vecindad donde las características de las marcas son máximas, este punto es el

lugar distintivo. La Figura 2.4 muestra el procedimiento descrito e ilustra la trayectoria del robot utilizando la estrategia local para colocarse en el lugar distintivo. El agente puede hacer uso de la representación de grafo utilizada por los métodos relacionales para planificar trayectorias mediante el uso de algoritmos clásicos de búsqueda de caminos.

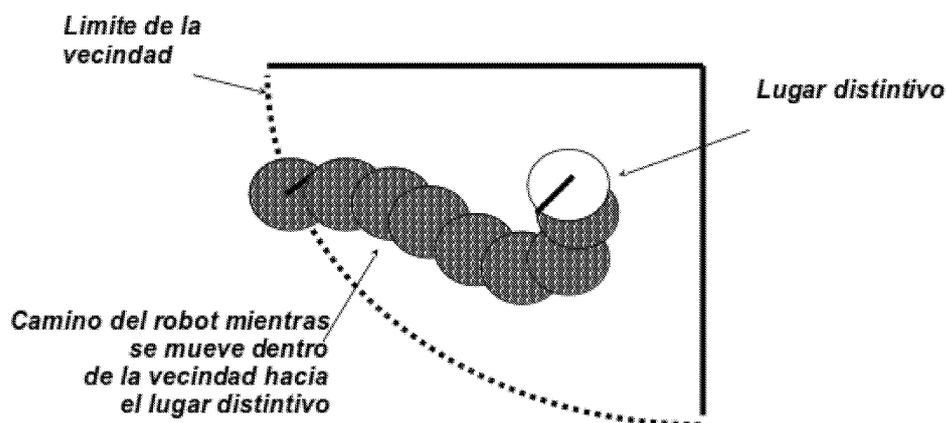


Figura 2.4 – Ejemplo de mapa topológico con información para la navegación.

Por otro lado, los métodos asociativos para la navegación topológica en esencia crean comportamientos que convierten las observaciones sensoriales en direcciones a seguir de manera de alcanzar una determinada marca de interés. Se requiere para ello que las observaciones sensoriales de lugares cercanos sean similares y lugares lejanos luzcan diferentes. Algunas técnicas procesan la información de visión de manera de extraer una firma de cada imagen y a partir de esta firma determinar la dirección de navegación, esto es reducir la diferencia entre la firma de la imagen actual y la imagen de la posición objetivo. En la Figura 2.5 se presenta un ejemplo de procesamiento visual, en la sub-figura (a) se define el lugar objetivo, se divide la imagen en regiones y para cada una de ellas se calculan sus características dando lugar a la firma, en la sub-figura (b) se compara la firma de la imagen actual con la objetivo para determinar vectores de movimiento. Un problema relacionado con este enfoque es el reconocimiento de lugares en ambientes complejos debido a la falta de información métrica que posibilite la discriminación entre dos lugares que parezcan similares.

2.1.2.2. Navegación métrica

Los métodos métricos aparecen en oposición a los métodos topológicos. Ambos métodos tienen como objetivo encontrar un camino para alcanzar un determinado lugar. La mayor diferencia entre ambos se puede presentar desde el punto de las características de la solución. Los métodos métricos manejan costos de llevar adelante la trayectoria solución, y la solución es expresada como un conjunto de puntos denominados waypoints. Los waypoints son posiciones fijas o coordenadas (x, y) por las cuales el agente debe pasar para recorrer la ruta planificada.

Desde la perspectiva métrica, el ambiente del robot es definido a través de un sistema de coordenadas globales en el que la navegación tiene lugar. Generalmente, el mapa es una matriz en la que cada grilla representa cierta cantidad de espacio en el mundo real, lo cual hace que este enfoque funcione bien en ambientes acotados, pues se requiere de gran cantidad de memoria para representar grandes áreas. Además, el robot debe reconocer el lugar en el que se encuentra dentro del mapa para poder utilizarlo en la navegación y agregarle nueva información. Los algoritmos que

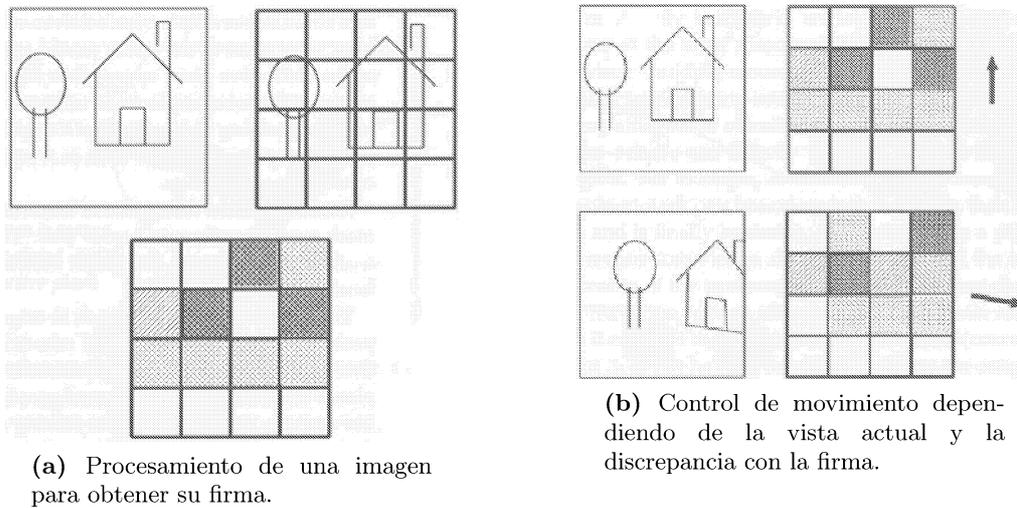


Figura 2.5 – Ejemplo de navegación asociativa (Murphy, 2000).

permiten construir un mapa métrico del ambiente comparten la característica de ser probabilísticos. Las técnicas probabilísticas ofrecen un mecanismo para fusionar en el mapa los datos provenientes de diversos sensores, y esta fusión hace que el ruido disminuya. El problema central consiste en generar un mapa consistente a partir del ruido y de datos incompletos provenientes de los sensores. Aún cuando se conozca la posición del robot, no es fácil determinar si un espacio del ambiente está ocupado o no debido a ambigüedades en la lectura de los sensores. Como el nombre del algoritmo lo sugiere, los mapas son grillas bidimensionales que representan un área fija en el sistema absoluto de coordenadas. Las grillas tienen alta resolución, en el orden de 5-10 cm por celda. Se utilizan filtros de Bayes para predecir la ocupación de cada celda. La actualización de los valores individuales de las celdas es incremental conforme llegan nuevos datos de los sensores. Al inicio, el valor de las celdas es 0.5, pues se desconoce si están o no ocupadas (Guivant et al., 2004).

2.1.3. Asociación de Datos y Ambigüedad Perceptual

La asociación de datos se relaciona con el problema de determinar si dos características observadas en dos momentos diferentes corresponden o no al mismo objeto o lugar en el mundo físico (Hähnel et al., 2003). Este problema también ha sido referido como identificación de marcas, donde las observaciones de marcas empatan con las almacenadas dentro del mapa o ayudan a definir nuevas (Frese, 2006).

Para los humanos, salvo contados ejemplos, el problema del alias sensorial o ambigüedad perceptual es raramente encontrado, esto es, cada lugar diferente luce diferente. Para los robots el alias sensorial es la regla y no la excepción. La ambigüedad perceptual ocurre al tratar de distinguir entre lugares del ambiente que proveen patrones visuales equivalentes (Kuipers et al., 2004).

Tanto las asociaciones incorrectas entre nuevos datos sensoriales y lugares previamente mapeados, como las distinciones incorrectas entre lugares perceptualmente similares, pueden conducir a fallas catastróficas en los algoritmos de SLAM. Tales fallas se evidencian cuando el robot trata de regresar a una región previamente mapeada después de una larga excursión, intenta realizar un cierre del ciclo (Savelli, 2004; Bosse et al., 2004). Los métodos basados en apariencia y las técnicas de multi-hipótesis abordan el problema de la asociación de datos. Las firmas de apariencia y las métricas

de similitud de imágenes relacionadas con el color, la forma y la textura han sido propuestas para reconocer lugares en enfoques topológicos de construcción de mapas (Ulrich and Nourbakhsh, 2000), las medidas de apariencia han sido aplicadas también para detectar ciclos en enfoques métricos de SLAM (Newman et al., 2006). Las técnicas multi-hipótesis, por otro lado, manejan situaciones en las que puede resultar imposible determinar la identidad de una marca al momento de observarla, y se requiere diferir la decisión acerca de la asociación de datos hasta que observaciones posteriores provean evidencia suficiente. Para ello, estas técnicas generan múltiples copias del mapa incierto cada vez que la identidad de una marca es ambigua, lo cual agrega una importante carga computacional. Algunos ejemplos de estas técnicas incluyen el filtro de Kalman multi-hipótesis (Bar-Shalom, 1987), y los algoritmos basados en filtros de partículas como FastSLAM (Montemerlo and Thrun, 2003). En este último caso, tanto la incertidumbre discreta de la identificación de marcas como la incertidumbre continua producida por el ruido en las mediciones son representadas por un conjunto de partículas, donde cada partícula corresponde a un mapa sin incertidumbre (Hähnel et al., 2003).

2.2. Memoria Espacial en Ratas

La posición en el espacio es parte de la información fundamental que los animales y las personas aprenden. La ubicación del alimento, el agua y el hogar debe ser recordada para poder regresar, y la localización de objetos dañinos y predadores debe ser recordada para que ambos puedan ser evitados. Además de la memoria de la posición de objetos o lugares, la memoria para moverse a través del espacio resulta igualmente importante para que, a partir de un punto de origen, el individuo pueda llegar de forma eficiente a un punto destino. Se utiliza el término cognición espacial para referir al proceso de codificación y almacenamiento de información espacial, la cual permite que la orientación hacia los objetos y el movimiento a través del espacio sean exitosos (Roberts, 1998). Los procesos espaciales de aprendizaje y memoria involucran la interacción de diversas estructuras cerebrales para manifestar habilidades relacionadas con la integración de la trayectoria recorrida y el uso de señales visuales para la localización, la generación de representaciones espaciales, el manejo de recompensas, y la navegación dentro del ambiente. Las secciones que a continuación se presentan describen tales habilidades.

2.2.1. Áreas del cerebro

El sistema hipocampal incluye a la formación hipocampal y la región parahipocampal. La formación hipocampal incluye el giro dentado (dentate gyrus - DG), hipocampo (compuesto por las capas CA3, CA2 y CA1), y el subiculum. La región parahipocampal incluye las cortezas perirrinal (PER), postrrinal (POR), entorrinal (EC), presubicular, y parasubicular. La región córtica más íntimamente conectada con el hipocampo es la corteza entorrinal, mientras que a un nivel menor e indirecto las cortezas perirrinal, postrrinal y retroplenia. La Figura 2.6 ilustra las regiones mencionadas y su organización en el cerebro de una rata.

2.2.1.1. Características funcionales

La importancia del hipocampo para el aprendizaje y la memoria fue reconocido a través del caso de HM (Scoville and Milner, 1957). Henry Molaison (HM) fue un paciente norteamericano con un trastorno de memoria ampliamente estudiado desde finales de 1957 hasta su muerte en 2008. La profunda amnesia de HM, luego de una cirugía practicada como tratamiento a la epilepsia intratable,

dio lugar a una enorme cantidad de estudios sobre la naturaleza de la contribución del hipocampo en la memoria. Mientras los primeros estudios se centraron en el propio hipocampo, con el tiempo se amplió la búsqueda para incluir sus alrededores. Aunque algunas de estas regiones han recibido más atención en la literatura que otros, la mayoría de los expertos están de acuerdo en que las estructuras más allá del hipocampo contribuyen de algún modo a la memoria episódica. La corteza perirrinal tiene un papel importante en el reconocimiento visual de objetos complejos, pero también hay evidencias importantes de que contribuye a la memoria, distinguiéndose de la contribución del hipocampo, y la amnesia completa sólo tiene lugar cuando ambas estructuras se encuentran dañadas.

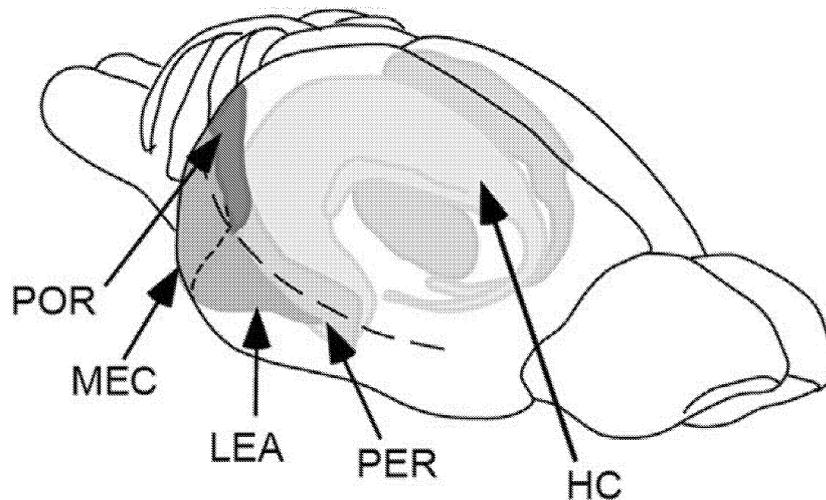


Figura 2.6 – Cerebro de una ratona. Glosario: POR - corteza postrinal; MEC - corteza entorrinal media; LEA - área entorrinal lateral; PER - corteza perirrinal; HC - Hipocampo (Agster and Burwell, 2013).

2.2.1.2. Conexiones en sistema hipocampal

La Figura 2.7 muestra que hay un número limitado de regiones que producen información que alcanza al hipocampo. Se muestran con líneas discontinuas las proyecciones más débiles, luego con líneas sólidas y cuanto más gruesa mayor cantidad de proyecciones entre las regiones.

Recientemente, las cortezas perirrinal y postrinal han ganado atención de los investigadores en memoria debido a que ellas proporcionan al hipocampo información procesada e información multimodal.

Las estructuras del hipocampo (CA1, CA2, CA3, giro dentado y subiculum) están fuertemente interconectadas y formadas por tres capas.

La región parahipocampal esta compuesta por PER, POR, EC, presubiculum y para subiculum, el presubiculum incluye la parte más dorsal denominada postsubiculum. Todas estas áreas tienen seis capas, lo que hace fácil su discriminación respecto de las estructuras del hipocampo. La corteza entorrinal es dividida en dos áreas, la media (MEC) y la lateral (LEC).

La POR tiene una gran cantidad de conexiones reciprocas con la parte caudal de la corteza temporal ventral, la corteza parietal posterior, corteza retroplenial dorsal y las áreas de asociación visual. Todas estas áreas están implicadas en la función visuoespacial. La POR recibe muy pocas entradas que no estén relacionadas con información sensorial visual, algo que la distingue de la PER. La POR está fuertemente interconectada al área dorsocaudal de la EC. Existen conexiones

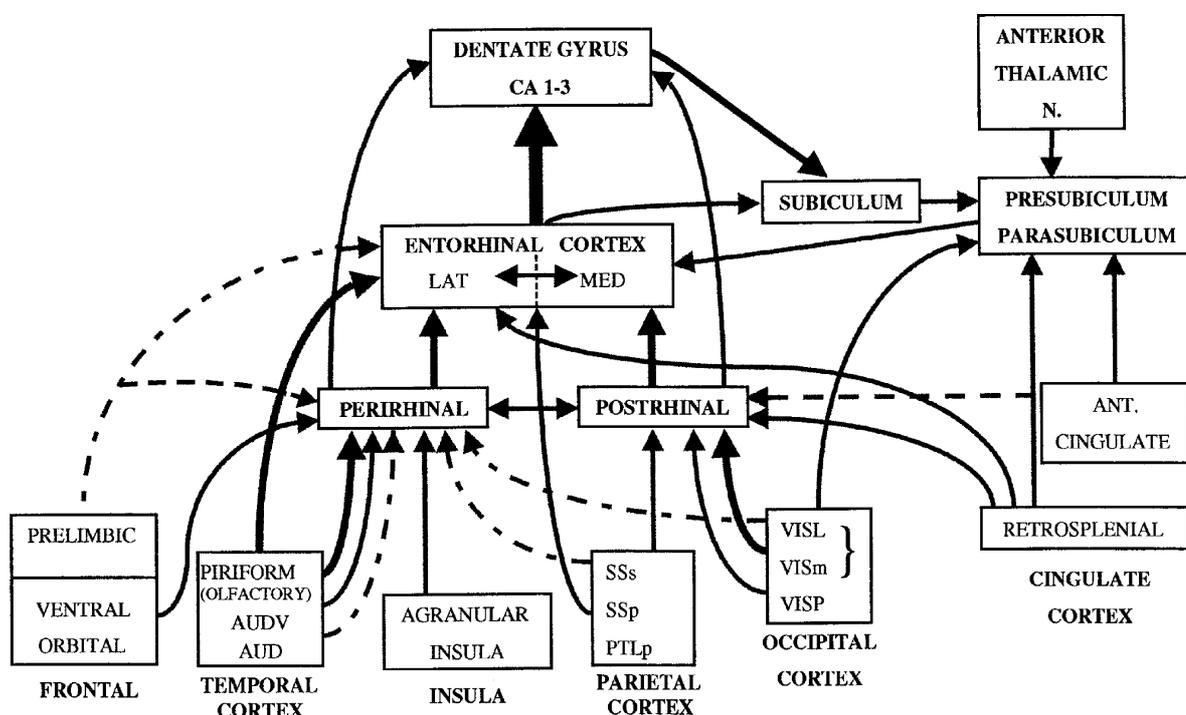


Figura 2.7 – Rutas en el sistema hipocampal (Aggleton et al., 2000). Glosario: AUD - área auditiva primaria; AUDV - AUD ventral; PTLp - áreas parietal posterior; SSp - área somatosensorial primaria; SSs - área somatosensorial suplementaria; VISL - área visual lateral; VISm - área visual media; VISP - área visual primaria.

directas desde el área CA1 del hipocampo dorsal al subiculum dorsal. Estas conexiones sugieren que la información visuoespacial llega al hipocampo a través de rutas dedicadas que involucran al subiculum dorsal, la POR y la MEC. En contraste con la POR, las proyecciones de la PER termina en la LEC . Existen conexiones entre la PER y el subiculum pero las conexiones más abundantes se presentan con la LEC.

2.2.2. Integración de Trayectoria

Gallister (Gallistel, 1993) define a la navegación como la capacidad de planificar y ejecutar caminos dirigidos por objetivo, y es visto como la forma en que se enlazan posiciones distintivas generalmente etiquetadas por marcas. La forma más simple de navegación utilizada por algunos animales permite retornar a un punto de partida luego de una recorrida sin hacer uso de señales posicionales. En este caso el agente estima su posición de forma continua con respecto a un punto de referencia y utilizando señales que infiere de su propia locomoción. Este proceso fue originalmente denominado 'dead reckoning' por su analogía con el término deduced (ded) reckoning usado por los navegantes para ubicarse en mar abierto sin ningún tipo de característica reconocible. Desde hace un tiempo se le conoce bajo el nombre de integración de trayectorias (PI) (Mittelstaedt and Mittelstaedt, 1980) dejando en claro que este proceso es llevado adelante por la suma sucesiva de pequeños incrementos del movimiento sobre el computo constante de la dirección y distancia respecto del punto de comienzo.

En ausencia de visión, la integración de trayectoria involucra dos sistemas receptores. Por un lado, los órganos vestibulares en los canales semicirculares del oído interno responden ante la aceleración y

la velocidad de movimiento a lo largo de un camino recto, y ante la velocidad de rotación cuando se efectúa un giro. Por otro lado, información adicional es provista por la retroalimentación kinestésica procedente de los músculos cuando se realizan movimientos en el espacio. Además, la habilidad del sujeto para estimar el tiempo también es importante, pues conociendo la velocidad de movimiento y el tiempo que tomó el desplazamiento entre dos puntos, es factible estimar la distancia recorrida. Entonces, el proceso de integración de trayectoria es posible al mantener un registro de la distancia viajada a lo largo de un camino recto y de los ángulos en que se ejecutaron las rotaciones.

Sin embargo, estos cálculos de rotaciones y traslaciones son estimaciones que involucran un nivel de error, el cual se acumula a medida que se efectúan movimientos lineales y rotaciones. Durante la exploración de un nuevo ambiente, la integración de trayectoria opera en diversas especies de vertebrados e invertebrados que manejan puntos de partida fijos. Tal es el caso de las hormigas, las arañas, los roedores, los perros y los humanos, entre otros. Mittelstaedt y Mittelstaedt (Mittelstaedt and Mittelstaedt, 1980), y Etienne (Etienne, 1998) han mostrado que los roedores son capaces de ejecutar un camino directo de regreso a la localidad de partida en ambientes con claves controladas incluso después de haber recorrido una trayectoria compleja. Cuando las claves relevantes son movidas, los animales las ignoran y regresan al punto de partida, lo cual sugiere que efectivamente llevan un registro de su posición relativa a la localidad de inicio a través del proceso de integración de trayectoria.

La integración de trayectorias fue estudiada inicialmente de manera extensa sobre hormigas, arañas y abejas, generalmente el contexto de tareas de recolección de alimentos (foraging), particularmente donde el animal explora el entorno y retorna al hogar (home) inmediatamente luego de encontrar y recolectar el alimento (hoarding).

En mamíferos, las señales de movimiento propio (también llamadas señales idiotéticas (Etienne and Jeffery, 2004)) pueden ser generadas desde distintas fuentes sensoriales, incluyendo información visual (flujo óptico), vestibular (aceleraciones de traslación y rotación), y propioceptivas (retroalimentación de información desde músculos, tendones y articulaciones). La información generada a través de estas señales de movimiento propio es procesada antes de ser transmitida al integrador de trayectorias. Por ejemplo, existen neuronas en el tegmentum dorsal que codifican los desplazamientos angulares a partir de la información que reciben desde los canales semicirculares vía el núcleo vestibular. En este sentido, la aceleración angular es captada y convertida a velocidad angular en los canales semicirculares, luego se pasan al tegmentum dorsal y se vuelve a integrar en el núcleo mamilar y en el tálamo para proporcionar desplazamientos angulares que posibilitan la actualización de la dirección de la cabeza.

Además del uso de información idiotética para determinar la dirección del movimiento, los mamíferos usan este tipo de información para estimar la distancia. No existe acuerdo sobre como esto ocurre y es poco el conocimiento a nivel neuronal sobre el proceso de integración de la información sensorial para determinar la distancia recorrida en línea recta, principalmente por que no se ha identificado aún una neurona que codifique desplazamientos y posiblemente no exista como una entidad aislada. O'Keefe y colaboradores (O'Keefe et al., 1998) reportaron una neurona o axón en el hipocampo que dispara en relación a la velocidad del animal, sugiriendo que el sistema nervioso computa de forma precisa una señal de velocidad. Las medidas de rotación y desplazamiento están inevitablemente acompañadas de errores, cuando éstas son estimadas sin ayuda de referencias externas. Más aún, el proceso de PI es un proceso incremental por el cual a partir de la última posición calculada y teniendo la dirección del movimiento y la distancia se estima la nueva posición, acumulando el error de las sucesivas señales de entrada.

2.2.3. Señales Visuales en la Navegación

Dado que el proceso de integración de trayectoria se degrada por la acumulación de errores que ocurren al calcular automática y continuamente las traslaciones y rotaciones ejecutadas por el animal cada vez que se desplaza, el sistema de navegación utiliza referencias externas cuando éstas se encuentran disponibles para el animal. Estudios conductuales y registros neuronales en ratas han mostrado que las señales visuales, también referidas como marcas, controlan la navegación sólo si la rata las percibe como estables (Jeffery, 1998), y de manera opuesta, el control visual se debilita después de experimentar inestabilidad (Knierim et al., 1996). Las ratas también pueden utilizar estímulos no visuales como referencias externas y asociarlas con localidades o direcciones particulares. Una vez establecidas dichas asociaciones, las ratas muestran una gran flexibilidad en el uso de señales espaciales de diferentes modalidades sensoriales (Etienne and Jeffery, 2004). Sin embargo, en condiciones donde prevalecen diferentes tipos de referencias, las ratas muestran una jerarquía de preferencias: la visión sobre el olfato, y el olfato sobre la locomoción (Maaswinkel and Whishaw, 1999). En condiciones naturales, las referencias externas y las señales derivadas del propio movimiento usualmente cooperan más que competir entre sí. De esta forma, el proceso de integración de trayectoria puede ser reiniciado mediante marcas estables para guiar la navegación de manera más precisa y se degrada cuando las marcas dejan de estar disponibles. La reinicialización implica que el animal establezca su localización actual a través de la percepción de las referencias externas, y que actualice el estado de su integrador de trayectoria de acuerdo con la posición del punto de partida. Este proceso ha sido demostrado en el comportamiento de retorno al punto de partida en hamsters cuando enfrentan situaciones de conflicto entre marcas visuales y la integración de trayectoria (Etienne et al., 2000).

2.2.4. Integrador de trayectorias y señales visuales

Un problema recurrente en psicología cognitiva es determinar cómo diferentes fuentes de información son integradas para dar lugar a una representación unificada, en lo que a navegación se refiere este aspecto aparece al momento de integrar información de marcas y de PI. Desde la corteza se reciben periódicamente correcciones visuales que resetean las señales de dirección de la cabeza para evitar desplazamientos debido al error acumulado por el proceso de sumas sucesivas de señales inexactas. Se ha indicado que el lugar donde esta integración de información (visual e idiótétiaca) puede darse es el postsubiculum pues recibe entradas tanto funcionales como anatómicas desde el tálamo anterior y desde áreas visuales. Independientemente del lugar de convergencia de estas dos fuentes de información, uno de los desafíos para el modelado computacional es explicar cómo esta información dispar puede integrarse para dar lugar a una señal de dirección unificada.

También es un problema los mecanismos de interacción entre estos dos sistemas generadores de información. Algunos estudios sobre hamsters permiten confirmar que frente a una marca estable el sistema de navegación realiza un reset total, esto es, tanto el sistema de dirección de la cabeza como el de localización. En este sentido es importante tener en cuenta que la percepción está asociada a un marco de referencia egocéntrico, las marcas son proyectadas en el campo visual del animal por lo que su posición es en una primera instancia calculada en función de la posición y orientación de sus ojos. Por este motivo, el sistema nervioso debe transformar las marcas egocéntricas en coordenadas geométricas para ser usadas en conjunto con la información de PI y posibilitar su integración a un mapa geométrico. Se ha sugerido que esta transformación en los mamíferos podría realizarse en alguna región de la corteza parietal (Burgess et al., 1997). Para poder navegar de manera

flexible en un entorno, tomar atajos y retornar (detours), el agente necesita representar el entorno mediante algún tipo de mapa neuronal en el cual las posiciones particulares son interconectados por relaciones euclidianas o topológicas. Este tipo de representaciones podrían permitir al animal manipular computacionalmente las relaciones espaciales y de esta forma planificar rutas óptimas en el entorno real.

2.2.5. Mapas Cognitivos

Un hito en el entendimiento acerca de los mecanismos cerebrales involucrados en el procesamiento de la información espacial fue sin duda el análisis que O'Keefe y Nadel (O'Keefe and Nadel, 1978) llevaron a cabo sobre las propiedades neurofisiológicas y neuropsicológicas del hipocampo, descubriendo la participación crucial de este sistema en el aprendizaje de representaciones internas de alto nivel sobre las relaciones espaciales aloécnicas, esto es, basadas en una referencia absoluta y no en la posición actual del animal y la relación entre las representaciones. La Figura 2.8 muestra la anatomía del hipocampo en forma esquemática.

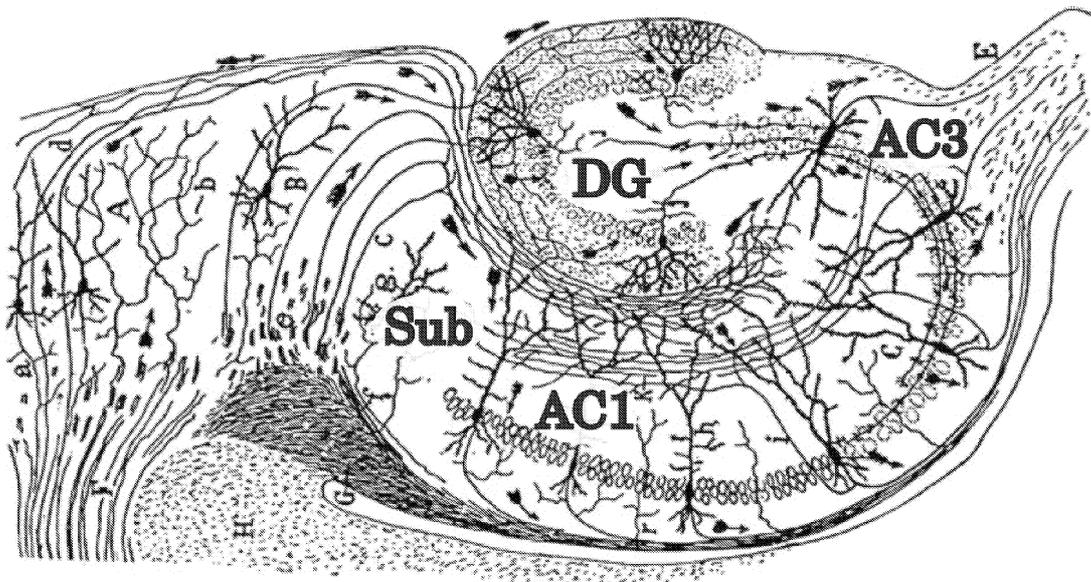


Figura 2.8 – Anatomía de la formación hipocampal. Glosario: CA - Cornu Ammonis (cuerno de Amón); DG: dentate gyrus (giro dentado). Sub: subiculum. Adaptado a partir de dibujos de Santiago Ramón y Cajal.

El sustrato neuronal de dichas representaciones espaciales internas fue el descubrimiento previo que hicieron O'Keefe y Dostrovsky (O'Keefe and Dostrovsky, 1971) a partir de registros individuales de las neuronas piramidales encontradas en las áreas CA3 y CA1 del hipocampo. A tales neuronas se les denominó neuronas de lugar (place cells), debido a que muestran una alta correlación entre su tasa de disparo y la localización del animal en el ambiente. Específicamente, cada una de estas células exhiben patrones de activación tipo gaussiano a una tasa elevada cuando el animal se encuentra en un área continua y compacta, la cual es definida como el campo de lugar (place field) de la célula. La actividad derivada de la población de células de lugar codifica en conjunto la ubicación actual del animal dentro de un ambiente familiar, y es dicha actividad global la que se almacena en la representación espacial interna referida por Tolman (Tolman, 1948) como mapa cognitivo.

La actividad de las neuronas de lugar parece ser dependiente de la disposición de señales visuales en el ambiente, ya que la rotación de tales claves provoca una rotación correspondiente en los campos de lugar (Mcnaughton et al., 1995). Sin embargo, las células de lugar mantienen sus campos de lugar cuando algunas de las claves visuales se retiran del ambiente (O'Keefe and Conway, 1978), e incluso continúan respondiendo en la oscuridad (Quirk et al., 1990), así que actualmente se asume que la respuesta de las células de lugar se deriva de combinar información kinestésica con información de señales visuales (Jeffery and O'Keefe, 1999). Según diversos investigadores (Etienne, 1998; McNaughton et al., 1996), el proceso de integración de trayectoria puede jugar el papel principal en la construcción del mapa cognitivo. En efecto, cuando las ratas exploran un nuevo ambiente, centran su excursión en el punto de partida y utilizan la integración de trayectoria continuamente para actualizar la relación entre su posición actual y el punto de referencia. En esta situación inicial, los campos de lugar se establecen rápidamente a través de la información kinestésica pues las señales ambientales no han sido aprendidas, pero conforme la exploración progresa, las ratas comienzan a asociar las diversas localidades relevantes del ambiente con su percepción actual de marcas.

De acuerdo con Poucet (Poucet, 1993), el mapa cognitivo se genera mediante la adquisición de información topológica y métrica del espacio. La información topológica se refiere al conocimiento de las relaciones espaciales entre localidades u objetos, mientras que la información métrica se relaciona con información cuantitativa acerca de direcciones angulares y distancias entre localidades u objetos. Poucet sugiere que los mapas cognitivos iniciales son mapas topológicos básicos que se van refinando con la adquisición de información métrica a medida que se explora el ambiente. Un animal empieza por formar un mapa cognitivo de una región, construyendo grafos locales que especifican las relaciones entre los lugares de un área. Poucet indica que la integración de vistas locales es importante para aprender acerca de un lugar. Si un animal permanece en un lugar y rota su cabeza y su cuerpo gradualmente hasta completar 360°, las vistas locales sucesivas son integradas para componer una representación completa de ese lugar. La vista local que el animal percibe al visitar nuevamente ese lugar debe reactivar el recuerdo entero del mismo. Por otro lado, cuando el animal viaja entre lugares, se establecen en el mapa relaciones acerca de qué lugar conduce a qué otro. A medida que se incrementa la exploración, se determina información métrica; en particular, el animal aprende las distancias y las direcciones entre lugares.

2.3. Navegación bio-inspirada

En 1948, para explicar la habilidad de procesamiento de la información Tolman (Tolman, 1948) argumentó que los animales debían tener un mapa cognitivo en algún lugar del cerebro, y en 1978 O'Keefe y Nadel (O'Keefe and Nadel, 1978) argumentaron que se encontraba en el hipocampo.

La investigación en busca de las bases neuronales para la navegación comenzó a principio de 1970 con el descubrimiento de las neuronas de lugar por John O'Keefe y Jonathan Dostrovsky (O'Keefe and Dostrovsky, 1971). Estas neuronas disparan sólo en un lugar específico del entorno. En 1984 James Rank identificó las neuronas de posición de la cabeza que disparan cuando el animal está mirando en cierta dirección. Un tercer tipo de neurona involucrada en navegación es la neurona grilla, identificada en 2005 en la corteza entorrinal. De forma similar a las neuronas de lugar, las neuronas grilla disparan en múltiples lugares en el entorno. Por último, las neuronas borde localizadas también en la corteza entorrinal reaccionan cuando el animal se encuentra próximo a un borde.

Dos estrategias diferentes son usadas por los animales para navegar, las marcas (landmark) y la integración de trayectorias. La navegación por marcas ocurre cuando el animal deriva su posición y

dirección actual en el entorno relativa a las marcas que tiene a su alrededor. La información sensorial que el animal utiliza en este caso es usualmente nombrada como señales externas (allothetic cues), y pueden obtenerse de alguna modalidad sensorial (visual, auditiva, olfativa). En contraste, usando integración de trayectorias, el animal registra su posición y orientación inicial, y a partir de éstas estima su posición y orientación actual mediante la integración de información de auto-movimiento interno (idiothetic cues), como ser flujo vestibular o información propioceptiva.

Varias especies pueden mantener una idea de su posición aún en ausencia de señales auditivas, visuales u olfativas, mediante la integración de su movimiento. Varios modelos han sido explorados en los cuales la integración de trayectorias se realiza mediante redes neuronales. Los ingredientes principales de estos son:

1. una representación interna de la posición,
2. representación interna de la velocidad y dirección del movimiento, y
3. un mecanismo para desplazar la posición codificada por la cantidad adecuada cuando el animal se mueve.

2.3.1. Neuronas para la navegación

Desde las hipótesis de mapas cognitivos propuestas en 1948 por Tolman varios fueron los trabajos de investigación en busca de las bases neuronales para la navegación. De esta forma desde 1970 con el descubrimiento de las neuronas de lugar han sido varias las neuronas descubiertas que intervienen en el circuito neuronal relacionado con la navegación, desde el ingreso de la información, su procesamiento y memoria.

Esta sección describe las principales neuronas involucrada con la navegación.

2.3.1.1. Neuronas de lugar

Las neuronas de lugar (place cells) son neuronas en el hipocampo que presentan una tasa alta de disparo cuando el animal se encuentra en una posición específica del entorno que se corresponde con el campo de la neurona de lugar. El incremento en la tasa de disparo puede ser dramático, desde prácticamente cero fuera del campo hasta alcanzar los 100 Hz (durante períodos breves) en el centro del campo. Se observó experimentalmente que neuronas cercanas anatómicamente no necesariamente definen campos de lugar cercanos en el entorno.

En la figura 2.9 se muestran los patrones de disparo espacial de siete células de lugar registradas en la capa CA1 de rata. La rata recorre varios cientos de vueltas en el sentido de las agujas del reloj alrededor de un laberinto triangular, parando en el medio de cada uno de los lados para comer una pequeña porción de comida. Los puntos negros indican las posiciones de la cabeza de la rata. Se utiliza un color diferente para cada una de las células muestreadas y se indica con el color asignado los lugares del entorno en los cuales se activa.

Aunque las señales visuales parecen ser el principal determinante de los disparos de las neuronas de lugar, los disparos persisten en la oscuridad, lo que sugiere que la además de la información visual otros sentidos contribuyen a la activación de estas neuronas.

El tamaño del campo de lugar varía dependiendo de la región del cerebro. En el hipocampo los campos de las neuronas de lugar son más pequeños y definidos en el polo dorsal, siendo más largos hacia el polo ventral. En entornos abiertos los campos de lugar tienen un diámetro que va desde los 20 cm, 50 cm en la región intermedia, llegando a algunos metros en la región más ventral.

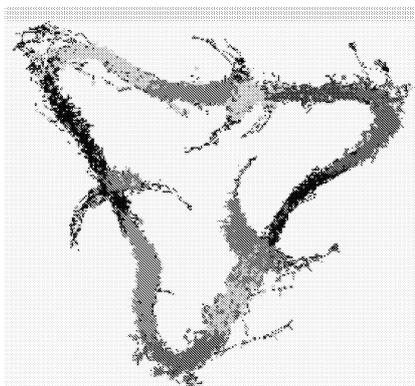


Figura 2.9 – Patrones de disparo espacial para siete neuronas de lugar (Commons, 2015). Se presenta un entorno triangular visto a ojo de pájaro donde se muestran los patrones de disparo espacial de siete células de lugar usando diferentes colores para cada una de ellas.

Fueron observadas por primera vez en el hipocampo, siendo luego observadas en el estriado dorsal, estriado ventral, corteza parietal posterior, corteza entorrinal, culiculus superior, septum lateral, parasubiculum y subiculum.

2.3.1.2. Neuronas de dirección de la cabeza

Varios mamíferos poseen neuronas llamadas neuronas de dirección de la cabeza (head direction cells) (HD), las cuales están activas sólo cuando la cabeza del animal apunta en una dirección específica, dentro del entorno en el plano horizontal. Esto significa que una neurona particular puede descargar cuando el animal apunta su cabeza en dirección noreste independiente de su posición. Las neuronas HD dependen de marcas y señales del movimiento, como ser señales vestibulares y propioceptivas. Estas neuronas se encuentran en varias áreas del cerebro, incluyendo el postsubiculum, corteza retroplenial, tálamo, núcleo mammillary lateral, núcleo dorsal tegmental, estriado y corteza entorrinal.

La dirección en la cual el disparo de la neurona es máximo se denomina dirección preferida de disparo, y todas las direcciones preferidas son igualmente representadas dentro de la población de neuronas. Estas neuronas integran la información de movimiento e información visual. La integración no es perfecta, especialmente para rotaciones lentas de la cabeza. Si un animal explora en la oscuridad un entorno sin señales de dirección, la alineación de la HD tiende a desfasarse lenta y aleatoriamente en el tiempo.

Uno de los aspectos más interesantes de las neuronas HD es que su disparo no está completamente determinado por las características sensoriales del entorno. Cuando el animal entra por primera vez a un entorno el alineamiento del sistema HD es arbitrario. En los primeros minutos de exploración el animal aprende a asociar marcas con direcciones. Luego cuando el animal regresa al mismo entorno, si el sistema de HD está desalineado, las asociaciones aprendidas son utilizadas para realinearlos.

Las teorías actuales postulan que las señales de las neuronas HD se originan en las conexiones recíprocas entre dos núcleos subcorticales, el núcleo tegmental dorsal y el núcleo mamilar. El núcleo tegmental dorsal tiene una gran cantidad de neuronas sensibles a la velocidad angular de la cabeza. Desde el núcleo mamilar, que contiene tanto neuronas sensibles a la velocidad angular como a la dirección de la cabeza, las neuronas HD se proyectan al tálamo anterodorsal, y de este al postsubiculum para llegar a la MEC y al hipocampo.

2.3.1.3. Neuronas grilla

Las neuronas grilla son un tipo de neuronas descubiertas en 2005 en la MEC por Edward Moser y su grupo en el centro de biología para la memoria en Noruega. Estas neuronas están moduladas, al igual que las neuronas de lugar, por la posición en el entorno, teniendo múltiples lugares de disparo que definen un arreglo triangular regular que cubre toda la superficie de un entorno abierto bi-dimensional. Se piensa que que las neuronas grilla son parte esencial del sistema cerebral de coordenadas para navegación métrica.

En la Figura 2.10 izquierda muestra con líneas negras la trayectoria del animal y con puntos rojos la posición en la arena donde dispara la neurona observada. Los puntos rojos forman pequeños agrupamientos y estos agrupamientos forman los vértices de una grilla de triángulos equiláteros. La figura derecha muestra otra forma de presentar la actividad de una neurona como una gráfica de temperatura.

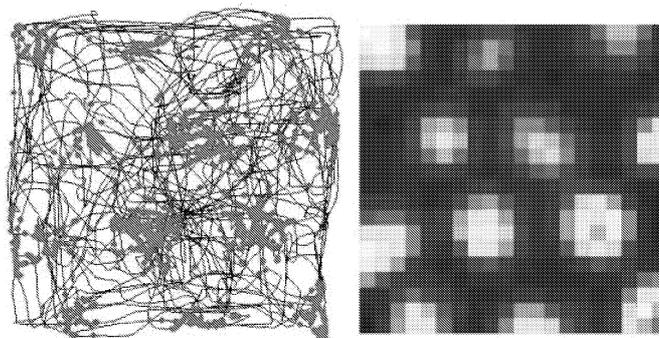


Figura 2.10 – Patrones de disparo de una neurona grilla (Moser et al., 2008). Se muestran dos formas de presentar los disparos de las neuronas espaciales, a la izquierda se presentan los puntos del entorno en los cuales la tasa de disparo es máxima y a la derecha se presenta con color azul los puntos donde la neurona no dispara cambiando su color en función de la tasa de disparo hasta el valor máximo representado en rojo.

La mayoría de los modelos de formación de los campos de grilla asumen que las neuronas de la MEC participan en la integración de trayectorias, basadas en la velocidad y dirección proveniente de neuronas especializadas pero calibradas a partir de señales sensoriales externas de forma de corregir el error acumulado.

En contraste con las neuronas de lugar del hipocampo, las neuronas grilla tienen múltiples campos de disparo, que cubren el entorno según un patrón regular. Las propiedades únicas de las neuronas grilla son las siguientes:

1. Tienen disparos dispersos en todo el entorno organizándose en una grilla regular, en contraste con las neuronas de lugar que disparan en ciertas regiones del entorno.
2. Los campos de disparo están igualmente separados, de forma que la distancia de un campo de disparo a los otros seis campos adyacentes es aproximadamente la misma.
3. Los campos de disparo están posicionados aproximadamente a incrementos de 60 grados.

Cuando se descubrió el fenómeno de precesión de fase (O'Keefe and Recce, 1993) se indicó que éste podría deberse al resultado de la interferencia de dos ondas, sugiriéndose que las neuronas del hipocampo oscilaban a una frecuencia mayor que theta y recibían una frecuencia theta de entrada.

La suma de estas dos oscilaciones causan que la neurona dispare con una envolvente que representa el campo de lugar. Se implementaron algunos modelos basados en interferencia de osciladores pero se encontraron algunas dificultades para explicar algunas propiedades de los disparos de lugar. El descubrimiento de los patrones regularmente repetitivos de los campos de lugar de las neuronas grilla supuso que esta interferencia de osciladores podría tener lugar en la MEC. A partir de esto O'Keefe, Burgess y colaboradores (O'Keefe and Burgess, 2005; Burgess et al., 2007) proponen un modelo basado en el producto de tres o más osciladores para generar los patrones espaciales de disparo generados en las neuronas grilla de la MEC. Ellos proponen que el soma de las neuronas de la MEC oscilan a una frecuencia theta y que las dendritas oscilan a una frecuencia que depende de la velocidad de la rata en una determinada dirección.

Para que las neuronas grilla puedan formar un patrón regular a partir de entradas formadas por osciladores modulados por la velocidad (p. ej. neuronas banda (Krupic et al., 2012) o neuronas theta de Welday (Welday et al., 2011)), se necesita que la entrada de al menos tres de estos osciladores estén exactamente separados por 60 (o 120) grados. Varios modelos de osciladores han sido propuestos pero todos ellos requieren de esta alineación precisa de las orientaciones, generando otras geometrías de grillas cuando esta restricción sobre la orientación no se cumple. Algunos estudios indican que las neuronas HD se alinean solamente con los seis ejes de la grilla, lo que posibilita que existan neuronas theta calibradas en orientaciones separadas por 60 grados. Welday muestra neuronas theta calibradas en diversas direcciones, no necesariamente separadas por 60 grados, sin embargo sugiere que las neuronas grilla reciben entradas desde neuronas theta con orientaciones separadas por 120 grados, junto con otras entradas.

Gran parte de las neuronas en las capas II y III de la corteza entorrinal media (MEC) presentan propiedad de grilla. La mayoría de las entradas a la neuronas de lugar del hipocampo provienen de las neuronas grilla entorrinales. Algo interesante que aparece a partir de esta conectividad refiere a cómo el patrón espacial de disparo periódico de las neuronas grilla puede ser transformado en una señal no periódica en las neuronas de lugar.

2.3.1.4. Neuronas borde

En 2000 Neil Burgess predijo la existencia de lo que él denominó vector de neuronas borde (vector boundary cells), que codifican la distancia a los bordes del entorno. Recién en 2008 Edward Moser y sus colegas confirmaron la existencia de estas neuronas en ratas. La mayoría de las neuronas observadas en la corteza entorrinal presentan características de neuronas de lugar o neuronas grilla, pero un número pequeño de neuronas (11 %) presentan un patrón inusual de disparo que no se había observado antes. Estas neuronas incrementan su disparo sólo cuando el animal está rodeado de uno o varios muros, independiente del largo del borde o su relación con otros bordes del entorno. También se notó que al observar simultáneamente dos neuronas borde que responden a bordes opuestos, la diferencia en la orientación relativa se mantiene entre distintos escenarios. Moser sospecha que las neuronas borde alinean las neuronas grilla a los bordes, y por esto están involucradas en la definición del perímetro de entorno del animal. También sugiere su relación con la planificación de rutas, proporcionándole a las neuronas grilla información de obstáculos móviles y bordes. Recientemente el grupo de Mildord y Wyeth (Cheung et al., 2012) ha llevado adelante experimentos para alinear neuronas de lugar utilizando información de borde tanto en simulación como sobre robots reales. Dichos experimentos se basan en protocolos de experimentación en ratas teniendo en cuenta la ausencia de marcas visuales en la oscuridad.

2.3.1.5. Neuronas de aceleración y velocidad

El sistema vestibular está ubicado atrás del oído de los humanos y otros mamíferos. Dos estructuras clave en el sistema vestibular son los canales semicirculares y los órganos otolíticos. Existen tres canales semicirculares que responden a los cambios en la aceleración lineal y movimientos de rotación (Carter, 2010).

Los órganos otolíticos sensan aceleraciones lineales. Esta información podría ser integrada dos veces de manera de generar desplazamientos lineales y una vez para generar velocidades lineales. Este tipo de procesamiento de la información ha sido observado en otras áreas del cerebro (p. ej. reflejo vestibulo-ocular).

2.3.1.6. Transformación de campos grilla a lugar

Desde el descubrimiento de las neuronas grilla, varios han sido los modelos que muestran la generación de campos de lugar a partir de la combinación de campos grilla con diferentes parámetros, topologías y métodos de aprendizaje (Cheng and Frank, 2011). El trabajo pionero de Solstad y colaboradores (Solstad et al., 2006) determina que la suma de al menos diez neuronas grilla con diferentes espaciados y similares fases espaciales y orientaciones, luego de aplicar una inhibición global resulta en la formación de un único campo de lugar en el entorno.

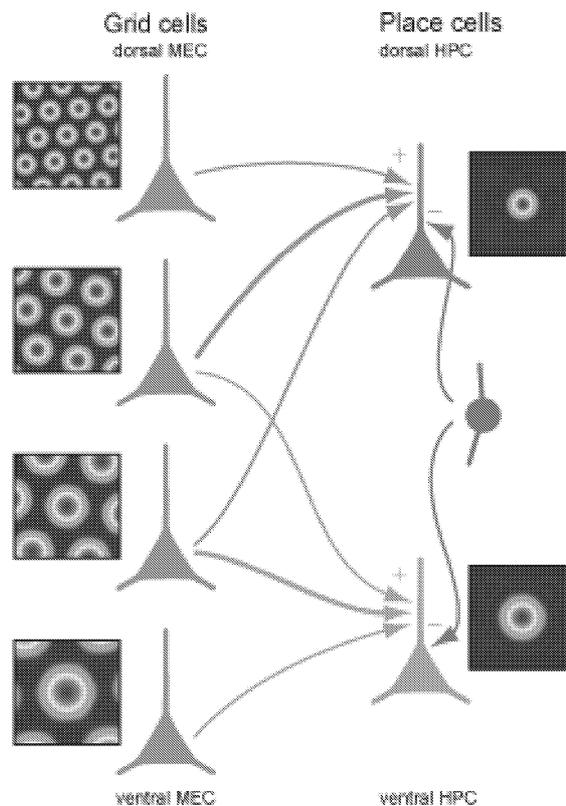


Figura 2.11 – Red de neuronas grilla y de lugar (Solstad et al., 2006).

La Figura 2.11 presenta la propuesta de Solstad y colaboradores para generar disparos de lugar a partir de de disparos grilla, esta propuesta tiene como objeto validar la generación de disparos de

lugar a partir de una cantidad razonable de disparos grilla. En su trabajo proponen transformar los campos periódicos de grilla a campos no periódicos de lugar mediante una suma ponderada de los disparos grilla. Para ello, una neurona de lugar recibe entradas de varias neuronas grilla con similar fase y orientación pero con diversidad de espaciado. En la figura el grosor de la línea entre neuronas grilla y neurona de lugar pretende mostrar el peso de la conexión, también se puede apreciar como se incrementan el espaciado y el campo de lugar desde la zona dorsal a ventral en la MEC y en el hipocampo respectivamente.

2.3.2. Escenarios para experimentación

Las ratas deben utilizar un sistema de orientación mediante el cual desenvolverse sin problemas en ambientes complejos, y alcanzar así los objetivos propuestos. Deben guiarse por el entorno, e ir creando un mapa interno al que acceden para volver sobre sus pasos o evitar lugares ya visitados que no aporten ningún beneficio. Las ratas suelen evitar los lugares abiertos, y tienden a desplazarse por esquinas y recovecos más ocultos, estableciendo siempre un lugar que servirá de refugio. Esto último aparte de servir como un punto de reseteado para establecerlo como punto cero en las incursiones en el medio, es un comportamiento increíblemente adaptativo en cuanto a depredación se refiere, ya que se evitan los lugares abiertos quedando así menos expuestas.

Este complejo sistema de navegación está sustentado por múltiples fuentes de información que la rata debe integrar y en algunos casos discernir cuál es la más fiable. La rata se vale de dos tipos de información, la externa y la interna. La información interna procede principalmente del sistema vestibular que le informa sobre la dirección que tiene su cabeza, o la velocidad a la que ésta se mueve. La información externa es la que proviene principalmente del sistema visual, pero también del sensorial, olfativo y auditivo. Este último tipo de información le será muy útil a la hora de establecer puntos de referencia, y así facilitar la memorización de un determinado entorno. La rata deberá integrar los distintos tipos de información, para poder establecer el mapa interno correctamente, y acceder a él y al contexto en el cual se encuentra dicho mapa. A veces, no dispondrá de la información externa de tal forma que deberá utilizar los mapas generados únicamente con la información vestibular. Este último sistema acumula errores, aunque ha demostrado ser bastante fiable.

Las ratas poseen la habilidad de aprender laberintos mediante el establecimiento en un mapa cognitivo. Mediante esta representación interna, las ratas son capaces de desenvolverse en laberintos a los que ya han sido expuestas y otros nuevos. Para exponer la capacidad de orientación de las ratas, se describen a continuación tres experimentos clásicos para estudiar la navegación espacial.

2.3.2.1. Laberinto de brazos radiales (David Olton y Robert Samuelson)

Este experimento fue diseñado en 1976 por Olton y Samuelson para evaluar la memoria de lugares previamente visitados, memoria de referencia y de trabajo. La memoria de referencia y de trabajo en la conducta de búsqueda de alimento son mecanismos básicos que permiten ahorrar energía al organismo al encontrar el alimento de forma más eficiente.

El aparato experimental consiste en un laberinto que contiene ocho brazos dispuestos radialmente elevados sobre el nivel del suelo. La Figura 2.12 muestra una posible construcción del laberinto con ocho brazos. Al final de cada uno de estos brazos hay depositada una recompensa de comida, por lo que la rata tenderá a realizar un mapa mental del laberinto de aquellos brazos ya visitados, para

optimizar la búsqueda de comida. De esta forma, y tras varios intentos, las ratas habrán aprendido a realizar la tarea realizando el menor número de repeticiones.

La memoria de referencia permite que el animal identifique los invariantes existentes en el ambiente que indican lugares de abundancia o de escasez de recursos, y la memoria de trabajo permite identificar las fuentes de alimento que el animal ha agotado al ir recorriendo las diferentes localidades. En este experimento se evalúa la capacidad de los animales respecto a omitir un brazo que no ha proveído alimento durante la fase experimental (memoria de referencia), mientras que tienden a visitar sólo una vez durante el ensayo los brazos que sí proveen alimento (memoria de trabajo).

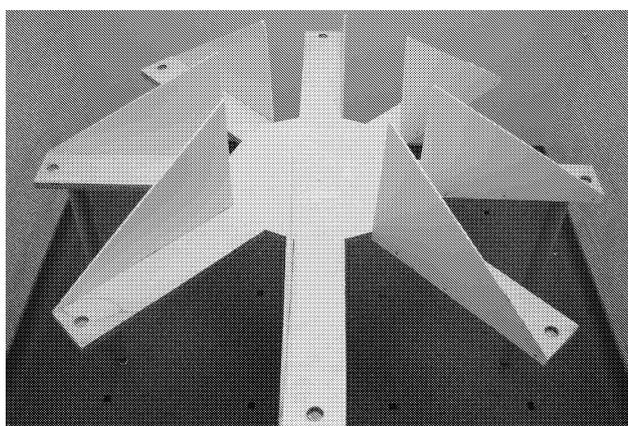


Figura 2.12 – Laberinto de brazos radiales de Olton (Commons, 2015).

2.3.2.2. Laberinto de agua (Richard Morris)

Las ratas, aún siendo buenas nadadoras, intentan evitar el agua. Basado en este comportamiento Richard Morris propuso este laberinto, que consta de un tanque con agua opaca en el que hay una plataforma sumergida en la que la rata puede situarse y evitar el contacto con el agua. En la Figura 2.13 se muestra una posible construcción del laberinto propuesto por Morris.

La rata no es capaz de visualizar la plataforma bajo agua, pero esta plataforma se encuentra siempre en una posición fija con respecto de múltiples señales visuales que se encuentran fuera del tanque. Una vez que la rata ha encontrado la plataforma, y tras repetidos intentos, aprende a localizarla en posteriores intentos, independientemente del lugar inicial en el que ella es situada.

En esta versión del laberinto de agua, la rata necesita asociar las señales externas con la posición de la plataforma, no obstante, la eliminación de alguna de esas pistas no suele entorpecer dicho comportamiento.

2.3.2.3. El laberinto de plataforma circular (Carol Barnes)

Este tipo de laberinto es similar al anterior, aunque se basa en otro comportamiento característico de los roedores y es que evitan los lugares abiertos. En este experimento se sitúa la rata sobre una plataforma con varios agujeros en su perímetro, pero solo uno de ellos da acceso a un túnel inferior (caja de escape). La Figura 2.14 muestra una posible construcción del laberinto de Barnes.

La rata tenderá a buscar este agujero para ocultarse, utilizando también distintas pistas situadas fuera de la plataforma.

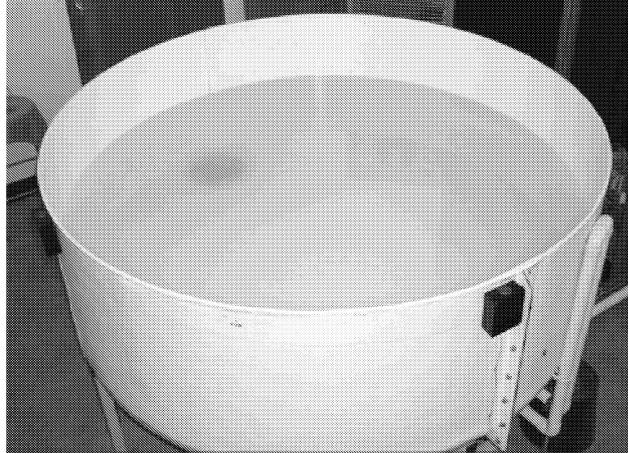


Figura 2.13 – Laberinto de agua de Morris (Commons, 2015).

El laberinto de experimentación se basa en la aversión de los roedores a los espacios abiertos, lo que motiva al animal a buscar refugio (resolver la tarea) sin necesidad de generar estrés en él. Un roedor normal aprende a escapar al cuarto o quinto intento, a partir del cual se dirigirá directamente hacia el agujero correcto. Durante el desarrollo del experimento se miden varios parámetros, incluyendo latencia para escapar, longitud de la trayectoria, el número de errores y la velocidad.

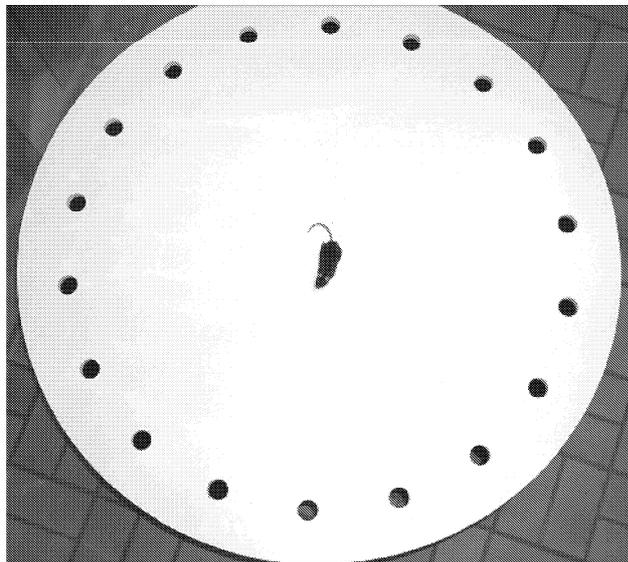


Figura 2.14 – Laberinto de plataforma circular de Barnes (Commons, 2015).

2.4. Trabajos Relacionados

Los descubrimientos biológicos relacionados con el aprendizaje y la memoria espacial de animales como las ratas han sido considerados por muchos investigadores como atractivos para incorporar sus principios en modelos de cognición espacial y navegación aplicados a robots móviles. Esta sección

introduce algunos de los esfuerzos más importantes documentados en los últimos años estableciendo comparaciones con el trabajo aquí propuesto.

En este sentido, se presenta un balance entre modelos generales de navegación para contextualizar y modelos que incorporan neuronas grilla como mecanismo de integración de trayectorias. Puede profundizarse respecto de modelos específicos sobre neuronas grilla en los trabajos realizados por Giocomo y colaboradores (Giocomo et al., 2011), y Zilli (Zilli, 2012). De igual forma, para profundizar sobre modelos de navegación y SLAM bio-inspirados puede consultarse los trabajos realizados por Sünderhauf y Protzel (Sünderhauf and Protzel, 2010), y Madl y colaboradores (Madl et al., 2015).

2.4.1. El modelo de Burgess y colaboradores (1994)

En su forma original, el modelo de Burgess y colaboradores (Burgess et al., 1994) consiste de cinco capas. Información espacial del ambiente dispara células sensoriales, la actividad de éstas se propaga a través de las células de la corteza entorrinal hasta llegar a las células de lugar del hipocampo. La salida de las células de lugar converge después, a través de células intermediarias del subiculum, en una capa de salida que consiste en una pequeña población de células de meta hipotéticas. La entrada al modelo es tomada, entonces, de conjuntos de células sensoriales, donde cada conjunto codifica la distancia hacia una señal externa específica y cada célula del conjunto genera su máxima respuesta ante una distancia particular. La última capa de la red incluye cuatro células de meta, cada una representa una dirección aloécéntrica (relativa al mundo, no a la rata) en el ambiente (norte, sur, este, oeste).

Una célula de meta que representa una dirección específica recibe una fuerte entrada excitatoria cuando la rata se encuentra en el lugar de la meta y su cabeza está dirigida hacia tal dirección. El modelo asume que las células de meta tienen entradas del sistema que calcula la dirección de la cabeza de la rata y el sistema que administra la recompensa, de tal forma que las conexiones entre las células de lugar y las células de meta pueden ser modificadas cuando la rata encuentra la meta y mira hacia la dirección correcta. Cuando el robot encuentra el lugar de la meta, una señal de refuerzo provoca un disparo de Hebb (Hebb, 1949) en las conexiones que van de las células de lugar a las células de meta. En contraste, las neuronas de lugar en el modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008) codifican la integración de información visual y kinestésica, y adicionalmente, las propiedades de las señales visuales son interpretadas por medio de neuronas sensibles a patrones específicos de información de marcas. Finalmente, el modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008) agrega la construcción explícita de un mapa topológico de lugares y de sus relaciones métricas, no limitándose a la generación de campos de lugar aislados.

2.4.2. El modelo de Redish y Touretzky (1997)

En el modelo de Redish y Touretzky (Redish and Touretzky, 1997), al igual que en el modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008), la representación de los lugares integra información vestibular y visual. La entrada visual consiste del tipo de cada marca, así como su distancia y orientación con respecto al animal. La dirección de la cabeza de la rata se actualiza mediante claves vestibulares y comandos motrices ejecutados por el animal. El modelo asume que el animal mantiene una estimación de su posición de acuerdo con un sistema de coordenadas interno. Este valor es actualizado por un módulo integrador de trayectoria mientras el animal se mueve considerando la entrada vestibular y de locomoción. La codificación de lugares en el modelo de los autores utiliza unidades de lugar para mantener la asociación entre la percepción local del animal y las

coordenadas definidas por el integrador de trayectoria. Como en el modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008), cuando no existen señales visuales en el ambiente, las unidades de lugar son disparadas únicamente por el integrador de trayectoria. En el modelo de Redish y Touretzky, las unidades de lugar se crean dinámicamente mientras el animal simulado explora el ambiente, a diferencia del modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008), en donde la cantidad de células de lugar se encuentra predeterminada y no depende del ambiente que la rata explore. Para determinar si el animal reconoce las señales percibidas en su localidad actual, los autores utilizan una medida de consistencia que resulta alta cuando la vista local actual es compatible con la vista local recordada por las coordenadas actuales del integrador de trayectoria, o cuando estas coordenadas empatan con las que se encuentran asociadas con la vista local actual. Este proceso de reconocimiento de lugares es similar al que lleva a cabo el modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008) sobre la representación espacial. En este sentido también contrastan los modelos, pues el modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008) no define la representación espacial a manera de campos de lugar aislados, sino que construye un mapa topológico-métrico o global considerando los patrones de actividad derivados de la población completa de unidades de lugar para definir lugares distintivos y sus relaciones. Información relativa a la motivación del animal es utilizada en el modelo de Redish y Touretzky para planificar una ruta hacia una meta dada, proceso que los autores relacionan con el estriado de la rata recibiendo entradas espaciales del hipocampo.

2.4.3. El modelo de Guazelli y colaboradores (1998)

El estudio llevado a cabo por Guazelli y colaboradores (Guazzelli et al., 1998) propone un modelo referido como TAM-WG, el cual provee dos sistemas de navegación: uno para llegar directamente hacia una meta perceptible desde la localización del animal (taxon), y otro para relacionar la posición de la meta con la localización de marcas externas para poder reconocer tal posición objetivo dentro del mapa cognitivo y navegar hacia ella (locale). La representación espacial provista por el modelo para posibilitar este último sistema de navegación combina información kinestésica y visual. El modelo fue validado mediante simulaciones en ambientes virtuales de algunas tareas espaciales clásicas que han sido implementadas con ratas.

El modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008) se encuentra parcialmente inspirado en el de Guazzelli y colaboradores. Una de las principales extensiones propuestas a este sistema consiste en un proceso de explotación del mapa para posibilitar la navegación orientada a metas en el robot móvil. El modelo original asigna a la rata simulada la capacidad de aprender localidades meta desde un punto de partida fijo dentro de laberintos que incluyen únicamente un punto de decisión. No obstante, el animal es incapaz de lograr dos aspectos fundamentales: (i) encontrar el objetivo en laberintos más complejos que incluyan dos o más localidades en las que la rata requiera decidir su próxima orientación, y (ii) alcanzar la meta a partir de localidades iniciales arbitrarias en el laberinto aprendido.

2.4.4. El modelo de Gaussier y colaboradores (2002)

En el modelo de Gaussier y colaboradores (Gaussier et al., 2002), las células de lugar o células de vista son aprendidas en la corteza perirrinal y en la corteza entorrinal, y el rol del hipocampo no consiste fundamentalmente en la construcción de mapas cognitivos o en la navegación, sino que es utilizado para aprender, almacenar y predecir transiciones entre diversos estados. Cada célula

de lugar codifica un lugar del ambiente, y la regla de Hebb permite el aprendizaje de la relación de tiempo entre dos lugares adyacentes. El modelo produce un grafo de las relaciones espaciales entre los lugares. La navegación implica el aprendizaje del vínculo entre el reconocimiento de un lugar dado y alcanzar el objetivo. Para ello, el modelo asocia el reconocimiento de ese lugar con la activación de una neurona motivacional. La conexión entre tal neurona y la célula de lugar que representa la situación reconocida es reforzada utilizando la regla de Hebb, y durante el proceso de navegación, la actividad motivacional se propaga hacia atrás dentro del mapa. Posteriormente, el sistema trata de reconocer la localización actual del robot, y selecciona como submeta el nodo más activo del mapa cognitivo directamente ligado con su posición actual. El sistema alcanza ese lugar y el proceso se repite hasta alcanzar la meta más cercana a su posición inicial. Para posibilitar la selección de las acciones a ejecutar para alcanzar la meta, los autores construyen una representación de la transición entre dos situaciones o lugares, la cual es asociada con el movimiento para ir de un lugar a otro. Posteriormente, las conexiones entre las representaciones son aprendidas para crear un grafo de las relaciones topológicas entre las transiciones. Cuando el robot alcanza la meta, aprende la asociación entre el reconocimiento de la última transición y la satisfacción de la motivación. Los autores proponen que el mapa cognitivo podría ser elaborado en la corteza prefrontal, pero que las representaciones internas de las transiciones podrían ser codificadas en las áreas CA3-CA1 del hipocampo. El modelo fue probado con un robot móvil en un ambiente abierto. En una primera fase, el robot explora el ambiente de manera aleatoria, y elabora progresivamente el mapa cognitivo creando un nuevo nodo por cada nueva transición y ligando nodos conforme son encontrados consecutivamente. El experimento consistió únicamente en el aprendizaje de un camino muy simple formado por cinco transiciones. Aún cuando el experimento resultó exitoso, los autores reconocen que con su modelo no es posible distinguir entre lugares visualmente similares que aparecen en corredores largos o en condiciones de oscuridad, lo cual no ocurre en el modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008) debido al uso de información kinestésica además de información visual derivada de marcas externas como entrada al sistema.

2.4.5. El modelo de Arleo y colaboradores (2004)

En el modelo de Arleo y colaboradores (Arleo et al., 2004), los estímulos externos son interpretados por células especializadas llamadas de fotografía para caracterizar las regiones del ambiente mediante patrones sensoriales distintos, lo cual resulta en una representación espacial alotética, y los estímulos internos son integrados en el tiempo para proveer una representación idiotética. Ambas representaciones, alotética e idiotética, se combinan para formar una representación espacial en el hipocampo que consiste de un gran número de campos de lugar solapados. Cada vez que el robot se encuentra en un nuevo lugar del ambiente, todas las células de fotografía activas simultáneamente se conectan a una nueva célula de lugar del hipocampo. A la nueva sinapsis se le asigna un peso aleatorio, y posteriormente su eficacia cambia de acuerdo a la regla de aprendizaje de Hebb. Cuando el robot visita un lugar, verifica primero si existen células de lugar que lo codifiquen. Finalmente, para posibilitar la navegación, el modelo incorpora una población de células de acción cuya actividad provee comandos de dirección de movimiento. Para cada tipo de meta (agua o comida, por ejemplo), cuatro neuronas de acción (codificando las acciones aloécnicas norte, sur, este y oeste) son disparadas por la capa de células de lugar. Las sinapsis de las células de lugar a las neuronas de acción son modificadas para aprender una función que mapea localidades espaciales continuas en acciones motrices. Se utiliza aprendizaje por refuerzo para encontrar dicha función. Este modelo tiene grandes similitudes con el modelo ITAM (el modelo desarrollado por Barrera (Barrera and

Weitzenfeld, 2008)), el cual agrega la construcción explícita de un mapa topológico de lugares y de sus relaciones métricas. Al respecto, tanto el modelo de Arleo y colaboradores como el de Burgess y colaboradores utilizan la activación de las células de lugar para controlar directamente las acciones motrices a ejecutar por el robot a través de una capa de cuatro células de acción que codifica las acciones aloécnicas norte, sur, este y oeste. Finalmente, el modelo de Arleo no está ligado en absoluto con experimentos reales practicados con ratas, y aunque utiliza una técnica estándar de aprendizaje por refuerzo, no incluye el aspecto motivacional que caracteriza el comportamiento de los animales, y tampoco predice y adapta expectativas de recompensa durante la exploración del ambiente para ser explotadas durante la navegación orientada a metas.

2.4.6. El modelo de Milford y colaboradores (2006-2012)

El trabajo realizado por Milford y colaboradores (Milford et al., 2006) se interesa por la efectividad de los modelos del hipocampo de la rata en aplicaciones con robots móviles explorando ambientes grandes que incluyen señales visuales naturales. Nuestro interés, en cambio, consiste en asignar a robots móviles capacidades de cognición espacial similares a las encontradas en roedores, con el afán de producir comportamientos comparables y eventualmente proveer retroalimentación valiosa a neurocientíficos experimentalistas. A pesar de esta diferencia en cuanto al propósito de la investigación, nuestro modelo coincide con el de Milford y colaboradores en algunos aspectos relacionados con el mapeo y la adaptación del mapa, y contrasta con él en la navegación orientada a metas. Específicamente, el modelo de Milford y colaboradores construye un mapa topológico de experiencias donde cada experiencia representa una fotografía de la actividad registrada a partir de células de posición y de células de vista local en un tiempo dado. Las células de posición codifican la localización y orientación físicas del robot, mientras que las células de vista local codifican información visual y forman parte de la entrada a las células de posición. Una escena visual familiar activa una célula de vista local, que a su vez inyecta actividad en las células de posición asociadas con ella. Las transiciones entre las experiencias almacenadas en el mapa están asociadas con información referente al movimiento físico del robot cuando pasó de una experiencia a otra; en particular, la magnitud de la rotación y la duración de la transición. En el caso del modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008), los nodos almacenados en el mapa topológico que el modelo construye también representan asociaciones entre patrones de información visual y señales de integración de trayectoria, y la actividad registrada en la población completa de células de lugar, mientras que las transiciones entre nodos están asociadas con información métrica derivada de la locomoción de la rata referente a su dirección aloécica al pasar de un nodo a otro y a la cantidad de pasos que ejecutó para hacerlo.

El mapa de experiencias de los autores puede ser adaptado ante cambios físicos del ambiente, lo cual implica la eliminación/creación de experiencias y la actualización de transiciones entre experiencias. En cuanto al aspecto de navegación, la información temporal almacenada en el mapa de experiencias de Milford y colaboradores se emplea para encontrar la ruta más rápida que conduce a la meta, y posteriormente, la información espacial y conductual almacenada en las transiciones entre experiencias se utiliza para navegar hacia el objetivo. En contraste, como se ha mencionado, el modelo desarrollado por Barrera (Barrera and Weitzenfeld, 2008) considera el estado motivacional de la rata en una arquitectura de aprendizaje por refuerzo que permite al animal aprender y desaprender localidades de recompensa, y que soporta la navegación hacia la meta desde cualquier punto de partida dentro del ambiente.

2.4.7. El modelo de Antonelo y Schrauwen (2009)

Antonelo y Schrauwen (Antonelo and Schrauwen, 2009) proponen una arquitectura de tres capas para modelar neuronas de lugar y en cierto sentido las neuronas grilla con el objetivo de resolver el problema de localización. Realizan experimentos con un robot simulado mostrando su capacidad de localizarse en el entorno con estructura de laberinto. El robot es dotado con 17 sensores de corta distancia y 17 sensores de color, y los comandos permiten cambiar la dirección entre -15 y 15 grados manteniendo siempre una velocidad lineal constante. Al modelo ingresa únicamente información de los sensores de distancia y color, no haciendo uso de información propioceptiva (p. ej. odometría). El modelo combina las técnicas de Reservoir Computing (RC), Slow Feature Analysis (SFA), e Independent Component Analysis (ICA) para el modelado de las neuronas grilla y de lugar. La salida de la capa SFA presenta disparos tipo grilla y la salida de la capa ICA presenta mayoritariamente características de disparo de neuronas de lugar. La Figura 2.15 presenta la jerarquía de capas del modelo propuesto. La entrada al modelo es un conjunto de neuronas dado por $u(t)$, que entregan al modelo la lectura de los sensores en cada paso de la ejecución. La estrategia de control de movimiento del robot está diseñada para recorrer completamente el laberinto. Los experimentos llevados adelante muestran que la capa de neuronas grilla presentan múltiples disparos en el entorno y son dependientes de la dirección del robot. La mayoría de las neuronas de lugar disparan en un solo lugar del entorno, si bien algunas no disparan en ningún lugar, y al igual que las neuronas grilla también dependen de la dirección. El modelo no usa información propioceptiva pero la memoria de corto plazo del reservorio (reservoir) es capaz de eliminar el alias perceptual que ocurre al usar solo la información de los sensores, permitiendo que el sistema aprenda la información relevante a partir del flujo de entrada.

El modelo propuesto por Antonelo y Schrauwen resuelve únicamente la localización del robot en un laberinto sin tener en cuenta el resto de los aspectos de navegación. Si bien utilizan neuronas grilla y de lugar, los aspectos biológicos y sus propiedades no son tenidas en cuenta para su diseño, por ejemplo las neuronas grilla ni reciben información propioceptiva ni presentan patrones regulares.

2.4.8. El modelo de Koene y Prescott (2009)

El modelo propuesto por Koene y Prescott (Koene and Prescott, 2009) presenta la integración del hipocampo, la amígdala y el ganglio basal con el objetivo de investigar estas áreas clave en el cerebro de la rata para llevar adelante tareas de búsqueda de alimento. Se le asocia al hipocampo el relacionar la entrada sensorial con el lugar, a la amígdala con la asociación de valores con lugares e información sensorial, y al ganglio basal con la selección de acciones basada en información sensorial. La Figura 2.16 presenta el diagrama de los principales componentes y como estos interactúan.

Este trabajo, además de intentar entender el funcionamiento interno de cada una de estas áreas, también estudia la interacción entre ellas. Los experimentos fueron realizados sobre simulación en laberintos radiales de cuatro brazos.

La tarea para evaluar el desempeño del modelo se denomina tarea con laberinto + con recompensas diferenciadas (differentially rewarded plus-maze task), al final de cada brazo se colocan diferentes cantidades de agua y al final del entrenamiento se evalúa la preferencia del animal hacia los lugares con mayor cantidad de agua. El módulo del hipocampo integra de manera exitosa información visual y de auto-movimiento para establecer su localización respecto de los elementos que lo rodean de manera de proporcionar información de lugar como una clave contextual para desambiguar estímulos visuales idénticos. La amígdala usa esta información contextual para modular relevancia de las

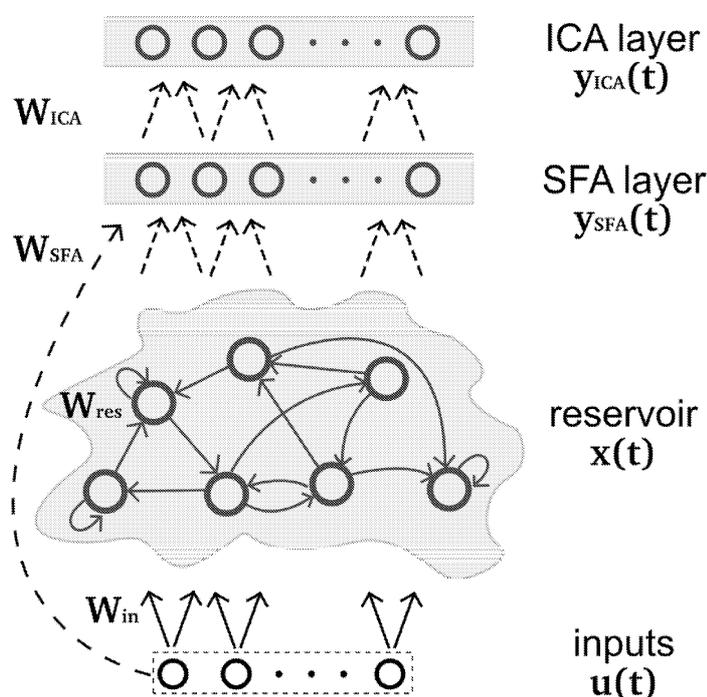


Figura 2.15 – Arquitectura del modelo de Antonelo y Schrauwen (Antonelo and Schrauwen, 2009).

entradas sensoriales las entradas y de esta manera guiar la selección de acciones en el ganglio basal hacia el estímulo con mayor recompensa.

2.4.9. El modelo de Samu y colaboradores (2009)

El modelo de Samu y colaboradores (Samu et al., 2009) utiliza información idiotérica y alotérica para dar lugar a neuronas grilla y de lugar, y simular su aprendizaje en un entorno virtual. A través de aprendizaje competitivo logra generar campos de lugar y mediante realimentación entre el hipocampo y corteza entorrinal, ajustando los pesos de las conexiones con aprendizaje hebbiano, permiten que las neuronas de lugar afecten la dinámica de las neuronas grilla. De esta forma, la realimentación desde las neuronas de lugar permite estabilizar los disparos de las neuronas grilla.

El modelo de neuronas grilla es una red neuronal que implementa un sistema atractor de dos dimensiones. Utiliza varias reglas de aprendizaje entre las capas de neuronas, algunas más biológicas que otras, inspiradas en la regla hebbiana. La Figura 2.17 presenta el diagrama de los principales componentes y como estos interactúan.

El propósito de los experimentos desarrollados es integrar las entradas y generar una representación unificada del entorno a través de las neuronas de lugar. Los experimentos fueron realizados sobre simulación con un robot capaz de obtener imágenes panorámicas con un campo horizontal de 360° y detectar obstáculos con 20 sensores de distancia que emulan los bigotes. El sistema motor del robot es diferencial, realizando avances a velocidad constante y giros a la izquierda o derecha de 0.3 radianes. El comportamiento del robot intenta realizar una exploración del entorno mediante la elección aleatoria en los comandos de giro. Los experimentos muestran la estabilidad de las neuronas grillas cuando aplican el mecanismo de realimentación propuesto y cómo se reflejan los mismos

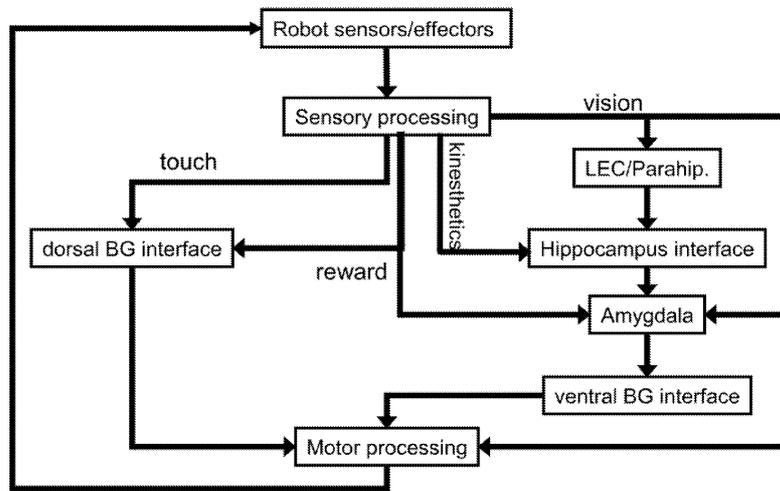


Figura 2.16 – Arquitectura del modelo de Koene y Prescott (Koene and Prescott, 2009).

patrones de disparos cuando el robot es sometido a distintos entornos o el entorno es escalado en alguna de sus dimensiones.

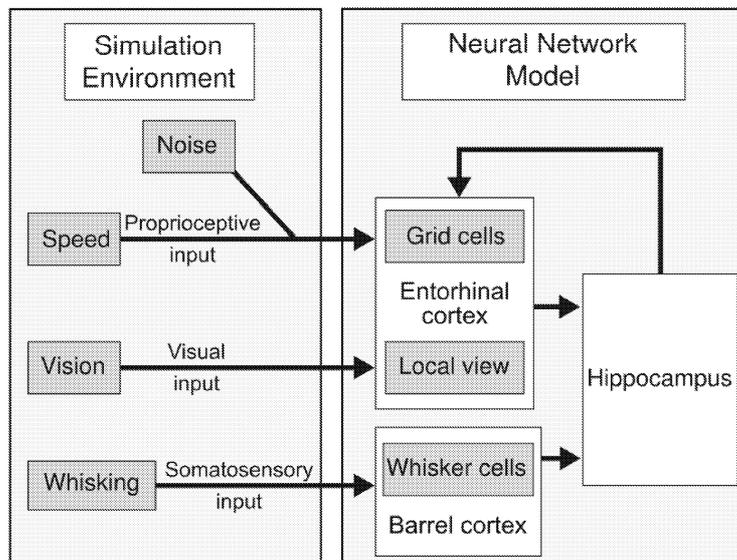


Figura 2.17 – Arquitectura del modelo de Samu y colaboradores (Samu et al., 2009).

2.4.10. El modelo de Cheung y colaboradores (2012)

El modelo de Cheung y colaboradores (Cheung et al., 2012) analiza la necesidad de una representación espacial unificada y multimodal para la navegación, lo cual es un aspecto actualmente discutido respecto de la cognición espacial en los animales. La mayoría de los experimentos sobre navegación son desarrollados con luz, de esta forma la información de claves visuales direccionales puede producir mejor exactitud y precisión de la localización. En el contexto de este estudio Cheung y colaboradores trabajan sobre entornos donde la información visual es eliminada o minimizada

para de esta forma evaluar la localización en condiciones de ausencia de luz. Los límites o bordes del entorno pueden considerarse como una subclase de marcas caracterizadas por su naturaleza geométrica, que limitan el movimiento del animal sin proporcionar ningún tipo de identificación de la posición. Al considerar las paredes del escenario homogéneas la rata simulada no puede identificar las paredes o segmentos. Por esto, el contacto con la pared no proporciona en sí mismo información de posición más allá del hecho que el animal se encuentra cerca de una pared.

Este trabajo mantiene un estimador de la posición de forma estable por más de media hora sin visión, combinando de forma óptima la información idiotética con información de borde sin características del mapa.

El modelo propuesto utiliza un filtro de partículas para combinar la información idiotética y la información de límites, permitiendo estimar de manera probabilística la posición, requiere de conocimiento previo de los límites geométricos del entorno.

El modelo es probado en simulación y en un robot real. Se utiliza el robot iRat para realizar los experimentos en entornos reales. El robot iRat es comparable en tamaño y masa con una rata de laboratorio, dispone de una cámara, parlante, micrófonos, una computadora a bordo de 1 GHz, WLAN, y tres sensores de proximidad infrarrojo a modo de bigotes. Se demuestra que la estabilidad de los campos de lugar dependen de la forma y la dimensión del escenario de prueba. Se utiliza un modelo simple de neuronas HD asumiendo errores gaussianos independientes.

Capítulo 3

Modelo de Cognición Espacial

Los modelos computacionales intentan describir de manera formal y simplificada una parte de la cognición y así permitir su ejecución en dispositivos de cómputo, proporcionando una descripción más detallada, precisa y clara. En este sentido, estos modelos podrían facilitar el entendimiento y aclarar las implicancias de una teoría, que sin su simulación podría ser difícil (McClelland, 2009).

El modelo de cognición espacial y navegación en ratas propuesto por Barrera (Barrera, 2007) comprende diversos módulos funcionales ilustrados en la Figura 3.1.a, estos módulos capturan propiedades de las estructuras del cerebro de la rata involucradas en el aprendizaje y la memoria espacial. La Figura 3.1.b presenta los dos cambios más importantes introducidos en el contexto de este trabajo al modelo original, éstos se refieren a la incorporación de un módulo de integración de trayectorias bio-inspirado y un mecanismo de realimentación para mitigar la acumulación del error inherente a él.

Luego de analizar el diseño y la implementación del modelo desarrollado por Barrera (Barrera, 2007) se evaluaron las posibilidades para su extensión y posibles mejoras a incorporar en los módulos que lo componen. Estos aspectos son presentados en los trabajos Weitzenfeld et al. (2012) y Tejera et al. (2013a). En este sentido, se definieron como las principales líneas de trabajo incorporar las neuronas grilla al modelo y evaluarlo en nuevos escenarios. Este módulo de neuronas grilla debe ser robusto frente al error que tiene la información propioceptiva y tener en cuenta aspectos biológicos que viabilicen su incorporación.

Este capítulo presenta el contexto biológico que subyace al modelo computacional, así como la descripción detallada de los cambios más relevantes llevados adelante en el contexto de este trabajo. En este sentido, se describen en detalle los módulos del modelo original cuyo entendimiento es necesario para comprender el desarrollo llevado adelante en el contexto de este trabajo, y los módulos incorporados a él. Pueden consultarse los trabajos desarrollados por Barrera (Barrera, 2007; Barrera and Weitzenfeld, 2008), donde se describen en detalle cada uno de los módulos del modelo original.

3.1. Presentación general del modelo

La Figura 3.1 muestra los módulos que componen al modelo de cognición espacial y como estos intercambian información. A continuación se realiza una breve reseña de ellos de forma de presentar una visión global del modelo para luego, en las siguientes secciones, detallar sus aspectos internos.

La motivación del animal puede asociarse con su necesidad de comer y sentirse a gusto. El módulo de motivación del modelo calcula el valor del hambre o frío. La habilidad de aprender

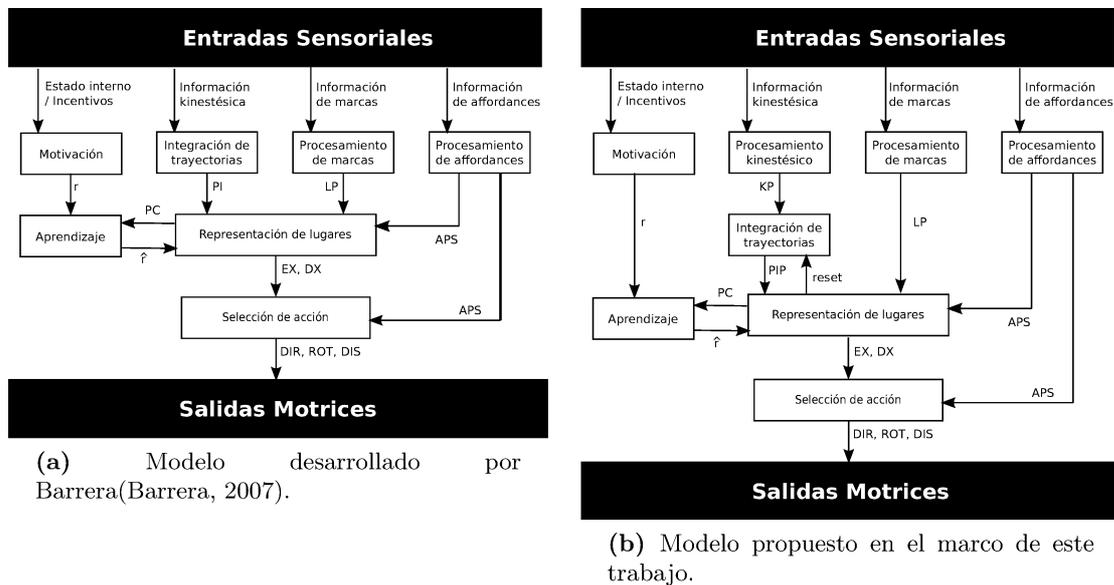


Figura 3.1 – Arquitectura del modelo de cognición espacial. Glosario: r – recompensa primaria o inmediata; PI – patrón de información kinestésica; PIP – patrón de información de integración de trayectorias; LP – patrón de información de marcas; APS – esquema perceptual de affordances; PC – patrón de información de lugar; \hat{r} – señal de refuerzo efectivo; EX – expectativas de máxima recompensa y sus direcciones correspondientes (DX); DIR – próxima dirección de la rata; ROT – rotación a ejecutar por la rata; DIS – próximo desplazamiento del animal; KP - patrón de información kinestésica; reset - señal de retroalimentación.

y desaprender localidades de recompensa es llevada adelante por el módulo de aprendizaje que implementa aprendizaje por refuerzo, interactuando directamente con el módulo de motivación.

La noción de affordances de movimiento, adoptada de Gibson (1966), representa todas las posibles acciones motrices que la rata puede ejecutar y que se determina a partir de la sensación inmediata del ambiente. En el modelo, las affordances de movimiento son codificadas a través de un vector lineal de neuronas referido como esquema perceptual de affordances (Affordance Perceptual Schema - APS), el cual representa las posibles rotaciones que la rata puede ejecutar que depende de su posición actual.

La información kinestésica se refiere a las señales internas generadas por el cuerpo de un individuo durante su locomoción. Estas señales son utilizadas por las ratas para llevar a cabo el proceso de integración de trayectoria. Las ratas utilizan, además de la información kinestésica, información visual para navegar en el ambiente, esta información permite su localización respecto a señales visuales o marcas. A partir de la información visual el módulo de procesamiento de marcas utiliza el tamaño y posición de las marcas para estimar la distancia y orientación relativa desde la posición actual.

El modelo combina en el módulo de representaciones de lugares la información sensorial kinestésica y visual, para determinar la actividad de las células de lugar del hipocampo y construir el mapa del mundo. Para representar el mapa del mundo se utiliza un grafo donde los nodos representan lugares distinguibles, y los arcos entre nodos están asociados con la dirección de la cabeza de la rata cuando se mueve de un nodo al siguiente.

En cualquier localidad del ambiente, la decisión de la rata referente a girar hacia una dirección específica está determinada en el modelo por el módulo de selección de acción que considera cuatro

aspectos: las affordances, una rotación aleatoria, rotaciones que no han sido exploradas, y la máxima recompensa esperada.

Si bien los cambios introducidos al modelo pueden parecer menores, deben señalarse dos aspectos centrales que los motivan. Primero, incorporar un módulo de procesamiento de información kinestésica y de integración de trayectorias basado en estudios anatómicos y fisiológicos, y su integración con la información visual. Segundo, poder tolerar el error acumulado inherente a los módulos de integración de trayectorias pues el modelo anterior no permite incorporar un mecanismo para tolerar el error en las entradas kinestésicas.

3.2. Contexto Biológico

Al momento de estudiar el cerebro existen múltiples aspectos que hacen referencia a la memoria espacial, esto se refleja en las múltiples estructuras, organizaciones y rutas a través de las cuales la información alcanza al hipocampo desde la corteza cerebral. Una consecuencia de esto se refleja a menudo cuando una lesión única tiene un efecto muy leve sobre el desempeño en los ensayos utilizados comúnmente para evaluar aspectos de cognición espacial en ratas. Al considerar las proyecciones de las cortezas al hipocampo aparecen un conjunto de regiones candidatas que pueden proporcionar parte de la información sensorial necesaria para llevar adelante la cognición espacial. Las regiones más destacadas que proporcionan información directa son la corteza entorrinal, corteza perirrinal, corteza postrinal y la corteza retroplenial.

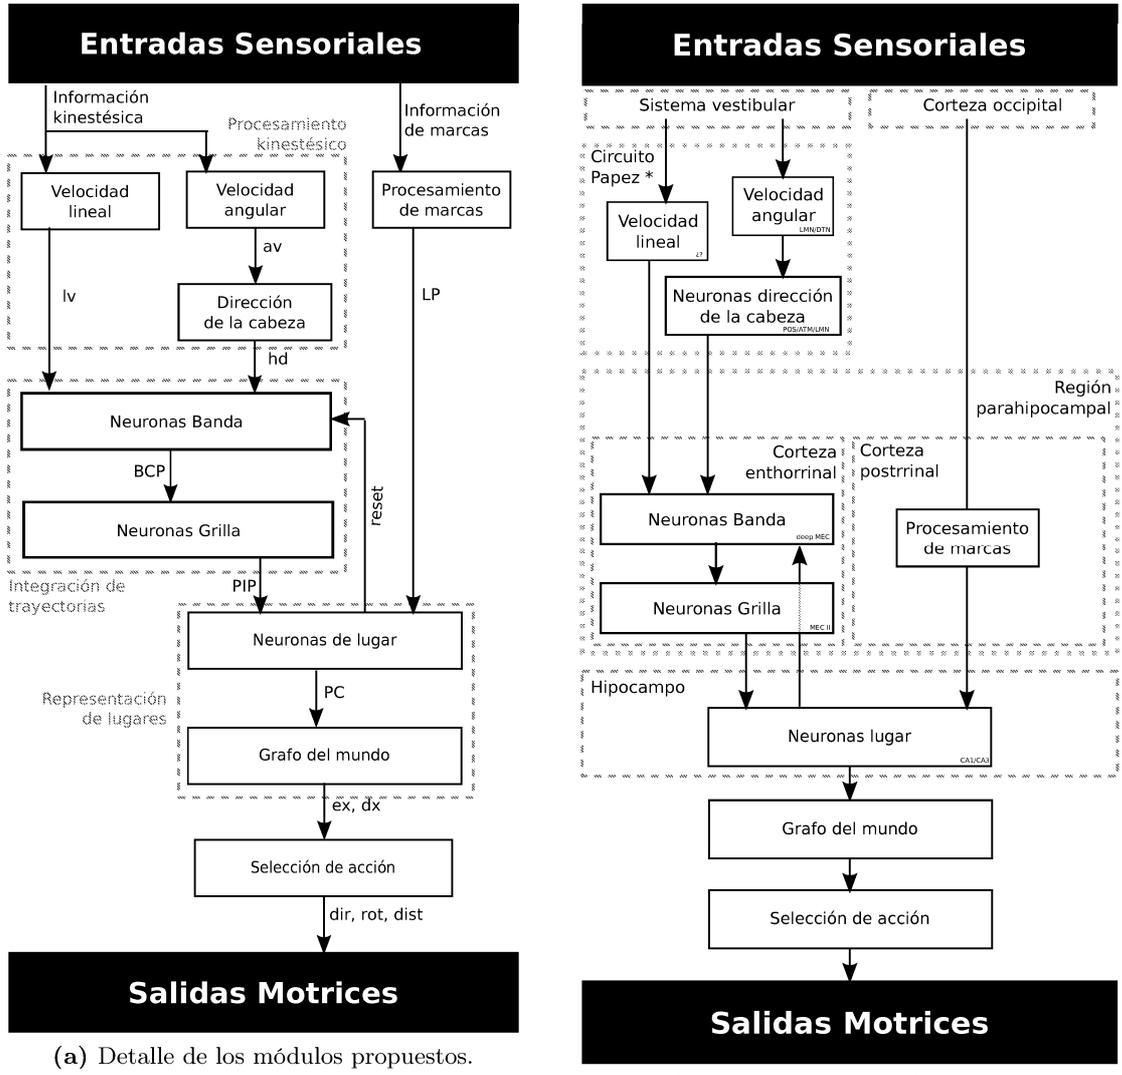
El modelo de cognición espacial utiliza información que proviene de estímulos externos (auditivo, olfativo y visuales) y estímulos internos (kinestésicos y vestibulares). En el contexto de este trabajo se utilizan como estímulos externos información visual originada en la corteza occipital y como estímulos internos información vestibular originada en los núcleos vestibulares. La información visual se transmite a las regiones parahipocámpales y de ellas al hipocampo. La información vestibular ingresa al circuito de Papez¹ atravesando la corteza entorrinal y llegando también al hipocampo.

La Figura 3.2.a presenta de manera detallada los módulos incorporados al modelo original y las neuronas involucradas con el objetivo de proporcionar un mecanismo de integración de trayectorias con inspiración biológica. En la Figura 3.2.b se ilustra el contexto biológico del modelo propuesto, indicando para cada uno de los módulos la región en el cerebro a la cual se le asocia, la interacción entre las distintas regiones del mismo y las neuronas modeladas.

El circuito de Papez es un camino neuronal en el cerebro descrito en 1937 por el neuroanatomista James Papez. Inicialmente se creía que este circuito estaba relacionado a las emociones, luego se agregaron a sus funciones la motivación, la memoria y el aprendizaje. Desde su descubrimiento varios fueron los experimentos realizados de manera de conocer como las distintas estructuras que lo conforman trabajan en conjunto. El circuito de Papez involucra varias estructuras del cerebro, comenzando y finalizando en el hipocampo. El circuito atraviesa las siguientes áreas: hipocampo → fornix → cuerpos mamilares → tracto mamilar-talámico → núcleo anterior del tálamo → corteza entorrinal → hipocampo (Shah et al., 2012). Este circuito presenta, distribuido entre las regiones que lo conforman, todas las neuronas con relevancia para la navegación utilizadas por el modelo de cognición espacial.

El sistema vestibular responde al movimiento y a estímulos gravitacionales. Esta información se envía desde el oído interno a los núcleos vestibulares que luego la envían al sistema nervioso

¹El circuito de Papez fue luego actualizado por el neurocientífico Paul D. MacLean y actualmente se conoce como sistema límbico.



(a) Detalle de los módulos propuestos.

(b) Contexto biológico de los módulos propuestos.

Figura 3.2 – Contexto biológico que subyace al modelo computacional de cognición espacial y navegación en ratas. Glosario: MEC – corteza entorrinal media; LMN - núcleo mamilar lateral; DTN - núcleo tegmental dorsal; POS - postsubiculum; ATM - tálamo anterodorsal; CA1/CA3 - áreas del hipocampo; lv - patrón de velocidad lineal; av - patrón de velocidad angular; hd - patrón de neuronas dirección de la cabeza; LP - patrón de información de marcas; PIP - patrón de integración de trayectorias; reset - señal de realimentación; PC - patrón de lugar; ex – expectativas de máxima recompensa y sus direcciones correspondientes (dx); dir – próxima dirección de la rata; rot – rotación a ejecutar por la rata; dis – próximo desplazamiento del animal.

autónomo y diversos las áreas del cerebro. El tálamo recibe la información vestibular y envía esta información al hipocampo, a través del camino de dirección de la cabeza (Carter, 2010; Taube, 2007). Las teorías actuales proponen como origen de la señal de dirección de la cabeza las conexiones recíprocas entre dos núcleos subcorticales, el núcleo tegmental dorsal y núcleo mamilar lateral. Esta señal de dirección de la cabeza se proyecta luego al tálamo anterodorsal → postsubiculum → corteza entorrinal → hipocampo. De esta manera la información dirección de la cabeza puede ser integrada con información de posición del animal en el hipocampo y en la corteza entorrinal.

El sistema hipocampal incluye a la formación hipocampal y la región parahipocampal. La formación hipocampal incluye el giro dentado (dentate gyrus - DG), hipocampo (compuesto por las capas CA3, CA2 y CA1), y el subiculum. La región parahipocampal incluye las cortezas perirrinal (PER), postrrinal (POR), entorrinal, presubicular, y parasubicular. La región córtical más íntimamente conectada con el hipocampo es la corteza entorrinal, mientras que a un nivel menor e indirecto las cortezas perirrinal, postrrinal y retroplenial, todas ellas son fuentes viables de información visual para el hipocampo. Una lesión única sobre alguna de estas cortezas tiene un efecto sorprendentemente leve sobre el desempeño en los ensayos estándares de cognición espacial en ratas. Si bien las cortezas antes indicadas están, entre otras cosas, relacionadas con el pasaje de información visual al hipocampo, la pérdida de una de ellas puede ser compensada por la presencia de las otras (Aggleton et al., 2000; Furtak et al., 2007; Agster and Burwell, 2009; 2013).

Tanto el circuito de Papez como en el sistema hipocampal presentan conexiones recurrentes a varios niveles entre los componentes que los conforman (Agster and Burwell, 2009; Shah et al., 2012). En el contexto de este trabajo interesan particularmente las conexiones recurrentes que existen entre el hipocampo y la corteza entorrinal, de manera de poder disponer de retroalimentación desde las neuronas de lugar al integrador de trayectorias.

La corteza entorrinal se estructura en seis capas, las neuronas de la capa II son de tipo grilla puro, en la capa III y más profundas (V y VI) contienen una mezcla de neuronas dirección de la cabeza, neuronas que disparan según un patrón grilla pero solo en una dirección particular, y neuronas borde (Sargolini et al., 2006).

Otras áreas del cerebro modeladas en la versión anterior de este modelo incluyen:

- Módulo de motivación basado en el hipotálamo. El hipotálamo es considerado como el área principal donde la información relacionada con el estado motivacional interno de la rata se combina con la presencia de incentivos.
- Módulo de affordances en la corteza parietal posterior. Se ha demostrado que antes de que la rata ejecute cualquier movimiento, aproximadamente la mitad de las neuronas encontradas en corteza parietal posterior exhiben actividad relacionada con el movimiento distinguiendo entre modos básicos de locomoción como rotaciones a la izquierda, a la derecha o desplazamientos hacia delante.
- Módulo de aprendizaje distribuido entre el estriado ventral y giro dentado. El módulo de aprendizaje implementa una arquitectura Actor-Crítico (Barto, 1995), donde las neuronas del estriado ventral (núcleo accumbens) llevan adelante el Crítico Adaptivo y un conjunto de unidades Actor es llevado adelante en el giro dentado (DG).

En el contexto de este trabajo se utiliza un enfoque minimalista desde el punto de vista de cantidad de regiones y de conexiones involucradas. De esta forma, se asume que la corteza occipital envía información visual a la corteza postrrinal y ésta hace llegar al hipocampo información espacial

acerca de marcas perceptibles, la cual consiste de la distancia y orientación relativa de cada marca. Como simplificación del circuito de Papez se asume que desde el oído interno la información llega a los núcleos vestibulares (núcleo tegmental dorsal y mamilar lateral), luego al tálamo y a la corteza entorrinal, y por último el hipocampo. Se incluye únicamente realimentación desde el hipocampo hacia la corteza entorrinal media, de forma de llevar adelante el mecanismo de calibración del integrador de trayectorias que permita tolerar el error propio de las señales integradas desde el sistema vestibular. Son varios los trabajos que analizan la interconexión existente entre las regiones del sistema hipocampal, Agster y Burwell (Agster and Burwell, 2009) encontraron evidencia de conexiones desde la capa CA3 a la corteza entorrinal, particularmente la capa IV de la MEC.

Teniendo en cuenta este enfoque minimalista, la información visual ingresa al modelo para ser utilizada por el módulos de procesamiento de marcas. La información de tipo kinestésico es utilizada por los módulos velocidad lineal y velocidad angular. Estos módulos integran la entrada provenientes del sistema vestibular (aceleraciones), y generan la salida para los módulos neuronas dirección de la cabeza y neuronas banda (velocidades). El módulo neuronas dirección de la cabeza toma como entrada la velocidad angular desde el módulo velocidad angular y a partir de esta produce como salida la dirección de la cabeza del animal. El módulo neuronas banda toma como entrada la velocidad lineal y la salida del módulo neuronas dirección de la cabeza y a partir de ellas produce patrón de disparos de las neuronas banda. El módulo neuronas grilla toma como entrada el patrón de disparos del módulo de neuronas banda y genera como salida un nuevo patrón con disparos grilla. En la figura 3.2 se presenta el flujo de esta información y los módulos que conforma el modelo.

El módulo de neuronas de lugar (place cell layer - PCL) recibe información de los módulos de neuronas grilla y procesamiento de marcas. La actividad de las células de lugar resulta de la integración de ambas fuentes de información. Para representar el mapa del mundo se utiliza un grafo del mundo donde los nodos representan lugares distinguibles, y los arcos entre nodos están asociados con la dirección de la cabeza de la rata cuando se mueve de un nodo al siguiente.

Por último, el módulo de selección de acción del modelo determina las salidas del modelo, la rotación requerida para orientarse hacia tal dirección, y el desplazamiento a ejecutar.

3.3. Modelos de osciladores vs atractores

En su gran mayoría, los modelos desarrollados sobre integración de trayectorias pueden clasificarse respecto a la utilización de interferencia de osciladores o atractores. En el contexto de este trabajo se utiliza la interferencia de osciladores para dar lugar a los patrones de neuronas grilla describiéndose en detalle este modelo en las siguientes secciones.

Un atractor es un estado estable de un sistema dinámico. Una red neuronal tiene un conjunto muy grande de estados. Un atractor es un conjunto cerrado de esos estados hacia los cuales el sistema tiende a evolucionar. Si el atractor es fijo una vez que es alcanzado el sistema permanece en él. Los atractores pueden organizarse de manera lineal o circular, en este caso el atractor es un conjunto continuo de estados equiprobables que forman una línea o un anillo. Toda posición en el atractor es igualmente estable, siendo posible el movimiento en la línea o anillo debido a la información en las entradas. Este tipo de atractores son usados para implementar integradores neuronales, computando el valor de una variable mediante la suma acumulada de sus incrementos en el tiempo. La información externa que ingresa al atractor puede mover la actividad a través su estructura topológica, línea o anillo, una vez que la entrada se apaga la red neuronal va a permanecer en el estado que alcanzó. Luego otra entrada puede volver a mover la red a otro estado.

En general, los atractores continuos se organizan como un conjunto de neuronas donde las neuronas cercanas topológicamente tienen conexiones excitatorias fuertes y las neuronas alejadas conexiones inhibitorias. El estado estable en estas redes consiste de una única agrupación (cluster) de neuronas activas. Este tipo de modelos de atractores continuos se han utilizado para modelar neuronas dirección de la cabeza y neuronas de lugar (Milford, 2008). En la Figura 3.3 se presenta un ejemplo de atractor continuo con topología de anillo usado para modelar una capa de neuronas de dirección de la cabeza.

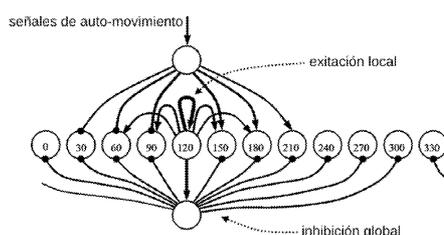


Figura 3.3 – Atractor continuo de neuronas HD.

3.4. Información kinestésica e integración de trayectorias

Como se ha indicado, los módulos de información kinestésica y de integración de trayectorias han sido incorporados al modelo original en el contexto de este trabajo basado en las nuevas evidencias fisiológicas y su consistencia anatómica. En esta sección se presenta la organización y el diseño de estos módulos, particularmente el modelo de neuronas grilla utilizado.

La información kinestésica se refiere a las señales internas generadas por el cuerpo de un animal durante su locomoción. Como se describió en el Capítulo 2 del documento, estas señales son utilizadas por las ratas para llevar a cabo el proceso de integración de trayectoria, por medio del cual, cada vez que se mueve se actualiza la información de posición en el mundo. La información kinestésica es inyectada al módulo de procesamiento de información kinestésica del modelo responsable computar la velocidad lineal y la dirección de la cabeza. La Figura 3.4 presenta el detalle de los módulos que realizan el procesamiento de información kinestésica e integración de trayectorias, y la interacción entre ellos.

El módulo de procesamiento de información kinestésica utiliza la información sensorial proveniente de estímulos internos, aceleración angular y lineal, y genera a su salida información de velocidad lineal y de dirección de la cabeza. En los mamíferos este tipo de información inercial es generada en el sistema vestibular. El sistema vestibular contiene dos estructuras claves para esto, los canales semicirculares y los órganos otolíticos. Existen tres canales semicirculares que responden a cambios en la aceleración angular y movimientos de rotación. Para completar el sistema inercial, los órganos otolíticos son los responsables de sensar aceleraciones lineales (Carter, 2010).

Este módulo de procesamiento de información kinestésica internamente está formado por tres módulos: el módulo de velocidad lineal, el módulo de velocidad angular y el módulo de dirección de la cabeza. Los módulos de velocidad lineal y angular integran la aceleración lineal y angular, para computar las respectivas velocidades. Por último, el módulo dirección de la cabeza computa a partir de la velocidad angular la dirección de la cabeza. En la versión actual del modelo los módulos velocidad lineal, velocidad angular y neuronas dirección de la cabeza no tienen una implementación

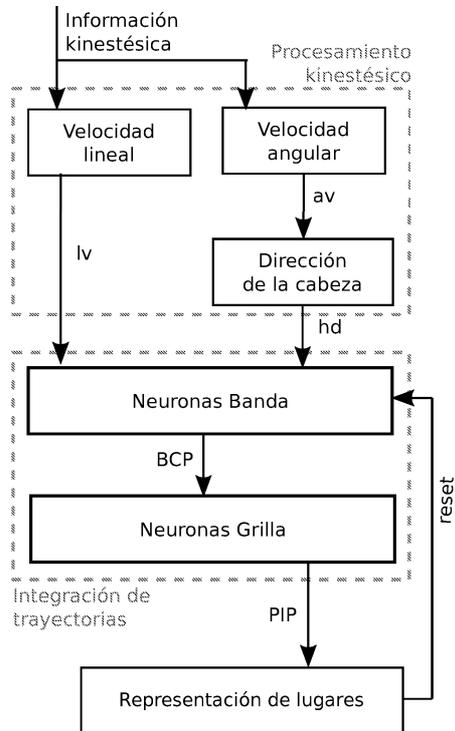


Figura 3.4 – Módulos de procesamiento de información kinestésica e integración de trayectorias, y su interacción.

con inspiración biológica, esto es, simplemente se utiliza la información vestibular, para actualizar un valor escalar generado como salida de dichos módulos.

Como se ha indicado, al registrar la actividad individual de algunas neuronas en la corteza entorrinal de las ratas, realizando una tarea de exploración en un entorno abierto, éstas muestran un patrón sorprendentemente regular en relación a la posición de la rata en el entorno. Estos patrones regulares son asociados a las denominadas neuronas grilla. Existe un gran consenso y acumulación de evidencias sobre la ubicación del integrador de trayectorias. De acuerdo con varios estudios que sugerían que el sistema encargado de integrar trayectorias estaba relacionado con circuitos recurrentes que incluían a la corteza entorrinal, estudios más reciente apuntan a la corteza entorrinal media (MEC) como el lugar donde se encuentra el integrador de trayectorias (McNaughton et al., 2006).

La grilla de cada neurona puede ser descrita a través de tres parámetros característicos:

- espaciado, distancia entre los centros de los campos
- orientación, inclinación de la grilla relativa a un eje de referencia
- fase espacial, desplazamiento en x e y relativo a un punto de referencia externo

3.4.1. Interferencia de ondas

El fenómeno de interferencias de ondas es estudiado por la física y puede ser observado en cualquier tipo de onda. Según Resnick “Cuando dos o más ondas se combinan en un punto determinado, se dice que interfieren, y el fenómeno se conoce como interferencia” (Resnick et al., 2001).

La interferencia de ondas es un fenómeno físico en el cual dos ondas se superponen generando una onda con mayor o menor amplitud que depende de las fases relativas de las ondas y de sus frecuencias. Cuando la interferencia de dos ondas crea un nuevo patrón ondulatorio de menor amplitud la interferencia entre las ondas es destructiva, si por el contrario la amplitud del patrón es mayor la interferencia es constructiva. La Figura 3.5 muestra un ejemplo de interferencia de dos ondas sinusoidales de igual amplitud y frecuencia. En la parte superior se presenta la interferencia (constructiva total) de dos ondas presentada en con fase cero mientras que la parte inferior de la imagen presenta un ejemplo de interferencia (destructiva total) donde la fase de la segunda onda es 180° .

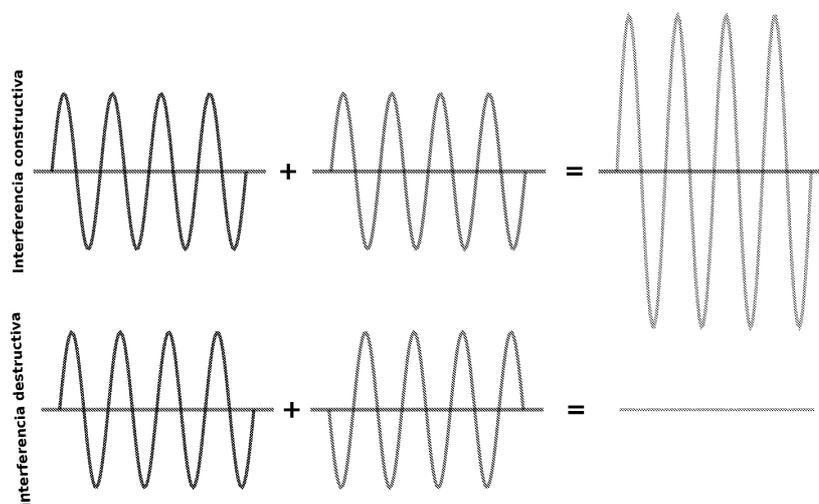
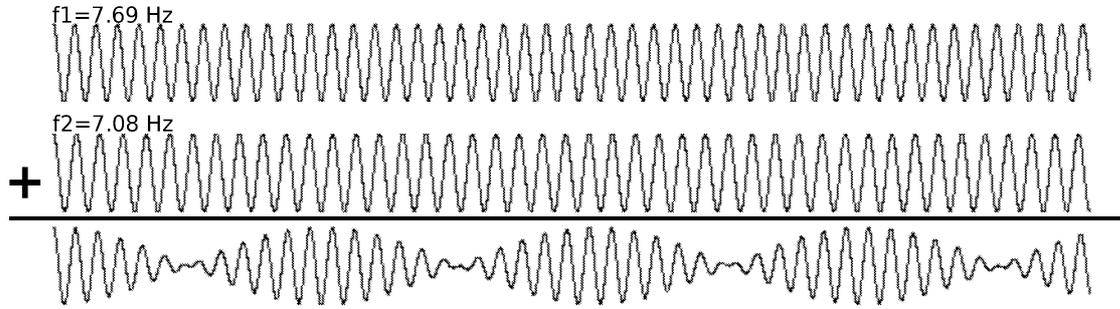


Figura 3.5 – Interferencia de dos ondas de igual amplitud y frecuencia.

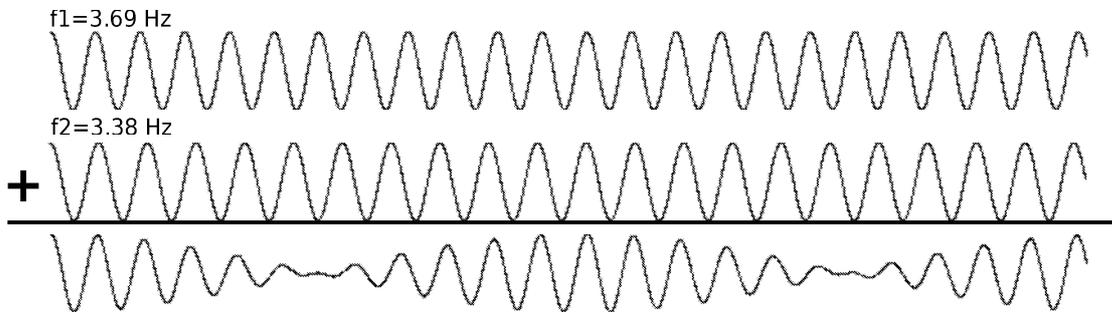
Cuando además de la fase las ondas tienen distinta frecuencia se producen patrones oscilatorios no necesariamente sinusoidales que presentan simultáneamente interferencia destructiva y constructiva. La Figura 3.6 presenta ejemplos de oscilaciones observadas en la MEC y los patrones de interferencia generados al combinarlos. La amplitud resultante es máxima cuando las ondas están en fase y va disminuyendo en la medida que éstas se van desfasando.

3.4.2. Grilla a partir de múltiples osciladores

Son muchos los trabajos de investigación sobre la función del hipocampo y su rol para codificar memoria episódica y memoria espacial. Varios de esos modelos se han centrado en la modificación de las conexiones sinápticas para codificar la asociaciones entre posiciones en el entrono, información sensorial y contexto de la tarea actual. Recientemente ha crecido el interés respecto de la interacción de las oscilaciones sub-umbral propias de una única neurona para la representación de información espacial y temporal. Este mecanismo de oscilaciones sub-umbral del potencial de membrana (subthreshold membrane potential oscillations - mpo) ha sido observado en neuronas estrelladas (stellate cells) en la capa II de la corteza entorrinal.



(a) Usando frecuencias similares a las observadas en la parte dorsal de la MEC.



(b) Usando frecuencias similares a las observadas en la parte ventral de la MEC.

Figura 3.6 – Interferencia de ondas con igual amplitud y fase.

3.4.2.1. Relación entre el espaciado y la frecuencia de los osciladores

Los patrones periódicos observados en la corteza entorrinal tienen distintas características a través del eje dorsal-ventral, con pequeñas distancias entre los centros de los campos de disparo y campos de disparo pequeños en la región dorsal y campos más separados y de mayor tamaño en la parte ventral (Hafting et al., 2005). Los datos experimentales obtenidos sobre la frecuencia de las oscilaciones sub-umbral en neuronas de la corteza entorrinal también difieren sistemáticamente a lo largo del eje dorsal-ventral (Giocomo et al., 2007). Esto es, el período de las oscilaciones sub-umbral cambia de manera consistente con el espaciado de las grillas.

El análisis de los resultados experimentales muestra que el promedio de la frecuencia de las oscilaciones sub-umbral en neuronas de la corteza entorrinal también difieren sistemáticamente a lo largo del eje dorsal-ventral (nombrado eje z). La Figura 3.7.A, muestra que las neuronas estrelladas de la corteza entorrinal dorsal (cerca de la frontera postrinal) presentan una mayor frecuencia de oscilación sub-umbral, respecto de las neuronas estrella obtenidas a partir de porciones ventrales de corteza entorrinal.

La Figura 3.7.B presenta la correspondiente frecuencia de oscilación $\left(f(z) = \frac{1}{T(z)}\right)$, en función de la posición en el eje dorsal-ventral. La Figura 3.7.C muestra el ajuste lineal sobre valor promedio del periodo (T) obtenido experimentalmente sobre registros en el eje z . Este ajuste está dado por la siguiente ecuación:

$$T(z) = 0,094z + 0,13 \tag{3.1}$$

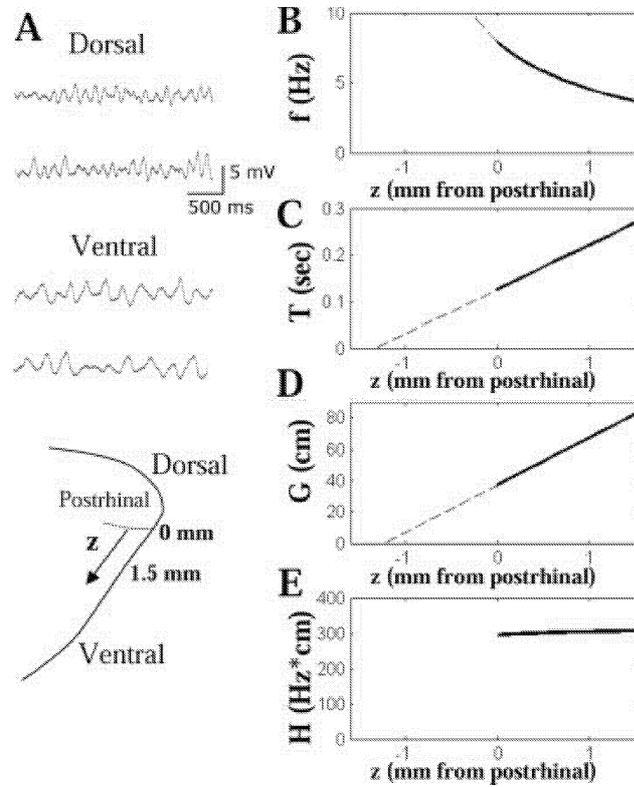


Figura 3.7 – Gráficas con la variación de la frecuencia, período, espaciado a través del eje dorsal - ventral. A) Frecuencia de oscilación subumbral de neuronas ventrales y dorsales. B) Variación de la frecuencia en función de la distancia a la frontera postrhinal. C) Variación del período. D) Espaciado de las neuronas grilla relativo a la frontera postrhinal. E) Valor escalado, H , basado en el producto de f y G . (Hasselmo et al., 2007)

De manera análoga se presenta en la Figura 3.7.D la gráfica del espaciado de los campos (G), la cual presenta al igual que el periodo una relación lineal con la posición dada por la ecuación $G(z) = 30z + 37,09$. Es posible relacionar la frecuencia de oscilación y el espaciado de la siguiente manera:

$$G(z) = \frac{H(z)}{f(z)}. \quad (3.2)$$

La gráfica para H se presenta en la figura 3.7 E, en la misma puede observarse que ella es casi constante y para el rango de los experimentos realizados por Giacomo su valor aproximado es de 300 Hz cm. Utilizando esta constante es posible determinar el espaciado para una determinada frecuencia y viceversa. El Cuadro 3.1 ilustra con algunos valores aproximados del período, la frecuencia y el espaciado para distintas posiciones en el eje z basado en las ecuaciones presentadas.

3.4.2.2. Derivación de la ecuación de disparos grilla

Esta sección presenta de manera resumida el desarrollo del modelo de interferencia de osciladores de Hasselmo (Hasselmo et al., 2007), desde la Ecuación 3.3 a la 3.10. Como se define en la Ecuación 3.3, el voltaje de la oscilación de membrana (mpo) de una neurona está definido por la función

z (mm)	Características de la neurona grilla		
	T(z) (s)	f(z) (Hz)	G(z) (cm)
0.0	0.13	7.69	39
0.5	0.177	5.65	53
1.0	0.224	4.46	67
1.5	0.271	3.69	81

Cuadro 3.1 – Ejemplos aproximados de período, frecuencia y espaciado.

V como la suma de la oscilación del soma a una frecuencia f y una oscilación dendrítica a una frecuencia f_d .

$$V(t) = \cos(2\pi ft) + \cos(2\pi f_d t) \quad (3.3)$$

La Figura 3.6 muestra la interacción de estas dos ondas de diferente frecuencia y el patrón de interferencia resultante, cuya envolvente varía su amplitud y tiene una menor frecuencia. Esto es similar a la interferencia que ocurre cuando dos notas musicales tienen frecuencias similares y dan como resultado una onda con aumentos y disminuciones periódicas de la intensidad que se denominan pulsaciones o batidos. La frecuencia de pulsación (beat) está dada por la diferencia entre la frecuencia de la dendrita y la del soma:

$$f_b = f_d - f. \quad (3.4)$$

Si se asume una dirección de movimiento fija a una velocidad lineal s constante durante T_b segundos, la distancia recorrida será la longitud de onda de la onda de pulsación.

$$\lambda_b = sT_b. \quad (3.5)$$

Salvo experimentos muy simples, difícilmente el movimiento del agente será en una dirección fija a una velocidad constante. Sin embargo, independiente de la velocidad y la dirección tomadas a partir de la posición inicial los disparos de una neurona grilla ocurren en el mismo intervalo de tiempo T , pero este intervalo se va a corresponder a distintas distancias recorridas dependiendo de la dirección y velocidad del movimiento. Sea \vec{v} el vector velocidad que se corresponde con una velocidad lineal s y una dirección dada por ϕ . Si consideramos el movimiento en una dimensión, x , el movimiento en esta dimensión está dado por la proyección de \vec{v} en x . Si el ángulo ϕ está dado respecto de la dimensión x , el desplazamiento queda determinado por $\Delta x = s \cos(\phi)$. Fisiológicamente esta información está disponible a partir de la salida de las neuronas de velocidad lineal y dirección de la cabeza. De esta manera la entrada a las neuronas de la corteza entorrinal deben responder de manera dependiente a la velocidad y a la dirección de la rata relativa a una dirección preferida determinada por ϕ_{HD} . De esta manera es posible codificar el desplazamiento en el eje determinado por la dirección preferida, ϕ_{HD} , de una dirección de la cabeza según:

$$\bar{v}_{HD} = s \cos(\phi - \phi_{HD}). \quad (3.6)$$

Si consideramos la distancia entre los lugares donde dispara es posible transformar la velocidad en una dirección arbitraria, en un desplazamiento en el eje determinado por la dirección preferida ϕ_{HD} :

$$\lambda_b = vT_b = s \cos(\phi - \phi_{HD}) T_b = s \cos(\phi - \phi_{HD}) / f_b. \quad (3.7)$$

Para mantener espacialmente fijos los disparos debe mantenerse constante la longitud de onda espacial λ_b sin importar los valores que tomen la velocidad y el ángulo. A partir de la Ecuación 3.7 queda claro que debe ajustarse la frecuencia de pulsación f_b para compensar los cambios en velocidad y ángulo. Entonces, para que la longitud espacial se mantenga constante la frecuencia de pulsación debe ajustarse de acuerdo a: $f_b = Bs \cos(\phi - \phi_{HD})$, donde B es una constante igual al inverso de la frecuencia de pulsación. Esta frecuencia de pulsación puede sustituirse en la Ecuación 3.4 y obtenerse de esta forma:

$$f_d = Bs \cos(\phi - \phi_{HD}) + f. \quad (3.8)$$

En estas condiciones, la neurona presenta interferencia con longitud de onda λ_b en la dirección ϕ_{HD} . Esta interferencia ocurre en bandas perpendiculares a la dirección de la cabeza preferida. Pueden generarse disparos grilla al combinar en una sola neurona varias bandas con distintas direcciones preferidas. En la Figura 3.8 se presentan diagramas para aclarar los resultados y el uso de las ecuaciones desarrolladas hasta ahora. Las subfiguras A-C y E muestran el recorrido de una rata en un entorno circular indicando en negro los lugares en los que la neurona dispara y en gris los lugares por los que pasó pero no disparó. La Figura 3.8.A muestra un ejemplo de disparos banda generados por una neurona cuando la dirección preferida es 0° ($\phi_{HD}=0$), la B y C muestran las bandas cuando los ángulos usados son 120° y 240° respectivamente. La Figura 3.8.D presenta un diagrama de una neurona grilla que utiliza como entrada la salida de tres neuronas banda alineadas a los ángulos 0° , 120° y 240° . De la combinación de estos tres disparos banda es posible generar disparos grilla (Burgess et al., 2007) como se muestra en la Figura 3.8.E. El modelo de múltiples osciladores banda para la generación de disparos grilla requiere que las direcciones preferidas difieran en múltiplos de 120° , pudiendo tolerar pequeñas variaciones en la dirección preferida.

Por último, la subfigura 3.8.F muestra la relación que existe entre la longitud de onda y el espaciado, a partir del triángulo equilátero que se forma de tomar el centro de tres campos vecinos.

Como se puede apreciar en la Figura 3.8.F, la distancia recorrida entre períodos de interferencia constructiva para una dendrita no es el espaciado de la neurona grilla, pues el modelo propone que los disparos grilla ocurren de la interferencia banda de múltiples dendritas. En ella se puede apreciar que la longitud de onda λ_b de la interferencia banda se corresponde con la altura del triángulo equilátero y el espaciado de la neurona grilla G se corresponde con el lado del triángulo. Si se considera medio triángulo, se forma un triángulo rectángulo que posibilita la aplicación del teorema de Pitágoras, por lo que $G^2 = (G/2)^2 + \lambda_b^2$ y al despejar G se obtiene que $G = \lambda_b (2/\sqrt{3})$. Como se indicó antes $\lambda_b = 1/B$, por lo que al combinar estas dos ecuaciones se obtiene que $G = 2/(\sqrt{3}B)$. Utilizando esta última ecuación y la Ecuación 3.2 se obtiene que $G = 2/(\sqrt{3}B) = H/f$, lo que permite determinar B como $B = f2/(H\sqrt{3})$. Si definimos $B_H = 2/(H\sqrt{3})$ podemos reescribir la ecuación anterior como $B = B_H f$ y usar el valor constante determinado experimentalmente para H . Esta definición y la Ecuación 3.8 permite reescribir la Ecuación 3.3 de la siguiente manera:

$$V_b(t) = \cos(2\pi ft) + \cos(2\pi(f + B_H f s \cos(\phi - \phi_{HD}))t). \quad (3.9)$$

Como ya se ha indicado el modelo de Burgess y colaboradores (Burgess et al., 2007) propone la generación de los disparos grilla a partir de la entrada de varias bandas. A partir de la multiplicación de diferentes $V(t)$ se llega a la ecuación de generación de disparos grilla:

$$V_g(t) = \Theta \left[\prod_{HD} (\cos(2\pi ft) + \cos(2\pi(f + f B_H s \cos(\phi - \phi_{HD}))t) + \varphi) \right], \quad (3.10)$$

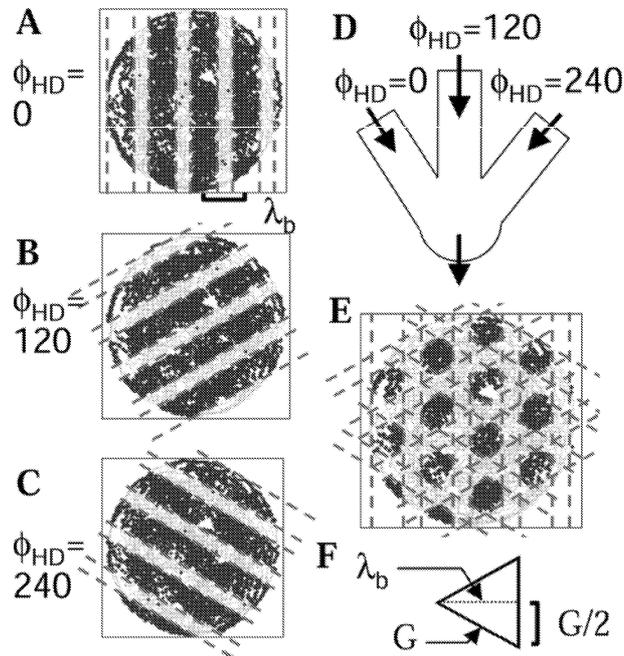


Figura 3.8 – Ejemplo de neuronas banda y su combinación. De A) a C) muestran las bandas generadas debido a la modulación de la frecuencia dendrítica al utilizar respectivamente neuronas direcciones preferidas de 0° , 120° y 240° . D) Esquemático que ilustra la interacción entre las tres bandas de interferencia. E) El producto de las tres bandas de interferencia genera en el soma disparos con patrón grilla. F) Triángulo equilátero que relaciona la longitud de onda (altura) de pulsación con el espaciado (lado). (Hasselmo et al., 2007)

donde $V_g(t)$ representa el patrón de disparo de una neurona grilla en función del tiempo, Θ es una función escalón con el umbral ajustado a 1.8, Π representa el producto de las bandas determinadas por el conjunto de direcciones preferidas HD y $\phi_{HD} \in HD$. El parámetro φ representa la fase inicial de cada potencial de membrana y determina la fase espacial de la neurona grilla.

Uno de los principal problemas del modelo presentado es su sensibilidad al ruido en las entradas. Cualquier ruido en la velocidad o en la dirección del movimiento va a causar un corrimiento gradual de la posición del agente que se acumula con el tiempo.

3.4.3. Módulo integrador de trayectorias

El módulo integrador de trayectorias recibe como entradas la velocidad lineal y la dirección actual desde el módulo de procesamiento de información kinestésica. La salida del módulo integrador de trayectorias es un patrón de neuronas grilla construidas a partir de la propuesta de Hasselmo y colaboradores (Hasselmo et al., 2007).

En dicha propuesta el disparo de una neurona grilla está gobernado por la amplitud dada por la Ecuación 3.10.

Esta ecuación depende del tiempo, toma como entradas los disparos de tres neuronas dirección de la cabeza (head direction cell - HD cell), determinadas por sus direcciones preferidas (ϕ_{HD}), y la magnitud de la velocidad (s). La constante B_H depende de la función H que es considerada contante a partir de los datos obtenidos experimentalmente (Hasselmo et al., 2007), la constante f es la frecuencia de oscilación sub-umbral y φ es la fase inicial de cada potencial de membrana.

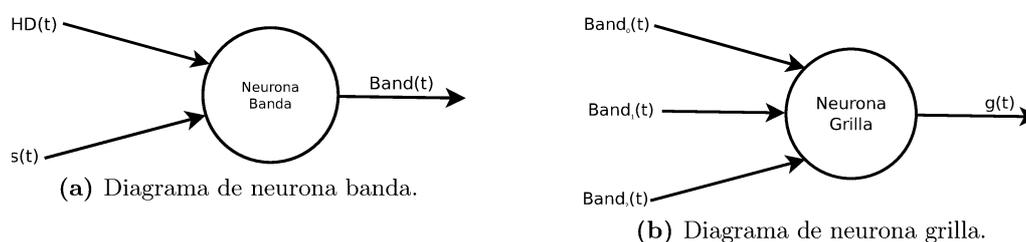


Figura 3.9 – Diagrama de neuronas incluidas en el módulo de integración de trayectorias.

La Figura 3.9.a muestra un esquema de las neuronas banda las cuales a partir de la entrada proporcionada por una neurona dirección de la cabeza y la velocidad lineal, computan la expresión dentro de la productoria de la Ecuación 3.10, esto es, la suma de los dos cosenos. La Figura 3.9.b muestra un esquema de la neurona grilla, que a partir de tres neuronas banda llevan adelante la productoria y luego la función de activación para completar el cómputo de la ecuación 3.10.

Al modificar en la Ecuación 3.10 los valores de f , θ_{HD} y φ , se afectan respectivamente las características de espaciado, orientación y fase del disparo de la neurona grilla.

Inicialmente, para evaluar los módulos de procesamiento de información kinestésica e integración de trayectorias, se utilizó un conjunto de puntos obtenidos a partir del seguimiento de la trayectoria de ratas en experimentos sobre neuronas grillas realizados por Hafting y Fyhn en el laboratorio de Moser². En la Figura 3.10 se puede apreciar con trazo negro el recorrido de la rata en el escenario circular de experimentación para estos datos.

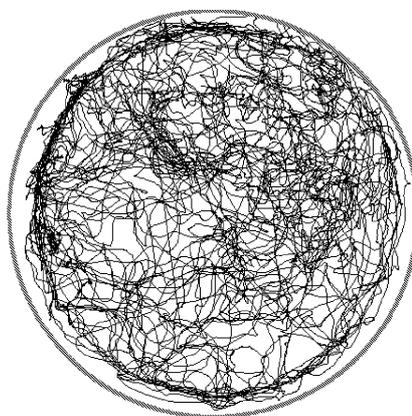


Figura 3.10 – La trayectoria de la rata en el escenario circular publicada por Hafting y Fyhn.

Las Figuras 3.11 a 3.13 presenta los puntos del entorno en los cuales se activa una neurona grilla utilizando distintos parámetros de f , θ_{HD} y φ . Estas figuras se generaron utilizando el módulo de procesamiento de información kinestésica e integración de trayectorias, utilizando como entrada la información vestibular que se produciría al seguir la trayectoria propuesta por Hafting y Fyhn.

El espaciado de los patrones grilla cambia a través del eje venral-dorsal de la MEC (eje z), con pequeñas distancias entre centros de los campos grilla en la parte dorsal de la MEC (cerca de la frontera postrinal) y mayores distancias entre los campos de disparos para las regiones más

²Disponible en la página web www.cbm.ntnu.no.

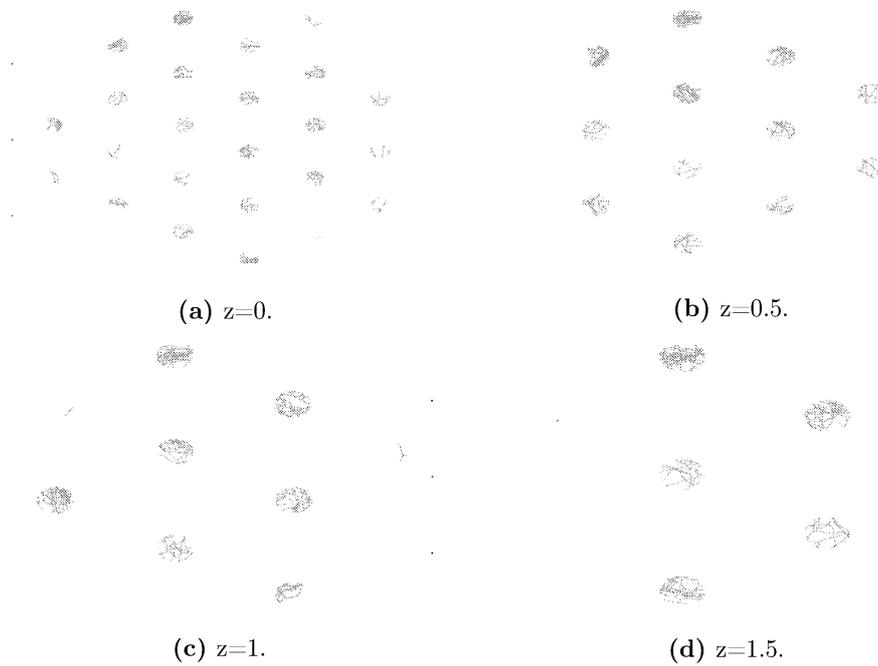
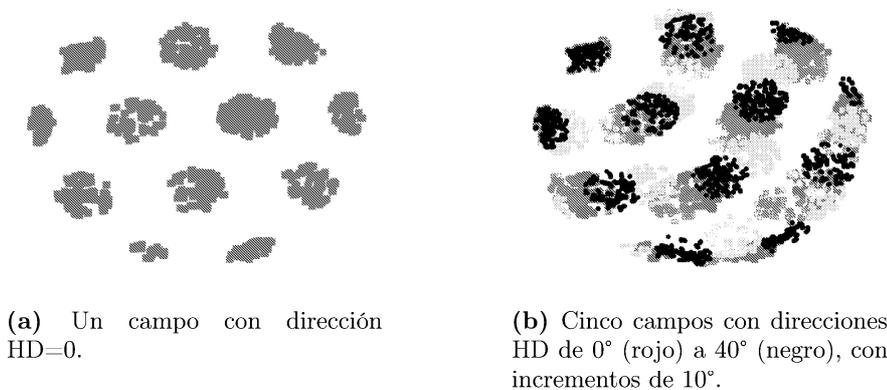


Figura 3.11 – Campos grilla para distintas posiciones en eje ventral-dorsal de la MEC en un entorno circular.

ventrales de la MEC. En el trabajo de Hasselmo y colaboradores (Hasselmo et al., 2007) se determina la relación entre f y z a partir de los datos obtenidos experimentalmente según la ecuación:

$$f(z) = \frac{1}{0,094z + 0,13} \quad (3.11)$$

La Figura 3.11 presenta los resultado de modificar únicamente el valor de la frecuencia de oscilación subumbral, cada figura muestra la posición z (posición en milímetros desde la frontera postrinal) utilizada para generar la frecuencia de oscilación subumbral, f , dejando fijos los otros dos parámetros de la Ecuación 3.10.



(a) Un campo con dirección HD=0.

(b) Cinco campos con direcciones HD de 0° (rojo) a 40° (negro), con incrementos de 10°.

Figura 3.12 – Campos grilla para distintas direcciones preferidas de las neuronas banda.

La Figura 3.12 muestra los campos grilla como resultado de modificar únicamente el valor de direcciones preferidas de las neuronas banda, θ_{HD} , determinando con ellas la orientación de patrón de disparos grilla. La subfigura a) muestra los campos para una neurona grilla con orientación 0° . La subfigura b) muestra simultáneamente los campos de cinco neuronas con igual espaciado y fase espacial, y diferentes orientaciones de 0° a 40° con incrementos de 10° .

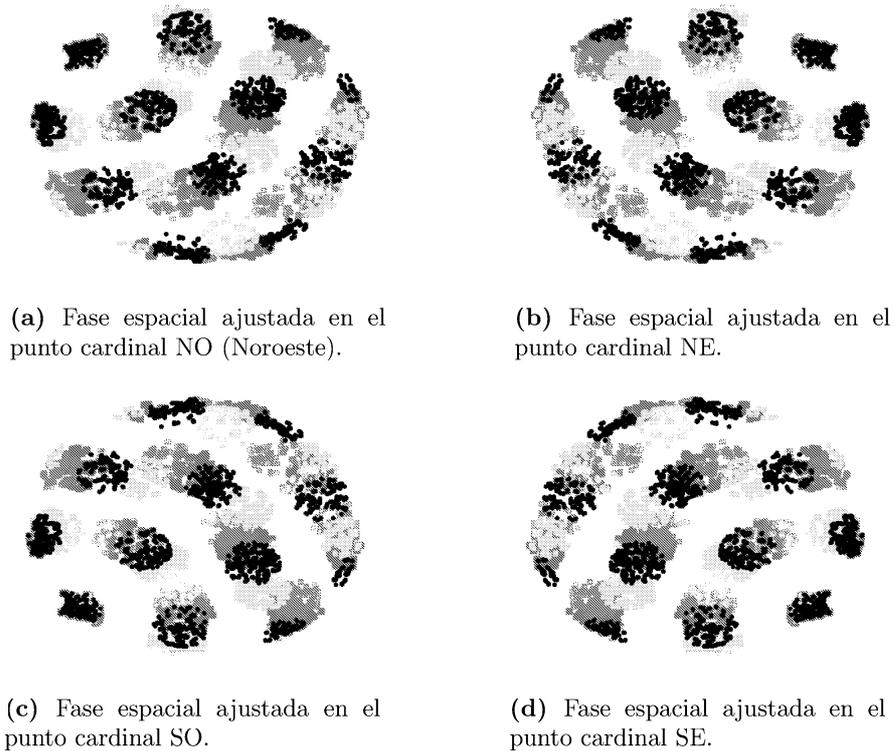


Figura 3.13 – Campos grilla para distintas fases espaciales.

La Figura 3.13 ilustra el efecto de modificar la fase espacial sobre campos grilla, para visualizar el efecto de cambiar la fase en cada figura se muestran con distintos colores cinco neuronas grilla, donde se mantiene la fase espacial y el espaciado, y se varía sólo la orientación. Puede observarse en ellas un punto fijo para las distintas orientaciones que marca la fase espacial. La subfigura a) muestra los campos de cinco neuronas grilla cuando la fase espacial de lugar de todas ellas se ajusta a la posición noroeste. Las siguientes subfiguras presentan otras fases espaciales ajustadas a otros puntos cardinales.

3.5. Transformación grilla - lugar

Desde el descubrimiento de las neuronas grilla, varios han sido los modelos que muestran la generación de campos de lugar a partir de la combinación de campos grilla con diferentes parámetros, topologías y métodos de aprendizaje (Cheng and Frank, 2011). El trabajo pionero de Solstad y colaboradores (Solstad et al., 2006) determina que la suma de al menos diez neuronas grilla con diferentes espaciados y similares fases espaciales y orientaciones, luego de aplicar una inhibición global resulta en la formación de un único campo de lugar en el entorno. Otros modelos proponen

el uso de aprendizaje competitivo, hebbiano o redes neuronales de función de base radial (radial basis function networks - RBFN) para ajustar los pesos sinápticos de manera de producir un único campo de lugar (Cheng and Frank, 2011; Savelli and Knierim, 2010; Saeidi and Towhidkhan, 2009). Las neuronas de lugar reciben la mayoría de las conexiones corticales desde las neuronas grilla, esto como ya se describió se debe a que la gran mayoría de las neuronas de la MEC se proyectan hacia el hipocampo. Todos los modelos entonces se centran en como, a partir de los disparos de neuronas grilla, generar disparos de lugar. En general todas las propuestas se pueden clasificar en dos categorías, según:

1. Los disparos de lugar se producen como combinación lineal de los disparos grilla con diferente espaciado entre los campos.
2. Los disparos de lugar se producen a partir de la combinación de disparo grilla con distinto espaciado, orientación y fase.

Como se indicó en el capítulo anterior, la propuesta de Solstad propone tomar una cantidad N_{gc} del espacio 2D para generar un campo de lugar en un punto específico del espacio 2D en el que se quiera generar un disparo de lugar. La salida de una neurona de lugar queda determinada a partir de esta cantidad de neuronas grilla según la siguiente ecuación:

$$p(t) = \left[\sum_{n=0}^{N_{gc}} A^n g^n(t) - C_{inh} \right]_+ \quad (3.12)$$

Esta ecuación propone hacer una suma ponderada de los disparos de un número adecuado de neuronas grilla, generando con esta suma disparos de lugar. Los valores A^n son elegidos teniendo en cuenta la posición (ventral - dorsal) de las neuronas origen y destino al momento de crear la red de neuronas grilla y de lugar, y permanecen fijos durante todo el experimento. Se agrega un valor de inhibición global, C_{inh} , para balancear la excitación.

Las primeras pruebas llevadas adelante al integrar los nuevos módulos al modelo de cognición espacial utilizaban la propuesta de Solstad por su simpleza y control sobre los resultados obtenidos. Luego se utilizó aprendizaje hebbiano, al igual que en el resto de las conexiones sinápticas que son adaptadas durante la ejecución del modelo. De esta forma, los valores A^n de la Ecuación 3.12 pasan a ser los pesos ajustados en cada paso utilizando la regla de Hebb.

La Figura 3.14.a presenta la interacción de la capa de integración de trayectorias (Path Integration Layer - PIL) y la capa extractora de características de ella (Path Integration Feature Detector Layer - PIFDL). Cada celda en las matrices o vectores presentadas en la figura se corresponde con una neurona. En la Figura 3.14.b se coloca en cada celda una imagen para mostrar la diversidad de disparos y sus características. Es por ellos que las imágenes en cada celda en la matriz PIL ejemplifican patrones de disparo espacial grilla que genera la neurona cuando la rata se mueve en un entorno cuadrado. De igual forma, las imágenes en cada celda de la matriz PIFDL ejemplifican posibles patrones de disparo aprendidos. Como puede apreciarse en la capa PIFDL pueden aparecer patrones grilla, de lugar u otros. Las matrices son organizadas por claridad como vectores, en este sentido PIL se organiza en el vector patrón de salida PIP, y la matriz PIFDL en el vector PIFDP.

Las capas detectoras de características son utilizadas al igual que en el trabajo de Guazzelli y colaboradores (Guazzelli et al., 1998) para mejorar y contrastar la información de entrada.

El nivel de actividad de cada neurona j en el patrón de salida de la capa extractora de características de integración de trayectorias (PIFDP), se calcula sumando los productos entre cada valor de

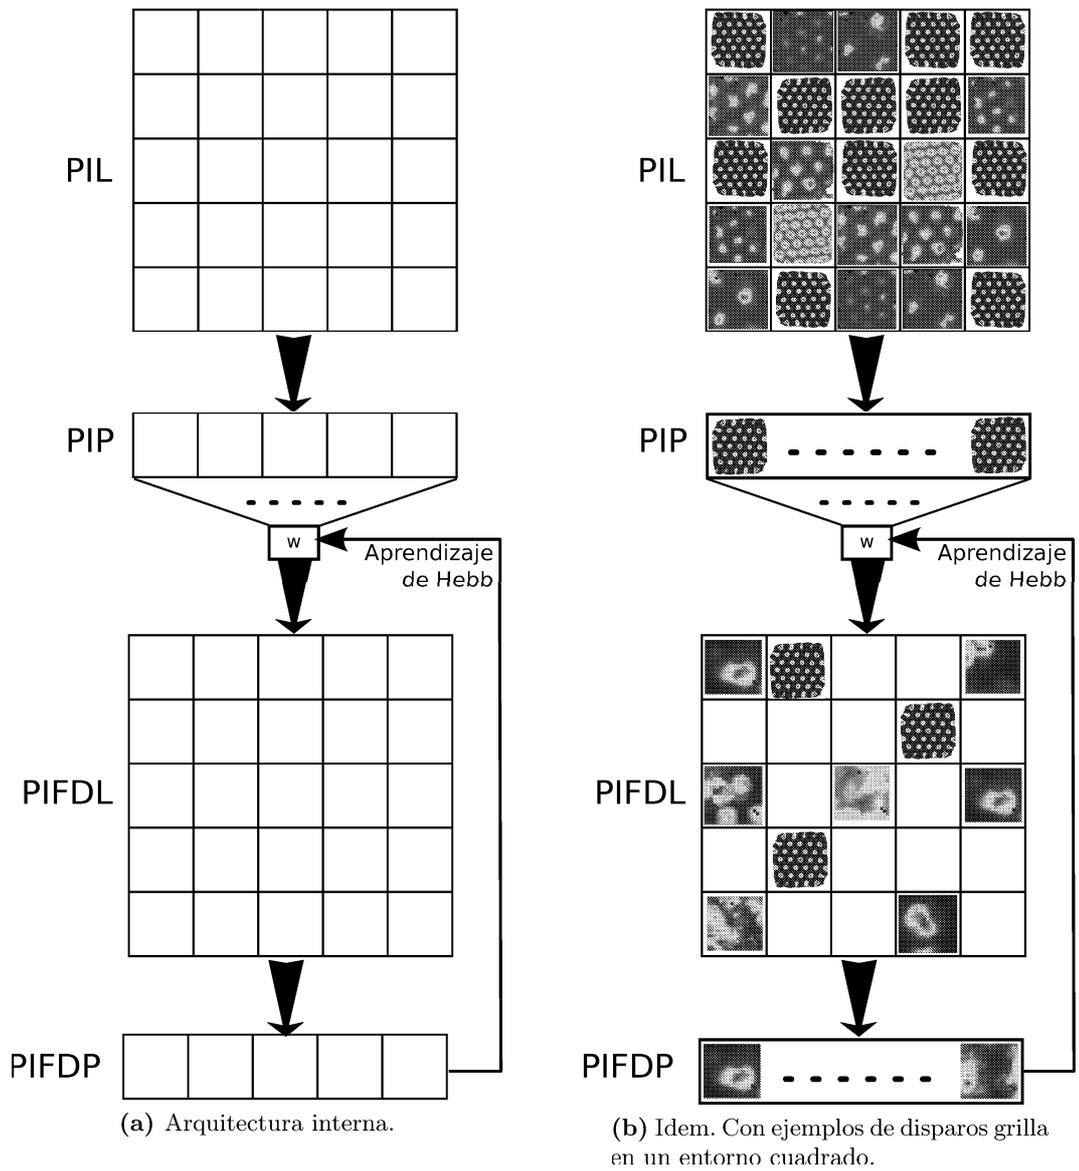


Figura 3.14 – Módulo integrador de trayectoria del modelo de cognición espacial. Glosario: PIL - capa de integración de trayectorias formada únicamente por neuronas grilla; PIP - patrón de salida de la capa de integración de trayectorias; PIFDL – capa de detección de patrones de integración de trayectoria; w - los pesos sinápticos de conexión entre el patrón PIL y la capa PIFDL utilizando la regla de aprendizaje de hebbiano.

entrada procedente de la neurona i del patrón de integración trayectorias (PIP) y el correspondiente peso de conexión w_{ij} como sigue:

$$PIFDP_j = \sum_{i=1}^{N_{pip}} PIP_i * w_{ij}. \quad (3.13)$$

La eficacia sináptica entre PIP y PIFDL es actualizada a través de la regla de aprendizaje de Hebb (Hebb, 1949), la cual permite asegurar que la próxima vez que el mismo patrón de actividad o uno similar se presente en PIP, el mismo conjunto de unidades en PIFDL se activarán representando la detección de un patrón específico de información de integración de trayectorias.

En este sentido, luego de calculado el PIFDP se utiliza para actualizar los pesos sinápticos entre PIP y PIFDL aplicando la regla de Hebb:

$$\Delta w_{ij} = \alpha PIP_i * PIFDP_j. \quad (3.14)$$

Otros trabajos utilizan un enfoque similar para generar campos de lugar a partir de un conjunto de neuronas grilla, mediante aprendizaje hebbiano (Samu et al., 2009).

3.6. Procesamiento de Información Visual

Este módulo tiene cambios menores respecto del modelo desarrollado por Barrera. La información espacial utilizada por las ratas para navegar en el ambiente incluye la localización respecto a señales visuales o marcas. El modelo de cognición espacial considera como entradas sensoriales tanto información vestibular como información visual. La información visual se origina en la corteza visual y en el caso de las ratas el campo de visión es de aproximadamente 270° (Hlscher, 2000). Luego de ingresar al modelo esta información visual (imagen panorámica) es procesada para identificar marcas, y a partir de su identificación estimar la distancia y orientación relativa de cada marca visible desde la posición y orientación actual. Todos los modelos relevados que incorporan información visual realizan suposiciones acerca de la manera de codificar la información de marcas, pero en todos los casos se consideran los mismos elementos a codificar, esto es, distancia y orientación relativa lo cual está avalado por estudios biológicos (Etienne and Jeffery, 2004; Gallistel, 1993).

La distancia y orientación relativa de cada marca respecto de la posición y orientación de la rata son representadas de forma independiente mediante dos arreglos lineales de neuronas incluidos dentro de un esquema perceptual de marca (Landmark Perceptual Schema - LPS). Este tipo de codificación que separa información de la distancia y de la orientación hacia la marca también es utilizada por Guazzelli et al. (1998). En nuestro modelo, cada arreglo lineal PS representa tanto la distancia como la orientación en términos de una distribución Gaussiana. Las distribuciones de Gauss codifican en el esquema perceptual la posición media de la distribución que representa la orientación del marca (pos_{lo}), la posición media corresponde a la rotación relativa de la rata hacia la marca, cuyo valor puede encontrarse entre -180° y +180°. Por otro lado, la posición media de la distribución que representa la distancia hacia la marca (pos_{ld}), está determinada por la proporción entre la estimación de la distancia actual y la distancia máxima conocida hacia la marca. De esta forma, cualquier patrón de información visual almacenado en el arreglo referido como LP representa una vista egocéntrica desde la ubicación y orientación actuales del animal.

La Figura 3.15 presenta la arquitectura interna del modulo de procesamiento de marcas. Al módulo ingresa una lista de tuplas (distancia y orientación) para cada marca y a partir de cada

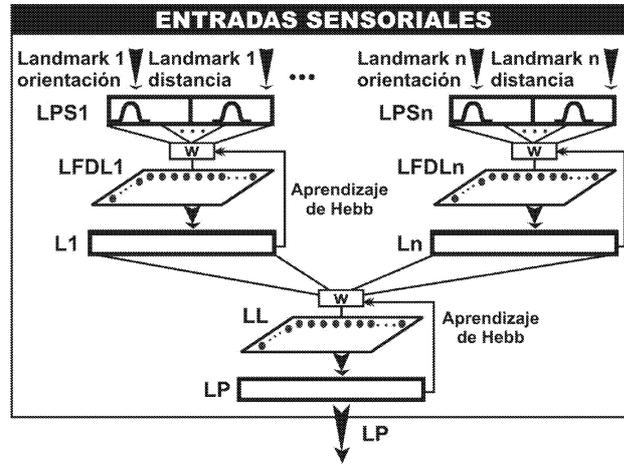


Figura 3.15 – El módulo de procesamiento de marcas del modelo de cognición espacial. Glosario: LPS – esquema perceptual de marca; LFDL – capa de detección de patrones de marca; LL – capa integradora de marcas. Los pesos de conexión w entre cualquier pareja de capas LPS – LFDL son actualizados a través de la regla de aprendizaje de Hebb. Los patrones de información de marcas $L1, \dots, Ln$ son integrados por LL para producir un patrón de marcas global LP que representa una vista egocéntrica desde el animal. (Barrera, 2007)

tupla se arma un LPS para cada marca. En la parte superior de la figura se muestran los LPSs y se ejemplifica poniendo en el mismo LPS una distribución gaussiana para la orientación y otra para la distancia.

Por lo antes expuesto los LPS se cargan de la siguiente manera:

$$lps_i^{land} = h_{land} \exp \frac{-(i - pos_{lo}^{land})^2}{2\sigma_{land}^2} + h_{ld} \exp \frac{-(i - pos_{ld}^{land})^2}{2\sigma_{land}^2}, \quad (3.15)$$

$$LPS_{land} = [lps_0^{land} \dots lps_{N_{LPS}}^{land}], \quad (3.16)$$

donde h , pos y σ son la altura, media y varianza de la función gauss, el índice ld determina los parámetros para la gaussiana almacenada en el arreglo lineal para la dirección de la marca y el índice lo para la orientación de la marca, para cada marca ($land$). El índice i varía entre 0 y $(N_{lps} - 1)$.

Al igual que en el módulo de integración de trayectorias se utilizan capas intermedias para la extracción de características (LFDL) y la eficacia sináptica entre las capas es actualizada a través de la regla de aprendizaje de Hebb. La capa LL codifica la información de todas las marcas.

3.7. Representación y Reconocimiento de Lugares

La estructura del módulo de representación y reconocimiento de lugares del modelo se muestra en la Figura 3.16. Como se presentó al principio de este trabajo, muchos modelos combinan información de integración de trayectorias y visual para determinar la actividad de las células de lugar del hipocampo. En este sentido este módulo recibe un patrón de integración de trayectorias (PI) desde el módulo de integración de trayectorias y un patrón de marcas (LP) desde el módulo de procesamiento de información visual. Ambas fuentes se combinan en la capa de neuronas de lugar (Place Cell Layer - PCL). La combinación de estas entradas se realiza utilizando una capa detectora de características

al igual que en el trabajo de Guazzelli y colaboradores (Guazzelli et al., 1998). La salida de cada elemento de la capa PCL es calculada utilizando la siguiente ecuación:

$$PC_j = \sum_{i=1}^{N_{pip}} w_{ij}^{pi} PIFDP_i + \sum_{i=1}^{N_{lp}} w_{ij}^{lp} LP_i. \quad (3.17)$$

Los pesos sinápticos de la Ecuación 3.17 son actualizados utilizando la regla de aprendizaje hebbiano.

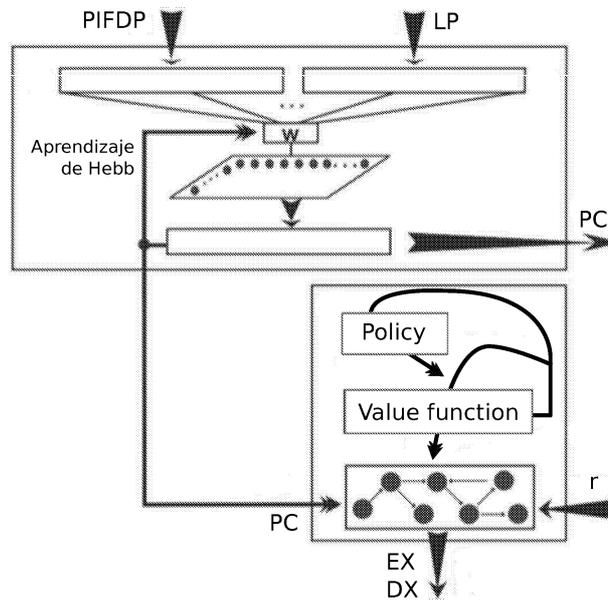


Figura 3.16 – El módulo de representación de lugares del modelo de cognición espacial. Glosario: PCL – capa de células de lugar; WGL – capa del mapa cognitivo; PI – patrón de información kinestésica; LP – patrón de información de marcas; w – pesos de conexión entre capas; PC – patrón de información de un lugar; APS – esquema perceptual de affordances; \hat{r} - señal de refuerzo efectivo; EX – expectativas de máxima recompensa sobre una secuencia de nodos en el mapa y sus correspondientes direcciones (DX).

La salida de la PCL es usada para generar el mapa topológico de navegación espacial, siendo éste mantenido por la capa grafo del mundo (World Graph Layer - WGL) del modelo. Como en el grafo del mundo propuesta por (Guazzelli et al., 1998), los nodos del mapa representan lugares distinguibles, y los arcos entre nodos están asociados con la dirección de la cabeza de la rata cuando se mueve de un nodo al siguiente. El modelo asume que el animal puede orientarse en ocho direcciones estando en cualquier localidad dada, i.e. de 0° a 315° en intervalos de 45° , de acuerdo a un marco de referencia alocéntrico. Cada nodo del grafo tiene asociado un conjunto de parejas <dirección, patrones de lugar>, este conjunto de parejas es lo que hace a los nodos lugares distinguibles, en el sentido que para cada nodo y para cada dirección de giro se almacena un patrón de activación. Estos patrones (PC) asociados al nodo son vistas respecto de como percibe el robot ese lugar.

Este módulo además es responsable de mantener la función valor y la política del algoritmo de aprendizaje por refuerzo. Originalmente el modelo utilizaba el algoritmo Actor-Critic extendiéndose en el contexto de este trabajo a los algoritmos Q-Learning y SARSA (Sutton and Barto, 1998).

Para determinar si el robot reconoce o no el lugar en que se encuentra se realiza una búsqueda en el conjunto de patrones almacenados en WGL. Este proceso de búsqueda involucra el cálculo del

grado de similitud (similarity degree - SD) entre PC y cada uno de los patrones almacenados. La siguiente ecuación presenta el calculo de similitud (distancia euclídea) entre patrones:

$$SD(x, y) = \sqrt{\sum_{i=1}^{N_{pcp}} (x_i - y_i)^2}, \quad (3.18)$$

donde i es el índice para las neuronas, N_{pcp} es la cantidad total de neuronas en PC o en cualquier patrón almacenado en WGL, y x e y son los patrones que se desea comparar. El patrón almacenado con mayor similitud es considerado como el patrón ganador (winner), según la siguiente ecuación:

$$winner = \underset{pat \in PatternSet}{\operatorname{arg\,min}} SD(pcp, pat). \quad (3.19)$$

Si el grado de similitud entre el patrón ganador y la salida de PC es menor a cierto umbral, θ_{sd} , el robot se localiza en el mapa reconociendo el nodo asociado a ese patrón como su posición actual, y **cierra el ciclo**. En caso contrario si el robot estaba avanzando crea un nodo nuevo en el mapa y le asocia la pareja <dirección actual, PC> al nuevo nodo, si estaba girando sobre si mismo le asocia al nodo actual la pareja con la nueva dirección.

En la Figura 3.17 se muestra un ejemplo de grafo del mundo luego de explorar completamente un entorno circular. Los nodos del grafo representan lugares distintivos del entorno, un lugar distintivo queda determinado por una firma particular de información integrada desde los módulos de marcas e integración de trayectorias, las aristas conectan nodos entre los cuales el robot navegó moviéndose en una dirección determinada.

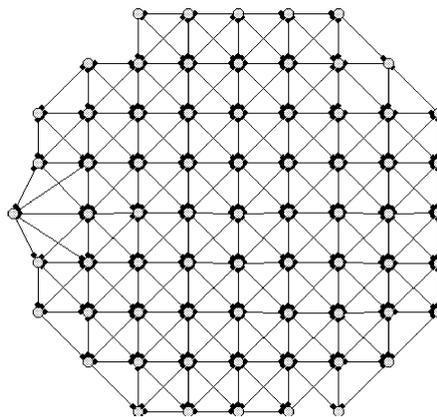


Figura 3.17 – Ejemplo de grafo del mundo construido por el módulo WGL.

3.8. Mecanismo de realimentación

Los mecanismos basados en integración de trayectorias tanto para el caso de robots móviles como en el caso de los animales sufren de acumulación de error debido a incertidumbre al momento de realizar una determinada acción o error propio de las señales de auto-movimiento respectivamente. Este error lleva a que, con el paso del tiempo, la información del sistema de integración de trayectorias no tenga sentido. Por esto es necesario disponer de un mecanismo que permita calibrar el integrador de trayectorias de forma de tolerar el error propio de las señales que proporcionan la información de entrada a él.

Existen algunas propuestas desde la biología que proponen como posible mecanismo de calibración del sistema de integración de trayectoria la caminos de retroalimentación desde el hipocampo hacia la MEC (Pilly and Grossberg, 2012). La Figura 3.18 muestra el diagrama de los componentes del modelo y su interacción en esta línea.

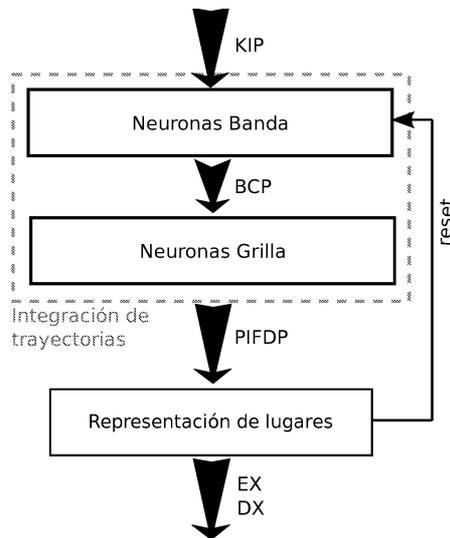


Figura 3.18 – Interacción entre los módulos integración de trayectorias y representación de lugares.

En el contexto de este trabajo se propone un enfoque simple para intentar alinear las neuronas grilla a sus fases espaciales originales pues debido al error de las señales kinestésicas con el tiempo los centros de los campos de disparo grilla se van corriendo. No es posible conocer en que lugar deberían disparar las neuronas grilla pero si es posible saber en algunos lugares en los que deberían disparar. Cuando el robot reconoce un lugar en el grafo del mundo, se localiza en él en base a información visual y kinestésica, alinea el centro de las neuronas grillas activas a la posición actual en el entorno.

Este procesamiento es llevado adelante desde la capa WGL, que reconoce un lugar como ya visitado y genera una señal de reset hacia el módulo de integración de trayectoria para alinear las neuronas grilla. Como ya se dijo, el módulo WGL determina si el robot reconoce un lugar realizando una búsqueda en el conjunto de patrones que almacena WGL. Este proceso se lleva adelante mediante el computo del mínimo grado de similitud entre el patrón actual de lugar y los patrones almacenados. Si este mínimo es menor a un umbral de similitud se activa la señal de realimentación hacia la capa de integración de trayectorias. Cuando la realimentación está activa la capa de integración de trayectorias refuerza la activación de todas las neuronas grillas activas en ese momento.

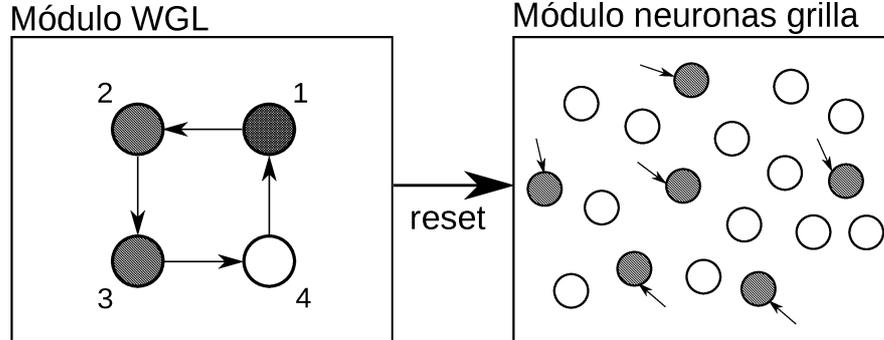


Figura 3.19 – Relación entre el módulo WGL y las neuronas grilla. Los nodos el grafo del mundo se colorean para conocer el nodo actual (violeta), en nodo anterior (amarillo) y otros nodos previamente creados (verde). Las neuronas del módulo grilla se colorean para mostrar las neuronas activas en rojo y el resto en blanco.

La Figura 3.19 ilustra el proceso antes explicado. Se muestra el grafo del mundo donde el agente inicio en el nodo 1 y recorrió los nodos 2, 3 y 4 para volver a llegar al punto de inicio, y además logró cerrar el ciclo del recorrido. En el momento en el que se detecta el cierre del ciclo se enciende la señal de reset. Como se muestra en la figura esta señal se propaga a cada una de las neuronas activas (en rojo) para que ajusten su fase espacial.

Si consideramos nuevamente la ecuación de Hasselmo

$$V_g(t) = \Theta \left[\prod_{HD} (\cos(2\pi ft) + \cos(2\pi(f + fB_{HS} \cos(\phi - \phi_{HD}))t) + \varphi) \right]$$

, esta ecuación puede reescribirse para ser calculada tomando intervalos discretos de tiempo por la siguiente ecuación

$$V_g(n) = \Theta \left[\prod_{HD} (\cos(x_{soma}(n)) + \cos(x_{dend}(n))) \right]$$

, donde

$$x_{soma}(0) = \varphi_{soma}$$

$$x_{soma}(n) = x_{soma}(n-1) + 2\pi f \Delta t$$

$$x_{dend}(0) = \varphi_{dend}$$

$$x_{dend}(n) = x_{dend}(n-1) + 2\pi(f + fB_{HS} \cos(\phi - \phi_{HD})) \Delta t$$

Reforzar el disparo de una neurona grilla en el contexto de la propuesta de múltiples osciladores requiere alinear las fases de los dos osciladores. Como puede observarse en la ecuación de Hasselmo, el oscilador soma no es afectados por el error mientras que el error sí afecta al oscilador dendrítico.

En este sentido se acerca la fase del oscilador dendrítico al oscilador del soma utilizando la siguiente ecuación:

$$x_{dend}(n) = x_{dend}(n) + \alpha_{reset}(x_{soma}(n) - x_{dend}(n)), \quad (3.20)$$

Si bien no existe evidencia biológica permita concluir que esto sea así, se han observado mecanismos de reseteo de la fase en base a estímulos sensoriales (Burgess et al., 2007). Esto en cierta forma viabiliza la propuesta de realimentación propuesta en este trabajo.

3.9. Limitaciones del modelo

El modelo de cognición espacial inició su desarrollo en 2004 y desde entonces se ha ajustado el diseño interno de los módulos que los componen y se han incorporado nuevos módulos, ambos casos han sido motivados por la aparición por nueva información desde la biología.

Si bien son varios los aspectos que pueden mejorarse e incorporarse al modelo actual se presentan aquí las limitantes más importantes del modelo que deben resolverse para que el modelo presente los aspectos requeridos para la cognición espacial. A continuación se presentan estos aspectos y se deja para la sección final del documento una discusión completa de los posibles trabajos a futuro.

Actualmente el módulo de dirección de la cabeza no corrige el error acumulado que se produce al integrar la información kinestésica, esto lleva luego de cierto tiempo inevitablemente a la destrucción del mapa. Es por ello que debe, al igual que con las neuronas grilla, ajustar la dirección actual mantenida por este módulo en base a información externa. Son varios los modelos de neuronas dirección de la cabeza propuestos y existe amplia información respecto del sistema de dirección de la cabeza en roedores (Wiener and Taube, 2005).

Otro aspecto a necesario a incorporar al modelo es la necesidad de eliminar el ajuste manual de neuronas grilla al comienzo de cada ensayo. Este problema se conoce en robótica móvil como el robot secuestrado, que ilustra este requerimiento en el cual el robot es trasladado a otro lugar sin interacción con el entorno, particularmente sin poder obtener información kinestésica ni visual. Es muy poco lo que se sabe en la biología al respecto y puede estar relacionado al remapeo de que presentan algunas neuronas (Fyhn et al., 2007; Bush et al., 2014). Una de las observaciones más tempranas y llamativas relativas a la representación del lugar es la forma en que las células de repente y colectivamente pueden alterar su actividad de un patrón a otro, este proceso es conocido como la reasignación (remapping). En el modelo esta reasignación debe ser realizada ajustando de manera coherente la fase espacial y la orientación de las neuronas grilla.

Capítulo 4

Implementación del Modelo

La implementación del modelo de cognición espacial y navegación en ratas implica tanto el diseño de los módulos que lo componen, como la definición de interfaces que le permitan interactuar con un ambiente virtual o real, y la ejecución de las distintas etapas o ensayos de un experimento.

El capítulo que se presenta a continuación discute tales aspectos de implementación. En particular, se incluyen tres secciones que describen el uso del Lenguaje de Simulación Neuronal (Neural Simulation Language - NSL) en el diseño de los componentes del modelo, la interacción del modelo con un robot virtual y con un robot real, y el control en la ejecución de los ensayos necesarios para completar un ensayo.

4.1. El Lenguaje de Simulación Neuronal

El modelo de cognición espacial y navegación en ratas fue diseñado e implementado utilizando el Lenguaje de Simulación Neuronal (NSL) 3 para Java (Weitzenfeld, 2002). NSL ofrece una plataforma orientada a objetos para construir arquitecturas neuronales (modelado) y ejecutarlas (simulación). El modelado biológico de arquitecturas neuronales tiene como propósito reproducir datos experimentales anatómicos y fisiológicos, lo cual implica la selección de representaciones de datos apropiadas para los componentes neuronales y sus interacciones, la especificación del funcionamiento de los mismos en términos de ecuaciones matemáticas, así como el control de las entradas y parámetros de la arquitectura. Por otro lado, la simulación por computadora de la arquitectura neuronal permite observar su comportamiento ante configuraciones diversas de sus parámetros y entradas, generando resultados numéricos y visuales que son analizados posteriormente para determinar posibles modificaciones al estado actual del modelo.

NSL ha evolucionado desde 1989, cuando el sistema original fuera escrito en el lenguaje de programación C. Una segunda versión basada en tecnología orientada a objetos y escrita en C++ fue liberada en 1991. La versión actual NSL 3 (1999) incluye modularidad y concurrencia, y se distribuye como un conjunto de bibliotecas para los lenguajes de programación Java y C++.

El sistema de simulación provisto por NSL comprende un subsistema de simulación donde tiene lugar el procesamiento de los modelos, y un subsistema de interfaz donde tiene lugar la interacción de gráficas mostradas durante la ejecución de los modelos. Específicamente, las funciones del subsistema de simulación incluyen la ejecución del modelo y sus módulos en una secuencia específica, mientras que el subsistema de interfaz ofrece bibliotecas gráficas que permiten instanciar marcos, paneles

y gráficos, así como controles de ventana que permiten al usuario interactuar con el proceso de simulación y así controlar su ejecución y parámetros.

El modelado biológico de una arquitectura neuronal en NSL implica el diseño de diversos módulos que pueden corresponder a diferentes estructuras del cerebro o representar funcionalidades distintas de una misma estructura. Los módulos en NSL se asocian a objetos que especifican el modelo computacional, y cada módulo puede ser descompuesto en submódulos. En particular, los módulos y submódulos NSL comprendidos dentro del modelo propuesto de cognición espacial y navegación en ratas, su correspondencia biológica, y la interacción entre ellos se presentan en el Cuadro 4.1. La funcionalidad interna de cada módulo ha sido descrita en el Capítulo 3 de este documento.

El modelo propuesto es capaz de interactuar tanto con un ambiente virtual o real a través de dos módulos externos de procesamiento sensorial y de control motriz nombrados en el Cuadro 4.1. A nivel simulado, el modelo utiliza la información sensorial que obtiene del mundo virtual, y controla la rotación y el desplazamiento del robot virtual dentro de su mundo. Por otro lado, al experimentar con un robot real, el modelo considera la información sensorial que obtiene del robot con su aparato sensorial local, y lo controla a través de rotaciones y desplazamientos dentro del ambiente construido para realizar los experimentos. Las siguientes secciones presentan la interfaz entre el modelo y el robot virtual o el robot real, describiendo la funcionalidad específica de los módulos externos de procesamiento sensorial y de control motriz en cada caso.

4.2. Interfaz Modelo – Agente

El modelo debe interactuar con el entorno obteniendo información de él a través de los sensores del robot y realizando acciones en él a través de sus actuadores. Para esto se define la interfase IRobot que define los métodos que deben implementar los robots para poder correr el modelo en ellos. La Figura 4.1 presenta un diagrama de esta interfase y el Cuadro 4.2 describe los métodos que incluye.

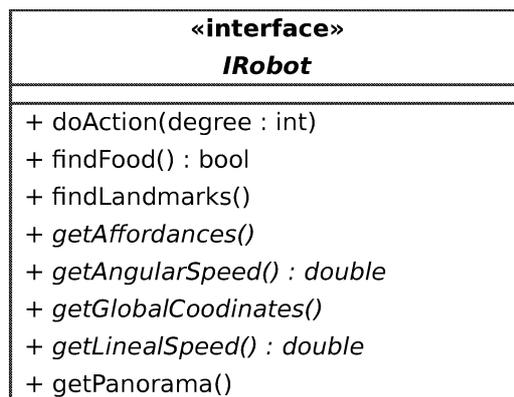


Figura 4.1 – Diagrama de la interfase IRobot.

Los métodos doAction, findFood, findLandmarks, getAffordances, getAngularSpeed, getLinealSpeed son los que interactúan con el modelo de cognición espacial representando el aparato motriz y sensorial del agente. El método getGlobalCoordinates permite conocer la posición global del robot y se utiliza únicamente para aspectos de visualización del grafo del mundo y para evaluar el desempeño

Modulo	Submódulo	Correspondencia biológica	Entrada - Origen	Salida - Destino
Procesamiento kinestésico	Velocidad lineal	núcleo vestibular lateral	Aceleración lineal - Control motriz	PVL - Neuronas banda
	Velocidad angular	núcleo mamilar lateral / núcleo tegmental dorsal	Aceleración angular - Control motriz	PVA - Dirección de la cabeza
	Dirección de la cabeza	postsubiculum	AVP - Velocidad angular	PDC - Neuronas banda
Integración de trayectorias	Neuronas banda	MEC profunda	LVP - Procesamiento kinestésico PDC- Procesamiento kinestésico	PNB - Neuronas grilla
	Neuronas grilla PIFDL	MEC II Corteza retrosplenial	BGP - Neuronas banda GCP - Neuronas grilla	GCP- PIFDL PI - PCL
Procesamiento de marcas	LL	Corteza postririnal	Distancias y orientaciones hacia marcas visibles – Procesamiento visual	LP - PCL
	PCL WGL	Hipocampo Corteza prelímbica	PI - PIFDL LP - LL PC - PCL	PC - WGL EX, DX – AS
Selección de acción	AS		EX, DX – WGL	Próxima rotación, desplazamiento – Control motriz

Cuadro 4.1 – Módulos NSL que componen el modelo de cognición espacial y su interacción. Glosario: LVP - Patrón de Velocidad lineal; AVP - Patrón de Velocidad angular; HDP - Patrón de Dirección de la cabeza; MEC: corteza entorrinal media; BCP - Patrón de Neuronas banda; GCP - Patrón de Neuronas grilla; PIFDL: capa característica de patrones de integración de trayectorias; PI – patrón de información de integración de trayectorias; LL: capa de procesamiento de marcas; LP – patrón de información de marcas; PCL: capa de neuronas de lugar; PC – patrón de información de lugar; WGL: capa del mapa del mundo; AS - módulo de selección de acción; EX – expectativas de máxima recompensa y sus direcciones correspondientes (DX).

del agente en la etapa de experimentación, y el método `getPanorama` permite visualizar de forma remota la imagen panorámica construida por el agente.

Método	Descripción
<code>doAction</code>	Este método comanda al robot a realizar un giro sobre si mismo o un avance. Valores positivos del parámetro <code>degree</code> determina giros antihorarios, valores negativos giros horarios y cero determina un avance de distancia fija.
<code>findFood</code>	Devuelve un valor booleano que indica si se encontró comida.
<code>findLandmarks</code>	Devuelve un conjunto que contiene la posición y el tamaño de las marcas encontradas en la panorámica construida desde la posición actual.
<code>getAffordances</code>	Devuelve un arreglo booleano que indica las direcciones (egocéntricas) en las cuales el robot se puede desplazar.
<code>getAngularSpeed</code>	Devuelve la velocidad angular.
<code>getGlobalCoordinates</code>	Devuelve la posición actual de robot en un marco de referencia.
<code>getLinealSpeed</code>	Devuelve la velocidad lineal.
<code>getPanorama</code>	Devuelve una imagen panorámica (matriz de píxeles) desde la posición y orientación actual del robot.

Cuadro 4.2 – Descripción de los métodos de `IRobot`.

4.2.1. Mundo Virtual

4.2.1.1. Entorno

El entorno virtual que se utiliza para simular un experimento particular se describe a través de un archivo XML (Extensible Markup Language), en donde se especifica la forma de cada objeto 3D, su color y su posición. El archivo XML es interpretado para dibujar en pantalla los diversos objetos en las posiciones indicadas. Para construir el mundo virtual se utiliza el paquete de visualización de Java 3D¹ sobre la información interpretada a partir del archivo XML que define el entorno de experimentación.

El diseño actual del interprete permite colocar cilindros y cajas en el entorno, para estos contenidos geométricos se indica su posición en el entorno, dimensión y color. Las marcas y la comida se definen como cilindros, y las paredes pueden definirse como cilindros o cajas dependiendo del laberinto que se esté utilizando para experimentar.

Si bien las ratas sólo reconocen contrastes y formas, la versión actual del sistema propuesto lleva a cabo un procesamiento visual simplificado que se basa únicamente en el reconocimiento de colores. Específicamente, se asignan distintos colores a las paredes del laberinto experimental (rojo), a la localidad meta (azul), y a marcas externas (magenta, cian, blanco y amarillo), con el fin de determinar las affordances disponibles en cada instante de tiempo, detectar la presencia de la meta, y estimar las distancias y orientaciones hacia marcas perceptibles desde la posición actual del robot.

4.2.1.2. Robot

En cada paso, el robot virtual toma cinco imágenes del ambiente para armar una imagen panorámica, se toma una al frente y dos a cada lado con un campo de visión de 45°, logrando

¹<https://java3d.java.net/>.

llegar a un campo visual de 225°. Aún cuando el uso de cinco imágenes no logra simular el amplio campo visual de 320° que tienen las ratas, ha resultado suficiente durante el procesamiento visual efectuado en los laberintos experimentales hasta ahora utilizados.

Cada imagen obtenida en la dirección actual en el entorno virtual tiene una resolución de 240 x 240 píxeles, a partir de ella se toma una muestra de 80 x 80 píxeles. En la Figura 4.2.a se muestra el robot en el entorno virtual y la configuración de las marcas. El robot se encuentra en el centro del entorno mirando hacia la marca cian (0° según dirección egocéntrica). En la parte superior de la Figura 4.2.b se muestran las cinco imágenes tomadas desde la posición actual indicando la rotación relativa que realiza el robot para tomarlas, la parte inferior de la figura muestra la panorámica que se arma a partir de ellas.

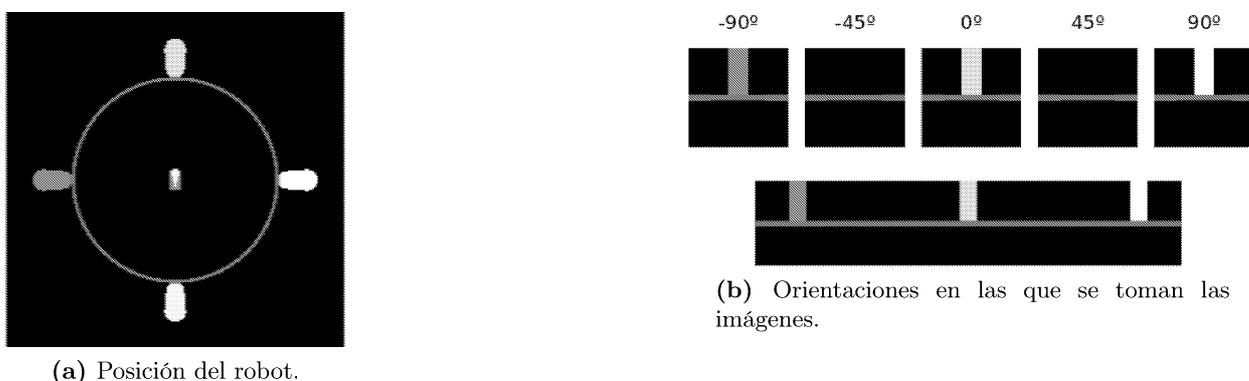


Figura 4.2 – Entorno virtual de simulación.

El módulo externo de procesamiento visual del sistema considera la imagen panorámica y calcula la cantidad de píxeles de cada color relevante. Después emplea estas cantidades para realizar las siguientes operaciones:

- Construir el arreglo de affordances. Utilizando la cantidad de píxeles de color de las paredes en las distintas direcciones y así determinar las direcciones hacia las que el robot puede avanzar a partir de su localización y orientación actual. En cada imagen, la cantidad de píxeles del color asociado a las paredes del laberinto (rojo) permite identificar su cercanía, y por tanto la posibilidad de transitar en una determinada dirección.
- Detección de la presencia de la meta. Aún cuando el color asociado a la localidad meta puede estar incluido en las imágenes tomadas por el robot desde diversas distancias, el módulo de procesamiento visual detecta la presencia de la meta únicamente cuando la imagen contiene un número importante de píxeles del color de la meta, el cual corresponde a uno o cero pasos de distancia del robot. Este valor de distancia del robot a la meta es enviado al módulo de motivación del modelo. En particular, cuando la distancia es un paso del robot, la percepción de comida se considera como un incentivo, mientras que si es cero pasos, se asume la ingestión de comida por parte del robot, lo cual implica una reducción en el valor del hambre.
- Estimación de las distancias y orientaciones hacia marcas perceptibles desde la localización y dirección actuales del robot. En los experimentos que se han llevado a cabo, cilindros de diferentes colores dispuestos fuera de los laberintos han sido utilizados como marcas. Mediante un procedimiento inicial de calibración se determina la cantidad mínima y máxima de píxeles

de una marca, esto es la cantidad de píxeles de color incluidos en la imagen tomada por el robot cuando se encuentra localizado lo más alejado o cercano posible de la marca dentro del laberinto. Considerando tales valores, la cantidad de píxeles del color de una marca contenida en la imagen actual tomada por el robot permite determinar el tamaño aparente del marca y estimar así la distancia hacia la localidad actual del robot. Por otro lado, la orientación de la marca es definida al considerar el ángulo en que el robot haya capturado la imagen que la contiene: 0° y 225° . Tanto las distancias como las orientaciones estimadas hacia las marcas perceptibles son enviadas al módulo de procesamiento de marcas del modelo, para codificar dicha información visual a través de esquemas perceptuales de marcas.

Como lo indica el Cuadro 4.1, el módulo de selección de acción del modelo entrega al módulo externo de control motriz los valores referentes a la próxima dirección del robot, a la rotación a ejecutar para orientarse hacia tal dirección, y al desplazamiento a efectuar. En este módulo, el cuerpo del robot virtual y su cabeza son controlados por separado, así que cuando el robot adquiere la nueva dirección indicada por el módulo de selección de acción, lo hace rotando su cuerpo y su cabeza, mientras que cuando captura las tres imágenes del ambiente en cualquier paso de tiempo dentro del experimento dado, lo hace rotando únicamente su cabeza. La magnitud del desplazamiento del cuerpo del robot indicada por el módulo de selección de acción puede ser 0 ó 1. El valor 1 equivale a “un paso” del robot, lo cual ocurre cuando la próxima dirección del robot es igual a su dirección actual. El valor 0 implica que el robot no debe trasladarse, pues su próxima dirección es distinta a la actual y se requiere que perciba el ambiente desde la localidad en que se encuentra, pero desde un ángulo diferente. Las traslaciones y rotaciones del robot virtual en el ambiente son ejecutadas por el módulo de control motriz utilizando la funcionalidad que ofrecen las clases Java3D.

4.2.2. Robot Real

El modelo ejecuta en línea y en tiempo real utilizando un robot Khepera III y una computadora personal (Procesador Core™ i7 2630QM con 8GB de memoria DDR3 1333 MHz), la cual se comunica con el robot de manera inalámbrica. Como capacidades sensoriales del robot se emplea un sensor láser (LRF - Laser Range Finder), dos sensores infrarrojo (IR), encoders y una cámara web. El Cuadro 4.3 presenta las características más relevantes del robot Khepera y los accesorios utilizados.

En el robot ejecutan dos servicios, uno para acceder a la lectura de los sensores de distancia (IR, encoders y LRF) y para controlar los movimientos de los motores, y el otro para obtener una imagen de la cámara. El servicio de distancia y movimientos se desarrolló como un servidor de RPC (Remote Procedure Call) en el lenguaje C utilizando la biblioteca libkorebot² 1.19 proporcionada por los fabricantes del robot Khepera, este servidor se denomina min-k-server. Para el servicio de visión se utilizó el servidor de streaming de vídeo mjpg-streamer³ 2.0 el cual deja constantemente imágenes disponibles para consumir.

La Figura 4.3 muestra los componentes de software necesarios para ejecutar el modelo y su distribución entre el robot Khepera y la PC.

²<http://ftp.k-team.com/korebot/libkorebot>

³<http://sourceforge.net/projects/mjpg-streamer>

Elemento	Descripción
Computadora abordo	Intel XSCALE PXA-270 @ 600MHz con 128 MB de RAM.
Sistema operativo	OpenEmbedded Ansgtröm (Kernel Linux 2.6).
Comunicación inalámbrica	Placa compatible con el estándar IEEE 802.11 B/G.
Infrarojo	Sensores infrarrojos con un alcance de hasta 30 cm.
Laser Range Finder	Rango de trabajo entre 20 mm y 5600 mm.
Cámara	Campo de visión horizontal: 60°. Campo de visión vertical: 45°.
Motores	Corriente continua con encoders (22 pulsos por mm).
Tamaño	Diámetro: 130mm. Alto: 70mm (Solo Khepera). Diámetro: 160mm. Alto: 190mm (Khepera con accesorios).
Autonomía	8hs (sin ningún módulo). 2hs con los módulos agregados para interactuar con el modelo.

Cuadro 4.3 – Características del robot Khepera III+KoreBot II y sus periféricos.

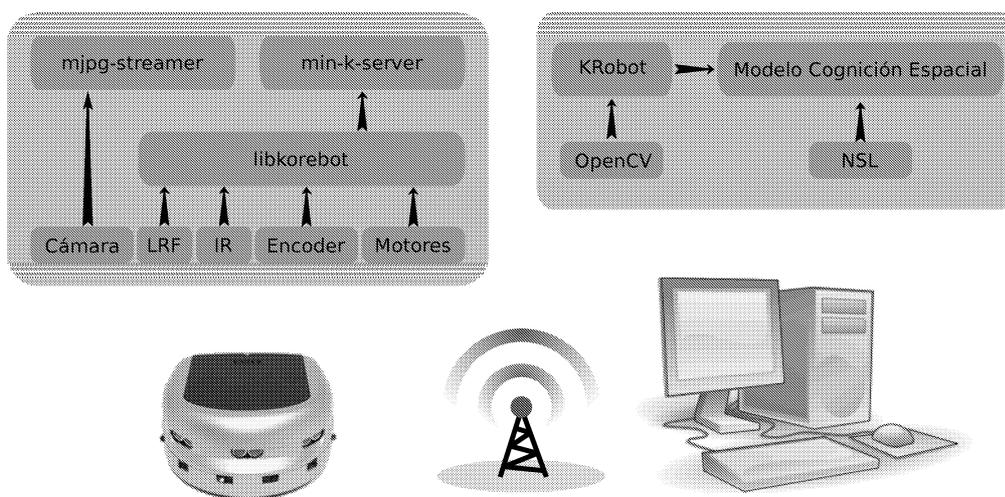


Figura 4.3 – Distribución del software entre el robot y el PC.

Antes de iniciar cualquier experimento es necesario conocer la variación del color con el propósito de que el robot reconozca los diferentes objetos que podrá encontrar en el ambiente a explorar. Para esto se toman fotografías de los colores de interés desde distintas distancias y orientaciones con la cámara local del robot, y se marcan y clasifican las regiones que contienen objetos a reconocer. Las imágenes y su clasificación alimentan a un sistema de calibración de colores, el cual genera como resultado un archivo que incluye el rango de valores en HSI⁴ de cada objeto de interés. De igual forma que con el robot virtual, se necesita además calibrar el tamaño mínimo y máximo de una

⁴El modelo de color HSI define un color en términos de sus componentes constituyentes, Matiz, Saturación e Intensidad (Hue, Saturation and Intensity).

marca, en este caso se utiliza la altura mínima y máxima de una marca tomada por el robot cuando se encuentra localizado lo más alejado o cercano posible de ella respectivamente.

La clase KRobot implementa la interfaz IRobot para el robot Khepera. En el Cuadro 4.4 se describen los aspectos más relevantes de esta implementación y la interacción con otros componentes de software. En el Cuadro 4.5 se indica que elemento de hardware de la plataforma robótica es utilizado para implementar los distintos métodos de la interfaz (no se incluyen los métodos que no hacen uso del hardware del robot).

Método	Interacción y procesamiento
doAction	Invoca según corresponda a las funciones de giro o avance del componente min-k-server.
findFood	Obtiene a través de min-k-server la lectura de los IRs y esta lectura es usada para conocer el color del piso bajo el robot, y así determinar la cercanía al alimento.
findLandmarks	A partir de la panorámica actual y utilizando métodos de reconocimiento de OpenCV determina la posición y el tamaño de las marcas.
getAffordances	Obtiene a través de min-k-server la lectura del sensor LRF y construye a partir de esta información un arreglo de booleanos que indica las direcciones (egocéntricas) en las cuales el robot se puede desplazar.
getAngularSpeed	Obtiene a través de min-k-server la lectura de los encoders y devuelve la velocidad angular.
getGlobalCoordinates	Se utiliza un servicio simple de visión global para identificar un parche sobre el robot y devolver su posición actual en el laberinto.
getLinealSpeed	Obtiene a través de min-k-server la lectura de los encoders y devuelve la velocidad lineal.
getPanorama	Invoca a las función de giro de min-k-server y obtiene a través de mjpg-streamer la imagen local. Repite esto para las rotaciones de interés y arma la panorámica.

Cuadro 4.4 – Implementación la interfaz IRobot para el Khepera.

Método	Elemento motriz o sensorial del robot utilizado
doAction	Motores de corriente continua.
findFood	Sensores IR inferiores.
getAffordances	Sensor LRF
getAngularSpeed	Lectura de los encoders.
getLinealSpeed	Lectura de los encoders.
getPanorama	Cámara y motores de corriente continua.

Cuadro 4.5 – Hardware del robot utilizado para implementar la interfaz.

Los dos servicios que ejecutan en el robot, mjpg-streamer y min-k-server, lo hacen de manera independiente por lo que es necesario sincronizar el flujo de imágenes a la posición en la que realmente ésta se espera tomar. Para esto se realiza un procedimiento simple en la clase KRobot de manera que toda vez que se requiere obtener una imagen se espera a que se estabilice.

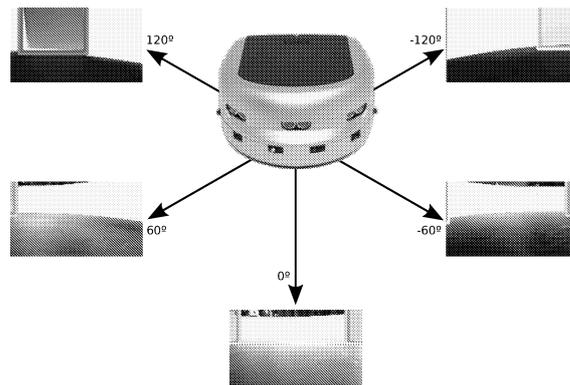
Algoritmo 4.1 Algoritmo para estabilizar imágenes

```

DELAY_MILLIS = ...
MAX_DIFF_PIXELS = ...

actualImage = getImageFromStream()
repeat
    sleep(DELAY_MILLIS)
    previousImage = actualImage
    actualImage = getImageFromStream()
until numberDifferentPixels(previousImage, actualImage) < MAX_DIFF_PIXELS
    
```

El Algoritmo 4.1 presenta el pseudo-código del proceso realizado para obtener una imagen estable cada vez que se desea obtener una imagen en la posición actual del robot.



(a) Imágenes y su orientación egocéntrica.



(b) Panorámica armada desde la posición actual.

Figura 4.4 – Imágenes locales tomadas con la webcam y su concatenación.

En cada paso de tiempo t dentro de un experimento dado, se obtienen cinco fotografías estables rotando el robot en el entorno en las direcciones egocéntricas -120° , -60° , 0° , $+60^\circ$ y 120° , logrando llegar a un campo visual de 300° aproximándose al campo visual que tienen las ratas. La Figura 4.4.a muestra las imágenes individuales tomadas en cada una de las direcciones antes indicadas cuando el robot se encuentra en el centro del escenario. Cada una de las imágenes es obtenida desde el servicio de streaming de vídeo con una resolución de 80×60 . El resultado del armado de la panorámica es una matriz de 400×60 píxeles, en donde cada casilla almacena el código numérico asociado con el color del píxel. La Figura 4.4.b presenta la panorámica que se arma a partir de las cinco imágenes tomadas, en ella se puede apreciar con el mismo color de la marca pero resaltado la identificación de la marca realizada utilizando algunas funciones de OpenCV.

El Algoritmo 4.2 presenta las etapas de procesamiento realizadas sobre una imagen panorámica

Algoritmo 4.2 Algoritmo para encontrar una marca.

Require: panorama a Image
Require: hsiRange a HSI Range
 filterNoise(panorama)
 cvInRangeS(panorama, hsiRange)
 contours = cvFindContours(panorama)
 maxArea = 0
for contour in contours **do**
 points = cvApproxPoly(countour)
 actualArea = cvContourArea(points)
 if actualArea > maxArea **then**
 actualArea = maxArea
 maxPoints = points
 end if
end for
return cvBoundingRect(points)

para obtener una marca. El algoritmo recibe como parámetro la panorámica y el color de la marca (como un rango de valores en HSI) a identificar, y retorna un rectángulo que representa la marca más grande encontrada.

Al igual que en la situación virtual descrita en la sección anterior, el módulo externo de procesamiento visual del sistema propuesto analiza las marcas encontradas en la panorámica para calcular las distancias y orientaciones hacia éstas desde la localización y dirección actuales del robot.

La Figura 4.5 presenta la interfaz gráfica del modelo⁵ y de la clase KRobot que ejecuta en el PC. La interfaz del modelo permite visualizar los esquemas perceptuales de marcas (LPS) para cada una de las marcas, los esquemas para la toma de decisiones y el grafo del mundo actual. Se utilizan cinco esquemas para la toma de decisiones Barrera (2007):

- APS: las affordances disponibles en la posición actual
- RPS: una rotación aleatoria entre las affordances disponibles
- CPS: rotaciones que no han sido exploradas desde la localidad actual de la rata
- EMP: la expectativa global de máxima recompensa
- Sum: la suma de los cuatro esquemas anteriores

Los nodos el grafo del mundo se colorean para conocer el nodo actual (violeta), el nodo anterior (amarillo) y otros nodos previamente creados (verde). El objeto KRobot cuando es instanciado levanta tres ventanas, una ventana para mostrar la imagen local, otra para mostrar la última imagen panorámica construida y por último una ventana para mostrar una vista global del escenario.

⁵Puede acceder a distintas ejecuciones del modelo en www.fing.edu.uy/~gtejera.

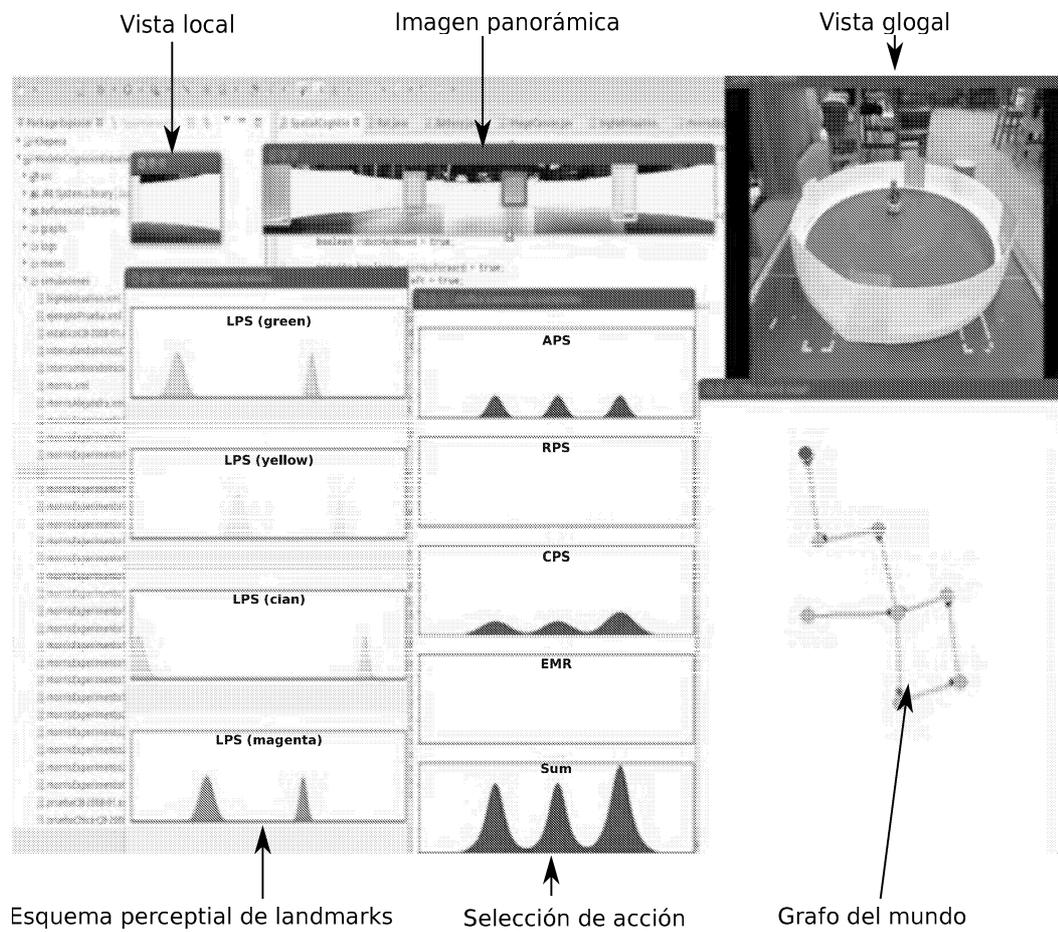


Figura 4.5 – Interfaz gráfica con el modelo.

4.3. Configuración de los ensayos para un experimento

Para los experimentos simulados se utilizan dos archivos XML, uno para definir el entorno y otro para definir el proceso de experimentación. Para los experimentos reales sólo se utiliza un archivo para definir el proceso de experimentación. En este último caso el robot y el escenario son manipulados por el experimentador humano que debe garantizar las condiciones iniciales del ensayo.

4.3.1. Definición del entorno

El archivo XML del entorno permite definir los límites del laberinto, las marcas y la posición del objetivo (comida o plataforma). El objetivo es un cilindro que se define de la siguiente manera:

- dimensiones del cilindro, radio y altura.
- color del cilindro dado por el peso de cada una de las componentes de color para el modelo de color RGB.
- posición inicial en el laberinto.

Un ejemplo para la comida sería `<food r='0.04' h='0' cr='0' cg='0' cb='1' x='0' y='0' z='0'/>`, definida como un cilindro de 4cm de radio, color azul e inicialmente ubicada en el origen de coordenadas del entorno.

A continuación se presenta el ejemplo completo para el laberinto de Morris.

```
<world>
  <!-- CYAN Landmark -->
  <cylinder r="0.045" h="0.3" cr="0" cg="1" cb="1" xp="0" yp="0.15" zp="-0.55"/>
  <!-- YELLOW Landmark -->
  <cylinder r="0.045" h="0.3" cr="1" cg="1" cb="0" xp="0" yp="0.15" zp="0.55"/>
  <!-- GREEN Landmark -->
  <cylinder r="0.045" h="0.3" cr="0" cg="1" cb="0" xp="-0.55" yp="0.15" zp="0"/>
  <!-- MAGENTA Landmark -->
  <cylinder r="0.045" h="0.3" cr="1" cg="0" cb="1" xp="0.55" yp="0.15" zp="0"/>

  <!-- Begin Maze -->
  <pool r="0.5" h="0.025" cr="1" cg="0" cb="0" xp="0" yp="0" zp="0"/>
  <floor r="4" cr="0" cg="0" cb="0" xp="0" yp="-0.075" zp="0"/>
  <!-- End Maze -->

  <food r="0.038" h="0" cr="0" cg="0" cb="1" xp="0" yp="-0.015" zp="-0.2"/>
</world>
```

4.3.2. Definición del experimento

Cada uno de los experimentos queda determinado por un conjunto de ensayos que determinan el proceso de experimentación. Para definir y almacenar de forma estructurada los experimentos se utiliza un archivo XML. En este archivo se definen tres tipos de elementos:

- punto, determina un punto en el espacio de coordenadas del entorno virtual. Ejemplo: `<point name='Sur' xp='0' yp='-0.4' zp='0' />`.
- ensayo, permite definir un ensayo de simulación. Incluye el tipo de ensayo (habitación, entrenamiento o testeo), un nombre, el punto de inicio del robot, la cantidad de veces que se desea repetir el ensayo y la condición para darlo por finalizado (tiempo o información sensorial). Para finalizar el ensayo por información sensorial debe usarse `time=0`. Ejemplo: `<trial type='habituation' name='HA1' pointName='Sur' reps='1' time='60' />`, donde se define el ensayo HA1 de tipo habitación, donde el robot se ubica inicialmente en el punto Sur, finaliza luego de 60 minutos de iniciado y se ejecuta solo una vez.
- operación: permiten manipular el entorno dinámicamente. Incluye el nombre de la operación a ejecutar (poner o quitar), sobre que objeto se realiza y al comienzo de que etapa. Ejemplo: `<operation name='removeFood' type='remove' object='food' trial='HA1' />`. Este ejemplo es usado para sacar la comida del escenario en el ensayo HA1, probablemente de habitación.

A continuación se presenta un ejemplo completo de la simulación para una rata robot a realizar uno de los experimentos de Morris.

```
<simulation >
<!-- Initial robot positions -->
<point name="W" xp="-0.4" yp="0" zp="0" rot="0"/>
<point name="N" xp="0" yp="0" zp="-0.4" rot="0"/>
<point name="E" xp="0.4" yp="0" zp="0" rot="0"/>
<point name="S" xp="0" yp="0" zp="0.4" rot="0"/>

<!-- Initial platform (goal) positions -->
<point name="SE" xp="0.2" yp="0" zp="0.2" rot="0"/>
<point name="SW" xp="-0.2" yp="0" zp="0.2" rot="0"/>
<point name="NE" xp="0.2" yp="0" zp="-0.2" rot="0"/>
<point name="NW" xp="-0.2" yp="0" zp="-0.2" rot="0"/>

<!-- Simulation step definition -->
<trial type="habituation" name="HADay1" pointName="S" reps="1" time="360"/>
<trial type="habituation" name="HADay2" pointName="S" reps="1" time="360"/>

<!--Day 3 - Eight trainigs stages-->
<trial type="training" name="Dia3LL" pointName="S" reps="1" time="0"/>
<trial type="training" name="Dia3RR" pointName="E" reps="1" time="0"/>
<trial type="training" name="Dia3LL" pointName="S" reps="1" time="0"/>
<trial type="training" name="Dia3RR" pointName="E" reps="1" time="0"/>
<trial type="training" name="Dia3L" pointName="W" reps="1" time="0"/>
<trial type="training" name="Dia3R" pointName="N" reps="1" time="0"/>
<trial type="training" name="Dia3L" pointName="W" reps="1" time="0"/>
<trial type="training" name="Dia3R" pointName="N" reps="1" time="0"/>

<!--Day 4 - Eight trainigs stages with other secuencia -->
<trial type="training" name="Dia4RR" pointName="E" reps="1" time="0"/>
```

```
<trial type="training" name="Dia4LL" pointName="S" reps="1" time="0"/>
<trial type="training" name="Dia4RR" pointName="E" reps="1" time="0"/>
<trial type="training" name="Dia4LL" pointName="S" reps="1" time="0"/>
<trial type="training" name="Dia4R" pointName="N" reps="1" time="0"/>
<trial type="training" name="Dia4L" pointName="W" reps="1" time="0"/>
<trial type="training" name="Dia4R" pointName="N" reps="1" time="0"/>
<trial type="training" name="Dia4L" pointName="W" reps="1" time="0"/>

<!--Day 5 -->
<trial type="training" name="Dia5LL" pointName="S" reps="1" time="0"/>
<trial type="training" name="Dia5RR" pointName="E" reps="1" time="0"/>
<trial type="training" name="Dia5L" pointName="W" reps="1" time="0"/>
<trial type="training" name="Dia5R" pointName="N" reps="1" time="0"/>

<!--Day 5 - Test A -->
<trial type="testing" name="TestALL" pointName="SE" reps="1" time="120"/>

<!-- Remove food at the begining of the TestA -->
<operation name="remove" primitive="food" trial="TestALL"/>

<!-- Move food to a fixed position al the begining of training stages -->
<operation name="move" primitive="food" trial="Dia3LL" pointName="NW"/>
</simulation>
```

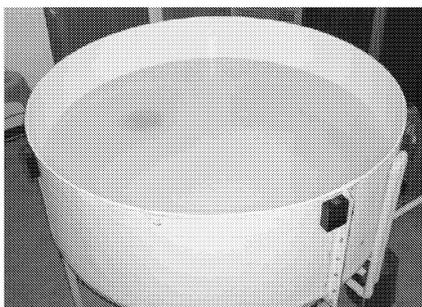
Capítulo 5

Experimentos

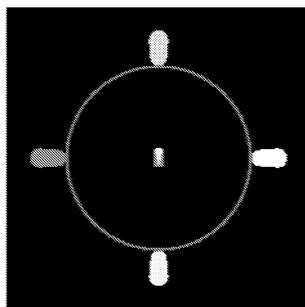
5.1. Introducción

Los experimentos llevados adelante pretenden evaluar el modelo de cognición espacial. Este modelo está basado en estudios realizados sobre ratas, incorporando las principales neuronas involucradas en el proceso de navegación y en particular con la localización espacial. El laberinto de Morris (Morris, 1981) es uno de los primeros escenarios diseñados con el objetivo de estudiar las estrategias de localización espacial en ratas y es utilizado hasta la actualidad.

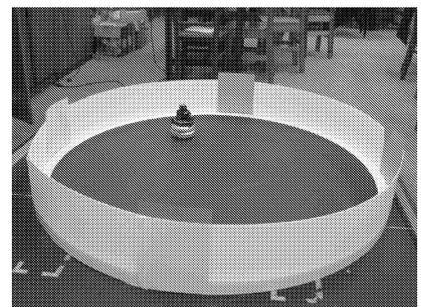
El laberinto de agua de Morris es un entorno circular abierto construido en general con un tanque con agua y una plataforma a la cual la rata puede subir para salir del agua. En la Figura 5.1 se presentan algunos ejemplos de laberintos de Morris, en (a) un laberinto utilizado para experimentación con ratas, en (b) una vista del entorno virtual con la rata virtual en el centro y en (c) el entorno real utilizado para interactuar con el modelo utilizando el robot Khepera.



(a) Utilizado para experimentación con ratas.



(b) Utilizado para simular el modelo.



(c) Utilizado para experimentación con el robot.

Figura 5.1 – Ejemplos de laberintos de Morris.

5.2. Setup del modelo

Es esta sección se presenta la forma en que es generada la población de neuronas grilla incluidas en el módulo de neuronas grilla de modelo y los parámetros de cada una de estas neuronas.

Como se presentó en la sección 3.4, la neurona grilla queda determinada por los parámetros de espaciado, orientación y fase espacial. Se ha observado que el espaciado crece desde la parte ventral a la parte dorsal de la MEC y esto a su vez concuerda con la variación del crecimiento de los campos de lugar del hipocampo, esto es, el tamaño de los campos de lugar del hipocampo crece desde su parte ventral a dorsal. Neuronas vecinas en la MEC presentan similar orientación y espaciado, y diversidad de espaciado. No se ha determinado aún cómo se organizan estas neuronas respecto de la orientación. Algunas observaciones preliminares sugieren que las neuronas grilla tendrían diferentes orientaciones en las diferentes regiones de izquierda a derecha (Hafting et al., 2005; Fyhn et al., 2007).

Basado en estas observaciones, y tomándolas como ciertas, se puede afirmar que estando en una determinada posición del eje ventral dorsal de la MEC y muestreando de izquierda a derecha, la población de neuronas grilla estaría caracterizada por un espaciado similar y una diversidad de orientaciones y fases.

Los métodos para generar campos de lugar a partir de disparos grilla no han tenido en cuenta la variación de las orientaciones como mecanismo principal para ello. Sin embargo, los resultados experimentales mostraron que si se generan campos de lugar a partir de neuronas grilla con similar fase y espaciado, y diferentes orientaciones, los disparos de lugar son capaces de tolerar mejor el ruido en sus entradas.

En la Figura 5.2 se muestra simultáneamente el disparo de neuronas grilla utilizando un color para cada una de ellas, la fase y el espaciado es el mismo para todas ellas, variándose la orientación. La misma muestra de izquierda a derecha y de arriba a abajo, simultáneamente 1, 5, 10, 20, 25, 30 y 35 neuronas grilla para las cuales sólo se varia la orientación. El hecho de usar una misma fase y espaciado se observa en la figura como una agrupación que se mantiene fija para todas las neuronas ubicado en el punto cardinal noroeste (borde superior izquierdo). Si el proceso de transformación de disparos grilla a lugar es capaz de detectar que neuronas grilla se activan simultáneamente solo en esa fase espacial podría generar un campo de lugar en el entorno.

La Figura 5.3 muestra la posición del entorno en que disparan cuatro neuronas lugar (diferenciadas por su color) generadas utilizando la Ecuación 3.12 sobre un conjunto de N_{gc} neuronas grilla. La neurona de lugar de color azul, en el punto cardinal noroeste (borde superior izquierdo), muestra la posición en el entorno que dispara cuando se utiliza como conjunto generador las neuronas grilla presentadas en la Figura 5.2, determinado por el punto fijo dado por la misma fase utilizada para la generación de los disparos grilla. De esta forma, las Figuras 5.2 y 5.3 presentan respectivamente los disparos grilla basados en la propuesta de Hasselmo y los disparos de lugar basados en Soldstad.

En este sentido, para los experimentos primero se define un único espaciado, luego se divide el entorno utilizando una grilla regular y por ultimo se utilizan distintas orientaciones en cada vértice de la grilla regular. Cada uno de los vértices de la grilla regular determina un punto en el espacio 2D de movimiento de la rata y por ello la fase espacial de las neuronas grilla.

En resumen, para determinar la población de neuronas grilla se elige un espaciado, un tamaño para la grilla regular y la cantidad de orientaciones aleatorias (N_{go}) a utilizar en cada vértice de la grilla. El valor de espaciado elegido es usado para todas las neuronas grilla. El tamaño de la grilla regular determina los puntos del espacio 2D que potencialmente podrían dar lugar a un campo de lugar, un punto del espacio determina la fase espacial, determinando el segundo parámetro de las neuronas grilla. Por último, se determina el parámetro de orientación generando aleatoriamente N_{go} orientaciones.

El diámetro de los campos de lugar crece en el hipocampo, al igual que la MEC, en el eje dorsal-ventral. En un entorno abierto los campos de lugar varían desde los 20cm en la parte dorsal

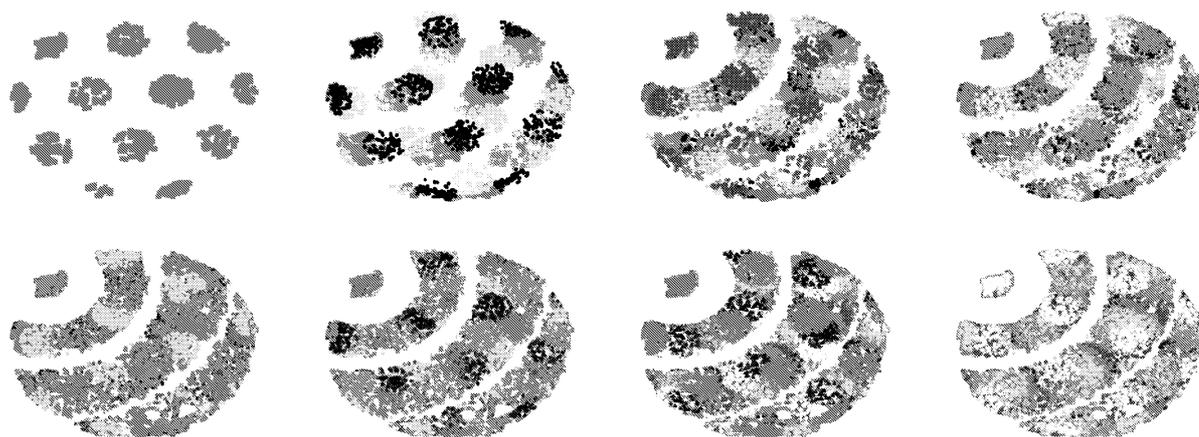


Figura 5.2 – Disparo grilla para diferentes orientaciones, y una misma fase y espaciado.

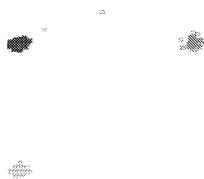
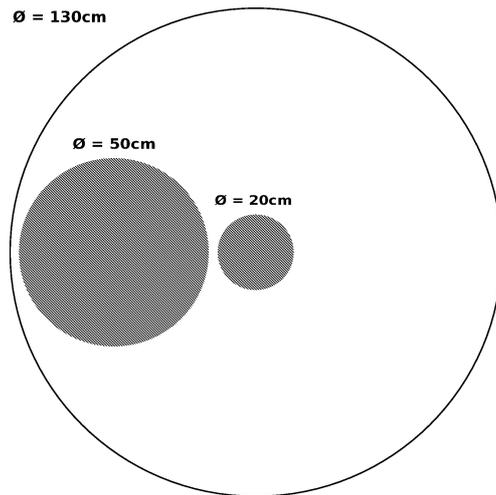
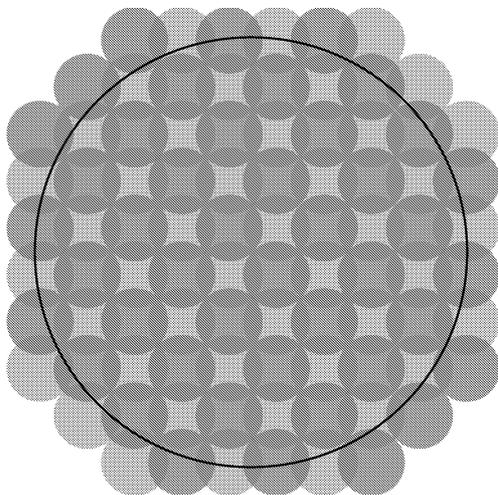


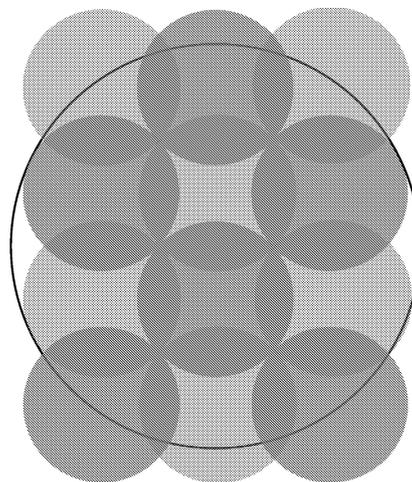
Figura 5.3 – Disparos de lugar usando ecuación de Soldstad.



(a) Diámetro de campos de lugar en relación al diámetro del entorno (130cm).



(b) Distribución regular de los campos de lugar ($\phi = 20cm$) en el entorno.



(c) Distribución regular de los campos de lugar ($\phi = 50cm$) en el entorno.

Figura 5.4 – Relación y distribución de los campos de lugar en el entorno de Morris.

del hipocampo, llegando a 50cm en su parte media, y a varios metros en la parte más ventral del mismo (Solstad et al., 2006). En la Figura 5.4.a se muestra la dimensión de estos campos de lugar y su relación con el entorno de experimentación. Se decidió tomar como referencia los puntos más dorsales tanto de la MEC como del hipocampo para lograr la mayor precisión posible en el módulo PI.

Una forma general para ubicar los campos de lugar de manera de cubrir completamente el entorno es utilizar una grilla regular de $N_{gg} \times N_{gg}$ celdas, colocando en cada vértice un campo de lugar. De esta manera se cubre todo el entorno con un patrón regular teniendo una cantidad razonable de campos de lugar. En la Figura 5.4.b se muestra el entorno de experimentación circular tapizado con un patrón regular de círculos de 20cm de diámetro. En este caso se utiliza una grilla de 10x10 sin colocar campos en las tres celdas de los cuatro vértices, éstas deben eliminarse pues el entorno es circular y el procedimiento propuesto genera tapizados rectangulares, utilizándose un total de 88 campos de lugar. De igual forma la Figura 5.4.c se muestra el entorno de experimentación circular tapizado con un patrón regular de círculos de 50cm de diámetro.

Para generar los campos de lugar en los puntos definidos por la grilla se colocan en esa posición un conjunto de neuronas grilla. Teniendo en cuenta la eficiencia computacional se utiliza la menor cantidad de neuronas necesarias para generar campos de lugar en un punto del espacio, variando la orientación de manera aleatoria para cada vértice. Como se reporta en el trabajo de Solstad y colaboradores (Solstad et al., 2006) si se utilizan al menos diez neuronas grilla es posible generar campos de lugar para la fase espacial elegida. Esto es condición suficiente para generar en la vecindad espacial del vértice una neurona de lugar por lo que se utiliza $N_{go} = 10$. La orientación de una neurona grilla queda determinada por las neuronas dirección de la cabeza utilizadas, para efectivamente generar una neurona grilla las tres neuronas dirección de la cabeza elegidas deben diferir en 120° . Por este motivo se selecciona aleatoriamente la dirección de la primera neurona de dirección de la cabeza como un ángulo entre 0° y 120° quedando determinada la dirección de las otras dos sumándole a la primera 120° para generar la segunda neurona y 240° para generar la tercera.

Queda entonces determinado el número total de neuronas grilla en 880, distribuidas en el escenario de manera de cubrirlo completa y uniformemente con campos de lugar.

5.3. Protocolo de Morris

El laberinto de agua de Morris fue desarrollado en 1981 por Richard G. Morris y continua siendo hasta hoy ampliamente utilizado para aprendizaje de lugares y memoria. Al igual que los laberintos en T o los basados en brazos, el laberinto de agua está diseñado para evaluar la memoria espacial, los mapas cognitivos y el control de movimiento del animal. El propósito de los trabajos de Morris era demostrar que las ratas son capaces de aprender rápidamente a localizar un objeto que nunca han visto, oído o olfateado mientras éste permanezca en una posición fija relativa a marcas externas (Morris, 1981). El modelo de Barrera (Barrera and Weitzenfeld, 2008) está diseñado para navegar en laberintos basados en corredores siendo el mismo evaluado en laberintos con ciclos, en T y los basados en brazos.

En esta sección se presentan y reproducen los protocolos de experimentación llevados adelante en ratas por Morris. Se presentan los resultados con robots, en tanto en un entorno virtual como en uno real, utilizando el modelo propuesto en este trabajo y se compara con los estudios en ratas realizados con Morris.

5.3.1. El laberinto

En la Figura 5.5 se presenta un esquema del laberinto y los elementos principales utilizados durante los distintos tipos de experimentos llevados adelante. El laberinto de Morris consiste de un tanque circular (piscina) de 1.3m de diámetro y una altura de 0.6m, colocando en él agua hasta un nivel de 0.4m. La piscina se coloca sobre una estructura de unos 0.8m de manera de permitir un acceso adecuado a una persona. El aparato es colocado en el centro de una habitación de 3x4m. La habitación tiene dos ventanas en una de las paredes, una puerta en la pared opuesta y estanterías en las otras dos paredes. Estas dimensiones son adecuadas para un roedor cuyo diámetro esté entre 15-18 cm y una altura de 6 cm. Dentro de la piscina se coloca una plataforma de escape que le permite al roedor salir del agua fría. La plataforma de escape es de 10 cm de diámetro. La plataforma no debe estar demasiado cerca del borde, o la rata la encontrará rápidamente al moverse en círculo alrededor del borde de la piscina. Se utiliza una de dos plataformas dependiendo del experimento que se esté llevando adelante, una visible desde la superficie del agua de color negro y una oculta de color blanco. Al agua se le realiza un pequeño agregado de leche de manera de ocultar la plataforma blanca y no generar señales locales. Se utilizan calentadores de agua para controlar la actividad del animal. Una buena temperatura del agua para las ratas es de $26^{\circ} C \pm 1^{\circ}$. Si bien más frío estimula la actividad, esto puede causar hipotermia, lo que dificulta el aprendizaje.

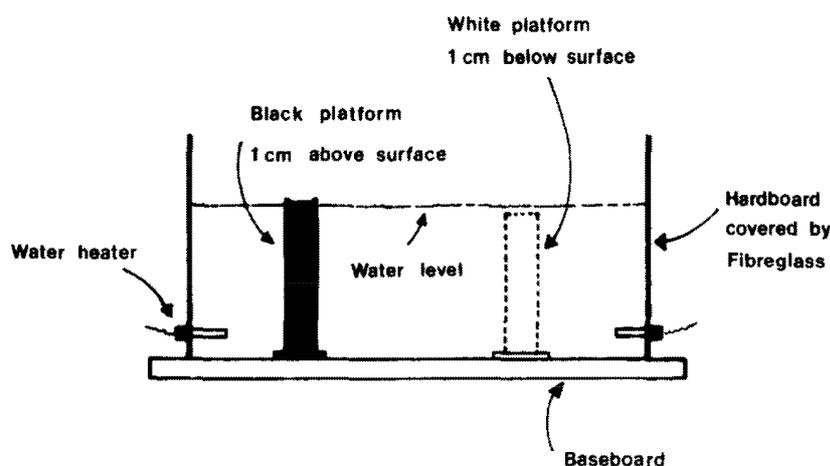


Figura 5.5 – Características y elementos que forman el aparato diseñado por Morris (Morris, 1981).

5.3.2. Protocolo de experimentación

En esta sección se describen los protocolos de experimentación con ratas en entornos abiertos desarrollados por Morris. Morris en su trabajo presenta dos experimentos de manera de investigar las estrategias empleadas por las ratas en una tarea de aproximación a una plataforma, en el primer caso dejándola fija mientras que en el segundo la plataforma es reubicada dentro de la piscina. Morris define para cada experimento dos posibles situaciones, plataforma oculta o visible, que se mantiene durante todos los ensayos del experimento.

En el contexto de este trabajo se diseñan únicamente los experimentos correspondientes a la plataforma oculta explotando las señales externas, o marcas, alrededor del escenario como es en cierta forma especificado por Morris. En la Figura 5.6 se presenta el escenario circular virtual utilizado

para los experimentos simulados. Los cuatro círculos de color alrededor del escenario representan las marcas distintivas posicionadas de forma equidistante.

Los experimentos que utilizan una plataforma visible no son llevados adelante en el contexto de este trabajo pues el modelo propuesto no incluye habilidades para navegar basado en taxias (control direccionado como respuesta a la percepción de un estímulo).

5.3.2.1. Experimento 1

Morris inicia el experimento con 33 ratas que son mantenidas en jaulas individuales, controlando la ingesta de comida y el agua. Una de las ratas muestra dificultades para nadar en el inicio del experimento por lo que es descartada. Los datos reportados son por ellos sobre las 32 ratas restantes. El procedimiento incluye tres tipos de ensayos: preentrenamiento, adquisición del escape y testeo.

Las ratas se asignan de manera aleatoria a uno de cuatro grupos posibles. Un grupo define las características de la plataforma a usar (oculta o visible) y si su posición cambia durante el entrenamiento. El Cuadro 5.1 presenta los cuatro grupos definidos para este experimento y, los detalles de visibilidad y posición de la plataforma.

Grupo	Descripción
<i>Cue + Place</i>	Se utiliza la plataforma visible (negra) y no se modifica su posición durante el entrenamiento.
<i>Place</i>	Se utiliza la plataforma oculta (blanca) y su posición no se modifica durante el entrenamiento.
<i>Cue-only</i>	Se utiliza la plataforma visible (negra) y su posición se modifica durante el entrenamiento.
<i>Place-Random</i>	Se utiliza la plataforma oculta (blanca) y su posición se modifica durante el entrenamiento.

Cuadro 5.1 – Variantes sobre la plataforma a la cual son sometidos los animales por grupos.

El experimento se divide en un conjunto de ensayos que son realizados de manera sistemática durante cinco días consecutivos. En el Cuadro 5.2 se presenta un resumen las característica del experimento 1 organizándolo en base al día en que ocurren los ensayos.

Día	Tipo de Ensayo	#Ensayos	Finalización
1 y 2	Preentrenamiento	1	180s
3	Entrenamiento	8	Alcanza la plataforma
4	Entrenamiento	8	Alcanza la plataforma
5	Entrenamiento	4	Alcanza la plataforma
	Testeo	1	60s (Test A) Alcanza la plataforma (Test B)

Cuadro 5.2 – Resumen diario de los ensayos para el experimento 1.

Todas las ratas son sometidas a dos ensayos de preentrenamiento llevados adelante en dos días diferentes y con una duración fija de 180s cada uno. Los preentrenamientos son ensayos de habituación que se caracterizan por no incluir ninguna de las plataformas en la piscina.

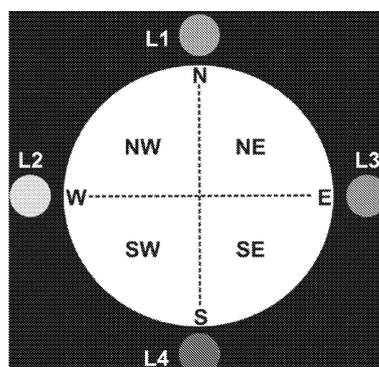


Figura 5.6 – El diagrama presenta las referencias cardinales dentro del escenario virtual. Glosario: L1 a L4 - Marcas 1 a 4; S - Sur; N - Norte; E - Este; W - Oeste. SE - Sureste; SW - Suroeste; NW - Noroeste; NE - Noreste.

El procedimiento de entrenamiento comienza en el tercer día con los ensayos adquisición del escape, realizándose ocho ensayos manteniendo la configuración del aparato. Para los grupos que mantienen fija la plataforma (*Cue + Place* y *Place*), la posición inicial de ella se elige aleatoriamente al comienzo entre los puntos cardinales SO, NO, NE y SE (no necesariamente coincidentes con las direcciones magnéticas terrestres, ilustrados en la Figura 5.6) y se balancean entre los individuos dentro de cada grupo de manera que haya dos individuos entrenados para cada punto. El animal es colocado cerca del borde en alguna de las posiciones N, E, S u O. La posición varía durante los ocho ensayos de forma que cada rata inicie dos veces en cada una de las posiciones. El Cuadro 5.3 presenta para cada una de las ratas del grupo *Place* la posición inicial de la plataforma y la posición inicial del animal para cada uno de los ensayos de entrenamiento¹.

El Cuadro 5.4 presenta la secuencia de posiciones utilizada para mover la plataforma entre ensayos para el grupo *Place-Random*, mientras que para las posiciones iniciales de la rata se utilizan las mismas secuencias del Cuadro 5.3. El día 4 consta de ocho ensayos similares a los del día 3 variando la posición de inicio de la rata (para todos los grupos) y la de la plataforma en los casos que corresponde (grupos *Cue-only* y *Place-Random*).

En el día 5 consta de cuatro ensayos de entrenamiento para los cuales los tiempos de ejecución de la tarea parecen estabilizarse. El último ensayo del día 5 es inmediatamente seguido por uno de dos tests, Test A o Test B. Para el Test A la plataforma utilizada se retira de la piscina y el animal es colocado en ella para un único ensayo de 60 segundos. Posteriormente se analiza la permanencia del animal en cada uno de los cuadrantes (SO, NO, NE y SE) durante ese lapso de tiempo. El Test B mantiene la plataforma en la piscina pero se coloca en la posición diametralmente opuesta para los grupos que la mantenían fija durante el entrenamiento y en un lugar fijo para los otros dos grupos.

En el Cuadro 5.5 se presentan las ratas elegidas a ser utilizadas en el experimento Test A y la posición inicial de ellas. En el documento de Morris no está definida la posición inicial a utilizar, en el contexto de este trabajo se utiliza la diametralmente opuesta a la posición utilizada en la etapa de entrenamiento para el grupo *Place* y aleatoria para el grupo *Place-Random*.

En el Cuadro 5.6 se presentan las ratas elegidas para el Test B y la posición inicial de ellas para cada uno de los cuatro ensayos de testeo.

¹Para generar los puntos iniciales de la rata y de la plataforma de manera aleatoria se utilizó la página www.random.org/lists.

Rata		Posiciones iniciales de la rata																					
		Día 3										Día 4										Día 5	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20		
1P	SO	SN	EO	EO	ON	ON	OS	SN	NS	NS	OS	OS	OS	OE	ES	ES	ES	ES	ES	ES			
2P	NE	EO	SO	SO	OS	ES	NS	NS	ES	ES	ES	ES	ES	ES	ES	ES	ES	ES	ES	ES			
3P	SE	EO	SN	ON	ON	ES	ES	ES	ES	ES	ES	ES	ES	ES									
4P	SO	ON	SN	SO	SO	ES	ES	ES	ES	ES	ES	ES	ES	ES									
5P	NO	EO	OS	OS	ES	NS	NS	NS	NS	NS	NS	NS	NS	NS									
6P	SE	ES	EO	ON	ON	OS	OS	OS	OS	OS	OS	OS	OS	OS									
7P	NO	EO	SN	NS	NS	OS	ES	ES	ES	ES	ES	ES	ES	ES	ES	ES	ES	ES	ES	ES			
8P	NE	NS	EO	EO	ES	NS	NS	NS	NS	NS	NS	NS	NS	NS									

Cuadro 5.3 – Posición de la plataforma y posición inicial de la rata para los 20 ensayos de entrenamiento para las ocho ratas que componen el grupo *Place*.
Glosario: PP - posición de la plataforma.

Rata		Día 3										Día 4										Día 5	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20		
		1PR	SO	NO	SE	SO	NE	SE	NE	NO	NO	NE	NE	NO	SE	SE	SO	SO	NO	NE	SE	SO	
2PR	NE	SE	SO	NO	SO	NO	NE	SE	SO	SE	NE	SE	NO	SO	NO	NE	SE	SE	NE	SO	NO		
3PR	NO	NE	SO	SO	SE	SE	NO	NE	NO	SE	NE	NO	NO	SE	SO	SO	NO	NO	SO	NO	SE		
4PR	SO	SE	NO	SO	NO	SE	NE	SO	NO	NO	SE	SO	SO	NE	NE	SE	SO	NO	SE	NE	NE		
5PR	SO	NO	NE	SO	NO	NE	SE	NE	SE	SE	NE	SO	SO	NO	NO	NE	SE	SE	SO	NO	NO		
6PR	NO	SE	SO	NE	SE	SO	NE	SE	NO	SO	NO	SO	SO	SE	NE	NE	NE	NE	SO	NO	SE		
7PR	SO	NO	SO	SE	NO	SE	NO	SE	NO	SO	NO	SO	SO	SE	NE	NE	NE	NE	SO	SE	NO		
8PR	NO	NO	SE	NE	SO	NE	SE	SO	NE	SE	NE	SE	SE	NO	NO	SO	SO	NO	SE	NO	SE		

Cuadro 5.4 – Posición de la plataforma para las ocho ratas que componen el grupo *Place-Random*.

Grupo <i>Place</i>		Grupo <i>Place-Random</i>	
Rata	Posición de inicio	Rata	Posición de inicio
1P	NE	1PR	SO
2P	NO	2PR	NO
3P	SE	3PR	SE
5P	SO	4PR	NE

Cuadro 5.5 – Posiciones iniciales de la rata durante el Test A para cuatro ratas del grupo *Place* y cuatro del grupo *Place-Random*.

Ensayo				Grupo <i>Place</i>		Grupo <i>Place-Random</i>	
1	2	3	4	Rata	Posición de inicio	Rata	Posición de inicio
O	S	N	E	4P	NE	5PR	SO
S	E	N	O	6P	SE	6PR	NO
N	O	E	S	7P	NO	7PR	SE
E	N	S	O	8P	SO	8PR	NE

Cuadro 5.6 – Posiciones iniciales de la plataforma y la rata durante el Test B para cuatro ratas del grupo *Place* y cuatro del grupo *Place-Random*.

Al igual que los resultados que presenta Morris, al utilizar el modelo de cognición espacial los agentes son capaces de alcanzar un objeto no visible mediante determinación de su posición en un entorno conocido. Se observa una buena adquisición de la tarea de escape sobre el final del experimento, al estabilizarse los tiempos necesarios para realizar los ensayos.

5.3.2.2. Experimento 2

Este experimento utiliza 15 ratas y el aparato tiene las mismas características pero solo se utiliza la plataforma oculta. Al igual que antes el procedimiento incluye tres tipos de ensayos: preentrenamiento, adquisición del escape y testeo. En el Cuadro 5.7 se presenta de manera resumida la información al respecto de los ensayos realizados para este experimento.

Día	Tipo	#Ensayos	Finalización
1	Preentrenamiento	1	180s
2	Entrenamiento	6	Alcanza la plataforma
3	Entrenamiento	6	Alcanza la plataforma
4	Entrenamiento	3	Alcanza la plataforma
5	Testeo	3	Alcanza la plataforma

Cuadro 5.7 – Resumen diario de los ensayos para el experimento 2.

Todas las ratas son sometidas a un ensayo de preentrenamiento con una duración fija de 180s. El procedimiento de entrenamiento comienza en el segundo día con los ensayos adquisición del escape, realizándose 15 intentos de escape distribuidos en tres días. Todos los ensayos de adquisición inician en la posición O (W) y la plataforma se coloca en la posición NE, como se muestra en la Figura 5.7.

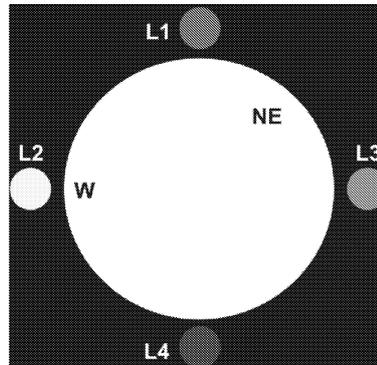


Figura 5.7 – Posición de la plataforma, NE, y el punto de partida de las ratas, W, durante el entrenamiento del experimento 2.

Al igual que en el experimento 1 la población inicial de ratas se divide en grupos pero éstos no quedan definidos al inicio del experimento sino que esta clasificación se realiza a partir de los ensayos de testeo.

Los grupos son *Same-Place*, *New-Place* y *Control*. En el Cuadro 5.8 se presentan los grupos en los que se clasifica la población inicial de ratas y sus diferencias. Los animales para el grupo *Same-Place* son testeados desde las tres posiciones iniciales no utilizadas en el entrenamiento (N, S y E) mientras la posición de la plataforma no se modifica. El cuadro muestra los puntos de partida para cada una de las ratas para cada uno de los ensayos de test.

Los animales para el grupo *New-Place* se utiliza la misma secuencia de nuevas posiciones de inicio mientras que la plataforma cambia de posición en cada ensayo manteniendo una relación angular respecto de la posición de inicio, esto es, cuando la posición de inicio es N la plataforma se coloca en SE, cuando el inicio es E la plataforma se coloca en SO y cuando el inicio es S se coloca en NO. Para el grupo de control mantiene la posición de inicio fija en O y la posición de la plataforma en NE de manera de tener una referencia de la latencia de escape sobre la cual evaluar el rendimiento de los otros dos grupos.

Grupo	#Ratas	Durante las etapas de testeo	
		Posición de inicio	Posición de la plataforma
<i>Same-Place</i>	6	N, S y E	NE
<i>New-Place</i>	6	N, S y E	SE, NO y SO
<i>Control</i>	3	O	NE

Cuadro 5.8 – Cantidad de ratas, posiciones de partida y posiciones de la plataforma para los animales de los distintos grupos.

5.3.3. Resultados de los experimentos

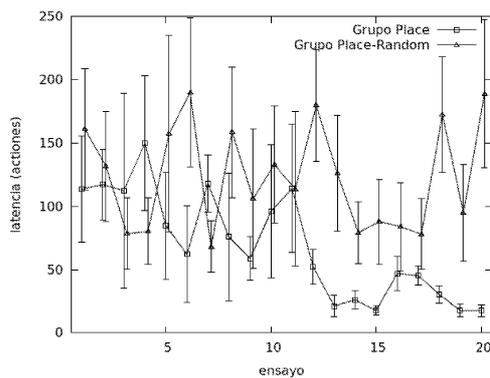
Para los experimentos se utilizan la misma cantidad de ratas virtuales que de ratas reales utilizadas por Morris y se valida con una rata robot. Esta decisión se tomo principalmente por los tiempos de ejecución del modelo en el mundo virtual contra el real pues, la ejecución de un experimento sobre un robot virtual requiere de aproximadamente 4 horas contra 32 horas de ejecución

en el robot real. Debe tenerse en cuenta que la mayor parte del tiempo el robot está tomando panorámicas y cada una de ellas insume un promedio de 52 segundos.

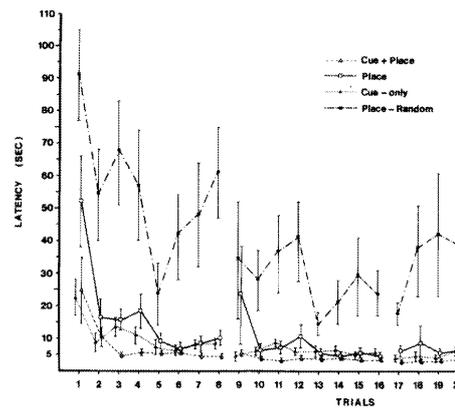
Durante los experimentos se realizan medidas de manera de poder evaluar tanto cualitativamente como cuantitativamente el rendimiento de las ratas. Esta información se utiliza para presentar los resultados y contrastarlos con los obtenidos por Morris.

5.3.3.1. Experimento 1

La Figura 5.8 muestra las latencias en los ensayos de entrenamiento para los grupos Place y Place-Random para la rata virtual en (a) y para todos los grupos para las ratas de Morris (b). Como puede observarse Morris presenta la latencia en segundos mientras que las ejecuciones del modelo utiliza cantidad de acciones. Este cambio se debe a la necesidad de reflejar la latencia en la toma de decisiones del modelo independiente de aspectos tales como asignación de recursos del sistema operativo, latencia y recuperación de errores en la comunicación inalámbrica, y el mecanismo de estabilización de las imágenes, entre otros.



(a) Latencia en acciones para las ratas virtuales.

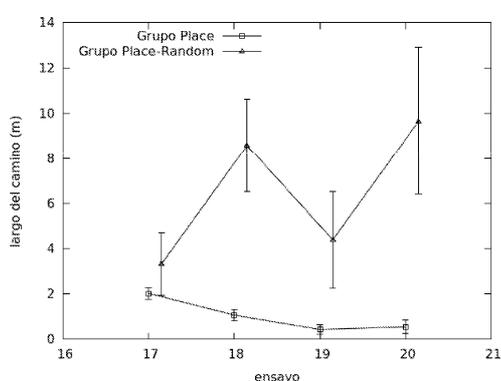


(b) Latencia en segundos para las ratas utilizadas por Morris (Morris, 1981).

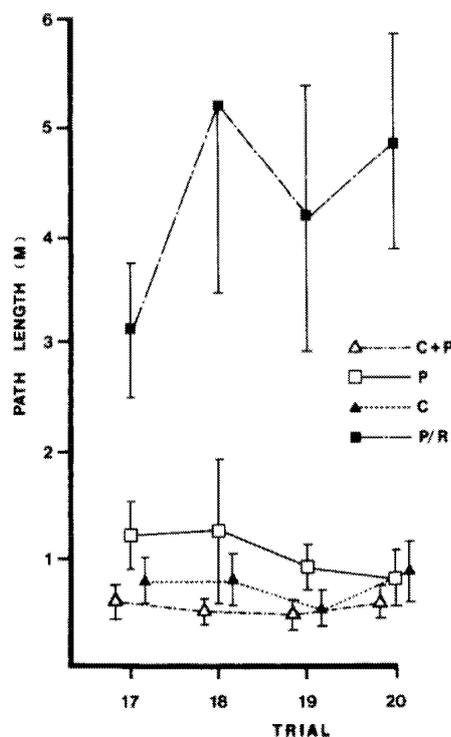
Figura 5.8 – Latencia de escape para los 20 ensayos de entrenamientos del experimento 1.

El grupo Place-Random presenta un rendimiento inferior que el grupo Place durante la adquisición de la tarea de escape. Al igual que Morris, las ratas virtuales del grupo Place-Random no son capaces de estabilizar la latencia de escape sobre el final de la etapa de entrenamiento debido a la variabilidad de la posición de la plataforma.

Luego que el rendimiento se estabiliza (Ensayos 17-20), se analiza el comportamiento de escape para cada grupo. La Figura 5.9 muestra el largo promedio de las trayectorias recorridas para las ratas agrupadas en grupos. Nuevamente, al igual que Morris compara cualitativamente el comportamiento de los distintos grupos, las ratas virtuales del grupo Place-Random recorren caminos mucho más largos con una considerable variabilidad entre ensayos, mientras que el grupo Place muestra una progresiva disminución en el largo de los caminos al considerar las etapas finales de los ensayos de entrenamiento.



(a) Largo de los caminos para las ratas virtuales.



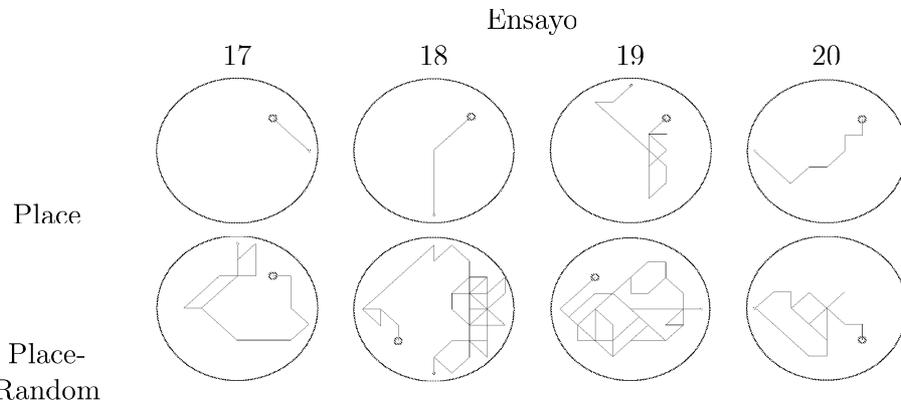
(b) Largo de los caminos para las ratas utilizadas por Morris (Morris, 1981).

Figura 5.9 – Largo de los caminos para los ensayos 17 a 20 del experimento 1.

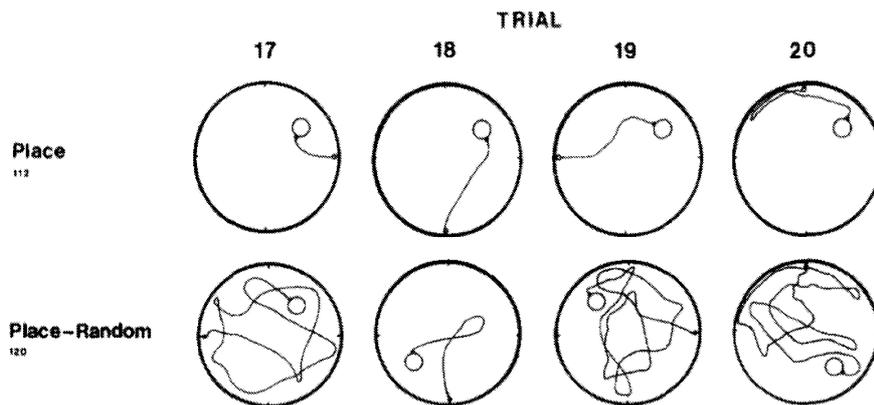
La Figura 5.10 presenta las trayectorias seguidas por las ratas virtuales (a) y reales (b) para cada grupo. Como puede observarse, solo las ratas en el grupo Place-Random se comporta de una manera no direccional, esto es, confundidas al momento de identificad una ruta directa hacia una plataforma que está cambiando entre ensayos su posición.

La Figura 5.10.a muestra una vista superior del escenario, el borde del escenario se presenta de color azul, la plataforma con un círculo grande rojo, la posición inicial de la rata con un círculo pequeño rojo y la trayectoria de la rata en negro. Los caminos son razonablemente dirigidos hacia la plataforma para las ratas del grupo para los puntos de partida desde E en el ensayo 17, desde el S para el ensayo 18, desde el N para el ensayo 19 y desde el O para el ensayo 20, si bien para el ensayo 19 la rata se dirige en un un primer momento hacia el SE. Para las ratas del grupo Place-Random se mueven por todo el entorno para los puntos de partida desde el N en el ensayo 17, desde el S para el ensayo 18, desde el E para el ensayo 19 y desde el O para el ensayo 20. La Figura 5.10.b incluye las trayectorias reportadas por Morris, el punto de inicio se muestra con un pequeño círculo y la plataforma con uno mayor, la rata número 112 es una de las representantes del grupo Place y la rata 120 del grupo Place-Random.

Al compararse los caminos realizados por las ratas virtuales con los realizados por las ratas reales puede observarse que las trayectorias de estas últimas son notoriamente más suaves, esto se debe a que las posibles acciones de las ratas virtuales están limitados a segmentos orientados a múltiplos de 45°.



(a) Trayectorias para las ratas virtuales. El círculo rojo pequeño representa el punto de inicio de la rata y el grande la posición de la plataforma.



(b) Trayectorias para las ratas de Morris (Morris, 1981). El círculo pequeño representa el punto de inicio de la rata y el grande la posición de la plataforma.

Figura 5.10 – Trayectorias realizadas por las ratas virtuales para los grupos Place y Place-Random. Ensayos 17 a 20 del experimento 1.

La Figura 5.11 muestra los caminos realizados en el primer ensayo de test para las mismas ratas cuyos caminos fueron presentados en la Figura 5.10. La rata del grupo Place ejecuta el Test B mostrando una fuerte atracción espacial hacia el cuadrante NE, cuadrante utilizado como objetivo durante los ensayos de entrenamiento. Durante este ensayo de entrenamiento la plataforma es colocada en la posición SO, y si bien la rata es capaz de alcanzarla, muestra una estrategia de búsqueda centrada en el cuadrante utilizado para colocar la plataforma durante en entrenamiento. Por otro lado, la rata en el grupo Place-Random ejecuta el Test A, esto es, sin la plataforma. Como se puede apreciar en la Figura 5.11, las ratas buscan la plataforma por todo el escenario.

Al analizar el rendimiento de las ratas virtuales para cada grupo en el ensayo que la plataforma se retira del escenario (Test A), se registra el tiempo que permanecen en cada uno de los cuadrantes. La Figura 5.12 muestra los tiempos promedios registrados en cada cuadrante, pudiéndose observar que las ratas del grupo Place presentan una fuerte atracción hacia el cuadrante donde se encontraba la plataforma durante el entrenamiento (TR), en oposición a las ratas del grupo Place-Random, que

no presentan una atracción particular hacia ninguno de los cuadrantes.

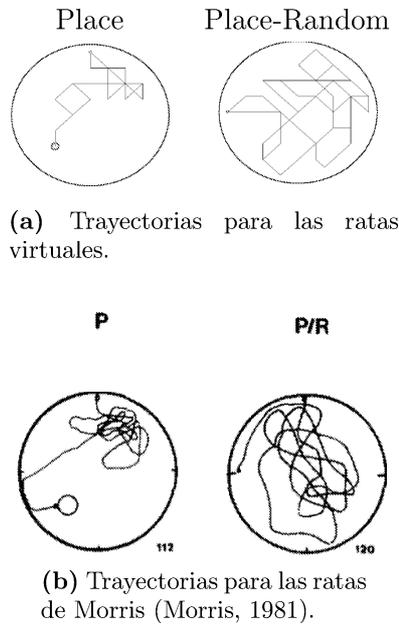


Figura 5.11 – Trayectorias realizadas por las ratas virtuales para el ensayo de Test A o B.

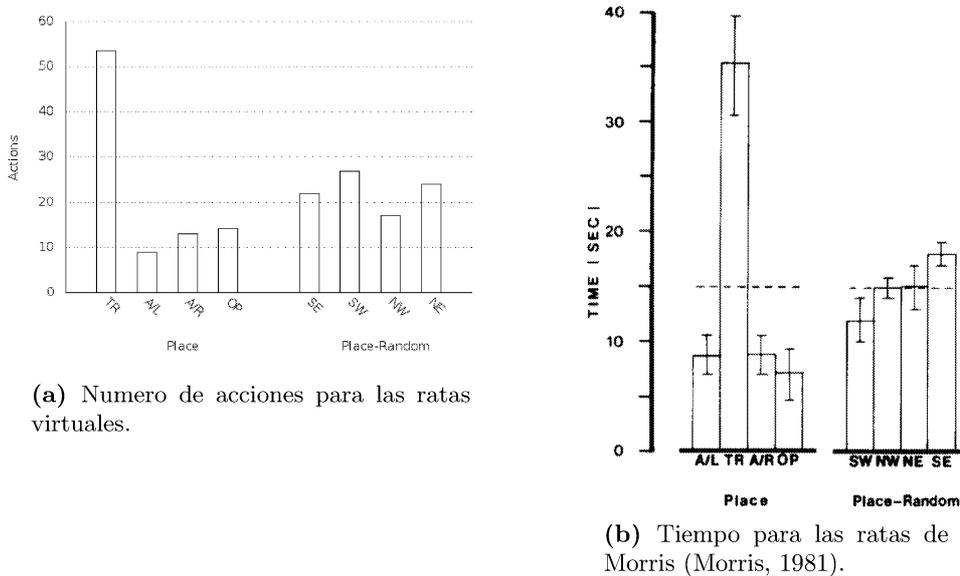
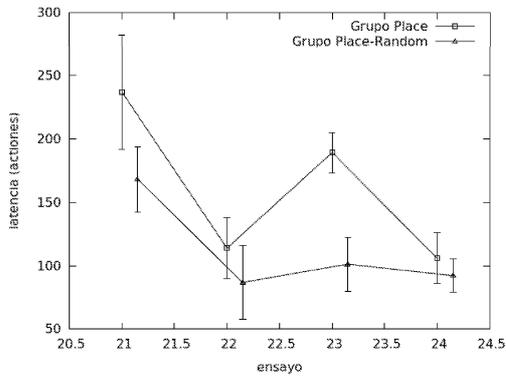


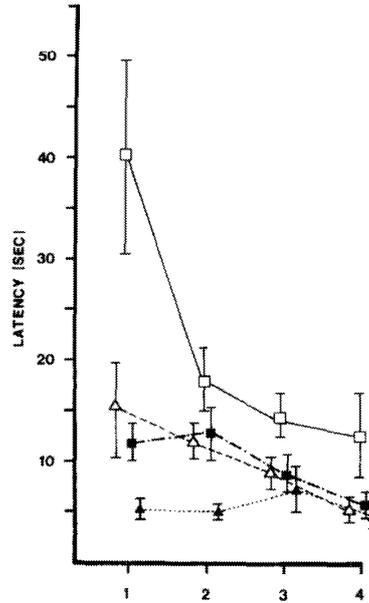
Figura 5.12 – Porcentaje del tiempo en cada cuadrante. Glosario: TR: en el cuadrante de entrenamiento; A/L: en el cuadrante a la izquierda del TR; A/R: en el cuadrante a la derecha del TR; A/L: en el cuadrante opuesto al del TR.

El rendimiento de las ratas para cada grupo en los cuatro ensayos de testeo para el Test B se muestran en las Figuras 5.13 y 5.14. Como puede observarse, la Figura 5.13 presenta el promedio de

la latencia de escape para las ratas para cada uno de los grupos, así mismo la Figura 5.14 muestra el promedio de la distancia de los caminos recorridos.

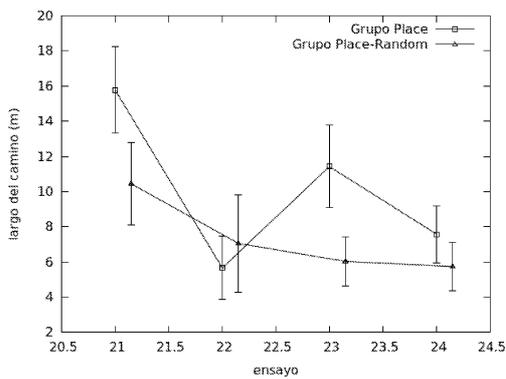


(a) Numero de acciones para las ratas virtuales.

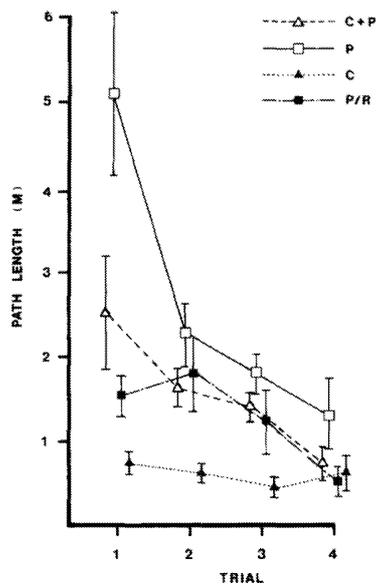


(b) Tiempo para las ratas de Morris (Morris, 1981).

Figura 5.13 – Latencia para los grupos Place y Place-Random al realizar los cuatro ensayos del Test B.



(a) Largo de los caminos para las ratas virtuales.



(b) Largo de los caminos para las ratas de Morris (Morris, 1981).

Figura 5.14 – Distancias recorridas para los grupos Place y Place-Random al realizar los cuatro ensayos del Test B.

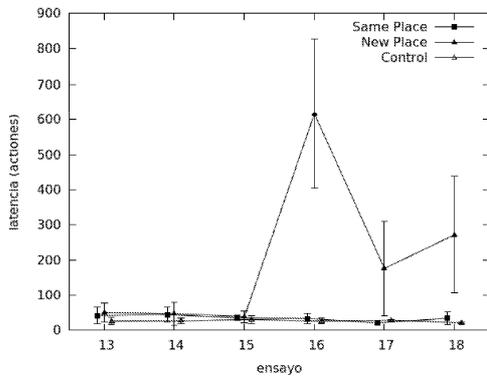
Las ratas en el grupo Place se desplazan hacia el lugar donde la plataforma solía estar durante los ensayos de entrenamientos hasta que eventualmente logran alcanzar la plataforma en su nueva posición. Para las ratas del grupo Place-Random, este test les presenta una condición totalmente novedosa, donde la plataforma permanece fija durante una serie de ensayos, y los resultados muestran un decremento en la latencia de escape y en el largo del camino recorrido. Por último, al comparar el rendimiento de ambos grupos se puede afirmar que el grupo Place alcanza la plataforma más lento que el grupo Place-Random, lo cual refleja una vez más el sesgo del primer grupo hacia la posición donde fue ubicada la plataforma en los ensayos de entrenamiento.

Una vez que se identifica la estrategia de aprendizaje espacial seguida por las ratas, el experimento 1 intenta analizar el impacto de introducir variabilidad en la posición de la plataforma. Cuando esta variabilidad se realiza durante el entrenamiento, tal como se realiza con el grupo Place-Random, las ratas no son capaces de aprender la posición del objetivo. Éstas no presenta direccionalidad hacia la plataforma durante el recorrido, y al medir los ángulos hacia la plataforma durante el recorrido se observa una gran variabilidad mientras que para las ratas del grupo Place la desviación promedio del ángulo a la plataforma es 0° . Al considerar la etapa de test del experimento 1 puede observarse que la estrategia de búsqueda de las ratas virtuales del grupo Group Place adquieren de su experiencia información espacial de la localización de la plataforma oculta, pues ellas se toman su tiempo buscando la plataforma en el cuadrante donde ella solía estar en los ensayos de entrenamiento. Este comportamiento se observa cuando la plataforma es retirada del escenario (Test A), y cuando ella es trasladada a otra posición en él (Test B). En en caso del Test B, las ratas son capaces de reaprender rápidamente la posición de la nueva plataforma. El rendimiento del grupo Place-Random es otro de los aspectos interesantes compartidos con los experimentos de Morris. Aún cuando las ratas no presentan direccionalidad en sus rutas de aproximación a la plataforma, son capaces de de decrementar el valor promedio de la latencia de escape.

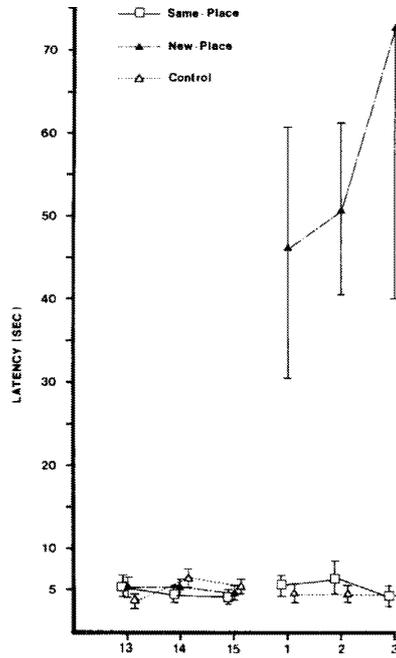
5.3.3.2. Experimento 2

Los resultados obtenidos al realizar estos experimentos utilizando el modelo de cognición espacial propuesto coinciden con los reportados por Morris (Morris, 1981). Todas las ratas virtuales aprenden la posición de la plataforma objetivo sobre el final de la fase de entrenamiento, estabilizándose el número promedio de acciones hacia los ensayos 13 a 15. La Figura 5.15 presenta la latencia de escape durante los ensayos de test (ensayos 16-18) para las ratas virtuales (a) y para las ratas de Morris (b). Todas las ratas del grupo New-Place presentaron una latencia de escape promedio mayor para los tres test que cualquier otra rata de los otros dos grupos (Same-Place y Control).

Las latencias de los grupos Same-Place y Control se solapan considerablemente, esto puede apreciarse también en la Figura 5.16 que presenta los mismos datos pero en función del punto de origen y destino del recorrido para los ensayos de test. Al comparar el rendimiento de las ratas de los grupos Same-Place y Control, puede observarse que es invariante respecto de la posición inicial, esto es, la latencia de escape no varía significativamente cuando las ratas son sujetas a realizar desde los distintos puntos cardinales (N, S, E, O) al destino (NE), en contraposición al grupo Group New-Place, para el cual la posición objetivo varía.

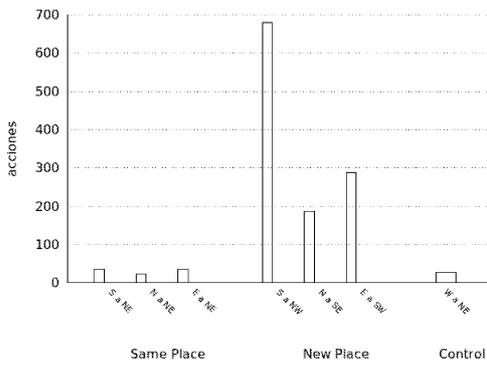


(a) Numero de acciones para las ratas virtuales.

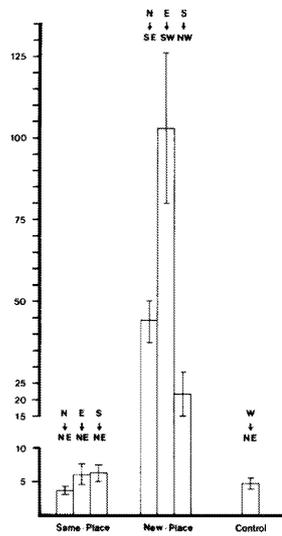


(b) Tiempo para las ratas de Morris (Morris, 1981).

Figura 5.15 – Latencia los ensayos de entrenamiento 13-15.



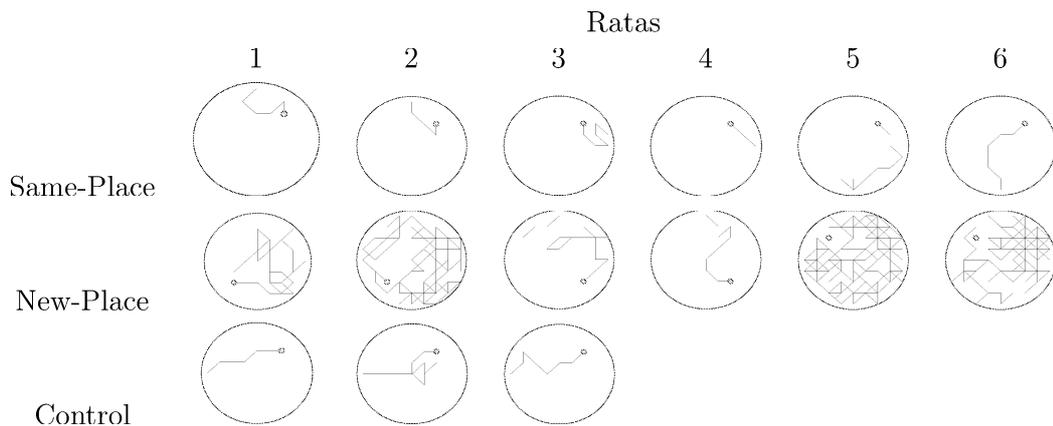
(a) Latencia en los ensayos de testeo en función del origen y destino para la rata virtual.



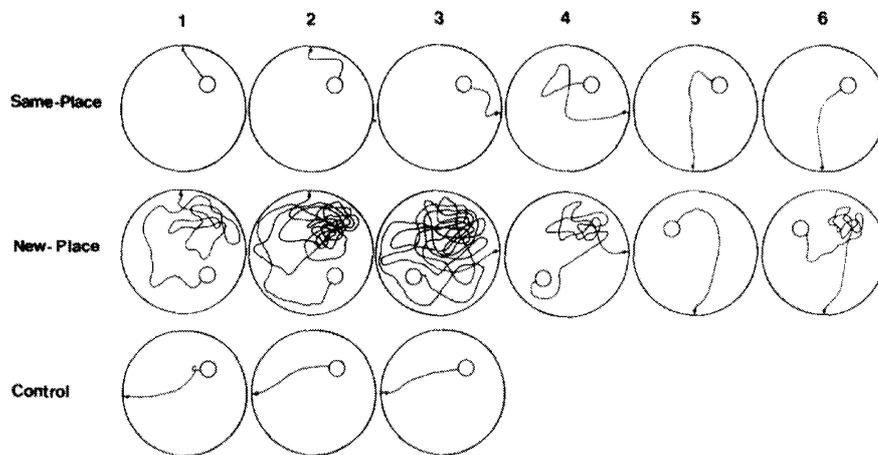
(b) Latencia en los ensayos de testeo en función del origen y destino para la rata de Morris (Morris, 1981).

Figura 5.16 – Ensayos de test para el experimento 2.

La Figura 5.17 presenta los caminos recorridos en el primer ensayo de test para cada una de las ratas usadas para el experimento, en la parte superior se presentan las trayectorias de las ratas virtuales y en la parte inferior las trayectorias de las ratas de Morris. Las ratas en el grupo Same-Place alcanzan la plataforma desde cualquier punto nuevo de partida siguiendo un camino directo hacia la plataforma, mientras que las ratas en el grupos New-Place buscan primero en la posición vieja de la plataforma (punto cardinal NE).



(a) Trayectorias para las ratas virtuales.



(b) Trayectorias para las ratas utilizadas por Morris (Morris, 1981).

Figura 5.17 – Trayectorias realizadas por las 15 ratas virtuales durante el primer ensayo de test del experimento 2. Las ratas son clasificadas en los grupos Same-Place, New-Place, y Control.

Estos caminos confirman que la rata realmente aprende la posición de la plataforma, la cual logra alcanzar desde cualquier posición inicial, y que ella no está aprendiendo la secuencia de acciones motoras necesaria para alcanzar la plataforma, puesto que busca en la vieja posición aún cuando se conserva la misma relación angular entre la posición inicial y la final tanto en los ensayos de entrenamiento como en los de test.

Al analizar los resultados del experimento 2, es claro que las ratas no aprendieron una secuencia de acciones motoras para alcanzar la plataforma, si fuera así, las ratas no podrían haber ido a buscar

la plataforma en su vieja posición si no directamente a la nueva, dado que se respeta la relación angular entre ambas posiciones sobre los ensayos de entrenamiento y test. Otro resultado importante de este experimento es el hecho que las ratas en el grupo Same-Place fueron capaces de adaptar su comportamiento para encontrar la plataforma en una nueva posición sin un significativo incremento en la latencia de escape relativa a la posición fija utilizada inicialmente.

Como resumen general, los experimentos realizados con las ratas virtuales utilizando el modelo de cognición espacial propuesto en el contexto de este trabajo muestran una gran similitud al comparar los resultados que obtuvo Morris:

1. la aparición de una estrategia de búsqueda no observada durante la etapa de entrenamiento, esta estrategia aparece tanto cuando la plataforma es retirada como relocalizada en el escenario.
2. la velocidad con que las ratas encuentran la nueva posición de la plataforma
3. la capacidad que presentan las ratas de instantáneamente adaptarse a las nuevas posiciones de inicio sin afectar la precisión o latencia, esto se relaciona con la capacidad del modelo de reconocer y aprender lugares distintivos.

5.3.3.3. Resultados con el robot

La experimentación con el robot es muy compleja, en tiempo y en el manejo, debido principalmente al armado de la panorámica (80% del tiempo en cada nodo) y al cambio de baterías (cada dos horas aproximadamente). Desarrollar entonces un experimento requiere de más de un día de ejecución y un cuidadoso manejo del desarrollo del experimento, principalmente en lo que hace a la gestión de baterías y la reinicialización del experimento.

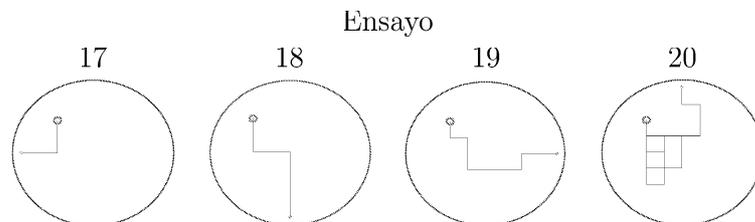


Figura 5.18 – Trayectorias realizadas por el robot para los ensayos 17 a 20 del experimento 1.

La Figura 5.18 muestra las trayectorias realizadas por el robot para los ensayos 17 a 20 del experimento 1 de Morris. Al igual que con los ensayos en el entorno virtual, los caminos son razonablemente dirigidos hacia la plataforma para las ratas del grupo para los puntos de partida desde O en el ensayo 17, desde el S para el ensayo 18, desde el E para el ensayo 19 y desde el N para el ensayo 20, si bien para el ensayo 20 el robot realiza varias acciones no razonables antes de dirigirse hacia la plataforma.

5.4. Evaluación del integrador de trayectorias realimentado

En esta sección se presentan los experimentos realizados sobre el modelo propuesto con el objetivo de evaluar el integrador de trayectorias bio-inspirado y el mecanismo de realimentación. El nuevo integrador de trayectorias posibilita incorporar algún mecanismo para tolerar el error acumulado inherentes a este tipo de módulos que integran información con ruido en el tiempo.

De manera análoga a los experimentos de Morris, se realizan un número importante de ejecuciones del modelo sobre el simulador y luego se realiza un ensayo de validación en el entorno real utilizando el robot Khepera.

5.4.1. Error experimental

La Figura 5.19.a muestra un esquema de interacción entre el agente robótico ejecutando el módulo y el entorno. Como el objeto de esta sección es medir la tolerancia del integrador de trayectorias al error acumulado cuando se trabaja con el simulador, se agrega ruido a la información que ingresa al módulo de manera artificial determinada por una variación sobre los valores sin error. La Figura 5.19.b muestra el módulo encargado de agregar ruido al modelo al cual toma como entrada la velocidad obtenida del módulo de velocidad lineal, le agrega el ruido definido para cada experimento y pasa la velocidad con ruido al módulo de integración de trayectorias.

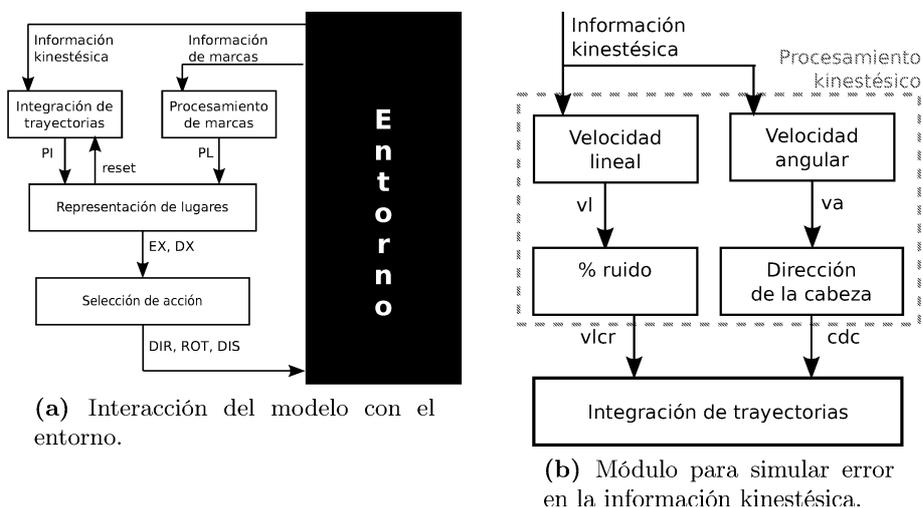


Figura 5.19 – Agente, entorno y ruido.

El ruido cae en una de dos categorías, errores sistemáticos o errores no sistemáticos. Los errores sistemáticos son los generados por las propiedades cinemáticas del robot. Ejemplos de fuentes de error sistemático:

- Diferencia entre el diámetro de las ruedas
- Diferencia en la separación de las ruedas
- Ruedas desalineadas
- Resolución de los encoders

Los errores no sistemáticos aparecen de la interacción entre el robot y el entorno. Ejemplos de fuentes de error no sistemático:

- Superficie irregular
- Superficie con diferente rozamiento

- La rueda pierde contacto con la superficie

En superficies regulares los errores sistemáticos son la principal fuente de error introducido al integrador de trayectorias. Es posible caracterizar el error generado en los movimiento del robot utilizando el procedimiento propuesto por Borenstein (Borenstein and Feng, 1996). El procedimiento propone realizar un camino que cierre un ciclo de manera horario y antihorario un número fijo de repeticiones para luego promediar los errores cometidos al recorrer el camino tanto en sentido horario como antihorario y quedarse con el peor caso. El Algoritmo 5.1 presenta el detalle del procedimiento realizado para calcular el error en los movimientos de avance del robot². Este procedimiento permite obtener experimentalmente los parámetros de la distribución normal que caracteriza el error del robot.

Algoritmo 5.1 Algoritmo para determinar la magnitud del error sistemático del robot Khepera.

Require: loopNumber

```

for currentLoop in range(0, loopNumber) do
  for currentEdge in range(0, 4) do
    KRobot.doAction(0)
    KRobot.doAction(-90)
  end for
  cwError[currentLoop]=measureError()
  for currentEdge in range(0, 4) do
    KRobot.doAction(0)
    KRobot.doAction(90)
  end for
  ccwError[currentLoop]=measureError()
end for
cwAverage=average(cwError)
ccwAverage=average(ccwError)
if cwAverage > ccwAverage then
  resAverage = cwAverage
  resStdDev = StdDev(cwError)
else
  resAverage = ccwAverage
  resStdDev = StdDev(ccwError)
end if
return resAverage, resStdDev

```

Los valores obtenidos utilizando este procedimiento para el robot Khepera en el entorno experimental utilizado son: media de 1.14mm (μ_{fwd_err}) y ($\sigma_{fwd_err}^2$) y desviación estándar de 0.18mm para cada acción de avance de 100mm. En este sentido el módulo que agrega ruido al la velocidad lineal está gobernado por la siguiente ecuación:

$$nlv = vl(1 + \xi * factor_{err}) \quad (5.1)$$

,donde ξ es una variable aleatoria con distribución normal con parámetros μ_{fwd_err} y $\sigma_{fwd_err}^2$ que caracterizan el ruido del robot Khepera, y un factor *que escala el error* entre 0 y 5, el cual

²El método measureError del algoritmo es realizado por una persona.

multiplica a los parámetros de la normal con el objeto de modificar los niveles de ruido sobre los obtenidos experimentalmente para el robot Khepera. Si el factor es cero no agrega error, si es uno agrega error según la caracterización realizada para el Khepera, si es dos agrega el doble, y así sucesivamente.

5.4.2. Métrica utilizada y experimento realizado

El experimento realizado para evaluar el integrador de trayectoria consta de un único ensayo de habituación de larga duración. Se realiza un solo ensayo pues al comienzo de cada ensayo se ajustan todas las neuronas grilla acorde a la posición de inicio eliminando el error que éstas acumularon en los ensayos anteriores, y justamente lo que se quiere evaluar es el efecto del error acumulado sobre estas neuronas. Al ser sólo un ensayo que finaliza por cantidad de acciones y no al momento de encontrar la plataforma o la comida, la única alternativa es un ensayo de habituación. En los ensayos de habituación el robot toma las decisiones basadas en su curiosidad de explorar el entorno, la curiosidad es un elemento motivacional que se incluye en el modelo para promover alcanzar lugares no explorados del entorno.

Al ser el navegador del modelo topológico, no incorpora explícitamente aspectos métricos, lo que dificulta la elección de la métrica a utilizar. Un aspecto clave para la elección de la métrica utilizada para evaluar la tolerancia al error es observar que cuando se trabaja en un entorno controlado, si el modelo no logra controlar el error acumulado en el PI se van a manifestar en errores al momento de cerrar ciclos.

Es por ello que la métrica utilizada para evaluar el integrador de trayectoria es la cantidad de veces que el modelo de cognición espacial no logra cerrar el ciclo. Esto se conoce como el problema de cierre de ciclos (loop closure problem) y es utilizado para determinar cuando el robot es capaz de reconocer un lugar previamente visitado como tal. En un mundo sin errores el modelo no debería cometer errores al cerrar ciclos, los errores aparecen en la medida que el módulo integrador de trayectorias no logra tolerar el ruido de las señales de entrada. Por lo antes expuesto se utilizará como métrica la cantidad de errores al cerrar el ciclo al realizar un ensayo de habituación de larga duración. Indirectamente esta métrica está relacionada con la calidad del mapa construido.

En el modelo el problema de cierre de ciclos se resuelve en el módulo del grafo del mundo. Este módulo recibe un patrón de actividad de las neuronas de lugar y busca el patrón más similar en la lista de patrones almacenados, el patrón más similar es denominado patrón ganador. Como medida de similitud de patrones se utiliza la distancia euclidiana. Si el valor de similitud entre el patrón actual y el patrón ganador está por debajo de un umbral se determina la posición del entorno actual como ya visitada y se le asigna el nodo del grafo asociado al patrón ganador, esto es, se cierra el ciclo.

Para determinar la ocurrencia de un error al cerrar el ciclo se almacena en cada nodo del grafo la posición global asociada a él. Luego toda vez que se crea un nuevo nodo en el grafo del mundo se verifica la existencia de otro en la misma posición global, si existe otro se está frente a un error de cierre de ciclo pues se llegó a la misma posición global del mundo y no se reconoció como ya visitada. Cuando se trabaja con el robot virtual la posición global se obtiene directamente desde el mundo virtual, mientras que, cuando se trabaja con el robot real esta posición se obtiene mediante el seguimiento del robot en el escenario utilizando una cámara global. En la Figura 5.20 se ilustra la cámara global sobre el entorno, la cual obtiene una imagen completa del mismo que es procesada en la PC para obtener la posición del robot en el entorno. Se coloca sobre el robot una marca

distintiva para que ella pueda ser identificada fácilmente a través de un proceso simple de visión por computador.

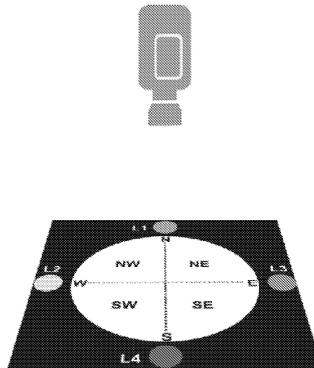


Figura 5.20 – El escenario circular y la posición de la cámara global.

5.4.3. Resultados experimentales

En la próxima sección se presentan los resultados para evaluar el integrador de trayectorias basado en la métrica de cierre de ciclos presentada en la sección anterior utilizando el menor espaciado reportado para las neuronas grilla. En la sección siguiente se presentan resultados variando los espaciados de las neuronas grilla.

5.4.3.1. Utilizando el mínimo espaciado

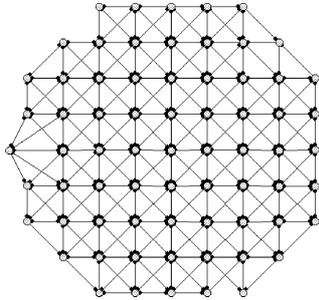
Al igual que en los experimentos de Morris, se realizó una corrida completa del experimento utilizando el robot Khepera y una cantidad significativa de ejecuciones (30) en el mundo virtual. La ejecución sobre el robot no presentó ningún error de cierre de ciclo. Para las ejecuciones en el mundo virtual se agregaron diferentes niveles de ruido a la velocidad lineal para que las simulaciones sean más realistas y medir la tolerancia al aumentar los niveles de ruido inyectados.

En cada ensayo se realizan para una cantidad fija de 1500 acciones de avance del robot sin tener en cuenta las acciones de giros pues lo que se quiere evaluar es el impacto del error en el integrador de trayectorias y son sólo las acciones de avance las que introducen error tolerable por el modelo. Para cada configuración del ensayo se fija un factor de error y módulo un módulo de PI a evaluar (DRL³, grillas sin reset o grillas con reset), y se ejecutan 30 corridas. El valor 1500 es elegido tomando en cuenta la cantidad necesaria de pasos de avance necesarios para ejecutar un experimento completo de Morris. La ejecución que requirió más acciones de avance para la rata virtual tomo casi 1300.

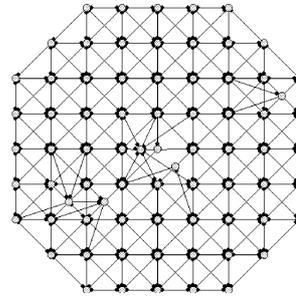
La Figura 5.21 presenta ejemplos del grafo del mundo que es construido por el modelo durante los experimentos de habituación de larga duración. La Figura 5.21.a muestra un ejemplo del grafo del mundo completamente explotado sin presencia de errores de cierre de ciclo, las siguientes figuras presentan respectivamente los grafos del mundo con 5, 250 y 500 errores al cerrar ciclo.

La figura 5.22 muestra el error acumulado en función de las acciones de avance tomadas. Se ejecuta un total de 30 ensayos de 1500 acciones de avance cada uno, en cada acción se inyecta el error caracterizado para el robot Khepera multiplicado por un factor. En la figura se muestra el

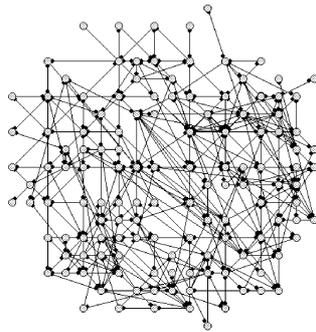
³Mecanismo de integración de trayectorias utilizado en el modelo original.



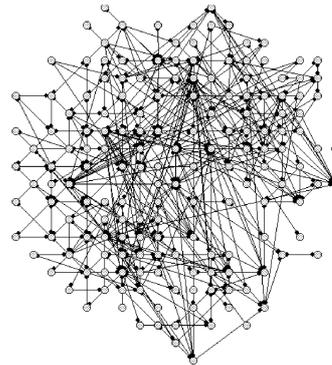
(a) Grafo sin errores.



(b) Grafo con 5 errores.



(c) Grafo con 250 errores.



(d) Grafo con 500 errores.

Figura 5.21 – Ejemplos de grafos del mundo generados para los experimentos de cierre de ciclo.

error acumulado según fuera caracterizado para el robot Khepera, mostrando que al final del ensayo de habituación el integrador de trayectorias acumula 2.41m. La distancia recorrida promedio entre todos los ensayos es de 181m.

Las siguientes figuras presentan la cantidad de errores de cierres que ocurren en función de la cantidad de avances. Las mismas se realizan para distintos factores de error y utilizando primero el integrador de trayectorias original del modelo (DRL) (Barrera, 2007), luego el integrador de trayectorias basado en neuronas grillas sin realimentación y por último el integrador de trayectorias basado en neuronas grilla con realimentación.

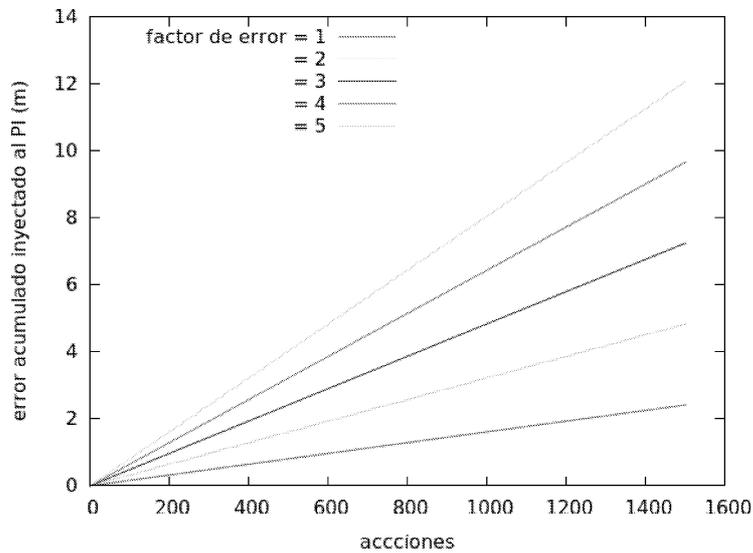
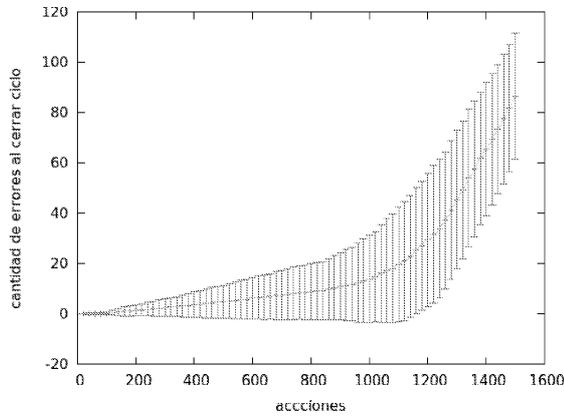
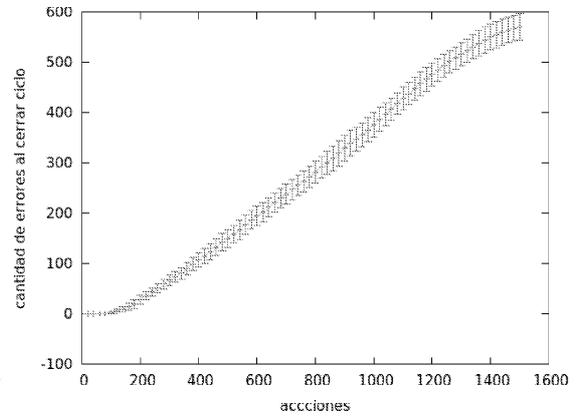


Figura 5.22 – Gráfica del error acumulado inyectado al integrador de trayectorias.

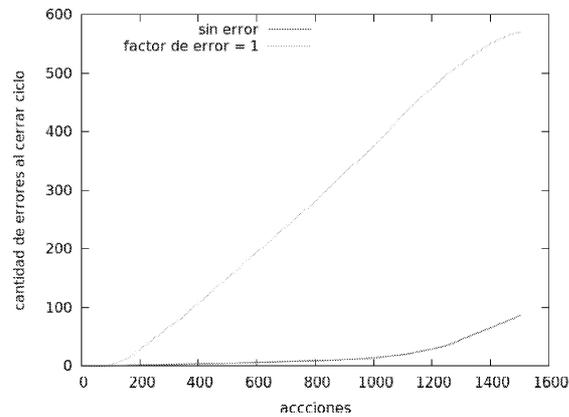
La Figura 5.23 presenta la cantidad de errores de cierre de ciclo para distintos factores de error, al ejecutar el experimento de larga duración utilizando como integrador de trayectorias el módulo de mapeo dinámico (DRL) utilizado en el modelo original. Cada función presenta el promedio sobre la cantidad de errores de cierre de ciclo sobre el total de ejecuciones independientes. La figura (a) y (b) presentan el valor medio y la desviación estándar de la cantidad de errores de cierre de ciclo para los factores de error 0 y 1 respectivamente. La figura (c) presenta de manera conjunta el valor medio de las gráficas (a) y (b).



(a) Gráfica sin inyectar errores.



(b) Gráfica al inyectar el error caracterizado para el robot Khepera.



(c) Gráfica sin error y con error simultáneamente.

Figura 5.23 – Gráficas de errores de cierre de ciclo para el módulo DRL.

La Figura 5.23.a muestra que este módulo genera errores de cierre de ciclo aún cuando no se inyectan errores, esto se debe a la poca información que genera este módulo a su salida generando que algunos lugares sean vistos como iguales cuando no lo son. En la Figura 5.23.b se muestra que si bien este módulo no permite realimentación tampoco tiene una buena tolerancia al ruido por lo que no se podría utilizar con el robot Khepera.

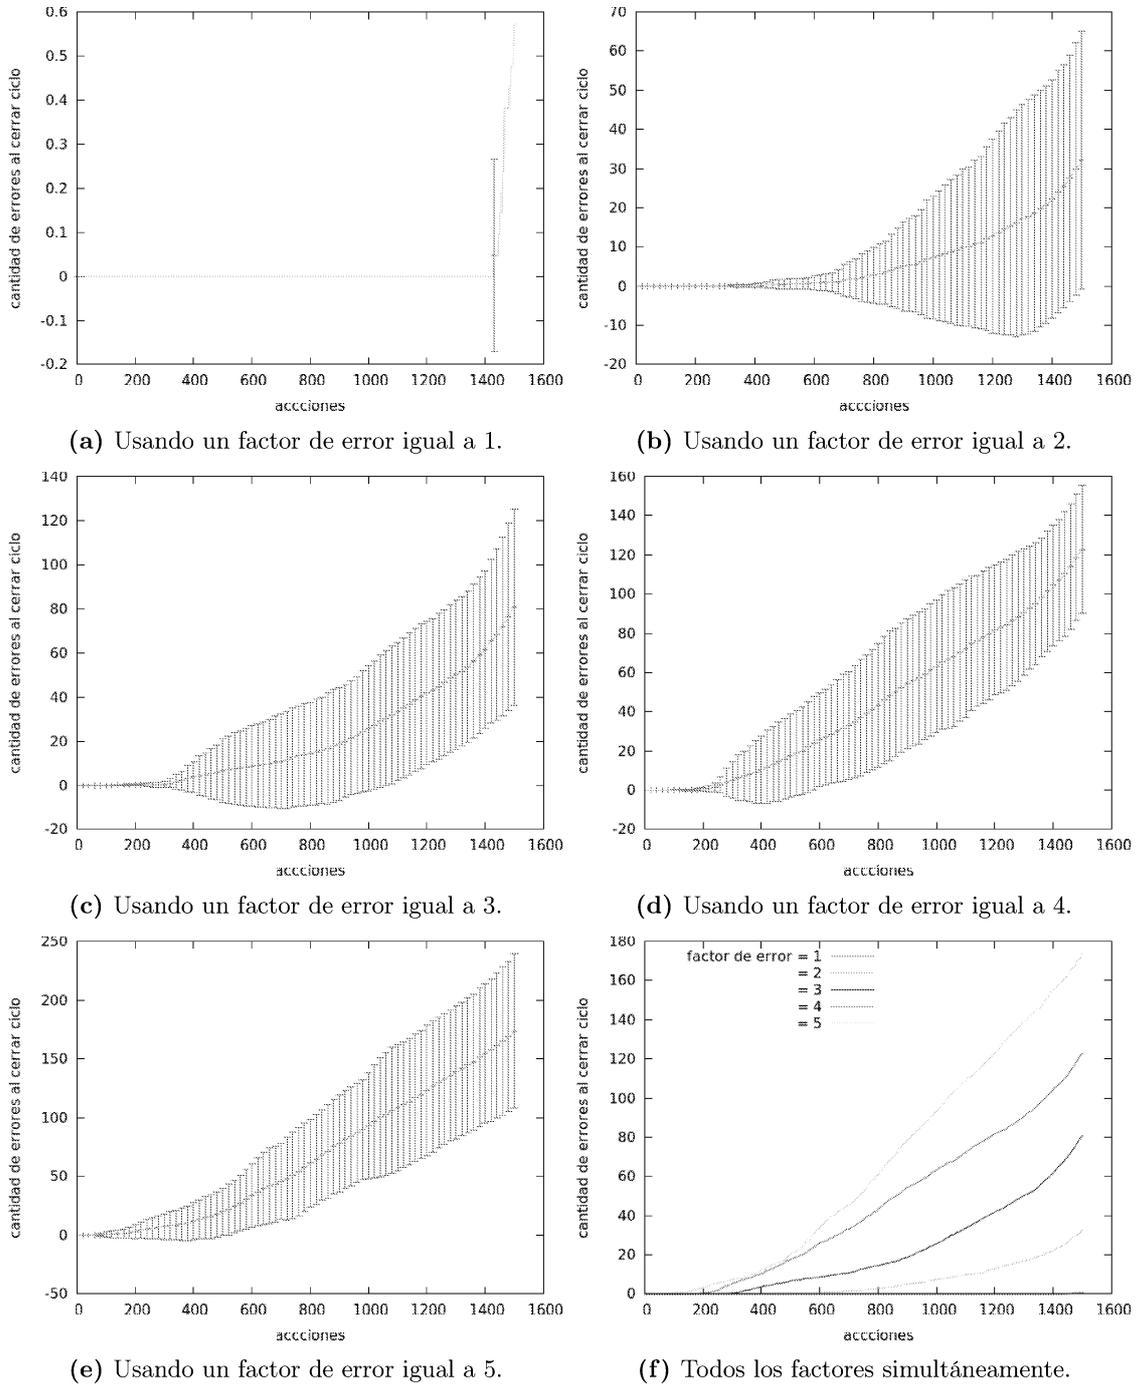


Figura 5.24 – Gráfica de errores de cierre de ciclo con el módulo de neuronas grilla sin realimentación.

La Figura 5.24 presenta los errores acumulados de cierre de ciclos cuando se utiliza el módulo de neuronas grilla sin realimentación como integrador de trayectorias en lugar del módulo DRL. La figura (a) a (e) presentan el valor medio y la desviación estándar de la cantidad de errores de cierre de ciclo para los factores de error 1 a 5. La figura (f) presenta de manera conjunta el valor medio de las gráficas (a) a (e). A diferencia del módulo DRL, este módulo no presenta errores de cierre

de ciclo cuando no se inyecta error (factor = 0) y su tolerancia al error es muy superior cuando el factor de error es 1.

La Figura 5.25 presenta los errores acumulados de cierre de ciclos cuando se utiliza el módulo de neuronas grilla con realimentación como integrador de trayectorias en lugar del módulo DRL. La figura (a) y (b) presentan el valor medio y la desviación estándar de la cantidad de errores de cierre de ciclo para los factores de error 4 y 5. La figura (c) presenta de manera conjunta el valor medio de las gráficas (a) y (b). A diferencia de los experimentos anteriores, este módulo no presenta errores de cierre de ciclo para factores de error menores a cuatro.

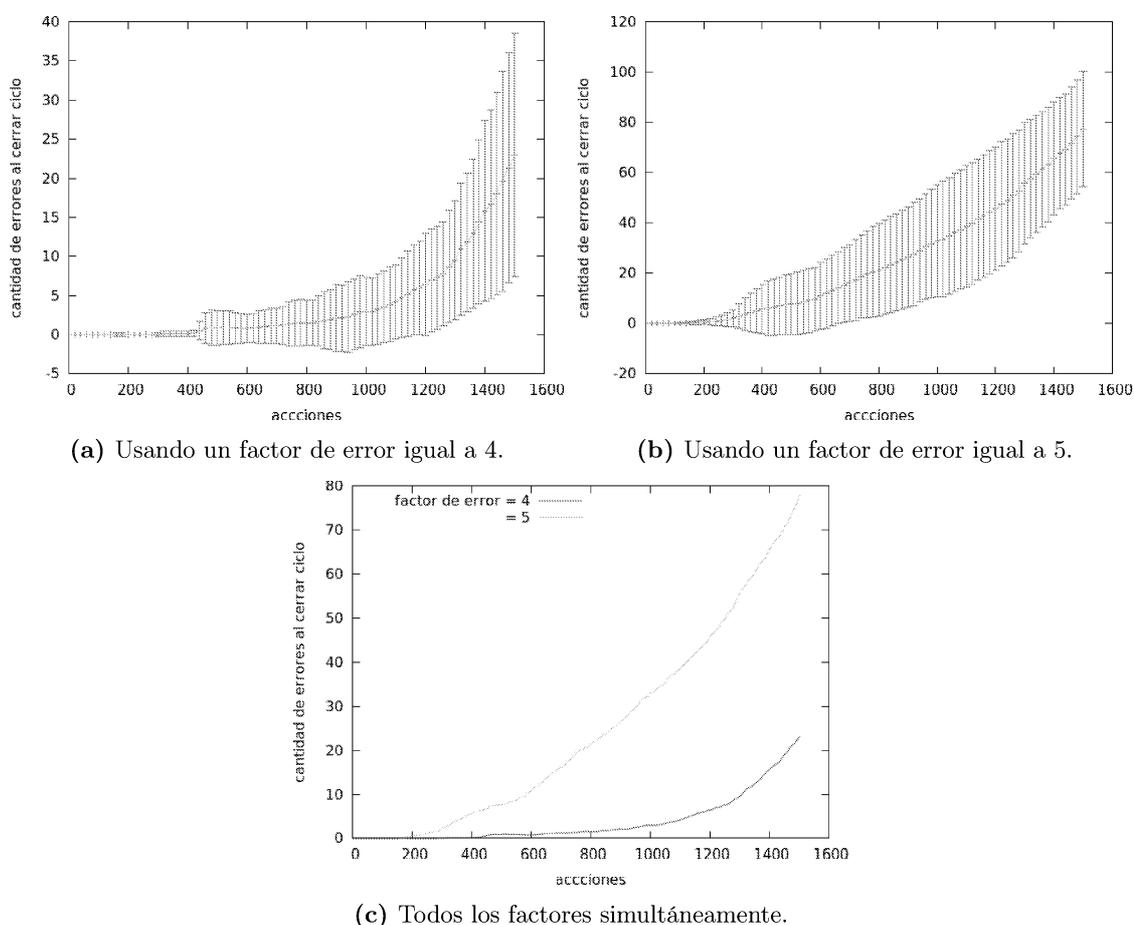


Figura 5.25 – Gráfica de errores de cierre de ciclo con el módulo de neuronas grilla con realimentación.

La Figura 5.26 presenta de manera conjunta el desempeño, al momento de cerrar ciclos, de los distintos integradores de trayectoria agrupados por el factor de error inyectado. La figura (a) presenta solamente los desempeños de los módulos DRL y neuronas grillas con realimentación pues el módulo grilla con realimentación no genera errores de cierre de ciclo para el factor de error 1. Las figuras (b) y (c) no incluyen al módulo DRL pues su error es muy elevado no permitiendo, por un tema de escala, comparar adecuadamente a los otros dos experimentos. La Figura 5.26 muestra mejoras significativas al utilizar el integrador basado en neuronas grillas sobre el integrador de trayectorias original (DRL) tanto cuando se utilizan sin y con realimentación. Si se compara el integrador basado

en neuronas grilla sin realimentación contra el mismo pero con realimentación se observan un número menor de errores y los mismos ocurren más tarde en el tiempo.

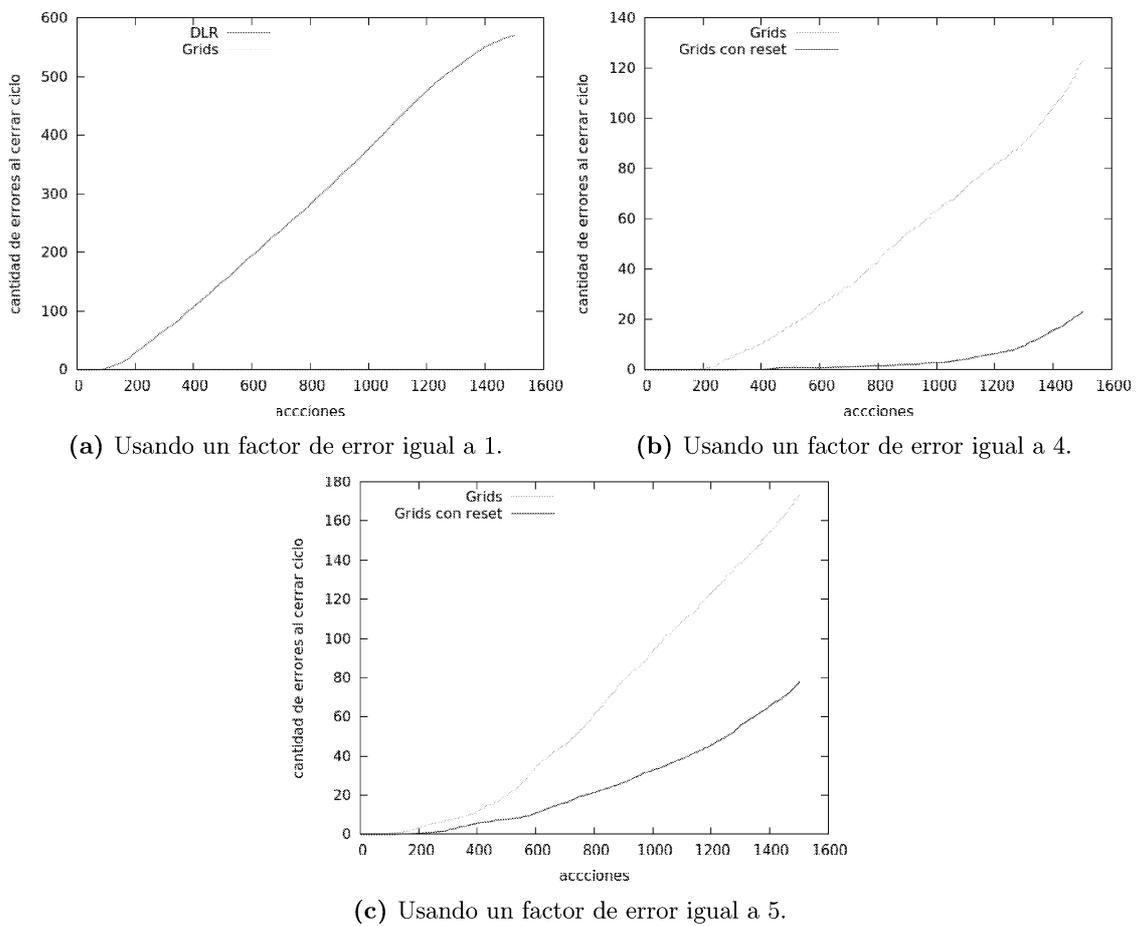


Figura 5.26 – Gráfica de errores de cierre de ciclo por factores de error inyectado.

La Figura 5.27 presenta todas las funciones de errores de cierre de ciclo antes presentadas en una única gráfica.

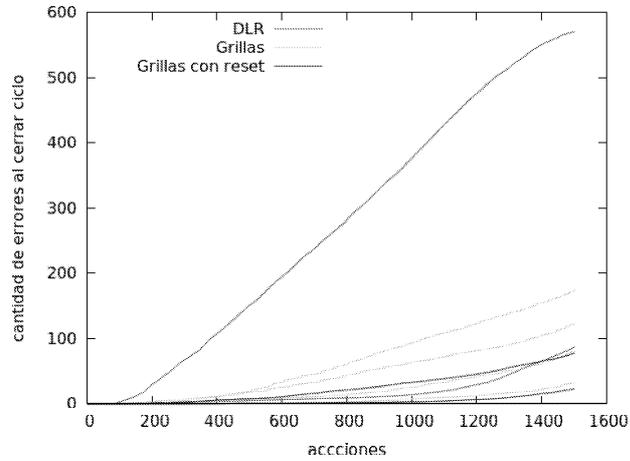


Figura 5.27 – Todas las gráficas de errores de cierre de ciclo.

El Cuadro 5.9 presenta las características más relevantes de cada uno de los experimentos realizados para poder ampliar la discusión del desempeño de los distintos integradores de trayectorias. Se puede observar que si bien los ensayos para el integrador de trayectorias sin realimentación para el factor = 1 presenta errores, el 80 % de los ensayos finaliza sin errores de cierre de ciclo, y sus valores medios y máximos son muy bajos. Por otro lado, si bien los resultados completos para un factor = 4 con realimentación presentan errores de cierre de ciclo muy inferiores a presentados sin realimentación, solamente un 5 % de los casos terminan sin errores de cierre de ciclo.

Factor	= 0	= 1		= 2	= 3		= 4		= 5	
		DRL	DRL		Grillas sin reset	Grillas sin reset	Grillas sin reset	Grillas sin reset	Grillas con reset	Grillas sin reset
<i>mínimo</i>	39	503	0	0	14	24	0	57	30	
media	87	570	0.57	0.57	80.8	123	23	174	75	
desviación estándar	25	26	1.33	1.32	44.53	33	15	66	21	
máximo	133	621	4	4	178	187	51	373	105	
% ensayos sin error	0	0	80	20	0	0	5	0	0	
acción primer error	153	91	1428	1429	20	229	642	133	232	

Cuadro 5.9 – Cuadro característica de la cantidad de errores al cerrar el ciclo.

5.4.3.2. Evaluando distintos espaciados

Los resultados presentados en la sección anterior utilizan el mínimo espaciado observado para las neuronas grilla en la MEC, lo cual desde el punto de vista de información de integración de trayectorias permite disponer de una gran precisión y genera patrones con un mínimo de alias perceptual, pues los campos de lugar de las grilla tienen un mínimo de solapamiento.

En esta sección se presentan los resultados al generar la población inicial de neuronas grilla utilizando distintos espaciados y manteniendo el resto de los parámetros fijos. Los espaciados se agrupan en el eje ventral-dorsal de la MEC identificándose entre 6 y 10 agrupaciones, dentro de cada agrupación el espaciado se mantiene fijo con muy poca dispersión y entre las agrupaciones el espaciado crece de manera geométrica. De esta forma el espaciado para las distintas agrupaciones puede determinarse con la siguiente ecuación:

$$G_f (factor_{spc}) = G(0) p^{factor_{spc}-1} \quad (5.2)$$

En el trabajo de Towse y colaboradores (Towse et al., 2013) se analiza el efecto de los distintos espaciados en cada agrupación sobre la exactitud en la localización, los mejores resultados se obtienen cuando el espaciado crece de manera geométrica con $p = 1,4$. El Cuadro 5.10 presenta el valor del espaciado en centímetros para las cuatro primeras agrupaciones.

$factor_{spc}$	espaciado (G - cm)
1	39
2	49
3	69
4	96

Cuadro 5.10 – Relación entre factor de espaciado y espaciado.

Los experimentos detallados en esta sección varían el factor del espaciado, además del uso del mecanismo de reset y el factor de error como se presentaron en la sección anterior.

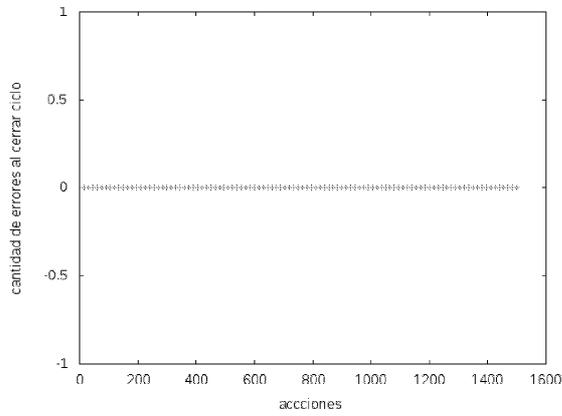
La Figura 5.28 presenta la cantidad de errores de cierre de ciclo cuando el factor de espaciado se mantiene fijo en 1, para ejecuciones del modelo con el mecanismo de realimentación deshabilitado (gráfica verde) como habilitado (gráfica roja). Las subfiguras (a) a (c) muestran los resultados para los factores de error de 0 a 2 respectivamente. Como puede apreciarse en las mismas, al igual que en la sección anterior, los errores en el cierre de ciclo crecen cuando aumenta el factor de error y cuando se deshabilita el mecanismo de realimentación.

Las Figuras 5.29 y 5.30 presentan los resultados de igual forma variando el espaciado a factor 2 y 3 respectivamente.

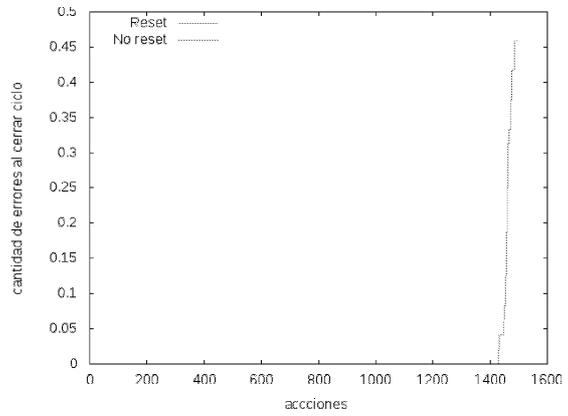
La Figura 5.31 presenta la evolución de la cantidad de cierres de ciclo para múltiples escalas con el mecanismo de realimentación deshabilitado. Las subfiguras de (a) a (c) muestran esta evolución manteniendo fijo el error inyectado al modelo desde factor 0 a 2.

La Figura 5.32 presentan los resultados de igual forma pero con el mecanismo de realimentación habilitado. En este caso la gráfica para factor de error cero no se muestra pues no presenta errores.

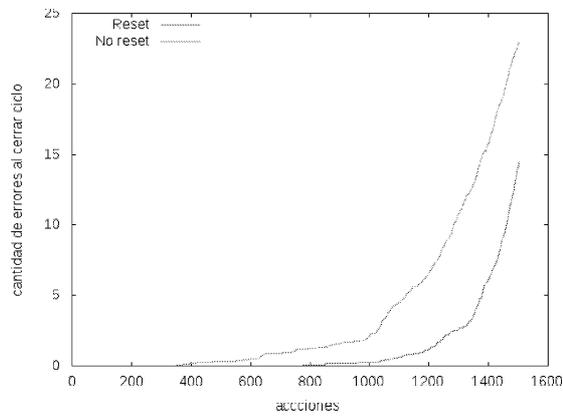
Capítulo 5. Experimentos



(a) Usando un factor de error igual a 0.



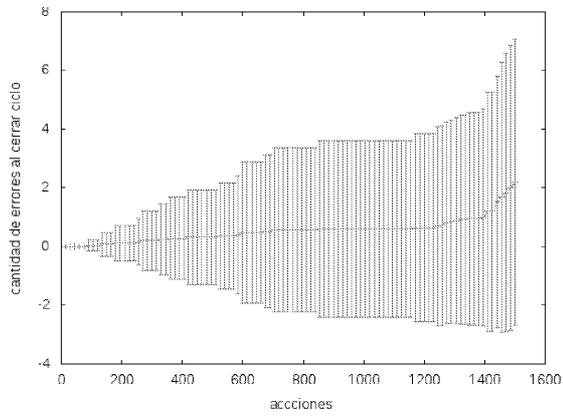
(b) Usando un factor de error igual a 1.



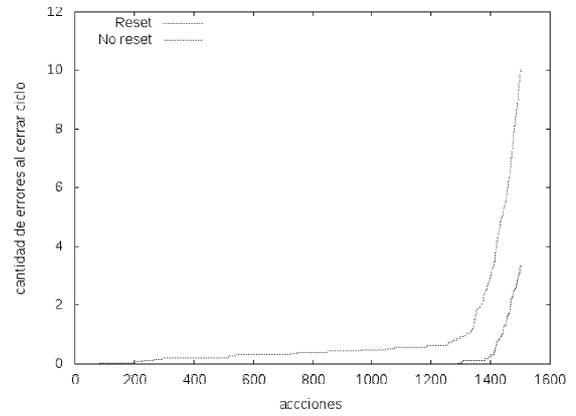
(c) Usando un factor de error igual a 2.

Figura 5.28 – Gráfica de errores de cierre de ciclo cuando el factor de espaciado es 1.

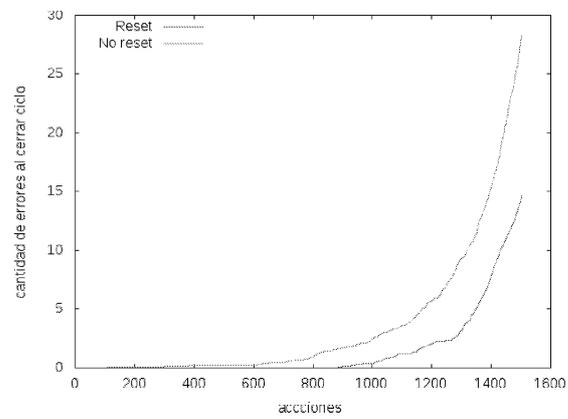
Capítulo 5: Experimentos



(a) Usando un factor de error igual a 0.

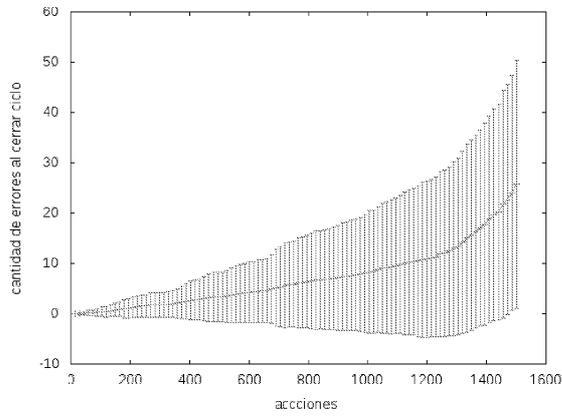


(b) Usando un factor de error igual a 1.

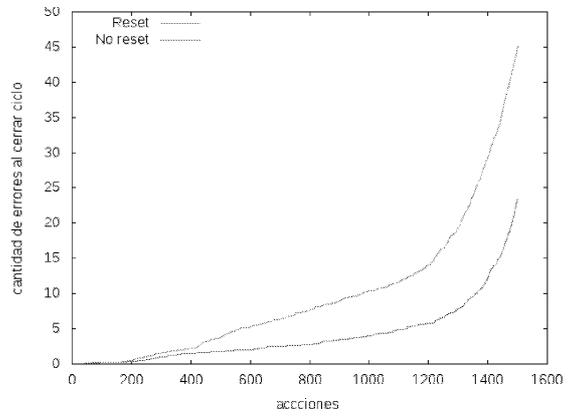


(c) Usando un factor de error igual a 2.

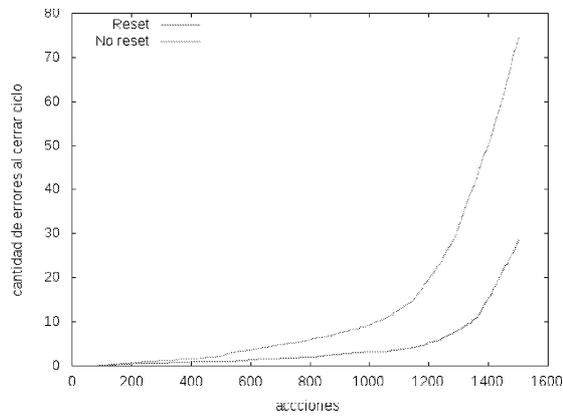
Figura 5.29 – Gráfica de errores de cierre de ciclo cuando el factor de espaciado es 2.



(a) Usando un factor de error igual a 0.



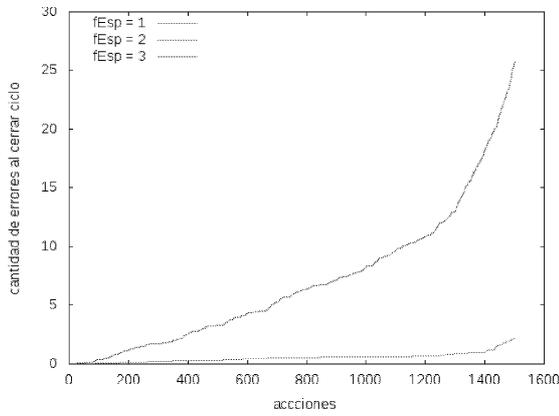
(b) Usando un factor de error igual a 1.



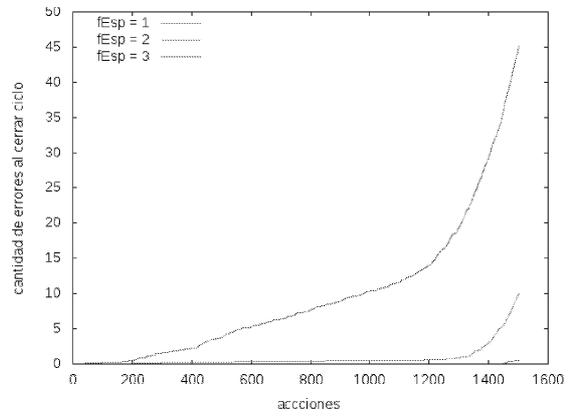
(c) Usando un factor de error igual a 2.

Figura 5.30 – Gráfica de errores de cierre de ciclo cuando el factor de espaciado es 3.

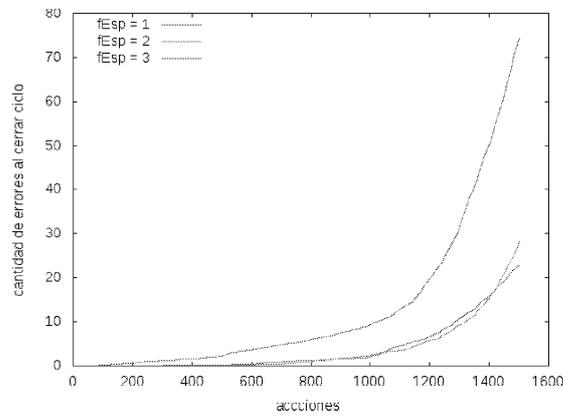
Capítulo 5: Experimentos



(a) Factor de error es 0.

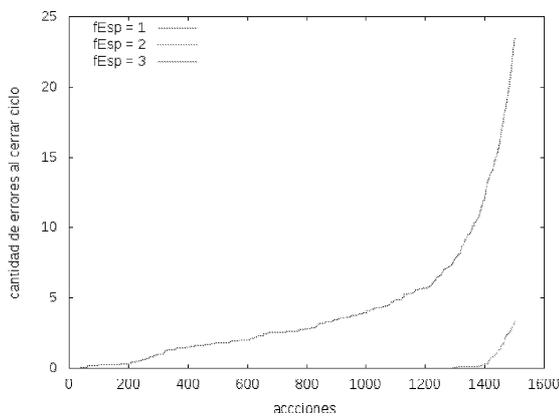


(b) Factor de error es 1.

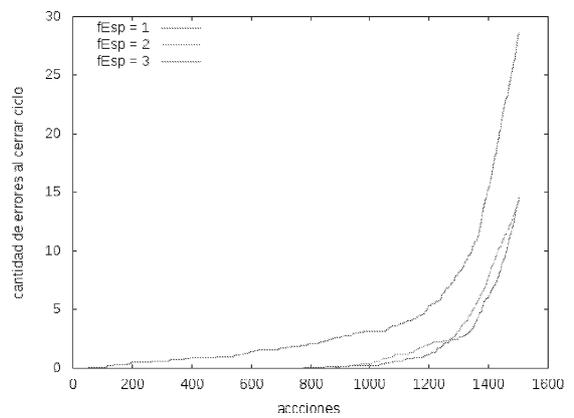


(c) Factor de error es 2.

Figura 5.31 – Gráfica de errores de cierre de ciclo multi escala sin realimentación.



(a) Factor de error es 1.



(b) Factor de error es 2.

Figura 5.32 – Gráfica de errores de cierre de ciclo multi escala con realimentación.

5.4.3.3. Discusión y conclusiones

En esta sección se presentan los resultados al evaluar el integrador de trayectorias incorporado al modelo de cognición espacial. Para esto se utiliza como métrica la cantidad de errores al cerrar el ciclo y se trabaja inicialmente en un escenario de con espaciado mínimo para luego utilizar espaciados mayores.

De los resultados para espaciado mínimo se puede concluir que el modelo propuesto tolera el error propio del robot Khepera, lo que posibilita su correcta localización para experimentos de larga duración y en este sentido permitiría su ejecución completa para el protocolo de Morris sin necesidad de eliminar el error acumulado en las neuronas grilla al comienzo de cada ensayo.

A partir de los resultados para distintas escalas puede comprobarse que, al incrementar el espaciado el error crece debido a la imposibilidad de discriminar los lugares con información dispar de integración de trayectorias. En este sentido, el error en la cantidad de cierre de ciclos es similar al que ocurre cuando no se inyecta error al integrador de trayectorias, el cual se debe a la imposibilidad de distinguir lugares similares al utilizar únicamente información de marcas.

Un aspecto a tener en cuenta es que una vez superada la tolerancia del módulo integrador de trayectorias y el mecanismo de realimentación, el error crece sin una cota superior. En uno de los trabajos de Milford y colaboradores (Milford, 2008) se presenta resultados donde el error en la localización crece con el tiempo y luego de una hora de ejecución el robot se pierde. De igual forma el módulo DRL demostró ser inestable y no tolerar el ruido en sus entradas. Si bien módulo basado en neuronas grilla permite la ejecución de experimentos sobre el robot Khepera, es necesario trabajar para que éste permita trabajar con otros robots y en no regulares.

Capítulo 6

Discusión y Conclusiones

El objeto de este documento es describir los aportes realizados sobre el modelo de cognición espacial inspirado en estudios en ratas desarrollado por Barrera-Weitzenfeld (Barrera and Weitzenfeld, 2008). En síntesis, se extiende el modelo original incorporando un módulo de neuronas grilla que representan un “odómetro” neuronal, que al ser integrado a información visual da lugar a patrones de disparo que determinan diferentes posiciones en el entorno. Esta integración de información es utilizada para realimentar el odómetro neuronal de manera de tolerar el error acumulado.

Este capítulo presenta una discusión general sobre el trabajo realizado, las conclusiones como resultado de su desarrollo y una serie de trabajo a futuro que en su mayoría apuntan a continuar incorporando información biológica. En este sentido, se organiza de la siguiente manera: inicia con un resumen de los resultados experimentales realizados sobre robots simulados y reales, luego se presentan las contribuciones de la investigación y por último las principales líneas de trabajo a futuro a desarrollar sobre el modelo.

6.1. Sobre los Resultados Experimentales

Como se indicó al comienzo de este documento, los modelos biorrobóticos esperan comprender los mecanismos que determinan el comportamiento animal. Como tal, al igual que cualquier otro modelo biológico, los modelos biorrobóticos deben ser evaluados desde el punto de vista del comportamiento observado y los datos neurobiológicos, así como las hipótesis experimentales que pueda generar. El estudio propuesto puede ubicarse en el ámbito de la Teoría del Cerebro y dentro de éste en el modelado biorrobótico. El modelo propuesto incorpora nuevas hipótesis y datos empíricos relativos a la cognición espacial y navegación en ratas, es por esto que debe ser evaluado en este sentido.

Los experimentos llevados adelante en el contexto de este trabajo intentan evaluar por un lado el desempeño del modelo propuesto en tareas diseñadas específicamente para las capacidades de cognición espacial en ratas (Morris, 1981), y por otro lado la efectividad del integrador de trayectorias desarrollado. En este sentido se realizan algunos de los experimentos propuestos por Morris para evaluar el desempeño del modelo en una tarea de cognición espacial y experimentos de exploración de larga duración para evaluar la tolerancia del integrador de trayectorias al error.

6.1.1. Experimentos de Morris

El modelo de Barrera (Barrera and Weitzenfeld, 2008) está diseñado para navegar en laberintos basados en corredores, es por esto que ha sido evaluado en laberintos con ciclos, en T y los basados en brazos. En el contexto de este trabajo se ajustó exitosamente el modelo para poder ejecutarse en entornos abiertos, como lo es el laberinto de agua de Morris, integrando información métrica a la información visual de manera de poder generar lugares distinguibles, que permitan mejorar las trayectorias aprendidas para alcanzar la plataforma. El laberinto de agua de Morris fue desarrollado en 1981 por Richard G. Morris y continua siendo hasta hoy ampliamente utilizado para evaluar la memoria espacial, los mapas cognitivos y el control de movimiento del animal.

Desde el punto de vista experimental se evalúa el modelo por primera vez en entornos abiertos, tomando como base los experimentos desarrollados y realizados por Morris (Morris, 1981), y se presentan los resultados en el artículo Barrera et al. (2014). Los experimentos realizados con las ratas virtuales utilizando el modelo de cognición espacial propuesto en el contexto de este trabajo muestran una gran similitud al comparar los resultados que obtuvo Morris, tanto desde los resultados cuantitativos como cualitativos. En este sentido, se puede afirmar que la latencia de escape y la distancia recorrida por las ratas virtuales son similares a las reportadas por Morris, aparecen estrategias de búsqueda cuando el entorno es modificado y se adaptan a nuevas posiciones de inicio.

6.1.2. Experimentos de larga duración

El aporte principal presentado en este trabajo se refiere al desarrollo de un módulo integrador de trayectorias basado en una población de neuronas grilla y la realimentación desde las neuronas de lugar para poder tolerar el error acumulado en el módulo de PI.

Los protocolos de Morris u otros llevados adelante sobre el modelo por Barrera tienen una duración reducida (del orden de 100 acciones) como para poder evaluar la tolerancia del modelo al error en las entradas. En este sentido, se propone en este trabajo realizar un experimento de larga duración para poder medir las capacidades de módulo integrador de trayectorias sobre los errores después de una cantidad razonable de pasos de ejecución.

Los experimentos de larga duración realizados permiten concluir que el modelo basado en una capa de neuronas grilla es más tolerante al ruido pero luego de un tiempo o aumentando el factor de error, empieza a crecer la cantidad de errores. Sin embargo, cuando se habilita la realimentación desde la capa de neuronas de lugar es posible mantener controlada la cantidad de errores de cierre de ciclo más allá de los errores caracterizados para la plataforma robótica utilizada. De todas formas, es importante notar que una vez que los errores se manifiestan crecen sin una cota superior.

Los resultados preliminares del módulo integrador de trayectorias con inspiración biológica son presentados en el trabajo Tejera et al. (2013b), integrando por primera vez neuronas grillas basadas en interferencia de ondas con realimentación a un modelo de navegación. Luego se caracterizan los errores para el robot utilizado y se ajusta el modelo de ruido a él, dando lugar la publicación del trabajo Tejera et al. (2015). A partir de los resultados de estos dos últimos trabajos se puede afirmar que el módulo de neuronas grilla realimentadas propuesto es robusto frente al error que tiene la información propioceptiva, posibilitando su uso en robots móviles y viabilizando este mecanismo en la biología.

6.2. Sobre la Contribución de la Investigación

6.2.1. Módulo integrador de trayectorias bio-inspirado

El modelo original incluía un módulo de remapeo dinámico (DRL) para realizar la tarea de integrar información de movimiento basado en la propuesta de Gaussier et al. (2002). Este módulo era muy simple y no permite ajustar la codificación interna para tolerar el error. Debe tenerse en cuenta que en el momento de su desarrollo era muy poco lo que se conocía al respecto del mecanismo de integración de trayectorias. Con el descubrimiento de las neuronas grilla en la MEC y su relación con el sistema de integración de trayectorias era necesario reemplazar el módulo DRL teniendo en cuenta estas nuevas hipótesis.

La investigación realizada en el marco de este trabajo propone como principal aporte un módulo integrador de trayectorias basado en una población de neuronas grilla que permite su ajuste para poder tolerar el error acumulado. Este módulo además de tener un fundamento biológico tanto desde su existencia como desde su construcción (basada en el modelo múltiples osciladores de Hasselmo) presenta una buena tolerancia al error que supera a la requerida para ejecutar el modelo sobre la plataforma robótica utilizada.

6.2.2. Mecanismo de reset

El modelo original presentaba la necesidad de disponer de un mecanismo de reset para poder resolver el error en la información sensorial interna, pero como ya se indicó, la propuesta original no lo permitía por las propias características del módulo DRL. Desde la biología se plantea claramente la necesidad de ajustar la información de integración de trayectorias para poder tolerar el error, surge entonces la posibilidad de apoyarse en señales externas para llevar adelante estos ajustes. Sin embargo, no se han generado resultados claros sobre como esto puede llegar a desarrollarse.

La investigación realizada en el marco de este trabajo propone un mecanismo simple y efectivo de realimentación. La información visual se integra a información de integración de trayectorias generando un patrón único de lugar, estos patrones son mantenidos en el grafo del modelo del mundo. Toda vez que el agente encuentra un patrón similar al actual se localiza en el mundo y aprovecha esta situación para alinear las neuronas grilla. En este sentido, se propone una heurística de ajuste basada en la información disponible. Las neuronas grilla que están activas actualmente pueden estar influyendo en el patrón generado en la capa de representación de lugares y si fuera así sería de interés reforzar estas neuronas grilla. El refuerzo intenta alinear la fases espaciales de las neuronas activas con la fase espacial actual (la posición actual del agente) y en cierta forma puede verse como una simplificación de la regla de Hebb donde se intenta relacionar la activación de los nodos con la activación de las grillas.

6.2.3. Aspectos de software

Originalmente el modelo tenía acoplada la definición del experimento y la interacción con el agente.

En el caso de la interacción con el agente, se disponía de un módulo del modelo que interactuaba con él y era necesario implementar las características de todos los agentes en él sin una interfaz clara. Como se indicó en el Capítulo 4, para mejorar este aspecto se definió una interfaz con el robot (iRobot) la cual debe implementarse para todo agente sobre el cual se quiera ejecutar el modelo, y se eliminaron del modelo los aspectos específicos de cada agente.

De manera similar ocurría con la definición del experimento, donde era necesario en un módulo del modelo implementar una secuencia de reglas para controlar la ejecución del modelo. En este caso se define una sintaxis para la definición de un experimento utilizando XML como soporte. Esto permitió de manera clara visualizar los experimentos, separarlos de la implementación del modelo, sistematizar la ejecución de los experimentos y reutilizar simulaciones al poder mantener un repositorio de simulaciones.

Otra de las mejoras realizadas sobre el modelo fue la generación de los APS y LPS lineales pues en el modelo original las posiciones de las gaussianas estaban fijas y podían tomar solo unos pocos valores. También se extendió el campo de visión al momento de armar la panorámica y se eliminaron zonas fantasmas que generaban discontinuidades en los LPS.

Por último, se levantaron algunas restricciones menores al modelo que permitieron su ejecución en entornos abiertos. Particularmente en lo que se refiere a creación de nodos en el módulo WGL donde sólo se creaban nodos si cambiaba el esquema perceptual de affordances.

6.3. Sobre las Líneas Futuras

6.3.1. Expansión de los campos de lugar de las grilla

Se ha observado que los campos de lugar de las neuronas se expanden en entornos novedosos y se contraen en entornos familiares (Barry et al., 2012). También en recorridos lineales bajo inactivación del hipocampo los campos grilla se vuelven amplios e inestables (Hafting et al., 2008). Teniendo en cuenta esta observación podrían expandirse los campos con el paso del tiempo y contraerse cuando se cierra un ciclo. Esto posibilita en cierta forma la tolerancia al ruido en el integrador de trayectorias pero reduciendo la precisión en la localización. Se evaluó sin obtener resultados contundentes la posibilidad de expandir los campos de lugar y contraerlos cada vez que se cierra el ciclo.

6.3.2. Módulo de neuronas de dirección de la cabeza

Como parte de los trabajos a futuro esperamos incorporar al modelo actual un módulo de neuronas dirección de la cabeza basado en estudios biológicos. El modelo presentado en el contexto de este documento utiliza un valor escalar que indica la dirección actual del agente y este valor es actualizado a través de las señales kinestésicas de entrada al modelo. Al igual que el cálculo de la posición utilizando únicamente integración de trayectorias, el cálculo de la dirección se basa en un proceso iterativo de suma de valores con error, en este caso los desplazamientos angulares, que deberá ser ajustado para que su valor tenga sentido para la navegación.

Como ya se ha indicado, existen neuronas en el tegmentum dorsal que codifican los desplazamientos angulares a partir de la información que reciben desde los canales semicirculares vía el núcleo vestibular. En este sentido, la aceleración angular es captada y convertida a velocidad angular en los canales semicirculares, luego se pasan al tegmentum dorsal y se vuelve a integrar en el núcleo mamilar y en el tálamo para proporcionar desplazamientos angulares que posibilitan la actualización de neuronas de dirección de la cabeza. Desde la corteza se reciben periódicamente correcciones visuales que resetean las señales de dirección de la cabeza para evitar desplazamientos debido al error acumulado por el proceso de sumas sucesivas de señales inexactas.

Son varios los modelos propuestos para dar lugar a neuronas HD (Wiener and Taube, 2005) siendo una de las posibilidades utilizar múltiples osciladores, permitiendo además de integrar la

neuronas HD, utilizar un mecanismo de realimentación similar al propuesto en este trabajo para las neuronas grilla.

6.3.3. Módulo de aprendizaje

En el contexto de esta investigación se llevaron adelante algunas modificaciones sobre el módulo de aprendizaje. El modelo original utilizaba una arquitectura Actor-Critic (Barto, 1995) la cual fue modificada para permitir implementar otros algoritmos como ser Q-Learning o SARSA (Sutton and Barto, 1998). La implementación actual permite obtener resultados de latencias de escape similares a las propuestas por Morris en sus experimentos.

Actualmente el modelo limita las posibles acciones a tomar a rotaciones de múltiplos de 45°, generando trayectorias bruscas si son comparadas con las presentadas por Morris. En este sentido, para poder realizar movimientos arbitrarios es necesario poder generalizar en el espacio de situaciones - acciones para poder obtener resultados similares a los encontrados al momento de experimentar con ratas. Ya se han iniciado algunos trabajos a nivel de grado y posgrado para resolver esto teniendo en cuenta la integración con el modelo.

Otros aspectos a investigar se refieren a mejorar la convergencia del aprendizaje y el desaprendizaje de rutas.

6.3.4. Módulo del grafo del mundo

Podría decirse que el módulo del modelo con menos inspiración biológica es el módulo del grafo del mundo (WGL). Este módulo utiliza listas y grafos para mantener la información, y realiza recorridos en estas estructuras como parte de sus funciones principales.

No existe actualmente ningún correlato neuronal establecido respecto de posibles representaciones topológicas en el cerebro, si bien son varios los modelos computacionales que trabajan sobre este supuesto que han representado con éxito por algunos datos experimentales del hipocampo. Existe evidencia neuronal que relaciona la corteza parietal posterior (PPC) y corteza retrosplenial (RSC) con aspectos relacionados a representaciones topológicas que podrían investigarse en este sentido (Madl et al., 2015).

6.3.5. Integración de información visual y de integración de trayectorias

Un problema recurrente en psicología cognitiva es determinar como diferentes fuentes de información son integradas para dar lugar a una representación unificada, en lo que a navegación se refiere este aspecto aparece al momento de integrar información de marcas y de PI. La información de origen visual es usada en el modelo junto a la información de integración de trayectorias para dar lugar un patrón de disparos neuronal que determina un lugar distintivo.

En este sentido, se requiere que ambas fuentes de información se encuentren disponibles para reconocer el lugar, si bien, como se ha indicado las ratas son capaces de navegar en ausencia de marcas. Por esto, es necesario evaluar alternativas a la integración de esta información y la búsqueda de patrones en la WGL (Chavarriga et al., 2005; Wessnitzer and Webb, 2006).

6.3.6. Integración de información de bordes

La rata es un animal nocturno que puede recorrer varios kilómetros en completa oscuridad hasta el alimento para luego regresar al nido. La información que ingresa al hipocampo de la rata es

multimodal y como se ha indicado los campos de lugar (grilla y de lugar) se mantienen aun en la oscuridad sin presencia de señales visuales. Estos campos pueden mantenerse estables por más de media hora en la oscuridad lo que sugiere la necesidad de utilizar otra fuente de información externa para alinear los campos frente al error acumulado.

La información de borde es importante para la navegación. Aún cuando la información sensorial externa es minimizada en la oscuridad, las ratas al navegar en un entorno cercado tienen la capacidad de sentir los bordes. Varios trabajos recientes comenzaron a incorporar información de borde para ayudar a reducir el error acumulado en el integrador de trayectorias. En general se observa que los campos de lugar se van corriendo en la oscuridad pero las colisiones con los bordes ayudan a rectificar el error acumulado (Zhang et al., 2014). Existen protocolos de experimentación especialmente diseñados con el objetivo de evaluar el efecto de los campos de lugar modificando dinámicamente las condiciones de luz (Quirk et al., 1990), los cuales podrían usarse para evaluar este aspecto.

6.3.7. Ejecutar el modelo en entornos no controlados

El uso de neuronas grilla como mecanismo de “odometría” y el mecanismo de realimentación puede mejorar el desempeño de robots móviles en entornos no controlados. Para ello, tenemos planificado investigar los beneficios de usar neuronas grilla para resolver el problema de integración de trayectorias y su robustez en contraste a los sistemas actuales de navegación usados en los robots móviles, o la incorporación a los sistemas actuales de esta propuesta. Si bien son varias las restricciones del modelo que deben levantarse previamente a esto, una de las más críticas se relaciona con la simplicidad en el módulo de extracción y codificación de marcas a partir de información visual.

6.3.8. Procesamiento de la información visual

La información espacial puede caracterizarse en base al marco de referencia usado. Las representaciones egocéntricas representan a la información espacial relativa al cuerpo del agente. En contraste, las representaciones aloécnicas representan la información espacial relativa a marcas o bordes en el entorno, independiente de su relación con el agente. Las representaciones aloécnicas no solo permiten el almacenamiento y la posterior recuperación de rutas, si no que también permiten calcular rutas nuevas, atajos o cierres de ciclo.

Es importante tener en cuenta que la percepción está asociada a un marco de referencia egocéntrico, las marcas son proyectadas en el campo visual del animal por lo que su posición es en una primera instancia calculada en función de la posición y orientación de sus ojos. Por este motivo, el sistema nervioso debe transformar las marcas egocéntricas en representaciones aloécnicas para ser usadas en conjunto con la información de PI y posibilitar su integración a un mapa. Se ha sugerido que esta transformación en los mamíferos podría realizarse en alguna región de la corteza parietal (Burgess et al., 1997; Etienne and Jeffery, 2004).

Se espera entonces, poder incorporar representaciones aloécnicas al modelo que actualmente resuelve este aspecto manteniendo un conjunto de patrones egocéntricos en un mismo nodo de la WGL.

6.3.9. Mecanismo de remapeo

El remapeo (re-map) fue observado en las neuronas de lugar al momento en que la rata entra a un entorno nuevo (Fyhn et al., 2007; Jeffery, 2011; Monaco et al., 2011).

Cuando la rata se mueve de un entorno a otro, la distribución de actividad en la población de neuronas de espacio varía, algunas se inhiben, otras se activan, y el resto cambian su patrón de actividad. Este remapeo va acompañado de un realineamiento de los patrones grilla de las neuronas de la MEC, los campos grilla se mueven y rotan, aunque la relación intrínseca entre las grillas de las neuronas colocalizadas no varía. Aún no está determinado como ocurre esto, pero las hipótesis actuales apunta a que este proceso ocurre de la interacción entre las neuronas grilla y las neuronas de lugar a través de las conexiones recurrentes entre ellas.

Es necesario estudiar los detalles de este mecanismo y analizar su incorporación como alternativa a alinear de forma manual las grillas cuando el robot se mueve de un lugar a otro, problema conocido como el robot secuestrado, por ejemplo entre ensayo y ensayo.

6.3.10. Integración a ROS

Desde hace algunos años comenzaron a aparecer plataformas robóticas genéricas para programar robots. La plataforma abierta Robotic Operating System¹ (ROS) es utilizada a nivel mundial en el desarrollo de software de robótica para investigación y la industria. ROS es un conjunto de bibliotecas, herramientas y convenciones que facilitan el proceso desarrollo de software robótico sobre una gran cantidad de robots, sensores y actuadores.

Otro aspecto importante es la gran comunidad de usuarios que lo utilizan y comparten los distintos paquetes desarrollados. Al usar ROS se espera al menos utilizar un simulador moderno, sus herramientas de diagnóstico, almacenamiento de una ejecución y la posibilidad de reproducción fuera de línea, e interfaces con distintas plataformas robóticas.

¹www.ros.org.

Capítulo 6: Discusión y Conclusiones

Bibliografía

- J.P. Aggleton, S.D. Vann, C.J.P. Oswald, and M. Good. Identifying cortical inputs to the rat hippocampus that subserve allocentric spatial processes: A simple problem with a complex answer. *Hippocampus*, 10:466–474, 2000.
- K. L. Agster and R. D. Burwell. Cortical efferents of the perirhinal, postrhinal, and entorhinal cortices of the rat. *Hippocampus*, 19:1159–1186, 2009.
- K. L. Agster and R. D. Burwell. Hippocampal and subicular efferents and afferents of the perirhinal, postrhinal, and entorhinal cortices of the rat. *Behavioural Brain Research*, 254:50–64, 2013.
- E. Antonelo and B. Schrauwen. Unsupervised Learning in Reservoir Computing: Modeling Hippocampal Place Cells for Small Mobile Robots. In Cesare Alippi, Marios Polycarpou, Christos Panayiotou, and Georgios Ellinas, editors, *Artificial Neural Networks - ICANN 2009*, volume 5768 of *Lecture Notes in Computer Science*, chapter 77, pages 747–756. Springer Berlin / Heidelberg, Berlin, Heidelberg, 2009. ISBN 978-3-642-04273-7.
- M. A. Arbib. *The Metaphorical Brain 2: Neural Networks and Beyond*. John Wiley & Sons, Inc., New York, NY, USA, 2nd edition, 1989. ISBN 0471098531.
- R. C. Arkin. *An Behavior-based Robotics*. MIT Press, Cambridge, MA, USA, 1st edition, 1998. ISBN 0262011654.
- A. Arleo, F. Smeraldi, and W. Gerstner. Cognitive navigation based on non-uniform gabor space sampling, unsupervised growing networks, and reinforcement learning. *IEEE Trans. on Neural Networks*, 15(3):639–652, 2004.
- Y. Bar-Shalom. *Tracking and data association*. Academic Press Professional, Inc., San Diego, CA, USA, 1987. ISBN 0-120-79760-7.
- A. Barrera. *Modelo de Cognición espacial y Navegación en Ratas para Controlar a un Robot Móvil Autónomo*. PhD thesis, Universidad Nacional Autónoma de México, 2007.
- A. Barrera and A. Weitzenfeld. Biologically-inspired robot spatial cognition based on rat neurophysiological studies. *Auton. Robots*, 25(1-2):147–169, 2008. ISSN 0929-5593.
- A. Barrera, G. Tejera, M. Llofriu, and A. Weitzenfeld. Learning spatial localization: From rat studies to computational models of the hippocampus. *Spatial Cognition & Computation*, 15(1): 27–59, 2014.

BIBLIOGRAFÍA

- Caswell Barry, Lin Lin Ginzberg, John O'Keefe, and Neil Burgess. Grid cell firing patterns signal environmental novelty by expansion. *Proceedings of the National Academy of Sciences*, 109(43): 17687–17692, 2012. doi: 10.1073/pnas.1209918109. URL <http://www.pnas.org/content/109/43/17687.abstract>.
- A. G. Barto. Adaptive critics and the basal ganglia. In Davis J. L. Beiser D. G. Houk, J. C., editor, *Models of information processing in the basal ganglia*, pages 249–270. MIT Press, 1995.
- J. Borenstein and L. Feng. Measurement and correction of systematic odometry errors in mobile robots. *IEEE Transactions on Robotics and Automation*, 12:869–880, 1996.
- M. Bosse, P. Newman, J. Leonard, and S. Teller. Slam in large-scale cyclic environments using the atlas framework. *International Journal of Robotics Research*, pages 1113–1139, 2004.
- N. Burgess, M. Recce, and J. O'Keefe. A model of hippocampal function. *Neural Networks*, 7(6-7): 1065–1081, 1994.
- N. Burgess, J. G. Donnett, and J. O'Keefe. Robotic and neuronal simulation of hippocampal navigation. *University of Manchester*, 352:1361–6161, 1997.
- N. Burgess, C. Barry, and J. O'Keefe. An oscillatory interference model of grid cell firing. *Hippocampus*, 17(9):801–812, 2007.
- D. Bush, C. Barry, and N. Burgess. Opinion. *Trends in Neurosciences*, 37(3):136–145, 2014. doi: 10.1016/j.tins.2013.12.003.
- D. Carter. Can Medial Septal Stimulation that Elicits Hippocampal Theta Rhythm Repair Cognitive and Emotional Deficits Resulting from Vestibular Lesions? Master's thesis, University of Otago, New Zealand, 2010.
- R. Chavarriaga, T. Strösslín, D. Sheynikhovich, and W. Gerstner. A computational model of parallel navigation systems in rodents. *Neuroinformatics*, 3(3):223–241, 2005.
- S. Cheng and L.M. Frank. The structure of networks that produce the transformation from grid cells to place cells. *Neuroscience*, 197(0):293 – 306, 2011. ISSN 0306-4522.
- A. Cheung, D. Ball, M. Milford, G. Wyeth, and J. Wiles. Maintaining a cognitive map in darkness: The need to fuse boundary knowledge with path integration. *PLoS Computational Biology*, 8(8), 2012. URL <http://dblp.uni-trier.de/db/journals/ploscb/ploscb8.html#CheungBMWW12>.
- Wikimedia Commons. Wikipedia: the free encyclopedia, Marzo 2015. <http://en.wikipedia.org>.
- A. S. Etienne. Mammalian navigation, neural models and biorobotics. *Connect. Sci.*, 10(3-4):271–289, 1998.
- A. S. Etienne and K. J. Jeffery. Path integration in mammals. *Hippocampus*, 14(2):180–192, 2004.
- A. S. Etienne, V. Boulens, R. Maurer, T. Rowe, and C. Siegrist. A brief view of known landmarks reorientates path integration in hamsters. *Naturwissenschaften*, 87(11):494–498, 2000.

BIBLIOGRAFÍA

- J. G. Fleischer, J. A. Gally, G. M. Edelman, and J. L. Krichmar. Retrospective and prospective responses arising in a modeled hippocampus during maze navigation by a brain-based device. *Proc Natl Acad Sci U S A*, 104(9):3556–3561, February 2007.
- J. Folkesson and H. Christensen. Graphical slam - a self-correcting map. In *In IEEE Intl. Conf. on Robotics and Automation (ICRA)*, pages 383–390, 2004.
- M. O. Franz, B. Schölkopf, P. Georg, H. A. Mallot, and H. H. Bülthoff. Learning view graphs for robot navigation. *Autonomous Robots*, 5:111–125, 1997.
- U. Frese. A discussion of simultaneous localization and mapping. *Autonomous Robots*, 20:25–42, 2006.
- S. C. Furtak, S. M. Wei, K. L. Agster, and R. D. Burwell. Functional neuroanatomy of the parahippocampal region in the rat: The perirhinal and postrhinal cortices. *Hippocampus*, 17:709–722, 2007.
- M. Fyhn, T. Hafting, A. Treves, M. B. Moser, and E. I. Moser. Hippocampal remapping and grid realignment in entorhinal cortex. *Nature*, 446(7132):190–194, March 2007. ISSN 1476-4687.
- C. R. Gallistel. *The Organization of Learning*. Learning, Development, and Conceptual Change. The MIT Press, 1993. ISBN 026257098X.
- P. Gaussier, A. Revel, J. P. Banquet, and V. Babeau. From view cells and place cells to cognitive map learning: processing stages of the hippocampal system. *Biological Cybernetics*, 86(1):15–28, 2002.
- L. M. Giocomo, E. A. Zilli, E. Fransén, and M. E. Hasselmo. Temporal Frequency of Subthreshold Oscillations Scales with Entorhinal Grid Cell Field Spacing. *Science*, 315(5819):1719–1722, 2007. ISSN 1095-9203.
- L. M. Giocomo, M. B. Moser, and E. I. Moser. Computational models of grid cells. *Neuron*, 71(4):589–603, 2011. ISSN 0896-6273.
- A. Guazzelli, F. J. Corbacho, M. Bota, and M. A. Arbib. Affordances, motivation, and the world graph theory. *Adaptive Behavior*, 6(3-4):435–471, 1998.
- J. Guivant, J. Nieto, F. Masson, and E. Nebot. Navigation and mapping in large unstructured environments. *The International Journal of Robotics Research*, 23:4–5, 2004.
- T. Hafting, M. Fyhn, S. Molden, M. B. Moser, and E. I. Moser. Microstructure of a spatial map in the entorhinal cortex. *Nature*, 436(7052):801–806, August 2005. ISSN 1476-4687.
- T. Hafting, M. Fyhn, T. Bonnevie, M. B. Moser, and E. I. Moser. Hippocampus-independent phase precession in entorhinal grid cells. *Nature*, 453(7199):1248–1252, May 2008. ISSN 0028-0836.
- D. Hähnel, S. Thrun, B. Wegbreit, and W. Burgard. Towards lazy data association in SLAM. In *Proc. of the International Symposium on Robotics Research (ISRR)*, 2003.
- M. E. Hasselmo, L. M. Giocomo, and E. A. Zilli. Grid cell firing may arise from interference of theta frequency membrane potential oscillations in single neurons. *Hippocampus*, 17(12):1252–1271, 2007. ISSN 1050-9631.

BIBLIOGRAFIA

- D. Hebb. *The organization of behavior : a neuropsychological theory*. Wiley-Interscience, New York, 1949.
- C. Hlscher. *Neuronal Mechanisms of Memory Formation : Concepts of Long-term Potentiation and Beyond*. Cambridge University Press, 2000. ISBN 9780511529818,0511529813.
- K. J. Jeffery. Learning of landmark stability and instability by hippocampal place cells. *Neuropharmacology*, 37(4-5):677–687, 1998.
- K. J. Jeffery. Place cells, grid cells, attractors, and remapping. *Neural plasticity*, 2011, 2011. ISSN 1687-5443.
- K. J. Jeffery and J. M. O’Keefe. Learned interaction of visual and idiothetic cues in the control of place field orientation. *Experimental Brain Research*, 127:151–161, 1999.
- J. J. Knierim, H. S. Kudrimoti, and B. L. McNaughton. Neuronal mechanisms underlying the interaction between visual landmarks and path integration in the rat. *International Journal of Neural Systems*, 2(7):213–218, 1996.
- A. Koene and T. J. Prescott. Hippocampus, amygdala and basal ganglia based navigation control. In Cesare Alippi, Marios M. Polycarpou, Christos G. Panayiotou, and Georgios Ellinas, editors, *ICANN (1)*, volume 5768 of *Lecture Notes in Computer Science*, pages 267–276. Springer, 2009. ISBN 978-3-642-04273-7.
- J. Krupic, N. Burgess, and J. O’Keefe. Neural Representations of Location Composed of Spatially Periodic Bands. *Science*, 337(6096):853–857, 2012. ISSN 1095-9203.
- B. Kuipers, J. Modayil, P. Beeson, M. Macmahon, and Savelli F. Local metrical and global topological maps in the hybrid spatial semantic hierarchy. In *IEEE Int. Conf. on Robotics & Automation (ICRA-04)*, pages 4845–4851, 2004.
- Franz M. and Mallot H. A. Biomimetic robot navigation. *Robotics and autonomous Systems*, 30: 133–153, 2000.
- H. Maaswinkel and I. Q. Whishaw. Homing with locale, taxon, and dead reckoning strategies by foraging rats: sensory hierarchy in spatial navigation. *Behavioural Brain Research*, 99(2):143 – 152, 1999.
- T. Madl, K. Chen, D. Montaldi, and R. Trappl. Computational cognitive models of spatial memory in navigation space: A review. *Neural Networks*, 65(0):18 – 43, 2015. ISSN 0893-6080.
- J. L. McClelland. The place of modeling in cognitive science. *Topics in Cognitive Science*, 1(1): 11–38, 2009. ISSN 1756-8765.
- B. L. Mcnaughton, Knierim, and M. A. Wilson. Vector encoding and the vestibular foundations of spatial cognition: Neurophysiological and computational mechanisms. In M. S. Gazzaniga, editor, *The cognitive neurosciences*, pages 585–595. MIT Press, 1995.
- B. L. McNaughton, C. A. Barnes, J. L. Gerrard, K. Gothard, M. W. Jung, J. J. Knierim, H. Kudrimoti, Y. Qin, W. E. Skaggs, M. Suster, and K. L. Weaver. Deciphering the hippocampal polyglot: the hippocampus as a path integration system. *Journal of Experimental Biology*, 199: 173–185, 1996.

BIBLIOGRAFÍA

- B. L. McNaughton, F. P. Battaglia, O. Jensen, E. I. Moser, and M. B. Moser. Path integration and the neural basis of the 'cognitive map'. *Nature Reviews Neuroscience*, 7(8):663–678, 2006.
- M. Milford, G. Wyeth, and D. Prasser. Ratslam on the edge : revealing a coherent representation from an overloaded rat brain. In *IEEE/RSJ International Conference on Robotics and Systems 2006*, page 4060. IEEE, 2006.
- M. J. Milford. *Robot Navigation from Nature: Simultaneous Localisation, Mapping, and Path Planning Based on Hippocampal Models (Springer Tracts in Advanced Robotics)*, volume 41. Springer, 1 edition, 2008. ISBN 3540775196,9783540775195.
- M. L. Mittelstaedt and H. Mittelstaedt. Homing by path integration in a mammal. *Naturwissenschaften*, 67:566–567, 1980.
- J. D. Monaco, L. F. Abbott, and Larry F. Abbott. Modular realignment of entorhinal grid cell activity as a basis for hippocampal remapping. *The Journal of neuroscience : the official journal of the Society for Neuroscience*, 31(25):9414–9425, June 2011. ISSN 1529-2401.
- M. Montemerlo and S. Thrun. Simultaneous localization and mapping with unknown data association using fastslam. In *IEEE International Conference on Robotics and Automation (ICRA)*, pages 1985–1991, 2003.
- H. Moravec and A. Elfes. High-Resolution Maps from Wide-Angle Sonar. In *IEEE International Conference on Robotics and Automation (ICRA)*. CS Press, 1985.
- R. Morris. Spatial localization does not require the presence of local cues. *Learning and Motivation*, 12(2):239–260, May 1981. ISSN 00239690.
- E. I. Moser, E. Kropff, and M. B. Moser. Place cells, grid cells, and the brain's spatial representation system. *Annual Review of Neuroscience*, 31(1):69–89, 2008.
- Robin R. Murphy. *Introduction to AI Robotics*. MIT Press, Cambridge, MA, USA, 1st edition, 2000. ISBN 0262133830.
- P. Newman, D. Cole, and K. Ho. Outdoor slam using visual appearance and laser ranging. In *IEEE International Conference on Robotics and Automation*, pages 1180–1187, 2006.
- J. O'Keefe and N. Burgess. Dual phase and rate coding in hippocampal place cells: theoretical significance and relationship to entorhinal grid cells. *Hippocampus*, 15(7):853–866, 2005. ISSN 1050-9631.
- J. O'Keefe and D. H. Conway. Hippocampal place units in the freely moving rat: Why they fire where they fire. *Experimental Brain Research*, 31:573–590, 1978.
- J. O'Keefe and J. Dostrovsky. The hippocampus as a spatial map. preliminary evidence from unit activity in the freely-moving rat. *Brain Research*, 34(1):171–175, 1971. ISSN 0006-8993.
- J. O'Keefe and L. Nadel. *The Hippocampus as a Cognitive Map*. Oxford Clarendon Press, 1978.
- J. O'Keefe and M. L. Recce. Phase relationship between hippocampal place units and the EEG theta rhythm. *Hippocampus*, 3(3):317–330, July 1993. ISSN 1050-9631.

BIBLIOGRAFÍA

- J. O'Keefe, N. Burgess, J. G. Donnett, K. J. Jeffery, and E. A. Maguire. Place cells, navigational accuracy, and the human hippocampus. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*, 353(1373):1333–1340, August 1998. ISSN 0962-8436.
- M. J. Pearson, B. Mitchinson, J. Welsby, A. G. Pipe, and T. J. Prescott. Scratchbot: Active tactile sensing in a whiskered mobile robot. In Stéphane Doncieux, Benoît Girard, Agnès Guillot, John Hallam, Jean-Arcady Meyer, and Jean-Baptiste Mouret, editors, *SAB*, volume 6226 of *Lecture Notes in Computer Science*, pages 93–103. Springer, 2010. ISBN 978-3-642-15192-7.
- P. K. Pilly and S. Grossberg. How do spatial learning and memory occur in the brain? coordinated learning of entorhinal grid cells and hippocampal place cells. *Cognitive Neuroscience*, 24(5):1031–1054, 2012.
- B. Poucet. Spatial cognitive maps in animals: new hypotheses on their structure and neural mechanisms. *Psychological Review*, 100(2):163–182, 1993.
- G. J. Quirk, R. U. Muller, and J. L. Kubie. The firing of hippocampal place cells in the dark depends on the rat's recent experience. *The Journal of neuroscience : the official journal of the Society for Neuroscience*, 10(6):2008–2017, June 1990. ISSN 0270-6474.
- A. D. Redish and D. S. Touretzky. Cognitive maps beyond the hippocampus. *Hippocampus*, 7:15–35, 1997.
- R. Resnick, D. Halliday, and K. S. Krane. *Física*, volume 1. Compañía Editorial Continental, 4 edition, 2001.
- W. A. Roberts. *Principles of animal cognition*. McGraw Hill, USA, 1998.
- RoboCup. RoboCup: the robot soccer world cup, Marzo 2015. [http://http://www.robocup.org](http://www.robocup.org).
- S. Saeidi and F. Towhidkhal. Different spatial scales in mapping from grid cells to place cells: A neural network model. In *Neural Engineering, 2009. NER '09. 4th International IEEE/EMBS Conference on*, pages 706–709, April 2009.
- D. Samu, P. Erős, B. Ujfalussy, and T. Kiss. Robust path integration in the entorhinal grid cell system with hippocampal feed-back. *Biological Cybernetics*, 101(1):19–34, 2009.
- D. Santos, B. Heyneman, S. Kim, N. Esparza, and M.R. Cutkosky. Gecko-inspired climbing behaviors on vertical and overhanging surfaces. In *Robotics and Automation, 2008. ICRA 2008. IEEE International Conference on*, pages 1125–1131, May. 2008. ISBN 978-1-4244-1646-2.
- F. Sargolini, M. Fyhn, T. Hafting, B. L. McNaughton, M. P. Witter, M. B. Moser, and E. I. Moser. Conjunctive representation of position, direction, and velocity in entorhinal. *Science*, 312(5774):758–62, 2006.
- F. Savelli. Loop-closing and planarity in topological map-building. In *In IEEE/RSJ Intl. Conf. on Intelligent Robots and Systems (IROS)*, pages 1511–1517, 2004.
- F. Savelli and J. J. Knierim. Hebbian analysis of the transformation of medial entorhinal grid-cell inputs to hippocampal place fields. *Journal of Neurophysiology*, 103(6):3167–3183, 2010.

BIBLIOGRAFÍA

- W. B. Scoville and B. Milner. Loss of recent memory after bilateral hippocampal lesions. *Journal of Neurology, Neurosurgery and Psychiatry*, 20(11):11–21, February 1957. ISSN 0895-0172.
- A. Shah, S. Singh Jhavar, and A. Goel. Analysis of the anatomy of the papez circuit and adjoining limbic system by fiber dissection techniques. *Journal of Clinical Neuroscience*, 19(2):289 – 298, 2012. ISSN 0967-5868.
- B. Siciliano and O. Khatib, editors. *Springer Handbook of Robotics*. Springer, Washington, 2008. ISBN 978-3-540-23957-4.
- T. Solstad, E. I. Moser, and G. T. Einevoll. From grid cells to place cells: a mathematical model. *Hippocampus*, 16(12):1026–1031, 2006. ISSN 1050-9631.
- N. Sünderhauf and P. Protzel. Learning from Nature: Biologically Inspired Robot Navigation and SLAM. *Review*. 24(3):215–221, 2010.
- R. S. Sutton and A. G. Barto. *Introduction to Reinforcement Learning*. MIT Press, Cambridge, MA, USA, 1st edition, 1998. ISBN 0262193981.
- J. S. Taube. The head direction signal: Origins and sensory-motor integration. *Annual Review of Neuroscience*, 30:181–207, 2007.
- G. Tejera, F. Benavides, and Casella S. Between rats and robots: A survey. In Universidad de Morón, editor, *Anales del VII Campeonato de Fútbol de Robots y Workshop de Sistemas Autónomos de Robots*, pages 8–14, 2009.
- G. Tejera, A. Barrera, J. M. Fellous, M. Llofriu, and A. Weitzenfeld. Spatial cognition: robot target localization in open arenas based on rat studies. In *Proceedings of SPIE*, volume 8756, 2013a.
- G. Tejera, A. Barrera, M. Llofriu, and A. Weitzenfeld. Solving uncertainty during robot navigation by integrating grid cell and place cell firing based on rat spatial cognition studies. In *Advanced Robotics (ICAR), 16th International Conference on*, pages 1–6, Nov 2013b.
- G. Tejera, M. Llofriu, A. Barrera, and A. Weitzenfeld. A spatial cognition model integrating grid cells and place cells. In *Neural Networks, International Joint Conference on*, pages 1–6, Jul 2015.
- E. C. Tolman. Cognitive maps in rats and men. *Psychological Review*, 55(4):189–208, 1948.
- B. W. Towse, C. Barry, D. Bush, and N. Burgess. Optimal configurations of spatial scale for grid cell firing under noise and uncertainty. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, 369(1635), 2013. ISSN 0962-8436.
- I. Ulrich and I. Nourbakhsh. Appearance-based place recognition for topological localization. In *Proceedings of IEEE International Conference on Robotics and Automation (ICRA)*, pages 1023–1029, 2000.
- W.G. Walter. *The Living Brain*. Pelican books. Penguin Books, 1961.
- B. Webb. Can robots make good models of biological behaviour? *Behavioral and Brain Sciences*, 24(6):1033–1050, Dec. 2001.

BIBLIOGRAFÍA

- A. Weitzenfeld, J. M. Fellous, A. Barrera, and G. Tejera. Allothetic and idiothetic sensor fusion in rat-inspired robot localization. In *Proceedings of SPIE*, volume 8407, 2012.
- Arbib M. Alexander A. Weitzenfeld, A. *The Neural Simulation Language*. MIT Press, 2002.
- A. C. Welday, I. G. Shlifer, M. L. Bloom, K. Zhang, and H. T. Blair. Cosine directional tuning of theta cell burst frequencies: evidence for spatial coding by oscillatory interference. *The Journal of neuroscience : the official journal of the Society for Neuroscience*, 31(45):16157–16176, November 2011. ISSN 1529-2401.
- J. Wessnitzer and B. Webb. Multimodal sensory integration in insects-towards insect brain control architectures. *Bioinspiration & Biomimetics*, 1(3):63, 2006. URL <http://stacks.iop.org/1748-3190/1/i=3/a=001>.
- S. I. Wiener and J. S. Taube, editors. *Head direction cells and the neural mechanisms of spatial orientation*. MIT Press, 2005.
- S. Zhang, F. Schoenfeld, L. Wiskott, and D. Manahan-Vaughan. Spatial representations of place cells in darkness are supported by path integration and border information. *Frontiers in Behavioral Neuroscience*, 8(222), 2014. ISSN 1662-5153.
- E. A. Zilli. Models of grid cell spatial firing published 2005-2011. *Frontiers in neural circuits*, 6, 2012. ISSN 1662-5110.
- Z. Zivkovic, B. Bakker, and B Kröse. Hierarchical map building using visual landmarks and geometric constraints. In *IROS*, pages 2480–2485. IEEE, 2005.

Nomenclatura

- affordances de movimiento** noción adoptada por Gibson que representa las posibles acciones motrices que pueden ejecutarse a partir de la sensación inmediata. En el modelo son las posibles rotaciones que la rata puede ejecutar de -180° a $+180^\circ$ en intervalos de 45° a partir de su localización y dirección de cabeza actuales..
- alotética** Los estímulos alotéticos (allothetic) son aquellos que proporciona el ambiente. Por ejemplo: estímulos olfativos, visuales o sonidos.
- aprendizaje de Hebb** cuando una capa de neuronas se proyecta sobre otra, esta regla de aprendizaje ajusta las conexiones entre ellas para que cada vez que un patrón de actividad similar se presente en la capa fuente, el mismo conjunto de unidades se active en la capa destino, con el fin de posibilitar la detección de patrones de información..
- APS** del Inglés affordance perceptual schema, o en Español: esquema perceptual de affordances
- AVP** del Inglés angular velocity pattern, o en Español: patrón de velocidad angular.
- BCP** del Inglés band cell pattern, o en Español: patrón de neuronas banda.
- CA** del latin cornus ammonis.
- cierre del ciclo** afirmar correctamente que un robot móvil ha vuelto a una posición previamente visitada.
- cognición espacial** proceso de codificación y almacenamiento de información espacial, la cual permite que la orientación hacia los objetos y el movimiento a través del espacio sean exitosos.
- DG** del Inglés dentate gyrus, o en Español: giro dentado.
- EC** del Inglés entorhinal cortice, o en Español: corteza entorrinal.
- esquema perceptual** Esquemarreglo lineal que almacena una o más distribuciones de Gauss cuyas posiciones medias dentro del arreglo corresponden a rotaciones relativas específicas entre -180° y $+180^\circ$ en intervalos de 45° ..
- GCP** del Inglés grid cell pattern, o en Español: patrón de neuronas grilla.

BIBLIOGRAFÍA

- HD** del Inglés head direction cells, o en Español: neuronas de dirección de la cabeza.
- HDP** del Inglés head direction pattern, o en Español: patrón de dirección de la cabeza.
- idiotético** Los estímulos idiotéticos (idiothetic) hacen referencia a estímulos del propio cuerpo que informan cambios de la posición o dirección. Por ejemplo estímulos vestibulares, propioceptivos o motores.
- información kinestésica** señales de retroalimentación interna procedentes de los músculos de un individuo durante su locomoción en el espacio. En el modelo propuesto, la información kinestésica incluye las magnitudes de la rotación y de la traslación ejecutadas por el animal en cualquier instante de tiempo..
- integración de trayectorias** La forma más simple de navegación utilizada por algunos animales en la cual estiman su posición de forma continua con respecto a un punto de referencia utilizando únicamente señales que infiere de su propia locomoción.
- IR** del Inglés infrared, o en Español: infrarojo.
- LEC** del Inglés lateral entorhinal cortice, o en Español: corteza entorrinal lateral.
- LFDL** del Inglés landmarks feature detector layer, o en Español: capa de detección de patrones de marcas.
- LL** del Inglés landmarks layer, o en Español: capa de marcas.
- LP** del Inglés landmarks pattern, o en Español: patrón de marcas.
- LPS** del Inglés landmark perceptual schema, o en Español: esquema perceptual de marca .
- LRF** del Inglés laser range finder, o en Español: sensor laser de distancia.
- LVP** del Inglés linear velocity pattern, o en Español: patrón de velocidad lineal.
- MEC** del Inglés medial entorhinal cortice, o en Español: corteza entorrinal media.
- mpo** del Inglés subthreshold membrane potential oscillations, o en Español: oscilaciones sub-umbral del potencial de membrana.
- neurofisiología** Fisiología del sistema nervioso. Fisiología: Ciencia que tiene por objeto el estudio de las funciones de los seres orgánicos.
- neuronas estrelladas** Son generalmente células pequeñas, en un número escaso. Tienen dendritas cortas y delgados axones amielínicos. Una variedad de estas células se conoce como células en cesta. .
- oscilación subumbral** fluctuaciones rítmicas de la diferencia de potencial entre el interior y el exterior de una neurona..
- PCL** del Inglés place cell layer, o en Español: capa de neuronas de lugar.
- PER** del Inglés perhinal cortice, o en Español: corteza perirrinal.

BIBLIOGRAFÍA

PI	del Inglés path integration, o en Español: integración de trayectorias.
PIFDL	del Inglés path integration feature detector layer, o en Español: capa de detección de patrones de integración de trayectoria.
PIL	del Inglés path integration layer, o en Español: capa de integración de trayectorias.
PIP	del Inglés path integration pattern, o en Español: patrón de integración de trayectorias.
POR	del Inglés postrhinal cortice, o en Español: corteza postrinal.
SD	del Inglés similarity degree, o en Español: grado de similitud.
SLAM	del Inglés Simultaneous Localization And Mapping, o en Español: Localización y construcción del mapa simultánea.
taxon	estrategia de aprendizaje dirigida por la percepción de la recompensa o basada en una hipótesis de orientación..
WGL	del Inglés world graph layer, o en Español: capa del grafo del mundo.

BIBLIOGRAFÍA

Apéndice A

Parámetros del modelo

Parámetro	Descripción	Valor
α_{hebb}	Tasa de aprendizaje utilizado para adaptar los pesos entre las capas del modelo.	0.001
α_{reset}	Tasa de aprendizaje utilizado para adaptar la fase dendritica de las neuronas grillas al ocurrir un reset.	0.05
β	Tasa de aprendizaje utilizado para adaptar los valores estimados de Q en el módulo de aprendizaje.	0.1
γ	Factor de descuento usado por el módulo de aprendizaje por refuerzo.	0.7
θ_g	Umbral a partir del cual una neurona grilla se considera activa.	1.8
θ_{sd}	Umbral de similitud utilizad para reconocer lugares en la WGL.	110
μ_{err_num}	Media de la distribución normal que caracteriza al error cometido por el robot Khepera al realizar una acción de avance.	1.14 mm
$\sigma_{err_num}^2$	Desviación estandar de la distribución normal que caracteriza al error cometido por el robot Khepera al realizar una acción de avance.	0.18 mm
B_H	Constante para la ecuación de Hasselmo para el cálculo de la activación de la neurona grilla.	0,0038 s/cm
H	Constante de escala determinada por Hasselmo para el cálculo de la activación de la neurona grilla.	300 Hz cm
N_{FDL}	Cantidad de neuronas en las capas detectoras de patrones.	400 (20x20)
N_{gc}	Cantidad de neuronas grilla.	880
N_{go}	Cantidad de orientaciones generadas en cada vértice.	10
N_{land}	Cantidad de marcas.	4
nPS	Cantidad de neuronas en cualquier esquema perceptual lineal.	80
mm_fwd_move	Milímetros indicados al robot para las acciones de avance.	150 mm

Cuadro A.1 – Cantidad de ratas, posiciones de partida y posiciones de la plataforma para los animales de los distintos grupos.