



UNIVERSIDAD AUTÓNOMA DE YUCATÁN
FACULTAD DE MATEMÁTICAS

MAESTRÍA EN CIENCIAS DE LA COMPUTACIÓN

MODELO PROBABILISTICO PARA LA INFERENCIA DEL PATRÓN DE
DESPLAZAMIENTO DEL ADULTO MAYOR EN LA VIDA ASISTIDA POR SU
ENTORNO

TESIS

PRESENTADA POR:

LCC. AY MANZANERO REYNA CONCEPCIÓN

EN OPCIÓN AL GRADO DE:

MAESTRA EN CIENCIAS DE LA COMPUTACIÓN

DIRECTORES DE TESIS:

DR. JORGE RICARDO GÓMEZ MONTALVO

DR. JOSÉ LUIS BATÚN CUTZ

MÉRIDA, YUCATÁN, MÉXICO

AGOSTO, 2019

*"Tu tiempo es limitado, de modo que no lo malgastes viviendo la vida de alguien distinto. No quedes atrapado en el dogma, que es vivir como otros piensan que deberías vivir. No dejes que los ruidos de las opiniones de los demás acallen tu propia voz interior. Y, lo que es más importante, **ten el coraje para hacer lo que dicen tu corazón y tu intuición.**"*

STEVE JOBS

Declaración de autoría

Yo, LCC. Reyna Concepción Ay Manzanero, declaro que esta tesis titulada “Modelo probabilístico para la inferencia del patrón de desplazamiento del adulto mayor en la vida asistida por su entorno” y el trabajo aquí presentado son de mi autoría.

Confirmo que:

- El trabajo fue realizado en el periodo que cursé en la maestría.
- Cualquier consulta realizada de la publicación de terceros, fue atribuido claramente.
- Cualquier cita mencionada en este trabajo cuenta con la referencia bibliográfica.
- Cualquier parte de esta tesis que haya sido previamente presentada para la obtención de título en esta universidad u otra institución, fue mencionado claramente.

Firmado: _____

Fecha: _____

Dedicado a

A mi familia por su apoyo y confianza.

A mi madre por los consejos y el apoyo incondicional que permitieron desarrollarme de manera adecuada en el ámbito profesional.

A mi novio por entenderme en todo y ayudarme en los momentos difíciles, en especial por motivarme en los momentos turbulentos.

A mi Luna por permanecer junto a mí en las desveladas.

A mis amigos.

Resumen

En esta tesis se desarrolló un módulo para inferir el patrón de desplazamiento a nivel habitacional del adulto mayor. El motor primordial para el funcionamiento del módulo es el modelo probabilístico. Dicho modelo probabilístico implementa los procesos estocásticos, principalmente la cadena de Markov en tiempo continuo para estimar las probabilidades de desplazamiento en el interior del hogar. El modelo probabilístico presentado tiene como ventaja el adaptarse a los distintos usuarios, y además el proceso de aprendizaje es no supervisado.

El resultado final del módulo involucra el algoritmo que permite una aproximación numérica de los parámetros, la verificación de la propiedad de Markov y una interfaz gráfica para la visualización del patrón de desplazamiento a nivel habitacional.

La prueba experimental se realizó como una prueba de concepto. Los resultados obtenidos son satisfactorios y en efecto motiva a continuar con este enfoque para la estimación del patrón de desplazamiento. Las trayectorias estimadas pueden ser datos de entrada para los sistemas que controlan una casa inteligente. Los sistemas inteligentes, con base en esta información, mejorarían la asistencia al anticiparse al desplazamiento del adulto mayor al proporcionar los servicios disponibles en la habitación.

Agradecimientos

Agradezco al Consejo de Ciencia y Tecnología (CONACYT) y a la Universidad Autónoma de Yucatán por su apoyo para la realización de este proyecto de tesis.

De igual manera, agradezco a todas las personas que fueron participes en este proceso. Principalmente, al Dr. Jorge Montalvo y Dr. José Batún por aportar de su tiempo y conocimientos.

Gracias a mi familia y amigos por ser el principal apoyo. Agradezco a mi madre por darme total libertad en la toma de mis decisiones. En especial a ti, Wilberth por motivarme a continuar al momento de querer desistir.

Índice general

1. Introducción	1
1.1. Preliminares	1
1.2. Contexto y problemática	4
1.3. Objetivo	9
1.3.1. Objetivo general	9
1.3.2. Objetivos específicos	9
1.4. Contribuciones	10
1.5. Estructura de tesis	12
2. Estado del arte	13
2.1. Sistemas de asistencia al interior del hogar	13
2.1.1. Métodos implementados para la asistencia en hogares inteligentes	16
2.1.2. Métodos probabilísticos para el tracking en el hogar	19
3. Contribución de la tesis	22
3.1. Plataforma del modelo probabilístico	22
3.1.1. Estructura de la arquitectura	22
3.2. Modelo probabilístico	27
3.2.1. Procesos Estocásticos	27
3.2.2. Cadenas de Markov	28
3.3. Implementación del modelo probabilístico	35
3.3.1. Verificar que los datos satisfacen la propiedad de Markov	35
3.3.2. Justificación de la homogeneidad	36
3.3.3. Estimar Q	37

3.3.4. Calcular P	38
4. Pruebas y resultados	40
4.1. Recolección de la información	41
4.2. Verificación de ajuste del modelo de Markov	50
4.2.1. Propiedad de Markov	50
4.2.2. Homogeneidad	53
4.3. Ajuste del Modelo	54
4.3.1. Estimación de Q	54
4.4. Aplicación: Predicción de la trayectoria	62
4.4.1. Visualización de las trayectorias estimadas	67
5. Conclusiones y trabajos a futuro	83

Índice de figuras

1.1. Desplazamiento del adulto mayor al realizar sus actividades	4
1.2. Grafo de movimientos del contexto de la Figura 1.1	5
1.3. Patrón de desplazamiento entre habitaciones en un día con frecuencias	6
1.4. Grafo de desplazamiento entre habitaciones en un día con probabilidades	7
1.5. Patrón de desplazamiento entre habitaciones de un mes	8
1.6. Patrón de desplazamiento entre habitaciones de un año	8
2.1. Arquitectura general de la plataforma OPAIEH para el reconocimiento de actividades en el interior del hogar.	15
2.2. Análisis de métodos de aprendizaje	16
3.1. Arquitectura general para la estimación del patrón de desplazamiento a nivel habitación en el interior del hogar.	23
3.2. Estructura de la interfaz.	26
3.3. S es el espacio de estados, y los valores A,B,D,C representan las habita- ciones.	28
3.4. Patrón de desplazamiento de un adulto mayor en su hogar.	29
3.5. Ejemplo en tiempo discreto.	30
3.6. Ejemplo en tiempo continuo.	30
3.7. Ejemplo de la suma de la probabilidad sea 1.	32
3.8. Matriz de transición.	33
4.1. Contexto de la prueba experimental.	41
4.2. Ejemplo de archivo json correspondiente a los datos del día lunes corres- pondiente a la primera semana de monitoreo.	43

4.3. Línea de tiempo del comportamiento.	44
4.4. Historial de trayectorias correspondiente al día lunes.	45
4.5. Historial de trayectorias correspondiente al día martes.	46
4.6. Historial de trayectorias correspondiente al día miércoles.	47
4.7. Historial de trayectorias correspondiente al día jueves.	48
4.8. Historial de trayectorias correspondiente al día viernes.	49
4.9. $X_1 = Kitchen$, porque la probabilidad máxima es 0.5968 que corresponde a la posición de la habitación <i>Kitchen</i>	65
4.10. $X_2 = Kitchen$, porque la probabilidad máxima es 0.3798 que corresponde a la posición de la habitación <i>Kitchen</i>	65
4.11. $X_3 = Bedroom$, porque la probabilidad máxima es 0.3071 que corresponde a la posición de la habitación <i>Bedroom</i>	66
4.12. $X_4 = Bedroom$, porque la probabilidad máxima es 0.6231 que corresponde a la posición de la habitación <i>Bedroom</i>	66
4.13. Pronóstico de trayectoria para los primeros cinco tiempos, en intervalos de 3 min, para el día lunes.	67
4.14. Trayectorias estimadas para el día lunes por habitación.	68
4.15. Trayectorias estimadas para el día martes por habitación.	69
4.16. Trayectorias estimadas para el día miércoles.	70
4.17. Trayectorias estimadas para el día jueves por habitación.	71
4.18. Trayectorias estimadas para el día viernes por habitación.	72
4.19. Trayectorias estimadas para el día lunes por habitación.	74
4.20. Historial de trayectorias correspondiente al día lunes.	75
4.21. Trayectorias estimadas para el día martes por habitación.	76
4.22. Historial de trayectorias correspondiente al día martes.	76
4.23. Trayectorias estimadas para el día miércoles por habitación.	77
4.24. Historial de trayectorias correspondiente al día miércoles.	78
4.25. Trayectorias estimadas para el día jueves por habitación.	79
4.26. Historial de trayectorias correspondiente al día jueves.	79
4.27. Trayectorias estimadas para el día viernes por habitación.	80
4.28. Historial de trayectorias correspondiente al día viernes.	81

4.29. Interfaz principal.	82
5.1. Diagrama de componentes: Inferencia del patrón de desplazamiento. . .	88

Índice de tablas

2.1. Tabla comparativa de los trabajos relacionados.	21
4.1. Relación entre las actividades y las habitaciones.	42
4.2. Ejemplo de los elementos registrados en la base de datos.	42
4.3. Mapeo de las habitaciones.	50
4.4. Mapeo de secuencia para la validación.	51
4.5. p-valores correspondientes a la prueba de bondad de ajuste.	52
4.6. Valor de la <i>etiWeek</i> según la semana.	55
4.7. Datos del archivo <i>Friday</i>	56
4.8. Matriz de intensidad para el día lunes.	58
4.9. Matriz de intensidad para el día martes.	58
4.10. Matriz de intensidad para el día miércoles.	58
4.11. Matriz de intensidad para el día jueves.	59
4.12. Matriz de intensidad para el día viernes.	59
4.13. Tiempo de permanencia esperado para el día lunes en minutos.	60
4.14. Tiempo de permanencia esperado para el día martes en minutos.	60
4.15. Tiempo de permanencia esperado para el día miércoles en minutos.	61
4.16. Tiempo de permanencia esperado para el día jueves en minutos.	61
4.17. Tiempo de permanencia esperado para el día viernes en minutos.	62

Capítulo 1

Introducción

En este capítulo, se presentan el contexto y la problemática que ataca en esta tesis y que motivaron a realizar este trabajo. Con base en lo anterior, se plantean los objetivos finales a conseguir. Igualmente, se mencionan las aportaciones del proyecto y la estructura que integra la tesis.

1.1. Preliminares

El envejecimiento del ser humano es un proceso irreversible que desencadena la aparición de impedimentos o limitaciones en habilidades y capacidades debido a los cambios físicos, psicológicos y sociales. Las limitaciones en las habilidades y capacidades se presentan en disminución o pérdida de la memoria, disminución de la sensibilidad, alteraciones motrices, lentitud al reaccionar a ciertas circunstancias, entre otros problemas [2]. Otro problema asociado al envejecimiento es el deterioro de la salud debido a la existencia de enfermedades como la diabetes, demencia, depresión, fatiga, entre otros [28].

Con relación al envejecimiento, existen varios estudios demográficos que demuestran el incremento de la población de la tercera edad y que establecen que un adulto mayor es un individuo a partir de los 60 años [28][18]. Por ejemplo, un análisis realizado por la Organización Mundial de la Salud (OMS) estima un incremento en la población de 900 millones hasta 2000 millones de personas entre el años de 2015 y 2050. Lo anterior

es debido a los avances de la medicina que han permitido que las personas tengan más años de vida [28]. Por otra parte, un análisis del Instituto Nacional de Estadística y Geografía (INEGI) muestra que en el censo de 1930, la población de adultos mayores era inferior a un millón de personas, pero en 2010, el censo registró 10.1 millones, que representó el 9% de la población en México de ese año [18].

Además, una parte de la población que llega a la vejez se encuentra trabajando o buscando trabajo. En septiembre del 2017, se reportó el porcentaje del 33.9% que corresponde a la población económicamente activa de adultos mayores; el 66.31% son adultos mayores no económicamente activos, de los cuales, el 54% se dedica a quehaceres del hogar [18].

Dentro de la población del adulto mayor en México, existe 1.6 millones que viven de manera independiente, es decir que habitan solos en su hogar [18]. La OMS señala que los entornos físicos y sociales son clave para que la persona pueda mantenerse saludable, independiente y autónomo, así pues, la vivienda debe ser un espacio adaptado a las necesidades del usuario [29].

En el contexto del hogar del adulto mayor independiente, es particularmente importante contar con plataformas que faciliten o adapten el ambiente a las necesidades con el objetivo de mejorar su calidad de vida. Es así como surge la Vida Asistida por el Entorno (*Ambient Assisted Living AAL*) que es un área de estudio que surgió con el propósito de ayudar a los usuarios en su vida diaria [30]. Para cumplir el objetivo de asistencia las plataformas *AAL* requieren de la detección de las actividades de la vida diaria. Por ejemplo, dormir, preparar el desayuno, ir al baño, entre otros [24].

Otro requerimiento importante, para las plataformas *ALL*, es la identificación del patrón de desplazamiento al interior del hogar. Por tal motivo, el presente trabajo tiene el propósito de identificar el patrón de desplazamiento entre habitaciones de un adulto mayor que vive de manera independiente. Al identificar el patrón de desplazamiento se puede preparar el entorno al cual se dirige. Por ejemplo, si se sabe que el adulto

mayor tiene una probabilidad de ir a la sala de 0.8 dado que se encuentra en la cocina, entonces se puede preparar el entorno de la sala como encender las luces, además, cuando el adulto mayor deja la cocina asegurarse que no existan riesgos como estufas encendidas, entre otros. La inferencia de patrón de desplazamiento a nivel habitación, con fundamento probabilístico, puede permitir que la asistencia automática en el hogar de los adultos mayores sea más eficiente, lo que posibilita al individuo tener una mejor calidad de vida.

Una posible solución para la inferencia del patrón de desplazamiento a nivel habitación es la implementación de procesos estocásticos [34][5], específicamente las cadenas de Markov en tiempo continuo [43].

1.2. Contexto y problemática

El contexto que se considera en este proyecto contempla a los adultos mayores que viven de manera independiente en su hogar y realizan sus actividades de la vida diaria (ADL) como son dormir, preparar el desayuno, ir al baño, entre otros [24] en diferentes habitaciones. En este contexto, se supone que los adultos mayores tienden a realizar sus actividades cotidianas con cierta rutina, es decir, normalmente realizan una actividad en un lugar, hora, duración y fecha específicos. Por ejemplo: un adulto mayor normalmente se baña, en el baño, a las 2 PM durante 20 minutos de lunes a domingo. Así mismo, mira la televisión en la recámara por 20 minutos de lunes a viernes. De esta manera, al observar la rutina de actividades, se puede obtener el patrón de desplazamiento entre habitaciones del individuo. El contexto del proyecto queda ejemplificado en la Fig. 1.1, en la que se muestra al adulto mayor realizando sus actividades en diferentes lugares del hogar y durante un determinado lapso de tiempo.

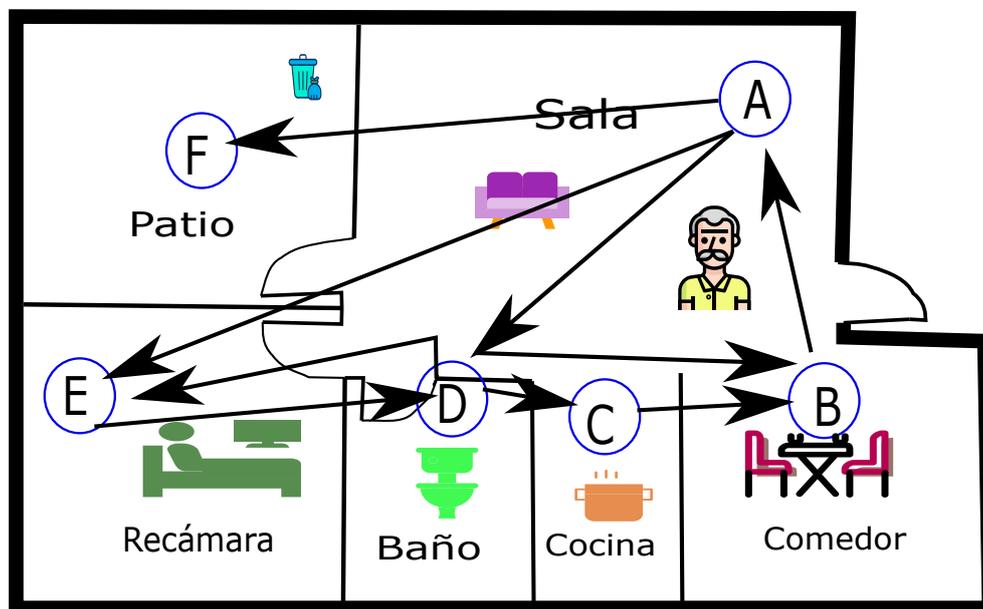


Figura 1.1: Desplazamiento del adulto mayor al realizar sus actividades

Como resultado de observar los movimientos del adulto mayor en su hogar durante un lapso de tiempo, es posible obtener su patrón de desplazamiento entre habitaciones. Dicho patrón puede ser utilizado para facilitar la asistencia al usuario; ya que, si se

conoce con anticipación hacia dónde se desplazará el usuario, entonces se pueden tomar decisiones o acciones de asistencia de acuerdo a su entorno o actividades. Por ejemplo: si el adulto mayor se encuentra en la cocina y, se calcula que hay una alta probabilidad de que posteriormente el individuo se desplace al cuarto, entonces se puede encender el sistema de ventilación de la habitación, encender las luces, entre otros; así como apagar los aparatos electrodomésticos en la cocina, con el objetivo de evitar accidentes. Así pues, el reconocimiento del patrón de desplazamiento entre habitaciones puede mejorar la calidad de vida del adulto mayor al preparar con anticipación el entorno.

Ahora bien, un patrón de desplazamiento entre habitaciones se puede representar por medio de un grafo dirigido o digrafo. En la Fig. 1.2 se muestra cómo representar el contexto o ambiente del usuario anteriormente mencionado, en la Fig. 1.1, mediante un grafo dirigido. En el grafo dirigido las habitaciones del hogar son representados por los vértices del grafo y las aristas indican la dirección del desplazamiento del adulto mayor.

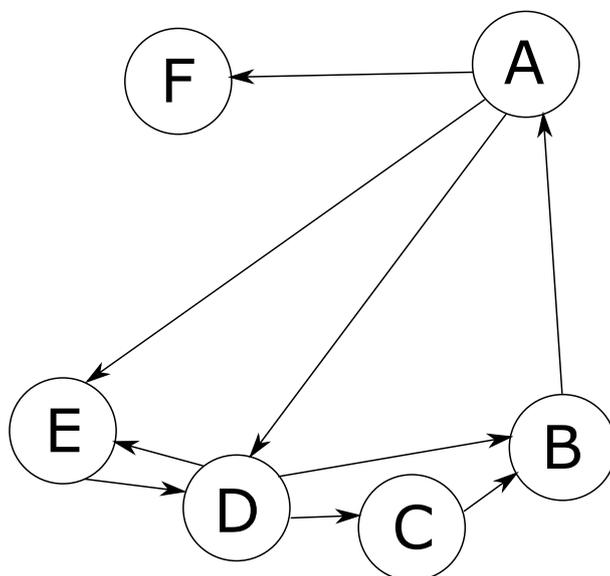


Figura 1.2: Grafo de movimientos del contexto de la Figura 1.1

Otro aspecto que se considera en este trabajo, es que el usuario suele moverse de una habitación a otra. Así que, para representar la frecuencia de desplazamiento del usuario de una habitación A a una habitación B se asigna una etiqueta de frecuencia a

la arista, es decir, la cantidad de veces que el individuo va de la habitación A a la B en un lapso de tiempo determinado de observación. Un lapso de tiempo determinado puede considerarse como horas, días, meses o años de observación. Por ejemplo, en la Fig. 1.3 se presenta el patrón de desplazamiento entre habitaciones de un usuario en un día, y se puede observar que el individuo se desplaza 15 veces de la habitación A a la D en ese lapso de tiempo. Al representar las habitación con vértices y el desplazamiento con las aristas, entonces se puede representar el patrón de desplazamiento entre habitaciones del usuario usando el grafo $G=(V,E)$ donde V es el conjunto de vértices, E es un conjunto de aristas que son pares ordenados de los elementos de V .

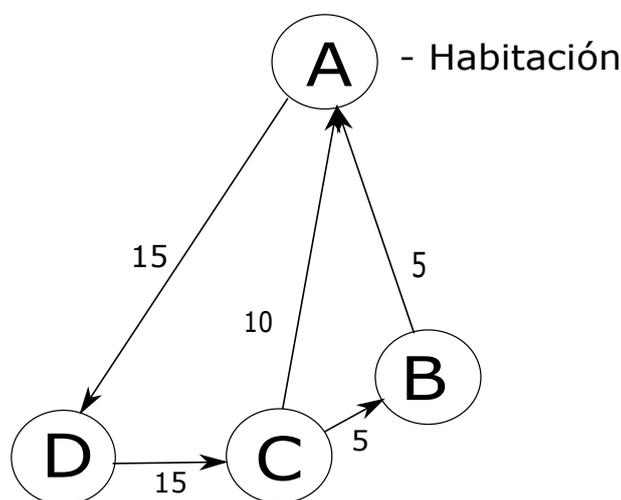


Figura 1.3: Patrón de desplazamiento entre habitaciones en un día con frecuencias

Teniendo el grafo de desplazamiento entre habitaciones con sus respectivas etiquetas de frecuencia, entonces nos preguntamos cómo calcular la probabilidad de que el usuario se desplace de la habitación A hacia la B, es decir la $P(B|A)$ si $\exists E(A,B)$. Así, al conocer la probabilidad del desplazamiento entre habitaciones se tiene una mayor certeza en la toma de decisiones al proveer una asistencia por parte del ambiente. Por ejemplo, en la Fig. 1.4, se representa una situación en donde el adulto mayor se encuentra en la habitación C y el grafo de desplazamiento muestra que puede ir a la habitación A ó B, pero se tiene que la probabilidad de ir de la habitación A dado que está en habitación C ($P(A|C)$) es 0.8 y la probabilidad que el usuario se desplace a la habitación B dado que se encuentra en C ($P(B|C)$) es 0.2, con base en este conocimiento, se puede anticipar la asistencia al usuario adecuando la habitación A. Una posible solución, para calcular

las probabilidades de desplazamiento entre habitaciones con fundamento probabilístico, son los procesos estocásticos [34][5], específicamente con cadenas de Markov [14][22][43].

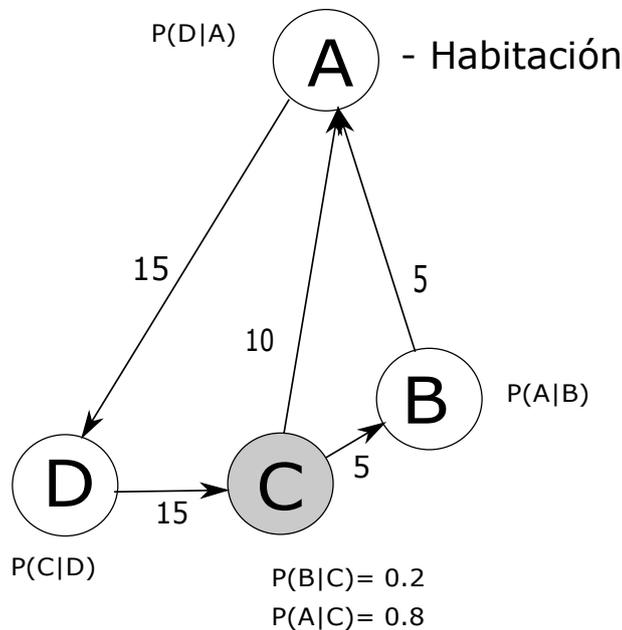


Figura 1.4: Grafo de desplazamiento entre habitaciones en un día con probabilidades

Por otro lado, conforme incrementa el tiempo de estar observando los desplazamientos del usuario, se obtiene mayor información; como por ejemplo, el apareamiento de nuevos nodos (habitaciones) que el usuario no había visitado; se actualizan las frecuencias de desplazamiento, lo que provoca cambios en las probabilidades de desplazamiento entre habitaciones. Por ejemplo: la Fig. 1.5 representa el patrón de desplazamiento en un periodo de un mes de observación, en donde, se muestra la aparición de la habitación F, así como el cambio de las frecuencias y las probabilidades de desplazamiento en comparación con la Fig. 1.4 del patrón de desplazamiento entre habitaciones de un día.

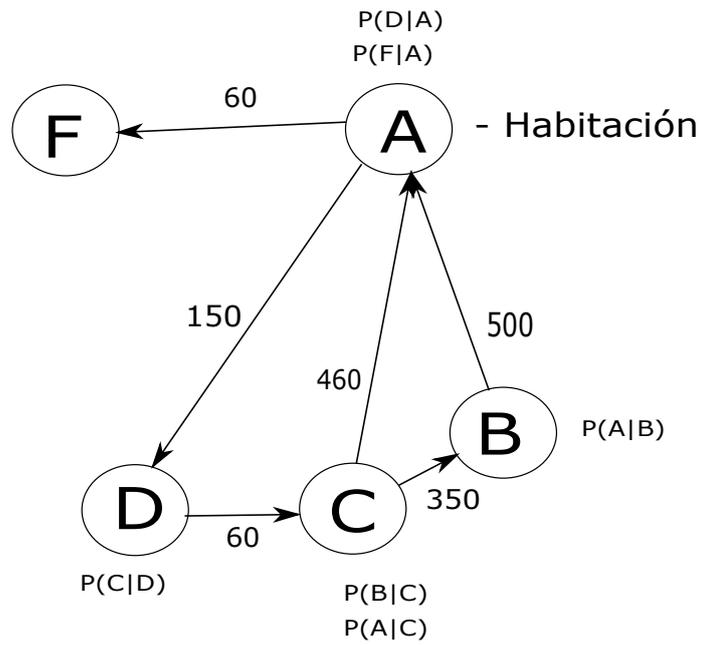


Figura 1.5: Patrón de desplazamiento entre habitaciones de un mes

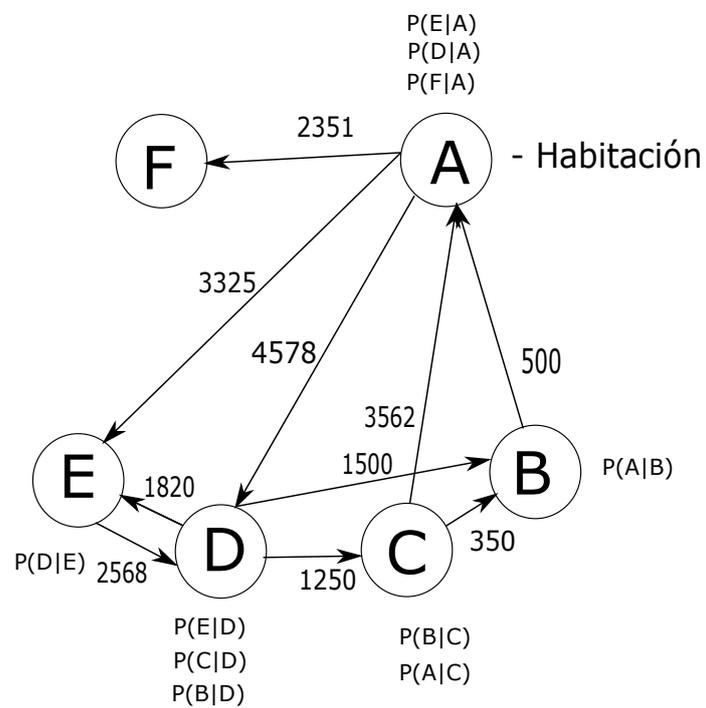


Figura 1.6: Patrón de desplazamiento entre habitaciones de un año

En resumen, en este proyecto, se considera a una persona que vive de manera autónoma. Al realizar sus actividades, el usuario se desplaza entre las habitaciones de su hogar generando una rutina. Además, se sabe que el individuo se desplaza cierta cantidad de veces entre las habitaciones que es considerada como la frecuencia de desplazamiento. Así, se puede tener mayor certeza al momento de adecuar el entorno del usuario debido a que se conocen las probabilidades de desplazamiento entre las habitaciones. Por lo tanto, se propone una solución basada en la implementación de procesos estocásticos [34][5], específicamente la utilización de cadenas de Markov en tiempo continuo [43]. Dicha solución se explica con más detalle en los siguientes capítulos.

1.3. Objetivo

Con base en la problemática presentada se establecen el objetivo general y los objetivos específicos.

1.3.1. Objetivo general

Seleccionar, estimar, validar un modelo probabilístico e implementarlo computacionalmente para inferir el patrón de desplazamiento entre habitaciones del adulto mayor en su hogar.

1.3.2. Objetivos específicos

- Seleccionar el modelo probabilístico que infiera el patrón de desplazamiento entre habitaciones.

Examinar el estado del arte para conocer propuestas implementadas en otros trabajos con el objetivo de determinar el modelo que se ajuste a la problemática de la tesis.

- Recopilar datos y estimar los parámetros.

Monitorear y registrar los desplazamientos de una persona en su vida cotidiana al interior de su hogar. Los datos recopilados son implementados como datos de entrada para el algoritmo que estima los parámetros del modelo probabilístico.

- Implementar en computadora el modelo probabilístico.
Codificar el algoritmo que permite modelar el desplazamiento del adulto mayor en su hogar.
- Evaluar el funcionamiento del modelo probabilístico.
Comparar la trayectoria inferida con el historial del desplazamiento con el objetivo de visualizar la trayectoria inferida en algún momento de la historia.
- Validar el modelo probabilístico.
Aplicar algoritmos para verificar las propiedades requeridas por el modelo implementado para la inferencia del patrón de desplazamiento.

1.4. Contribuciones

En el proyecto de tesis se desarrolló una plataforma que permite inferir probabilísticamente el patrón de desplazamiento entre habitaciones del adulto mayor en el interior de su hogar, particularmente a los que viven de manera independiente, es decir, que aún pueden realizar sus actividades por sí solos y sin la necesidad de ser cuidados por terceras personas en el interior de su hogar.

Las prueba de la propuesta del proyecto de tesis se realizó por medio de una prueba de concepto (*proof of concept*), y la recolección de datos se realizó con la aplicación en [7]. Dicha aplicación requiere del uso de un smarphone durante el tiempo requerido, lo cuál suele ser incómodo para el adulto mayor.

El proyecto de tesis proporciona el desarrollo de un módulo para inferir el patrón de desplazamiento a nivel habitación que incluye:

- Un modelo probabilístico basado en cadena de Markov en tiempo continuo.
- El algoritmo que permite calcular una aproximación numérica de los parámetros del modelo.

CAPÍTULO 1. INTRODUCCIÓN

- La verificación de la propiedad de Markov con la prueba de *Bondad de ajuste*
- La visualización del patrón de desplazamiento por medio de una interfaz gráfica.

1.5. Estructura de tesis

En el capítulo 2, se describen los trabajos previos relacionados con la detección de actividades y los sistemas de asistencia en el hogar, así como los métodos de aprendizaje para el reconocimiento de patrones, principalmente los métodos probabilísticos para el análisis del comportamiento en el interior del hogar.

En el capítulo 3, se presentan las aportaciones del proyecto de tesis, que consta de una explicación sobre el funcionamiento de la arquitectura, el modelo probabilístico con la inclusión de los algoritmos implementados para la aproximación numérica de los parámetros y la correspondiente validación del modelo.

En el capítulo 4, se describe las diferentes etapas involucradas para lograr la obtención del patrón de desplazamiento a nivel habitacional. Entre esas fases se encuentra el método llevado a cabo para la obtención de los datos, el debido preprocesamiento de los datos para ser utilizados por el modelo probabilístico, los resultados de las validaciones; y por último, la representación de manera gráfica de las trayectorias de desplazamiento estimadas.

En el capítulo 5, se plantean las conclusiones del proyecto, así como el cumplimiento de los objetivos planteados durante el proyecto de tesis y; al final, las propuestas de trabajo a futuro.

Capítulo 2

Estado del arte

En este capítulo, se describen las herramientas empleadas para el reconocimiento de actividades y, también los algoritmos implementados para la detección de patrones que genera un adulto mayor al moverse en el interior de su hogar, específicamente, se mencionan algoritmos de aprendizaje no supervisado, métodos probabilísticos, entre otros.

2.1. Sistemas de asistencia al interior del hogar

La AAL ha sido área de investigación muy activa en los últimos años. Entre las acciones que se implementan existen programas encargados de desarrollar productos, servicios y sistemas innovadores que contemplen la mejora en la calidad de vida en el hogar, en la comunidad y en el trabajo, que permitan al usuario participar en la vida social e igualmente reducir los costos de salud y asistencia social [23].

Una alternativa, en cuanto al desarrollo de sistemas inteligentes para el hogar, se encuentra la casa inteligente (*Smart home*) la cual es bien aceptadas por los adultos de la tercera edad. Para el mejoramiento de estos sistemas, se han diseñado diferentes combinaciones entre tecnologías, herramientas y técnicas para mejorar la vida asistida por el entorno. También, se han implementado tecnologías que permiten reconocer el estado físico del usuario como la temperatura y la presión arterial; con esa información

los sistemas pueden ser más eficientes si el usuario realiza una actividad física o se encuentra en una situación de peligro. Al conocer dicha información se puede asistir al individuo, por ejemplo, al estar en una situación de peligro se avisa algún familiar o cuidador [30] [40] [38].

Por otro lado, para lograr una asistencia adecuada por parte del ambiente en un hogar inteligente, se requiere saber qué actividad realiza el usuario, para este caso, existen diversos trabajos que han desarrollado alternativas no intrusivas para recolectar dicha información. Estas alternativas se enfocan en avances tecnológicos como el uso de teléfonos inteligentes o guantes en combinación con sensores, para lograr que permanezca la privacidad y seguridad del usuario, con eso se evita el uso de cámaras [7][17] [10].

Uno de los trabajos relacionados con el reconocimiento de actividades es la plataforma OPAIEH. Esta plataforma implementa el método de ontologías, y como segunda opción, redes neuronales. Dicha plataforma estaba al alcance del proyecto y con la estructura que posee fué una opción para la obtención de los datos del proyecto de esta tesis. En la Fig. 2.1 se muestra la arquitectura general para el reconocimiento de la actividad de la plataforma OPAIEH.

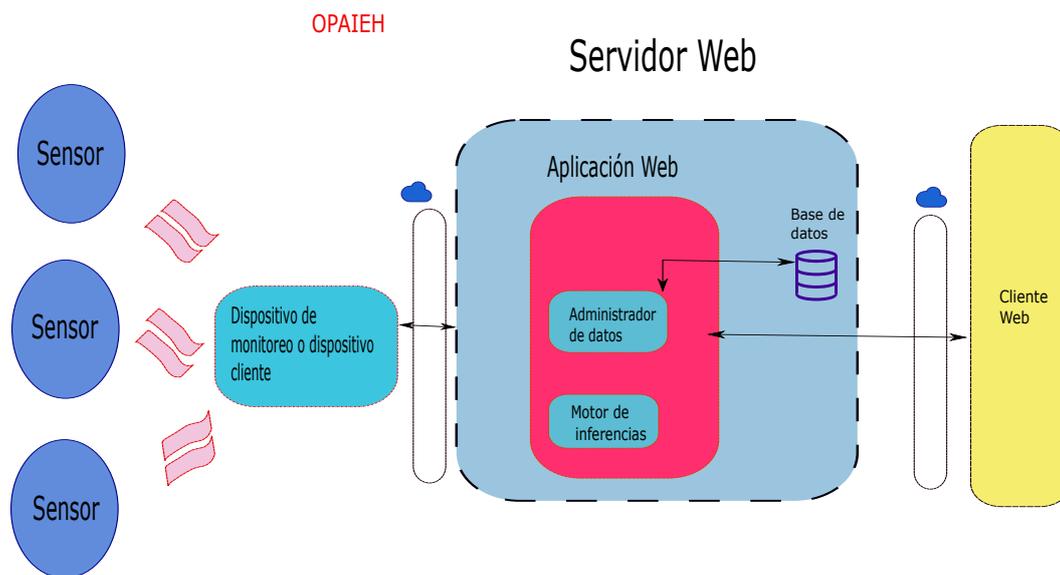


Figura 2.1: Arquitectura general de la plataforma OPAIEH para el reconocimiento de actividades en el interior del hogar.

Dicha plataforma consta de sensores con tecnología bluetooth que son instalados en las habitaciones. Además, contiene una aplicación para sistemas Android que permite recibir información de los sensores y procesarla para ser enviada al Servidor web. El Servidor web se encarga de procesar la información para inferir la actividad, y posteriormente almacenarla en la base de datos. Por otra parte, el Cliente web se encarga de proveer información de manera visual para el análisis de las actividades del usuario.

Por otro lado, también se necesita conocer en qué parte del hogar se realiza determinada actividad, por ejemplo, la actividad cocinar se lleva a cabo en la cocina. Al conocer las habitaciones en las cuales se realizan las actividades, se puede deducir el patrón de desplazamiento cuando el usuario abandona una habitación para ir a otra.

En la siguiente sección, se analizan algunos de los métodos implementados para el modelado del comportamiento en el interior del hogar.

2.1.1. Métodos implementados para la asistencia en hogares inteligentes

Para el proceso de aprendizaje de las actividades y el comportamiento de las personas en un entorno inteligente, se han implementado diferentes métodos para optimizar dichos procesos. A continuación, se mencionan los métodos más comunes dedicados a cumplir el aprendizaje de actividades o el comportamiento (ver Fig. 2.2):

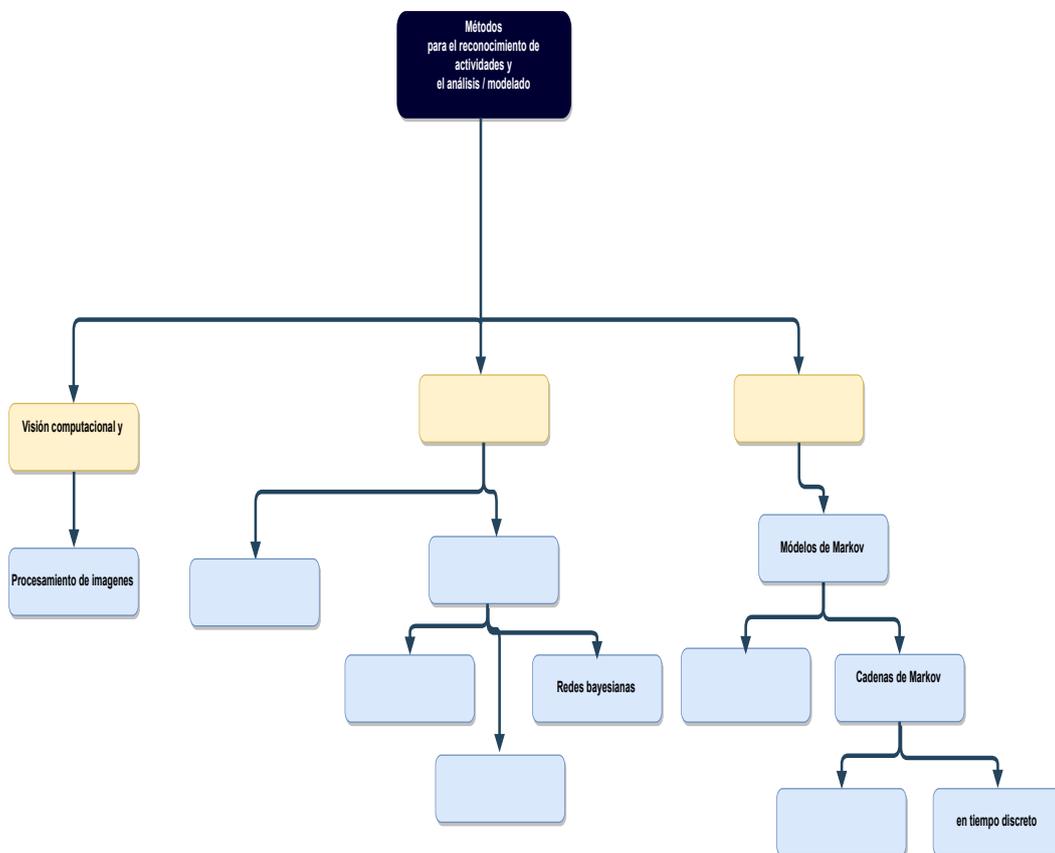


Figura 2.2: Análisis de métodos de aprendizaje

La visión por computadora en casas inteligentes tiene un rol importante en la construcción de modelos predictivos de actividades y el comportamiento humano. Lo anterior se puede obtener con la implementación de sensores instalados en las casas inteligentes, con el propósito de que el entorno sea consciente de las actividades que se realizan en el hogar por el usuario [25] [20]. Por ejemplo, la implementación de identificación biométrica construida por técnicas de reconocimiento de patrones para identificar a las personas por sus características fisiológicas. La visión computacional puede incluir técnicas como el aprendizaje automático para el reconocimiento de las actividades al momento de rastrear la silueta de una persona [21]. Por otro lado, el procesamiento de imágenes involucra algoritmos matemáticos para el procesamiento de imágenes obtenidas por medio de cámaras con el objetivo del reconocimiento. Por ejemplo, la asistencia de pausar una película cuando la persona abandona el sofá implica el procesamiento de imágenes [20].

La inteligencia artificial se relaciona con procesos que incluye el razonamiento en la toma de decisiones [1] [37]. Los agentes inteligentes son módulos o dispositivos que perciben los sucesos de su entorno y actúan sobre el medio ambiente por medio de efectores. Los agentes inteligentes involucran la detección, toma de decisión, acciones por medio de la red informática y las bases de datos. Por ejemplo, un sistema basado en multiagentes para rastrear al usuario en una casa inteligente, la cual se pudo adaptar a los cambios de patrones de una persona y también en la actualización automática del modelo para reflejar los cambios [35]. En cuanto al aprendizaje automático, se limitan los esfuerzos para la programación detallada, la computadora aprende con base a la experiencia [39]. Los algoritmos de redes neuronales (*ANN*) son especialmente aplicados en el procesamiento de imágenes, clasificación y reconocimiento de imágenes [26][11]. Pero en las casas inteligentes, las *ANN* son implementadas para aprender el hábito de los usuarios, dependiendo de un número de variable como parámetros [9]. Por otro lado, las redes bayesianas son un modelo gráfico probabilístico que permite representar un conjunto de variables aleatorias y sus dependencias condicionales. Por ejemplo, en [31] implementan redes bayesianas para el aprendizaje automático para predecir la secuencia de habitaciones, la duración de estancia y el momento en que

ingresa a la habitación. Además, en [15] utilizan las redes bayesianas para predecir los patrones de comportamiento de la persona basado en sensores multimodales. En cuanto a *SVM* (Máquina de vectores de soporte) son algoritmos que aprenden por medio de ejemplos para clasificar objetos. En el caso, de casas inteligentes, se ha implementado para monitorear al adulto mayor con el propósito de detectar la pérdida de autonomía.

Por otro lado, se han estudiado modelos probabilísticos para la asistencia [6], por ejemplo: el modelo de Markov que es un proceso estocástico que permite modelar sistemas que cambian de manera aleatoria específicamente que dependen del tiempo. Los modelos de Markov se han implementado para diferentes circunstancias en las casas inteligentes. Por ejemplo, en [6] se utilizaron datos extraídos por cámaras y sensores de audio, que posteriormente sirvieron como datos de entrada para el modelo de Markov para el reconocimiento del comportamiento del usuario, y en [16] se desarrolló un sistema de asistencia para el proceso de lavado de manos. Adicionalmente, los modelos ocultos de markov (*HMM*) son utilizados para modelar datos de series de tiempo. Usualmente conocidas como una subclase de las redes bayesianas como redes dinámicas bayesianas. Son implementadas en sistemas de reconocimiento de voz, biología molecular computacional, reconocimiento de patrones [13]. En el caso particular de las casas inteligentes, se han enfocado en el reconocimiento de las actividades y el reconocimiento de actividades intercaladas [12] [19].

En la siguiente sección, se analizan más a detalle los modelos probabilísticos para el análisis del comportamiento en el hogar.

2.1.2. Métodos probabilísticos para el tracking en el hogar

Actualmente, ha incrementado el interés por el reconocimiento automático de rutinas diarias en el hogar. Los modelos implementados se basan en aprendizaje no supervisado y supervisado, por ejemplo, los modelos ocultos de Markov, redes neuronales, entre otros. Los modelos supervisados requieren datos preseleccionados y etiquetados manualmente, un inconveniente es la necesidad de un número suficiente de datos para obtener resultados satisfactorios. Lo anterior, hace que los métodos supervisados tengan una limitante, en cuanto a la cantidad de datos, en comparación con los modelos no supervisados [40] [43].

Además, el seguimiento del desplazamiento (*tracking*) en el hogar se ha utilizado para modelar el comportamiento de las personas con el objetivo de proveer asistencia. La asistencia se puede realizar a través de la adecuación de la habitación o el facilitar la realización de alguna actividad. En algunas ocasiones, se ha implementa para modelar el comportamiento y descubrir situaciones irregulares [43] [44].

A continuación se describen trabajos que estudian el comportamiento humano con modelos probabilísticos:

En [43] se presenta una arquitectura para el reconocimiento de patrones. Para la inferencia del patrón se implementa el modelo de cadenas de Markov en un conjunto de datos pertenecientes a una persona de 79 años. Los datos son obtenidos por medio de sensores. Además, los datos son divididos en 24 intervalos de tiempo. Al final, se obtienen 4 patrones correspondientes a los intervalos de tiempo de 12 a 6 am, de 8 a 10 am, 14 a 18 pm y, por último, de 18 a 20 pm. Este proyecto no menciona la razón por la cual no aparecen periodos de tiempo, así como, si antes de llevar el experimento se efectuó la verificación de la propiedad de Markov. De igual manera, no dice si los lapsos de tiempos a considerar son homogéneos.

En [44] se describe un sistema inteligente distribuido basado en agentes. El agente es una entidad computacional autónoma que percibe su entorno a través de sensores y

actúa sobre su entorno. Cada agente debe conocer a sus vecinos con el propósito de obtener un modelo de datos globales. El agente genera y mantiene su matriz de transición que contiene los vecinos agentes y las probabilidades de transición. Las probabilidades de transición son obtenidas por medio de cadenas de Markov, con las probabilidades de transición el agente puede predecir la próxima ubicación de una persona al seleccionar a agente vecino con la probabilidad más alta, con base a esta predicción, las acciones se pueden activar con anticipación. Se implementa un algoritmo de agrupamiento para identificar los patrones de comportamiento de los residentes. Este proyecto no menciona, en ningún momento, si se realiza la verificación correspondiente a la propiedad de Markov. También, no se encontró nada relacionado con la propiedad de homogeneidad.

En [42] se enfocan en construir el modelo de actividades para observar y analizar el comportamiento de la persona, principalmente para encontrar comportamientos irregulares. Lo anterior se logra al implementar la combinación del modelo oculto de Markov (HMM), el algoritmo *forward* y el algoritmo *Viterbi* para construir y analizar el modelo de actividades diarias de la persona. Se instala una red de sensores para observar a fondo las actividades y el comportamiento del usuario. En el caso del modelo oculto de Markov, realizan la partición del día en periodos de 30 minutos así obtienen 48 estados por día; los estados de observación son 0 o 1 que significa presencia o ausencia; y las correspondientes probabilidades de transición de estados y la matriz de distribución de emisión de estado. La prueba se realiza con los datos obtenidos de un sensor instalado en una sala de estar por la recopilación de 15 días. El modelo de Markov oculto sirve para calcular la probabilidad en las secuencias de observaciones. El algoritmo de Viterbi obtiene las mejores secuencias que se adaptan a las secuencias de observación, para poder decir si es una actividad regular o no.

En [36] presentan un enfoque automatizado para descubrir y dar seguimiento al patrón de actividades. En este proyecto, se emplean sensores de movimiento y magnéticos para puertas. Para tener el seguimiento de las actividades implementan el modelo oculto de Markov, en este caso como parámetros se tienen como estados ocultos las actividades, las etiquetas de los sensores son los estados observables, la matriz de pro-

babilidad de transición entre actividades y la matriz de emisión del estado observable dado el estado actual. Además, implementan un algoritmo de agrupamiento aglomerativo para agrupar las actividades descubiertas. También, proporcionan un componente para visualizar el patrón de seguimiento de actividades y sus diferentes derivaciones. El enfoque se pone a prueba con datos obtenidos de 2 apartamentos en un periodo de 3 meses, los datos utilizados provienen de una persona de 92 años y una de 80 años.

A continuación, se muestra en la tabla 2.1 una comparación entre los trabajos relacionados con el proyecto presentado:

Nombre del proyecto	Implementación de cadena de Markov	Verificación de la propiedad de Markov	Pronóstico de la trayectoria	Visualización de la trayectoria	Implementación de HMM
Unsupervised daily routine and activity Discovery in Smart homes [43]	X				
Distributed agent system for behavior pattern recognition [44]	X				
Data analyzing and daily activity learning with hidden Markov model [42]					X
COM: A Method for mining and monitoring human activity patterns in home-based health monitoring systems [36]					X
Modelo probabilístico para la inferencia del patrón de desplazamiento del adulto mayor en la vida asistida por su entorno	X	X	X	X	

Tabla 2.1: Tabla comparativa de los trabajos relacionados.

Capítulo 3

Contribución de la tesis

En este capítulo, se describe la arquitectura general del proyecto y las partes que conforman el módulo que permite inferir el patrón de desplazamiento.

3.1. Plataforma del modelo probabilístico

3.1.1. Estructura de la arquitectura

La arquitectura general de la plataforma (Fig. 3.1) está compuesta por dos secciones: la primera denominada *inferencia de actividades* y la segunda nombrada como *inferencia del patrón de desplazamiento*. La fusión, de dichas secciones logran los siguientes objetivos:

- El reconocimiento de las actividades que realiza un adulto mayor en su hogar, previamente desarrollado en otro proyecto de tesis [8].
- Pronosticar el patrón de desplazamiento a nivel habitación.

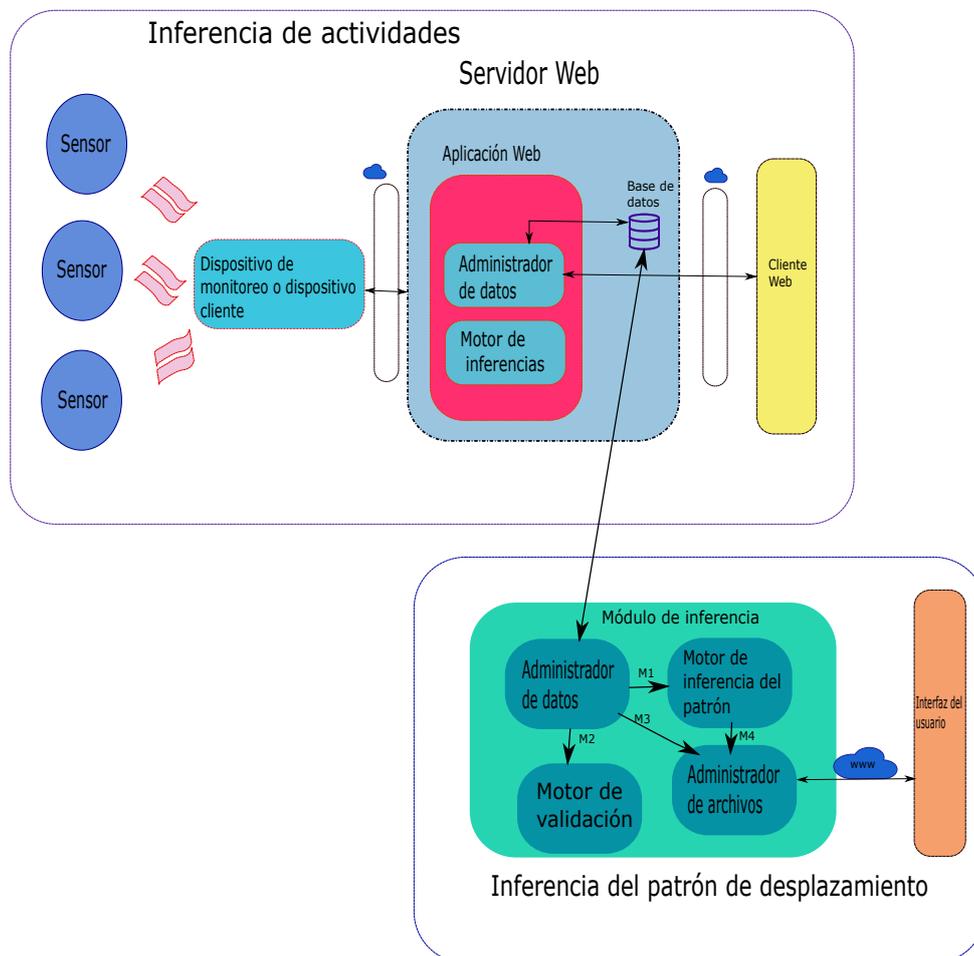


Figura 3.1: Arquitectura general para la estimación del patrón de desplazamiento a nivel habitación en el interior del hogar.

La sección de *inferencia de actividades* corresponde al desarrollo de una plataforma que permite el reconocimiento de las actividades en el interior del hogar destinado a los adultos mayores [8]. Dicha plataforma utiliza sensores para realizar el monitoreo de manera no invasiva para una mayor seguridad en la privacidad del usuario. Cuenta con un dispositivo de monitoreo, que consta de una aplicación desarrollada para sistemas Android. Además, contiene un servidor Web que se encarga de la inferencia de la actividad por medio de la implementación de ontologías y un cliente Web que permite visualizar un análisis de las actividades que se realizan al interior del hogar.

La sección de *inferencia del patrón de desplazamiento* contiene los siguiente módulos,

los cuales son desarrollados en esta tesis:

El **Administrador de datos** es el módulo encargado de:

- Obtener la información de la base de datos proveniente de la sección de inferencia de actividades. La información se obtiene con las siguientes atributos: *No*, *Date*, *Room*, *Duration*, *Inferred_activity*, *List_activity*, *User_activity*, *DateFinal*, *Day*.
- Procesar la información seleccionada en formato JSON para ser enviada como mensaje (M3) considerando los valores de las etiquetas *Room*, *Date* y *DateFinal*.
- Separar la información por día de monitoreo y generar los archivos correspondientes para el módulo de motor de validación, es decir contemplar solamente los valores de *Room* que representa al mensaje M2.
- Enviar la información en el mensaje M1 con el contenido *Room*, *Date*, *Duration*, *DateFinal* al módulo motor de inferencia del patrón.

El **Motor de inferencia del patrón** es el módulo encargado de:

- Recibir el contenido de M1 y los utiliza para inferir el patrón de desplazamiento con la estimación de parámetros del modelo probabilístico.
- Generar los archivos del mensaje M4 para ser enviados al administrador de archivos. Los archivos del mensaje M4 constan de las estimaciones de los patrones en formato JSON con las etiquetas: *Room*, *Date* y *DateFinal*.

El **Motor de validación** es el módulo encargado de:

- Recibir la información proveniente del administrador de datos en el M2 y son utilizados para realizar la correspondencia con la propiedad de Markov. Además, validar que la cadena de Markov sea homogénea.

El **Administrador de archivos** es el módulo encargado de:

- Gestionar la información recibida del administrador de datos y el motor de inferencia del patrón, correspondientes al mensaje M3 y M1. El contenido de M3 es el historial de trayectorias almacenadas en la base de datos y M1 almacena las trayectorias estimadas por el modelo probabilístico. Además, cuando recibe una solicitud, del interfaz del usuario, envía la información solicitada. Es decir, si la interfaz de usuario desea la información del día lunes, entonces el administrador de archivo envía los datos correspondientes al día solicitado.

Interfaz del usuario :

Este módulo permite visualizar las trayectorias de desplazamiento almacenadas en la base de datos durante el tiempo de observación del adulto mayor en su hogar; para presentar dicha información requiere de los archivos que son gestionados por el administrador de archivo. Con base en esta información, se pretende visualizar el registro de los desplazamientos almacenados y los posibles cambios de desplazamiento que puede realizar el adulto mayor en su hogar.

La interfaz implementada para la visualización de los patrones se muestra en la Fig. 3.2, en el cual se puede seleccionar el día para visualizar la información deseada. La interfaz consta de dos apartados; el primero, denominado *History* presenta las trayectorias almacenadas en la base de datos; el segundo, denominado *Inference* que exhibe los patrones pronosticados iniciando en las diferentes habitaciones.

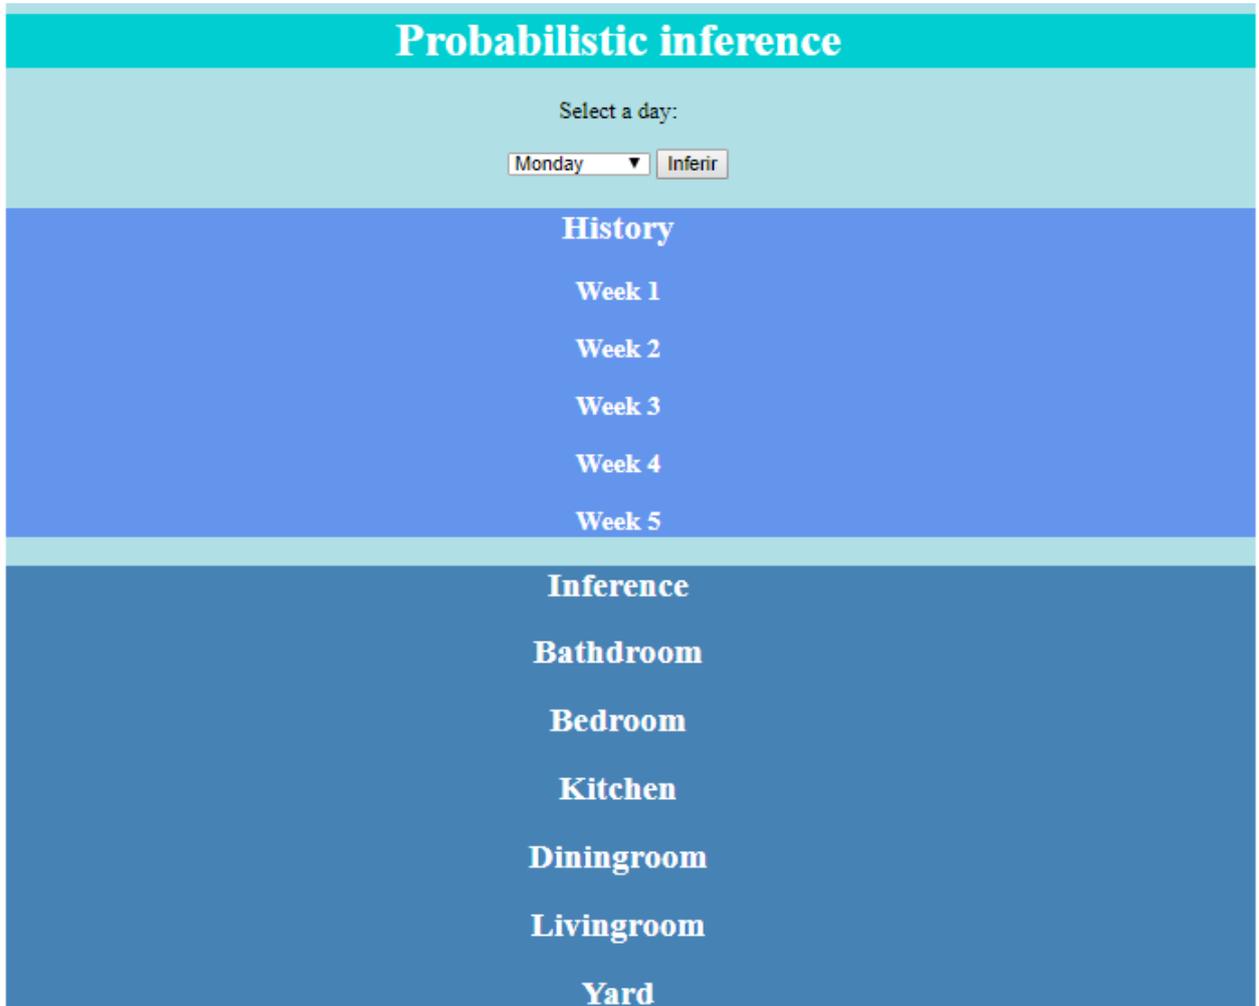


Figura 3.2: Estructura de la interfaz.

3.2. Modelo probabilístico

Los procesos estocásticos permiten el estudio de variables aleatorias que dependen del tiempo. En el caso de la tesis, se requiere de una variable que modele el comportamiento de un individuo con el paso del tiempo en su hogar. A continuación, se mencionan los conceptos relacionados con el tema a tratar [14] [41].

3.2.1. Procesos Estocásticos

Un proceso estocástico se define como [14]:

Proceso estocástico

Un proceso estocástico o aleatorio es una colección de variables aleatorias indexadas por un conjunto T al que se le denomina tiempo, es decir, $X = \{X_t : t \in T\}$ con cada $X_t : \Omega \rightarrow \mathfrak{R}$ es variable aleatoria.

Los procesos estocásticos se clasifican según el tipo del conjunto T [32]:

Clasificación de acuerdo al tiempo T

Si T es discreto se llama **proceso estocástico en tiempo discreto**.

Si T es continuo se denomina **proceso estocástico en tiempo continuo**

De acuerdo a las variables aleatorias X_t los procesos estocásticos se clasifican como sigue:

Clasificación de acuerdo a los estados de X_t

Para cada $t \in T$, se tiene una variable aleatoria $X_t : \Omega \rightarrow \mathfrak{R}$. Cuando X_t es discreta $\forall t \in T$, el proceso se llama *cadena* y se dice que el proceso tiene espacio de estados discreto. Cuando X_t es continua, el espacio de estados es continuo.

En este trabajo, el modelo que se propone es una cadena de Markov a tiempo continuo, ya que el conjunto de valores que toman las variables aleatorias son los distintos espacios de la casa, como se describe a continuación.

El conjunto de posibles valores que puede tomar X_t se denomina *espacio de estados de la cadena*. Por ejemplo, en la Fig. 3.3 se define la habitación en donde se encuentra la persona en su hogar y, solamente puede ser uno de los 4 estados **A,B,C,D**.

$$S = \{ A, B, C, D \}$$

Figura 3.3: S es el espacio de estados, y los valores A,B,D,C representan las habitaciones.

3.2.2. Cadenas de Markov

Entre todas las cadenas, en este trabajo, se utilizará la cadena de Markov. La cadena de Markov se divide, dependiendo del conjunto T , en tiempo discreto o continuo[41]:

Cadena de Markov en tiempo discreto

Una cadena de Markov de tiempo discreto $\{X_n \mid n = 0, 1, 2, \dots\}$ es una secuencia de variables aleatorias discretas, tal que, dada X_0, \dots, X_n , la variable aleatoria X_{n+1} depende solamente de X_n [41].

Cadena de Markov en tiempo continuo

Una cadena de Markov en tiempo continuo (CTMC) es un proceso estocástico $X_t : t \geq 0$ tal que $\forall t \geq 0, s \geq 0$, y estados $i, j \in S$. Se satisface la propiedad de Markov [27]:

$$P[X_{s+t} = j \mid X_s = i; X_\mu : 0 \leq \mu < s] = P[X_{s+t} = j \mid X_s = i], \quad (3.1)$$

La ecuación 3.1 se conoce como la propiedad de Markov. Dicha propiedad, considera la pérdida de memoria, es decir, solo se necesita conocer el estado actual para determinar la probabilidad de los n pasos siguientes, en donde $n \geq 1$. Es decir, que el futuro y el pasado son condicionalmente independiente dado el presente [14]. Por ejemplo, en la Fig. 3.4 se muestra el historial de desplazamiento, en el cual la persona ha visitado las habitaciones de su hogar; primero, fue a la habitación A, después se desplazó a B y; ahora se encuentra en D, para tomar la decisión para ir a C solamente

considera la habitación en la cual se encuentra, es decir, D. No le interesa el historial de desplazamiento entre las habitaciones que ya ha visitado anteriormente. Por lo cual, el comportamiento del desplazamiento satisface la propiedad de Markov antes mencionada.

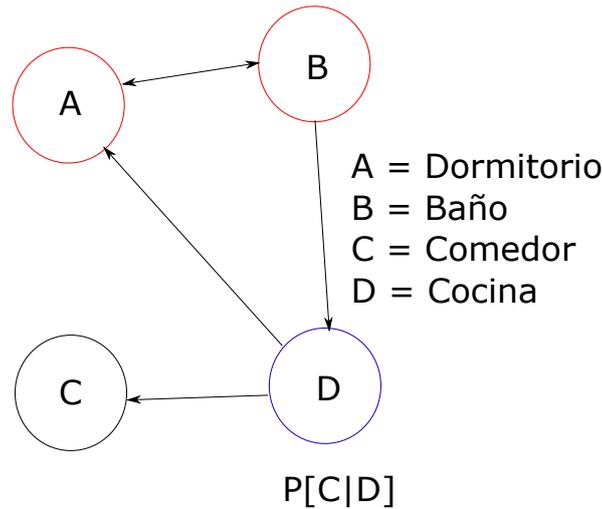


Figura 3.4: Patrón de desplazamiento de un adulto mayor en su hogar.

A continuación, se presentan dos trayectorias muestrales de una cadena de Markov en tiempo discreto y continuo. En la Fig. 3.5 se observa un ejemplo de cadena de Markov en tiempo discreto contrastado con la Fig. 3.6 de tiempo continuo que en todo momento se conoce el estado del proceso, es decir, que el proceso continúa en ese estado (raya continua) y los tiempos t_i son los tiempos de cambio de estado o saltos que se pueden dar en cualquier instante.

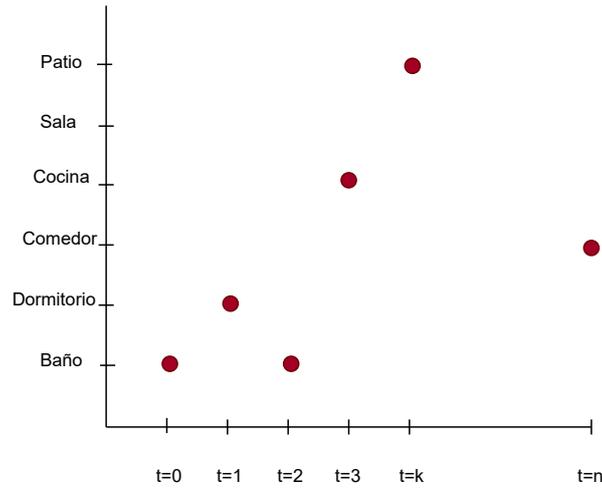


Figura 3.5: Ejemplo en tiempo discreto.

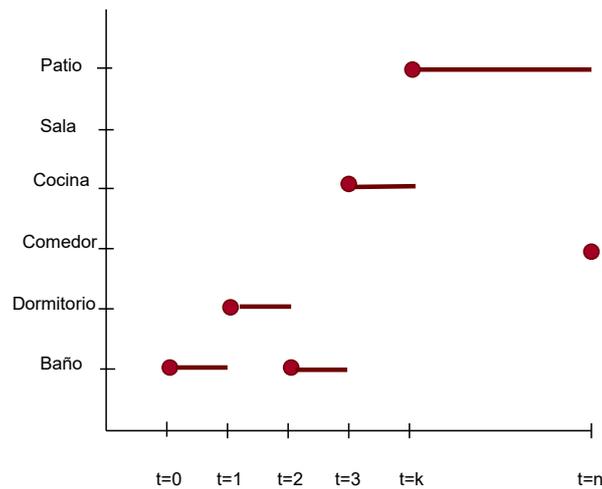


Figura 3.6: Ejemplo en tiempo continuo.

Recordemos que un objetivo de esta tesis es estimar de manera probabilística la habitación a la que se moverá el sujeto de estudio conociendo la habitación actual en la que se encuentra la persona, entonces se define la variable aleatoria $X_t = \{ \text{la habitación en la que se encuentra la persona en el tiempo } t \}$. La variable aleatoria X_t es discreta en tiempo continuo, por lo tanto, una solución es la implementación de un modelo probabilístico basado en cadena de Markov en tiempo continuo.

Como se sabe, las cadenas de Markov son procesos que involucran la “falta de memoria”, es decir, solo requieren la información del último estado visitado para calcular

la probabilidad del próximo estado. A continuación, se mencionan algunas propiedades de la cadena de Markov a tiempo discreto debido a la “corta memoria”:

- En una cadena de Markov $\{X_n\}_{n \geq 0}$, se define la probabilidad de transición, del tiempo n al $n + 1$ (en un paso), como $P[X_{n+1} = j | X_n = i]$ [14].

- Las $p_{ij}(n)$ se llaman probabilidades de transición de un paso, porque son las probabilidades de pasar del estado i al j en un paso de tiempo. Tener en cuenta que la suma de todas las probabilidades que dejan un estado debe ser 1. Esto es porque para cada estado i $\sum_{j=0}^m p_{ij}(n) = \sum_{j=0}^m P[X_{n+1} = j | X_n = i] = 1$ [14] [22].

Por ejemplo, en la Fig. 3.7 se muestra las probabilidades de estar en el estado A e ir a los otros estados (B,C,D), dichas probabilidades suman 1.

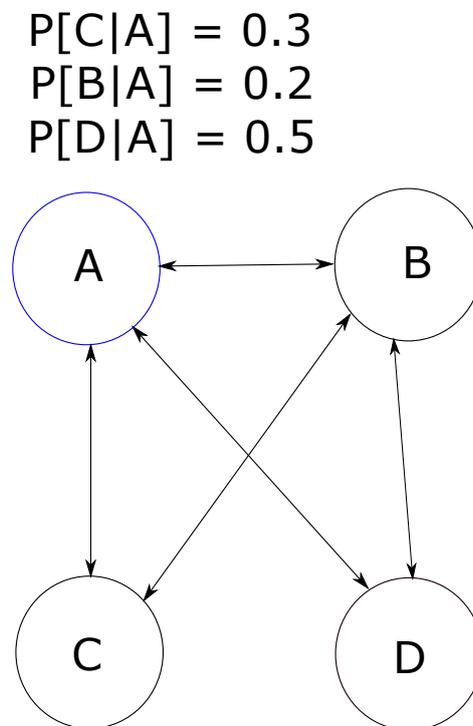


Figura 3.7: Ejemplo de la suma de la probabilidad sea 1.

- Una cadena de Markov se dice que tiene probabilidades de transición estacionarias o que es homogéneo con respecto al tiempo, si las probabilidades de transición no dependen del tiempo n , entonces $p_{ij} = P[X_{n+1} = j | X_n = i], \forall n$. Por ejemplo, la $P[B|A]=0.2$ en un tiempo $t=2$ es la misma con un tiempo distinto a 2 [14].

- Un proceso de Markov homogéneo tiene probabilidades condicionales que pueden ser representadas en una matriz de transición [14].

Matriz de transición

Sea $X = \{X_n\}, n \geq 0$ una cadena de Markov estacionaria, se establece la matriz de transición como $P = p_{ij}$ con $p_{ij} = P[X_{n+1} = j | X_n = i]$, en donde p_{ij} es la probabilidad de transición entre i y j .

En la Fig. 3.8 se muestra un grafo dirigido con su respectiva matriz de transición.

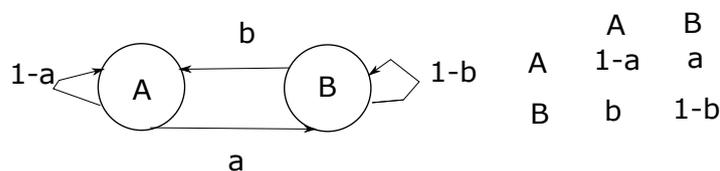


Figura 3.8: Matriz de transición.

- En una cadena de Markov con probabilidades estacionarias, se obtienen las probabilidades de transición en m pasos como sigue: $p_{ij}^m = P[X_m = j | X_0 = i] = P[X_{n+m} = j | X_n = i]$, es decir [14]:

$$p_{ij}^m = \begin{bmatrix} p_{00} & \dots & p_{0j} \\ \dots & \dots & \dots \\ p_{i0} & \dots & p_{ij} \end{bmatrix}^m \tag{3.2}$$

El comportamiento de las cadena de Markov en tiempo continuo se determina por medio de la matriz intensidad Q .

En el tiempo continuo es de interés calcular probabilidades de transición en un intervalo de tiempo (de un tiempo arbitrario s a otro tiempo arbitrario $s + t$). En una cadena de Markov homogénea, se tiene que la probabilidad de transición es [22]:

$$P[X_{s+t} = j | X_s = i] = P[X_t = j | X_0 = i] = p_{ij}(t), t \geq 0, \forall s. \quad (3.3)$$

La formula (3.3) se interpreta como la probabilidad de pasar del estado i al estado j es la misma para periodo de tiempos iguales, ya que el tiempo entre X_{s+t} y X_s es t que es el mismo entre X_t y X_0 .

Como consecuencia de la propiedad de Markov, el tiempo de permanencia S_i , en el estado i , es una variable aleatoria con distribución exponencial con parámetro q_i . Es decir, $S_i \sim Exp(q_i)$, su función de densidad es $f_i(s) = \frac{1}{q_i} e^{-\frac{s}{q_i}}$ y la esperanza está definida por $E(S) = q_i$. En consecuencia, por (3.3) $P[X_t = j | X_{t-\Delta t} = i] = P[X_{\Delta t} = j | X_0 = i]$, donde Δt es un cambio en el tiempo casi instante [41].

Sea $q_{ij} = \lim_{\Delta t \rightarrow 0} \left(\frac{P(X_{\Delta t} = j | X_0 = i)}{\Delta t} \right)$, entonces $P[X_t = j | X_{t-} = i, X_t \neq i] = \frac{q_{ij}}{q_i}$ que es la probabilidad instantánea de un cambio de estado i al estado j [41].

Si la cadena tiene k estados, entonces $q_{ii} = \sum_{j=1, j \neq i}^k q_{ij}$. La matriz generadora infinitesimal del proceso está definida por [41] :

$$Q = \begin{bmatrix} -q_{11} & q_{12} & q_{13} & \dots & q_{1k} \\ q_{21} & -q_{22} & q_{23} & \dots & q_{2k} \\ & & \dots & & \\ q_{k1} & q_{k2} & q_{k3} & \dots & -q_{kk} \end{bmatrix}$$

Sean dos tiempos arbitrarios s y t . La probabilidad de que ocurra un cambio, entre esos dos tiempos, esta dado por [4]:

Para $s \geq t$

$$P(s, t) = \exp\{(s - t)Q\} \quad (3.4)$$

Es decir, cada entrada de esta matriz, representa la probabilidad de cambiar de un estado a otro, del tiempo t al tiempo s .

Después de conocer la matriz de intensidad Q , en el capítulo de implementación del modelo probabilístico se mencionan las técnicas implementadas para obtener un valor numérico aproximado de los elementos de la matriz de intensidad y, posteriormente la matriz de transición P .

3.3. Implementación del modelo probabilístico

En esta sección, se describe la justificación del modelo, la correspondencia de los datos con la cadena de Markov, así como las técnicas y algoritmos que son empleados para la estimación de los parámetros del modelo probabilístico.

3.3.1. Verificar que los datos satisfacen la propiedad de Markov

En cuanto a la validación del modelo probabilístico se necesita verificar que los datos correspondan a una cadena de Markov y, además cumplan con la propiedad de homogeneidad; y posteriormente, se realiza la estimación de los parámetros.

Con respecto a la validación de correspondencia de los datos con una cadena de Markov, se puede realizar por medio de la *prueba de bondad de ajuste* para la cadena de Markov [3]. Se supone que las observaciones son un solo flujo $y = (y_1, \dots, y_n)$ donde cada y_t es un estado en $S = 1, 2, \dots, s$. Con base en esas observaciones se quiere evaluar la compatibilidad entre y con una cadena de Markov de primer orden o

una cadena de Markov de segundo orden teniendo en cuenta que la única restricción es que las sumas de las filas sea 1. Con base en lo anterior, el estadístico de prueba es [3]:

$$u_1 = 2 \sum_{i,j,k} n_{i,j,k} \log\left(\frac{n_{ijk}/n_{ij+}}{n_{+jk}/n_{++}}\right), \quad (3.5)$$

Es decir : H_0 = Cadena de Markov de primer orden vs H_1 : Cadena de Markov de orden 2. H_0 significa que la probabilidad del siguiente estado depende solo del estado presente y H_1 que la probabilidad del siguiente estado depende del estado actual y el estado anterior. La decisión se basa en el p-valor de la prueba, es decir, si el p-valor es menor a 0.05 se rechaza H_0 , o sea, no es cadena de Markov. Pero, si el p-valor > 0.05 no se rechaza H_0 , es decir, no se tiene evidencia suficiente en contra de que sea una cadena de Markov.

Después de verificar que los datos correspondan a una cadena de Markov, ahora se enfoca la atención en determinar si el comportamiento del individuo es homogéneo.

3.3.2. Justificación de la homogeneidad

El comportamiento del adulto mayor tiende a seguir una rutina, también tienen la característica de ser rígida y difícil de cambiar [45], aunque suelen tener leves variaciones. Por esto, en el proyecto de tesis se asume que no importa el tiempo en que ocurra el cambio de una habitación a otra la probabilidad siempre es la misma, si el momento en el que ocurrió el movimiento se encuentra en el periodo de monitoreo. Por ejemplo, en el caso de estudio se contempla el periodo de monitoreo de 15 a 19 horas, por lo tanto, la probabilidad de ir a la habitación Kitchen dado que me encuentre en el Bedroom es la misma a las 15:30 hrs o las 17:25 hrs.

3.3.3. Estimar Q

Si los datos de la muestran cumplen con las dos condiciones anteriores, es decir, son compatibles con una cadena de Markov y el comportamiento del individuo es homogéneo. Ahora, se pueden estimar la matriz Q y calcular P con las formulas que se describen más adelante.

Con base en los datos obtenidos, la estimación de la matriz generadora \hat{Q} se puede realizar por el método de máxima verosimilitud, es decir, el estimador es aquel que maximiza la función [33]:

$$L(Q) = \prod_{i=1}^I \prod_{j \neq i} (q_{ij})^{N_{ij}(T)} \exp(-q_{ij} R_i(T)), \quad (3.6)$$

En donde:

T es el tiempo final de observación.

$N_{ij}(T)$ es el número de transiciones de i a j dentro del tiempo T.

$R_i(T)$ es la suma de los tiempos acumulados de estancia en el estado i antes de que ocurra un cambio de estado.

El estimador de máxima verosimilitud resulta ser:

- Los elementos fuera de la diagonal de Q son [4]:

$$\hat{q}_{ij} = \frac{N_{ij}(T)}{R_i(T)} \quad (3.7)$$

- Los elementos en la diagonal principal son [4]:

$$\hat{q}_{ii} = -\sum_{j=1}^J \hat{q}_{ij} \quad (3.8)$$

de tal forma que $\sum_{j=1}^J q_{ij} = 0$

3.3.4. Calcular P

La estimación de la matriz P se realiza utilizando la estimación de la matriz Q mediante la formula [4]:

Para $s \geq t$

$$P(s, t) = \exp\{(s - t)Q\} \quad (3.9)$$

donde

$$\exp\{hQ\} = \sum_{n=0}^{\infty} \frac{(hQ)^n}{n!} \quad (3.10)$$

Enseguida, se muestra el algoritmo involucrado para obtener los valores correspondientes a las matrices \hat{P} y \hat{Q} es:

- 1 Input: *Datos* y t . Los *Datos* es un objeto contenido en un archivo csv y t es un número entero en el tiempo, en el cual, se desea conocer la probabilidad de cambio de estado.
- 2 Se estiman los elementos fuera de la diagonal principal de la matriz generadora \hat{Q} con la formula (3.7).
- 3 Se estima los elementos en la diagonal principal de la matriz generadora \hat{Q} con la formula (3.8).
- 4 Se calcula \hat{P} con la formula (3.10) con parámetro $t\hat{Q}$.

A continuación, se muestra la lógica general del algoritmo que permite estimar Q y, posteriormente calcular P :

```

Input: [ ][ ] Datos,int t
Result: Estimación de la matriz  $\hat{Q}$  y  $\hat{P}$ 
Rooms[] = Datos[:, 1]
Times[length(Rooms)]=0
/* Obtener los tiempos de permanencia en cada rooms */
for 1:length(Rooms) do
    for j:length(Datos[,2]) do
        if Rooms[i]== Datos[j,1] then
            Times[i]=Times[i]+ Datos[j,2]
        end
    end
end
/* Matriz auxiliar para guardar las transiciones i→j */
Trans[length(Rooms),length(Rooms)]=0
for 1: length(Rooms)-1 do
    IndI = index(Datos[i,1])
    IndJ = index(Datos[i+1,1])
    Trans[IndI,IndJ] = Trans[IndI,IndJ]+1
end
/* Método para obtener los elementos fuera de la diagonal */
/* TransDivision matriz que contiene la division de las
transiciones entre la suma del tiempo de permanencia */
TransDivision[length(Rooms)][length(Rooms)]=0
for i:length(Rooms) do
    TransDivision[i,]= Trans[i,]/Time[i]
end
/* Se obtienen los elementos en la diagonal principal */
for i:length(TransDivision) do
    TransDivision[j,j]= -sum(Transdivision[j,])- TransDivision[j,j]
end
/* Se multiplica t*TransDivision para obtener Q */
 $\hat{Q}$ = t* TransDivision
 $\hat{P}$ = Calcular la exponencial de una matriz  $\hat{Q}$  aplicando la formula  $\sum_{n=0}^{\infty} \frac{(n\hat{Q})^n}{n!}$ 

```

Capítulo 4

Pruebas y resultados

En este capítulo se presenta las condiciones y el proceso del cómo se realizó la prueba experimental. También se mencionan las conclusiones obtenidas con base a los resultados obtenidos de la prueba experimental.

Para realizar la prueba experimental se llevó a cabo en diferentes fases: la primera es la recolección de la información, en la cual se considera todo lo necesario para la obtención de los datos; posteriormente, se realiza la verificación de la propiedad de Markov y la homogeneidad; la siguiente fase es el ajuste del modelo, se adaptan los datos para ser procesados para obtener la estimación de \hat{Q} ; y por último, la aplicación que permite el cálculo de las probabilidades de la matriz P y el pronóstico de la trayectoria de desplazamiento.

4.1. Recolección de la información

La recolección de datos se realizó bajo las siguientes condiciones:

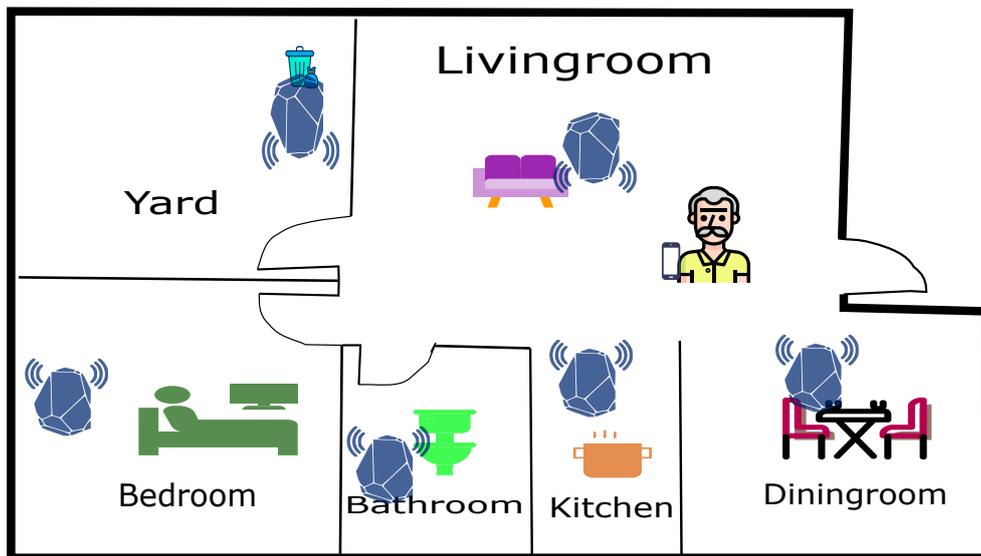


Figura 4.1: Contexto de la prueba experimental.

- La persona vive de manera independiente y es la única residente en el hogar.
- Se instalaron sensores en las habitaciones del hogar como se muestra en la Fig. 4.1 para utilizar la aplicación OPAIEH [7] para la obtención de la información.
- Para obtener la habitación en la que se encuentra el usuario, la aplicación requiere el registro de actividades, así que se añaden las actividades que suele realizar el individuo en dichas habitaciones. En total se obtienen 21 actividades, las cuales son: *Clean the kitchen*, *Clean the bathroom*, *Clean the bedroom*, *Clean the diningroom*, *Drink water*, *Make the lunch*, *Snack*, *Washing dishes*, *Take a shower*, *Toilet activities*, *Get clothes*, *Homework*, *Watch tv*, *Homework living*, *Read a book*, *Watch tv living*, *Have lunch*, *Homework diningroom*, *Clean the yard*, *Take out the trash*, *Wash the clothes*. Además, el hogar de la persona cuenta con 6 habitaciones las cuales son: *Bathroom*, *Bedroom*, *Diningroom*, *Kitchen*, *Livingroom* y *Yard*.

En la tabla 4.1 se muestra la relación entre la actividad con su correspondiente habitación. Por ejemplo, la actividad *Drink water* se realiza en la habitación denominada *Kitchen*.

<i>Bathroom</i>	<i>Bedroom</i>	<i>Diningroom</i>	<i>Kitchen</i>	<i>Livingroom</i>	<i>Yard</i>
<i>Clean the bathroom</i>	<i>Clean the bedroom</i>	<i>Clean the diningroom</i>	<i>Clean the kitchen</i>	<i>Homework living</i>	<i>Clean the yard</i>
<i>Take a shower</i>	<i>Get clothes</i>	<i>Have lunch</i>	<i>Drink water</i>	<i>Read a book</i>	<i>Take out the trash</i>
<i>Toilet activities</i>	<i>Homework</i>	<i>Homework dining</i>	<i>Make the lunch</i>	<i>Watch tv living</i>	<i>Wash the clothes</i>
	<i>Watch tv</i>		<i>Snack</i>		
			<i>Washing dishes</i>		

Tabla 4.1: Relación entre las actividades y las habitaciones.

- El monitoreo se llevó a cabo en un lapso en donde el individuo permaneciera en su hogar realizando sus actividades, debido a que no se considera el estado “no estar en el hogar”, porque el objetivo es inferir la habitación a la que se desplazará. Tomando en cuenta lo anterior, se decide monitorear entre el periodo de 15 hasta las 19 horas de manera continua. Es decir, en todo momento se sabe en qué habitación se encuentra la persona.
- El monitoreo se realizó por varias semanas, obteniendo la respectiva base de datos considerando las condiciones anteriores. En la tabla 4.2 se muestran los datos que son registrados con su respectivo ejemplo.

No	<i>Date</i>	<i>Room</i>	<i>Duration</i>	<i>Inferred_activity</i>	<i>List_activity</i>	<i>User_activity</i>	<i>DateFinal</i>	<i>Day</i>
1	2018-09-19 15:00:09	<i>Kitchen</i>	17	0	1	<i>Make the lunch</i>	2018-09-19 15:17:11	<i>Wednesday</i>
2	2018-09-19 15:17:11	<i>Bathroom</i>	3	1	0	<i>Toilet activities</i>	2018-09-19 15:20:39	<i>Wednesday</i>

Tabla 4.2: Ejemplo de los elementos registrados en la base de datos.

Para obtener una visualización de las trayectorias almacenadas, se crean líneas de tiempo. Lo anterior, se logra accediendo a la base de datos por medio del lenguaje R. Los datos son guardados en formato JSON. Las etiquetas consideradas para el archivo json son: *Room*, *Date*, *DateFinal*. Por ejemplo en la Fig. 4.2 se tiene los

datos correspondiente al día lunes de la primera semana de monitoreo en formato json.

```
[{"Room":"Diningroom","Date":"2018-09-24 15:00:14","DateFinal":"2018-09-24 15:05:03"},
{"Room":"Bathroom","Date":"2018-09-24 15:05:22","DateFinal":"2018-09-24 15:08:14"},
{"Room":"Diningroom","Date":"2018-09-24 15:08:24","DateFinal":"2018-09-24 15:19:05"},
{"Room":"Kitchen","Date":"2018-09-24 15:19:13","DateFinal":"2018-09-24 15:27:42"},
{"Room":"Bedroom","Date":"2018-09-24 15:28:02","DateFinal":"2018-09-24 15:46:30"},
{"Room":"Bathroom","Date":"2018-09-24 15:46:42","DateFinal":"2018-09-24 15:52:56"},
{"Room":"Kitchen","Date":"2018-09-24 15:53:02","DateFinal":"2018-09-24 15:54:42"},
{"Room":"Bedroom","Date":"2018-09-24 15:54:53","DateFinal":"2018-09-24 16:12:32"},
{"Room":"Bathroom","Date":"2018-09-24 16:12:55","DateFinal":"2018-09-24 16:15:09"},
{"Room":"Bedroom","Date":"2018-09-24 16:15:50","DateFinal":"2018-09-24 16:38:36"},
{"Room":"Kitchen","Date":"2018-09-24 16:39:17","DateFinal":"2018-09-24 16:44:16"},
{"Room":"Bedroom","Date":"2018-09-24 16:44:25","DateFinal":"2018-09-24 16:54:00"},
{"Room":"Diningroom","Date":"2018-09-24 16:54:06","DateFinal":"2018-09-24 17:13:04"},
{"Room":"Bedroom","Date":"2018-09-24 17:13:39","DateFinal":"2018-09-24 17:17:24"},
{"Room":"Bathroom","Date":"2018-09-24 17:18:26","DateFinal":"2018-09-24 17:31:58"},
{"Room":"Diningroom","Date":"2018-09-24 17:32:31","DateFinal":"2018-09-24 17:51:04"},
{"Room":"Kitchen","Date":"2018-09-24 17:51:17","DateFinal":"2018-09-24 17:56:56"},
{"Room":"Bathroom","Date":"2018-09-24 17:57:36","DateFinal":"2018-09-24 18:00:38"},
{"Room":"Kitchen","Date":"2018-09-24 18:01:26","DateFinal":"2018-09-24 18:08:24"},
{"Room":"Livingroom","Date":"2018-09-24 18:09:03","DateFinal":"2018-09-24 18:16:40"},
{"Room":"Kitchen","Date":"2018-09-24 18:16:44","DateFinal":"2018-09-24 18:20:10"},
{"Room":"Livingroom","Date":"2018-09-24 18:20:55","DateFinal":"2018-09-24 18:28:20"},
{"Room":"Bedroom","Date":"2018-09-24 18:28:29","DateFinal":"2018-09-24 18:42:16"},
{"Room":"Diningroom","Date":"2018-09-24 18:42:21","DateFinal":"2018-09-24 18:56:08"},
{"Room":"Bedroom","Date":"2018-09-24 18:56:13","DateFinal":"2018-09-24 18:58:09"},
{"Room":"Bathroom","Date":"2018-09-24 18:58:16","DateFinal":"2018-09-24 19:00:28"}]
```

Figura 4.2: Ejemplo de archivo json correspondiente a los datos del día lunes correspondiente a la primera semana de monitoreo.

Por ejemplo, en la Fig. 4.3 se gráficán los movimientos y tiempo de duración en las habitaciones. Como se observa, la persona comienza en la habitación denominada *Diningroom* a las 15:00 y permanece ahí hasta las 15:04 aproximadamente; posteriormente como a las 15:04 se encuentra en el *Bathroom*. Los pequeños lapsos de tiempo perdidos entre cambios de habitación son considerados como el tiempo requerido para registrar la información en la base de datos. Por lo cual, se asumen que no interfieren en el análisis y los procesos presentados.



Figura 4.3: Línea de tiempo del comportamiento.

En total se tienen 5 archivos en formato json por día, que representan las trayectorias de las semanas monitoreadas. Al final se representan todas las trayectorias correspondientes a un día en específico. Por ejemplo, en la Fig. 4.4 se muestran las trayectorias correspondientes al día lunes en las distintas semanas, en el cual se observa que el individuo suele comenzar y terminar el patrón de sus movimientos en diferentes habitaciones. Además, suele pasar mayor tiempo en el *Bedroom*, *Livingroom*, *Diningroom*. En cambio, en el resto de los días suele estar más tiempo en cuatro habitaciones *Bedroom*, *Livingroom*, *Diningroom* y *Kitchen* (ver Fig. 4.5, 4.6, 4.7, 4.8).

A continuación, se muestran todas las trayectorias correspondientes a los datos obtenidos en esta sección:

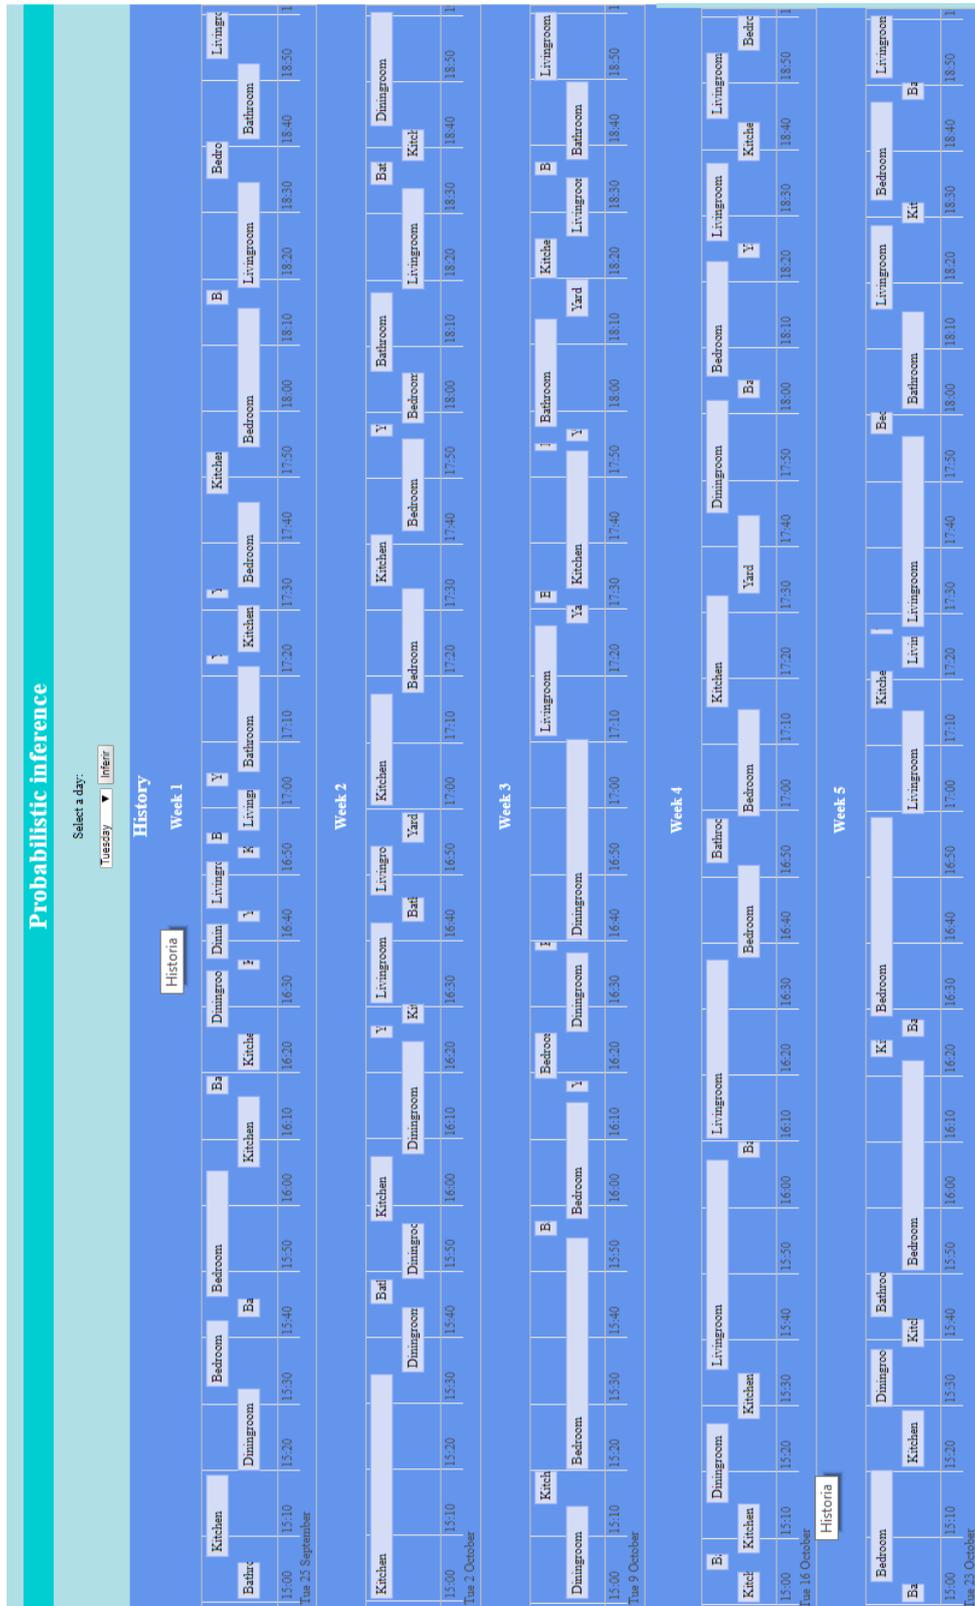


Figura 4.5: Historial de trayectorias correspondiente al día martes.

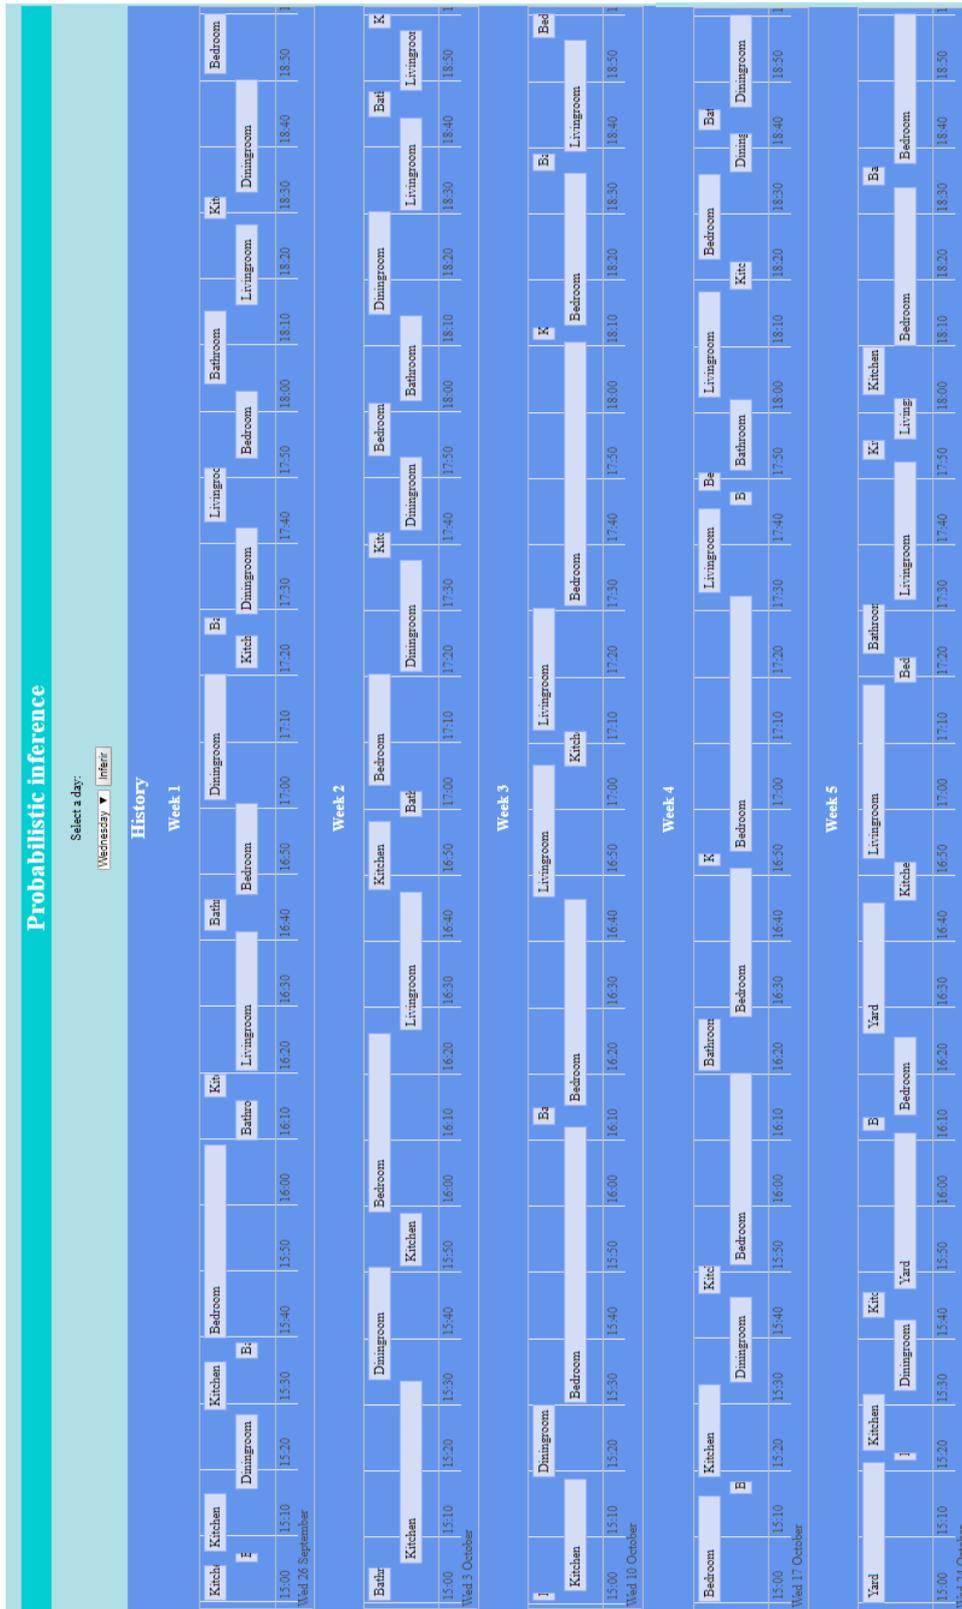


Figura 4.6: Historial de trayectorias correspondiente al día miércoles.

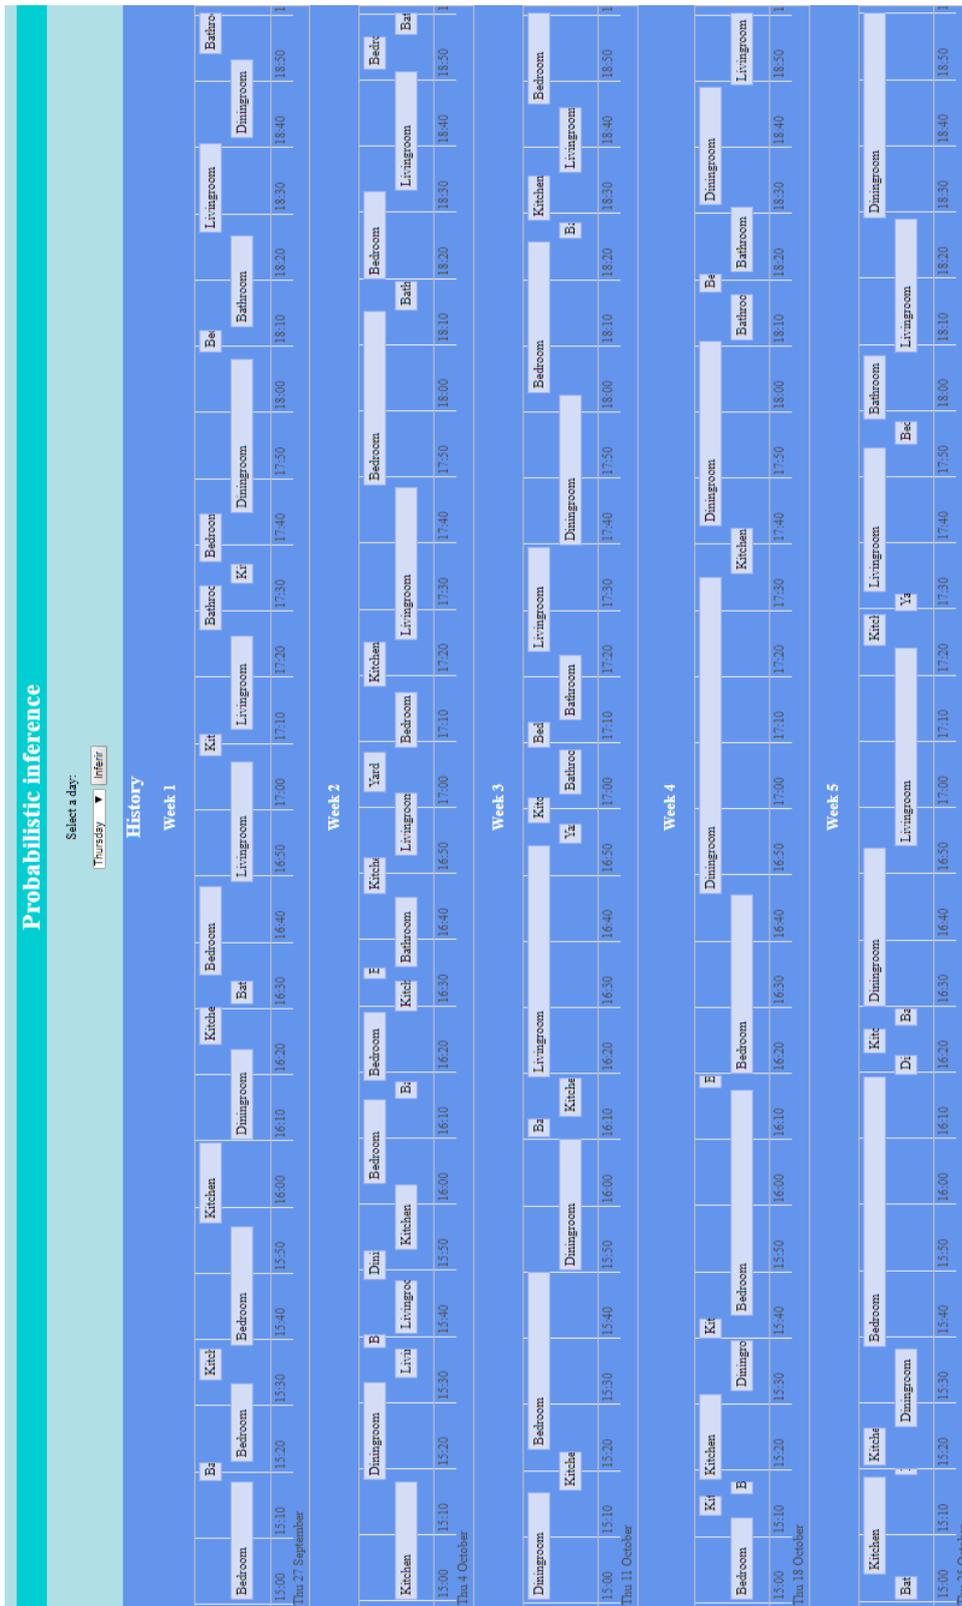


Figura 4.7: Historial de trayectorias correspondiente al día jueves.

4.2. Verificación de ajuste del modelo de Markov

En esta fase, primeramente, se realiza la validación relacionada con la correspondencia de los datos con una cadena de Markov y; posteriormente, si la cadena es homogénea.

4.2.1. Propiedad de Markov

Con respecto a la validación de correspondencia de los datos a una cadena de Markov, se implementa el algoritmo de *bondad de ajuste*. El algoritmo requiere que los datos de entrada se encuentren en un archivo csv con los registros por día. Cada archivo csv contiene la secuencia de habitaciones visitadas durante el proceso de monitoreo. Durante el proceso del algoritmo, las habitaciones son mapeadas a un número entero como se muestra en la tabla 4.3.

Habitación	Etiqueta
<i>Bedroom</i>	1
<i>Bathroom</i>	2
<i>Kitchen</i>	3
<i>Diningroom</i>	4
<i>Livingroom</i>	5
<i>Yard</i>	6

Tabla 4.3: Mapeo de las habitaciones.

Como ejemplo a continuación, se muestra en la tabla 4.4 la secuencia de movimientos o desplazamientos realizados por el usuario en el primer día de monitoreo y su secuencia en números enteros, según la tabla 4.3, para realizar la validación.

Secuencia	Correspondencia
<i>Diningroom, Bathroom, Diningroom,</i> <i>Kitchen, Bedroom, Bathroom,</i> <i>Kitchen, Bedroom, Bathroom, Be-</i> <i>droom, Kitchen, Bedroom, Dinin-</i> <i>groom, Bedroom,</i> <i>Bathroom, Diningroom, Kitchen, Bath-</i> <i>room,</i> <i>Kitchen, Livingroom, Kitchen, Livin-</i> <i>groom, Bedroom, Diningroom,</i> <i>Bedroom, Bathroom</i>	4 2 4 3 1 2 3 1 2 1 3 1 4 1 2 4 3 2 3 5 3 5 1 4 1 2

Tabla 4.4: Mapeo de secuencia para la validación.

Además, cada día se considera independiente, es decir, se validaron 25 trayectorias. Con base a estas observaciones, se evalúa la compatibilidad entre la observación del día a una cadena de Markov, estableciendo el supuesto de hipótesis [3]:

H_0 = cadena de Markov de primer orden vs

H_1 = cadena de Markov de orden 2(4.1).

En la tabla 4.5 se muestran los resultados obtenidos al aplicar el algoritmo *bondad de ajuste*.

Día	u_1	p-valor
2018-09-24	25.65	0.9999
2018-09-25	45.06	1
2018-09-26	27.55	0.9999
2018-09-27	37.05	0.9999
2018-09-28	38.10	0.9999
2018-10-01	26.64	0.9999
2018-10-02	25.82	1
2018-10-03	28.09	0.9999
2018-10-04	31.20	1
2018-10-05	21.50	0.9999
2018-10-08	37.05	1
2018-10-09	35.50	1
2018-10-10	18.72	0.9999
2018-10-11	24.27	1
2018-10-12	28.09	1
2018-10-15	21.09	1
2018-10-16	31.54	1
2018-10-17	20.73	0.9999
2018-10-18	17.68	0.9999
2018-10-19	35.86	1
2018-10-22	22.18	0.9999
2018-10-23	28.36	1
2018-10-24	20.95	1
2018-10-25	25.32	1
2018-10-26	22.68	1

Tabla 4.5: p-valores correspondientes a la prueba de bondad de ajuste.

Como se mencionó en el capítulo anterior, la regla de decisión es: si el p-valor < 0.05 se rechaza H_0 , es decir, no es cadena de Markov de orden 1. Pero, si el p-valor > 0.05 no se rechaza H_0 , es decir, no hay evidencia suficiente en contra que sea una cadena de Markov de orden uno.

En conclusión, se puede decir que no existe evidencia suficiente en contra de que la trayectoria registrada cada día corresponda a una cadena de Markov de orden 1.

4.2.2. Homogeneidad

Con respecto a validar si la cadena es homogénea en el tiempo, en el proyecto de tesis, se justifica que existe la homogeneidad debido a la manera de comportarse el individuo en su hogar. En este caso, no depende del tiempo para desplazarse de una habitación a otra, es decir, la probabilidad de ir de una habitación a otra es constante siempre y cuando el intervalo de tiempo de interés sea el mismo. Por ejemplo, la probabilidad de pasar a *Kitchen* dado que se está en *Bedroom* es la misma en el intervalo de 4 a 4:05, 6:05 a 6:10, o cualquier otro intervalo de longitud 5. Por lo tanto, suponemos que la cadena de Markov presentada es homogénea.

4.3. Ajuste del Modelo

En esta sección se estiman los valores de la matriz Q y el tiempo de permanencia esperado en las distintas habitaciones según el día.

4.3.1. Estimación de Q

A continuación, se describe el proceso de la transformación de los datos obtenidos en la recolección para ser utilizados en la estimación de Q .

En primera instancia, se concentran los datos con sus respectivos metadatos según las siguientes condiciones:

- Para la implementación del modelo, se asume que todos los días son independientes y que todos los lunes corresponden a una misma cadena de Markov. Teniendo así, 5 realizaciones de una cadena de Markov disponibles para la estimación de la Matriz de intensidad Q , donde se encuentran los parámetros del modelo. Lo mismo aplica para todos los martes, miércoles, jueves y viernes.
- Se realiza un análisis de los datos obtenidos, en el cual se excluyen las semanas incompletas si por alguna razón, el usuario no registró la información perteneciente a algún día de la semana. Al excluir las semanas incompletas, solamente se utilizan 5 semanas correspondientes a los días de lunes a viernes.
- De los datos obtenidos, no se requieren todos los campos debido a que solamente se quiere estimar la siguiente habitación para obtener el patrón de desplazamiento. Por lo tanto, en esta fase se consideran los campos: *Room*, *Date*, *Duration* y *DateFinal*. El campo *Date*, representa la fecha y hora en

la que inicia la estancia en la habitación, *Duration* son los minutos de permanencia, *Room* el nombre de la habitación; y por último, *DateFinal* que almacena la fecha y hora final en la habitación.

- Los valores de las etiquetas *DateFinal* y *Date* son utilizados para verificar que la obtención de los datos se realizó de manera consecutiva.

Posteriormente, los datos son agrupados según el día en que fueron realizados y se añade la etiqueta *etiWeek*. La etiqueta *etiWeek* sirve para identificar a cuál semana pertenecen los datos. El valor que puede tomar *etiWeek* según la semana se muestra en la tabla 4.6.

<i>Date</i>	<i>etiWeek</i>
De 24-09-2018 a 28-09-2018	<i>one</i>
De 01-10-2018 a 05-10-2018	<i>two</i>
De 08-10-2018 a 12-10-2018	<i>three</i>
De 15-10-2018 a 19-10-2018	<i>four</i>
De 22-10-2018 a 26-10-2018	<i>five</i>

Tabla 4.6: Valor de la *etiWeek* según la semana.

Como resultado del proceso anterior, se obtienen 5 archivos denominados: *Monday*, *Tuesday*, *Wednesday*, *Thursday* y *Friday*. Cada archivo contiene 3 columnas: *Room*, *Duration* y *etiWeek*. En la tabla 4.7 se muestra una parte de los datos del archivo *Friday*.

<i>Bedroom</i>	31	<i>one</i>
<i>Yard</i>	2	<i>one</i>
<i>Bedroom</i>	5	<i>one</i>
<i>Bathroom</i>	12	<i>one</i>
<i>Livingroom</i>	9	<i>one</i>
<i>Bedroom</i>	22	<i>two</i>
<i>Kitchen</i>	11	<i>two</i>
<i>Diningroom</i>	12	<i>two</i>
<i>Kitchen</i>	8	<i>two</i>
<i>Bathroom</i>	4	<i>two</i>

Tabla 4.7: Datos del archivo *Friday*.

Además, la etiqueta *etiWeek* permite tener el control adecuado al momento de calcular las transiciones realizadas durante todos los días. Es decir, no se toma en cuenta el registro de la última estancia del día con la primera del día posterior. Por ejemplo, en la Fig. 4.7 de *Yard* a *Bedroom* se considera una transición porque pertenecen a la misma semana, pero *Livingroom* a *Bedroom* no es una transición correcta, porque difiere el valor de la etiqueta *etiweek*. De esta manera, se evitan transiciones no adecuadas.

Después de organizar los datos como se requiere, éstos son utilizados entrada para el algoritmo de estimación del parámetro \hat{Q} . A continuación, se muestra el algoritmo para estimar \hat{Q} :

Algoritmo para estimar Q

```

Input: Datos[][]
Result: Estimación de Q
/* Declaración de variables */
testcvs= Datos
/* Se obtienen las distintas habitaciones */
Rooms = levels(testcvs$Room)
/* DifDAYS guarda los diferentes semanas */
DifDAYS = testcvs$etiWeek
/* Creamos un array del tamaño de Rooms para guardar los tiempos
de estancia en los diferentes Rooms, se inicializa con 0s */
Times = array(0,dim=length(Rooms))
/* Se obtiene la suma de los tiempos de espera y se asigna en el
indice correspondiente en el array Times */
for i=1:length(Rooms) do
  | ObtDatosEstado = testcvs[testcvs$Room== Rooms[i],]
  | Times[i ] = colSums(ObtDatosEstado["Duration"])
end
/* 1. Matriz para guardar el numero de transiciones de i a j por
dia según la etiqueta */
Trans = matrix(0,nrow = length(Rooms),ncol = length(Rooms))
for i=1:length(DifDAYS) do
  | /* 2. Si los días son consecutivos se cuenta como transición
correcta */
  | if DifDAYS[i]==DifDAYS[i+1] then
  | | /* Se obtiene los indices correspondiente */
  | | indI = which(Rooms== testcvs[i,Room"])
  | | indJ = which(Rooms==testcvs[i+1,Room"])
  | | /* aux guarda el valor actual de la transición acumulada.
Posteriormente, se incrementa 1 transicion */
  | | aux = Trans[indI,indJ]
  | | Trans[indI,indJ] = aux+1
  | end
end
/* 3. Obtención de los elementos fuera de la diagonal */
/* TransDivision es la matriz que contiene la division de las
transiciones entre los tiempos de permanencia */
TransDivision = matrix(0,nrow = length(Rooms), ncol = length(Rooms))

for i=1:length(Rooms) do
  | TransDivision[i,] = round(Trans[i,]/Times[i],6)
end
/* 4. Se obtiene los elementos de la diagonal principal */
for j=1:nrow(TransDivision) do
  | TransDivision[j,j]= -(sum(TransDivision[j,]) - TransDivision[j,j])
end
Q = TransDivision
return (Q)

```

CAPÍTULO 4. PRUEBAS Y RESULTADOS

Seguidamente, se muestran las matrices de intensidad \hat{Q} por día .

	<i>Bathroom</i>	<i>Bedroom</i>	<i>Diningroom</i>	<i>Kitchen</i>	<i>Livingroom</i>	<i>Yard</i>
<i>Bathroom</i>	-0.192660	0.055046	0.036697	0.073394	0.018349	0.009174
<i>Bedroom</i>	0.020964	-0.054506	0.010482	0.010482	0.010482	0.002096
<i>Diningroom</i>	0.015038	0.015038	-0.063910	0.030075	0.0034759	0.000000
<i>Kitchen</i>	0.027778	0.062500	0.048611	-0.180555	0.034722	0.006944
<i>Livingroom</i>	0.017964	0.029940	0.000000	0.023952	-0.071856	0.000000
<i>Yard</i>	0.000000	0.428571	0.000000	0.000000	0.000000	-0.428571

Tabla 4.8: Matriz de intensidad para el día lunes.

	<i>Bathroom</i>	<i>Bedroom</i>	<i>Diningroom</i>	<i>Kitchen</i>	<i>Livingroom</i>	<i>Yard</i>
<i>Bathroom</i>	-0.173610	0.048611	0.006944	0.034722	0.06500	0.020833
<i>Bedroom</i>	0.028302	-0.062894	0.003145	0.018868	0.003145	0.009434
<i>Diningroom</i>	0.011494	0.005747	-0.068965	0.034483	0.005747	0.011494
<i>Kitchen</i>	0.026549	0.022124	0.039823	-0.119470	0.022124	0.008850
<i>Livingroom</i>	0.0111450	0.019084	0.000000	0.015267	-0.061068	0.015267
<i>Yard</i>	0.068182	0.068182	0.022727	0.090909	0.068182	-0.318182

Tabla 4.9: Matriz de intensidad para el día martes.

	<i>Bathroom</i>	<i>Bedroom</i>	<i>Diningroom</i>	<i>Kitchen</i>	<i>Livingroom</i>	<i>Yard</i>
<i>Bathroom</i>	-0.213592	0.077670	0.029126	0.058252	0.048544	0.000000
<i>Bedroom</i>	0.022573	-0.042889	0.006772	0.004515	0.006772	0.002257
<i>Diningroom</i>	0.005682	0.017045	-0.068182	0.034091	0.011364	0.000000
<i>Kitchen</i>	0.024540	0.036810	0.042945	-0.134970	0.024540	0.0006135
<i>Livingroom</i>	0.013393	0.017857	0.000000	0.031250	-0.062500	0.000000
<i>Yard</i>	0.031250	0.0000000	0.000000	0.015625	0.000000	-0.046875

Tabla 4.10: Matriz de intensidad para el día miércoles.

	<i>Bathroom</i>	<i>Bedroom</i>	<i>Diningroom</i>	<i>Kitchen</i>	<i>Livingroom</i>	<i>Yard</i>
<i>Bathroom</i>	-0.170940	0.059829	0.017094	0.059829	0.034188	0.000000
<i>Bedroom</i>	0.032544	-0.065088	0.011834	0.014793	0.005917	0.000000
<i>Diningroom</i>	0.010033	0.010033	-0.050166	0.020067	0.010033	0.000000
<i>Kitchen</i>	0.033113	0.039735	0.033113	-0.145697	0.033113	0.006623
<i>Livingroom</i>	0.007937	0.015873	0.015873	0.007937	-0.055557	0.007937
<i>Yard</i>	0.000000	0.083333	0.000000	0.083333	0.083333	-0.249999

Tabla 4.11: Matriz de intensidad para el día jueves.

	<i>Bathroom</i>	<i>Bedroom</i>	<i>Diningroom</i>	<i>Kitchen</i>	<i>Livingroom</i>	<i>Yard</i>
<i>Bathroom</i>	-0.155340	0.038835	0.019417	0.048544	0.048544	0.000000
<i>Bedroom</i>	0.008499	-0.050991	0.005666	0.014164	0.011331	0.011331
<i>Diningroom</i>	0.011628	0.011628	-0.075582	0.029070	0.011628	0.011628
<i>Kitchen</i>	0.027027	0.010811	0.027027	-0.118919	0.032432	0.021622
<i>Livingroom</i>	0.012346	0.012346	0.000000	0.015432	-0.046297	0.006173
<i>Yard</i>	0.057143	0.142857	0.085714	0.028571	0.028571	-0.342856

Tabla 4.12: Matriz de intensidad para el día viernes.

A continuación, se calculan los tiempos esperados de estancia por día en las diferentes habitaciones. Estos tiempos se obtienen de la diagonal principal de la matriz \hat{Q} , mediante la fórmula: $E(T_i) = \frac{1}{q_{ii}}$.

- Los tiempos de permanencia esperados para el día lunes en las diferentes habitaciones son:

<i>Room</i>	$E(T_i) = \frac{1}{q_i}$
<i>Bathroom</i>	5.19
<i>Bedroom</i>	18.34
<i>Diningroom</i>	15.64
<i>Kitchen</i>	5.53
<i>Livingroom</i>	13.91
<i>Yard</i>	2.33

Tabla 4.13: Tiempo de permanencia esperado para el día lunes en minutos.

Con base en la tabla 4.13 se concluye que se esperan obtener cambios de habitación si observamos la conducta cada 2.33 minutos al menos.

- Los tiempos de permanencia esperados para el día martes en las diferentes habitaciones son:

<i>Room</i>	$E(T_i) = \frac{1}{q_i}$
<i>Bathroom</i>	5.76
<i>Bedroom</i>	15.89
<i>Diningroom</i>	14.50
<i>Kitchen</i>	8.37
<i>Livingroom</i>	16.37
<i>Yard</i>	3.14

Tabla 4.14: Tiempo de permanencia esperado para el día martes en minutos.

Con base en la tabla 4.14 se concluye que se espera observar cambios de habitación si observamos la conducta cada 3.14 minutos al menos.

- Los tiempos de permanencia esperados para el día miércoles en las diferentes habitaciones son:

<i>Room</i>	$E(T_i) = \frac{1}{q_{ii}}$
<i>Bathroom</i>	4.68
<i>Bedroom</i>	23.31
<i>Diningroom</i>	14.66
<i>Kitchen</i>	7.40
<i>Livingroom</i>	16
<i>Yard</i>	21.33

Tabla 4.15: Tiempo de permanencia esperado para el día miércoles en minutos.

Con base en la tabla 4.15 se concluye que se espera observar cambios de habitación si observamos la conducta cada 4.68 minutos al menos.

- Los tiempos de permanencia esperados para el día jueves en las diferentes habitaciones son:

<i>Room</i>	$E(T_i) = \frac{1}{q_{ii}}$
<i>Bathroom</i>	5.85
<i>Bedroom</i>	15.36
<i>Diningroom</i>	19.93
<i>Kitchen</i>	6.86
<i>Livingroom</i>	17.99
<i>Yard</i>	4

Tabla 4.16: Tiempo de permanencia esperado para el día jueves en minutos.

Con base en la tabla 4.14 se concluye que se espera observar cambios de habitación si observamos la conducta cada 4 minutos al menos.

- Los tiempo de permanencia esperados para el día viernes en las diferentes habitaciones son:

<i>Room</i>	$E(T_i) = \frac{1}{q_i}$
<i>Bathroom</i>	6.43
<i>Bedroom</i>	19.61
<i>Diningroom</i>	13.23
<i>Kitchen</i>	8.40
<i>Livingroom</i>	21.59
<i>Yard</i>	2.91

Tabla 4.17: Tiempo de permanencia esperado para el día viernes en minutos.

Con base en la tabla 4.17 se concluye que se espera observar cambios de habitación si observamos la conducta cada 2.91 minutos al menos.

Al final, tomando en cuenta los tiempos de permanencia esperado minimos correspondientes a los distintos días de la semana y al notar que son diferentes, se concluye que el periodo de permanencia para el patrón inferido debe ser en intervalos de 3 minutos, es decir, se espera observar los cambios en las trayectorias inferidas en lapsos de 3 minutos.

Después de obtener la estimación de Q y conocer el tiempo de permanencia en el cual se observarían los cambios de estados, se procede a la predicción de la trayectoria en el siguiente sección.

4.4. Aplicación: Predicción de la trayectoria

Para predecir la trayectoria se necesita del cálculo de $P(t)$ en donde t es el tiempo en el cual se va predecir el estado y de un vector de probabilidades iniciales Π . El vector Π se define como: $\Pi = (\Pi_1, \dots, \Pi_k)$ en donde $\Pi_i \geq 0$ para $i = 1, \dots, k$ y $\sum_{i=1}^k \Pi_i = 1$.

Los valores de Π , para el pronóstico de la trayectoria, representan las probabilidades de iniciar en alguna habitación, es decir, $\Pi = [P[\textit{Bathroom}], P[\textit{Bedroom}],$

$P[\textit{Diningroom}], P[\textit{Kitchen}], P[\textit{Livingroom}], P[\textit{Yard}]$. En este caso, este vector consta de un 1 en la probabilidad de la habitación actual (habitación inicial) y el resto de las probabilidades es 0. Para obtener el vector de probabilidades de desplazamiento, con el cual se forma la trayectoria inferida, se calcula:

$$\Pi' = \Pi * P(t) \tag{4.2}$$

A continuación, se muestra el algoritmo que permite estimar la próxima habitación para establecer la trayectoria inferida.

Algoritmo que permite calcular la trayectoria

```

Input: Datos[][]
Result: Estimación de la trayectoria
/* Declaración de variables */
/* Vector que almacena el nombre de las habitaciones en orden
   alfabético */
Rooms[] = Datos[,1]
/* Se considera a t con el valor de tiempo de estancia, en el
   cual, se podría observar cambios */
t = valor de tiempo de espera
/* pi_inicial es el vector de probabilidades iniciales, que se
   actualiza en cada interacción */
pi_inicial = vector de probabilidades inicial.
pi_ac = vector auxiliar /* n es el número de tiempos que contiene la
   trayectoria a pronósticar. Además del tiempo t0 inicial */
n = número de estados a calcular en la trayectoria
pi_ac = pi_inicial
/* Se inicia con la estimación del patrón */
/* 1. Se calcula los valores correspondientes para Q */
Q = obtener_Q(Datos)
for i=1:n do
    /* 2. Se calcula P con el intervalo de tiempo correspondiente
       y Q */
    P = expm (i*t)Q, method = "Taylor", order=12)
    /* 3. Se calcula el nuevo vector de probabilidades iniciales
       */
    Pi_aux = pi_acc * P
    /* 4. Se obtiene el índice del valor máximo del vector Pi_aux
       para identificar el nuevo estado más probable y se guarda
       el nombre de la habitación más probable */
    ind = which.max(Pi_aux)
    Estimacion[i+1]=Rooms[ind]
    /* 5. Se actualiza el vector pi_ac convirtiendo todos los
       valores a 0 */
    pi_ac = 0
    /* 6. Se actualiza el índice que corresponde al máximo con el
       valor a 1, se convierte en el nuevo vector inicial de
       probabilidades */
    pi_ac[ind]=1
end

```

Enseguida, se ejemplifica el algoritmo anterior con el pronóstico de la trayectoria comenzando en la habitación *Kitchen* el día lunes. Además, la trayectoria inferida se compone de 5 tiempos t con intervalos de 3 minutos. A continuación, se muestra la obtención de los estados en los 5 tiempos de t .

El primer estado es la habitación de inicio, en este caso es $X_0 = \textit{Kitchen}$ y $\Pi_0 = [0, 0, 0, 1, 0, 0]$. El siguiente estado se obtiene de la multiplicación de Π_0 con la correspondiente $P(3)$ como se muestra en la Fig. 4.9. Con lo anterior, se obtiene un vector con probabilidades de ir a las diferentes habitaciones, se toma la probabilidad mayor que representa la habitación siguiente a visitar, es decir, $X_1 = \textit{Kitchen}$ con la probabilidad de 0.5968.

$$\begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0.5732 & 0.1436 & 0.0888 & 0.1337 & 0.0478 & 0.0125 \\ 0.0462 & 0.8605 & 0.0311 & 0.0291 & 0.0290 & 0.0039 \\ 0.0351 & 0.0485 & 0.8332 & 0.0676 & 0.0145 & 0.0009 \\ 0.0563 & 0.1522 & 0.1080 & 0.5968 & 0.0768 & 0.0095 \\ 0.0409 & 0.0839 & 0.0076 & 0.0550 & 0.8114 & 0.0010 \\ 0.0219 & 0.6599 & 0.0136 & 0.0130 & 0.0129 & 0.2783 \end{bmatrix} = \begin{bmatrix} 0.0563 & 0.1522 & 0.1080 & 0.5968 & 0.0768 & 0.0095 \end{bmatrix}$$

Figura 4.9: $X_1 = \textit{Kitchen}$, porque la probabilidad máxima es 0.5968 que corresponde a la posición de la habitación *Kitchen*.

Hasta ahora se tiene $X_0 = \textit{Kitchen}$, $X_1 = \textit{Kitchen}$. Para calcular el valor de X_2 se establece como valor de probabilidad inicial a $\Pi_1 = [0, 0, 0, 1, 0, 0]$ y se multiplica por la correspondiente $P(6)$ como se muestra en la Fig. 4.10. Con base al resultado se obtiene la probabilidad más alta que representa a la habitación *Kitchen*.

$$\begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0.3481 & 0.2429 & 0.1444 & 0.1695 & 0.0821 & 0.0126 \\ 0.0702 & 0.7580 & 0.0602 & 0.0524 & 0.0535 & 0.0053 \\ 0.0560 & 0.0993 & 0.7064 & 0.1036 & 0.0321 & 0.0023 \\ 0.0801 & 0.2480 & 0.1650 & 0.3798 & 0.1170 & 0.0098 \\ 0.0639 & 0.1555 & 0.0248 & 0.0859 & 0.6671 & 0.0024 \\ 0.0509 & 0.7585 & 0.0392 & 0.0352 & 0.0355 & 0.0805 \end{bmatrix} = \begin{bmatrix} 0.0801 & 0.2480 & 0.1650 & 0.3798 & 0.1170 & 0.0098 \end{bmatrix}$$

Figura 4.10: $X_2 = \textit{Kitchen}$, porque la probabilidad máxima es 0.3798 que corresponde a la posición de la habitación *Kitchen*.

Para calcular el valor de X_3 se establece como valor de probabilidad inicial a $\Pi_2 = [0,0,0,1,0,0]$ y se tiene multiplica con $P(9)$ el resultado se muestra en la Fig. 4.11, entonces la habitación más probable es *Bedroom* con la probabilidad de 0.3071.

$$\begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0.2291 & 0.3072 & 0.1780 & 0.1692 & 0.1056 & 0.0106 \\ 0.0827 & 0.6814 & 0.0862 & 0.0698 & 0.0738 & 0.0059 \\ 0.0687 & 0.1478 & 0.6082 & 0.1218 & 0.0498 & 0.0034 \\ 0.0896 & 0.3071 & 0.1944 & 0.2624 & 0.1377 & 0.0086 \\ 0.0769 & 0.2149 & 0.0456 & 0.1027 & 0.5559 & 0.0036 \\ 0.0708 & 0.7234 & 0.0660 & 0.0555 & 0.0576 & 0.0264 \end{bmatrix} = \begin{bmatrix} 0.0896 & 0.3071 & 0.1944 & 0.2624 & 0.1377 & 0.0086 \end{bmatrix}$$

Figura 4.11: $X_3 = \textit{Bedroom}$, porque la probabilidad máxima es 0.3071 que corresponde a la posición de la habitación *Bedroom*.

Para calcular el valor de X_4 se establece como valor de probabilidad inicial a $\Pi_3 = [0,1,0,0,0,0]$ y se multiplica con $P(12)$ el resultado se muestra en la Fig. 4.12. Se obtiene que X_4 es *Bedroom* con la probabilidad de 0.6231.

$$\begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0.1659 & 0.3476 & 0.1975 & 0.1586 & 0.1213 & 0.0089 \\ 0.0890 & 0.6231 & 0.1086 & 0.0825 & 0.0903 & 0.0061 \\ 0.0765 & 0.1916 & 0.5311 & 0.1301 & 0.0663 & 0.0042 \\ 0.0930 & 0.3438 & 0.2090 & 0.1986 & 0.1480 & 0.0075 \\ 0.0843 & 0.2629 & 0.0670 & 0.1116 & 0.4696 & 0.0044 \\ 0.0824 & 0.6666 & 0.0906 & 0.0717 & 0.0767 & 0.0117 \end{bmatrix} = \begin{bmatrix} 0.0890 & 0.6231 & 0.1086 & 0.0825 & 0.0903 & 0.0061 \end{bmatrix}$$

Figura 4.12: $X_4 = \textit{Bedroom}$, porque la probabilidad máxima es 0.6231 que corresponde a la posición de la habitación *Bedroom*.

Al final, se tiene la trayectoria pronosticada iniciando en la habitación *Kitchen*, en 5 tiempos de t , con intervalos de 3 minutos: *Kitchen, Kitchen, Kitchen, Bedroom, Bedroom*.

Para una mejor comprensión de las trayectorias inferidas se almacenan en un formato JSON para poder ser visualizadas como líneas de tiempo, como se ilustra en la Fig. 4.13.

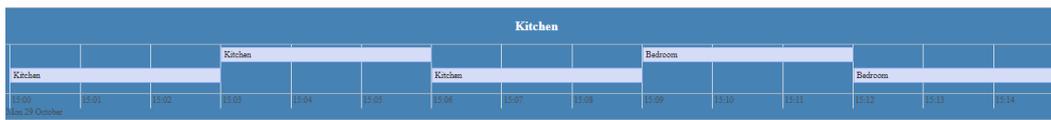


Figura 4.13: Pronóstico de trayectoria para los primeros cinco tiempos, en intervalos de 3 min, para el día lunes.

4.4.1. Visualización de las trayectorias estimadas

El modelo propuesto ofrece la estimación del patrón o trayectoria del desplazamiento a nivel habitación. A continuación, se muestra el resultado obtenido correspondiente a los datos analizados, según el día de la semana:

En el patrón inferido para el día lunes (ver Fig. 4.14), se pueden observar cambios de estados cuando la persona inicia su trayectoria en la habitación *textitBathroom*, *Kitchen* y *Yard* en comparación con el resto de las habitaciones, que permanece en la misma habitación. Lo anterior se debe a que los tiempos de permanencia esperado tienen un valor demasiado grande. Además, es el único día que muestra cambio de estado en la trayectoria comenzando en la habitación *Kitchen* en comparación con el resto de los días.

Por otro lado, los días martes (ver Fig. 4.15), miércoles (ver Fig. 4.16), jueves (ver Fig. 4.17) y viernes (ver Fig. 4.18) solamente muestran cambios en la trayectoria cuando se inicia en la habitación *Bathroom* o *Yard* debido a que tienen un tiempo de permanencia esperado menor a 6 minutos. Lo anterior permite visualizar esos cambios de estado solo en dos trayectorias correspondientes a *Yard* y *Bathroom*.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

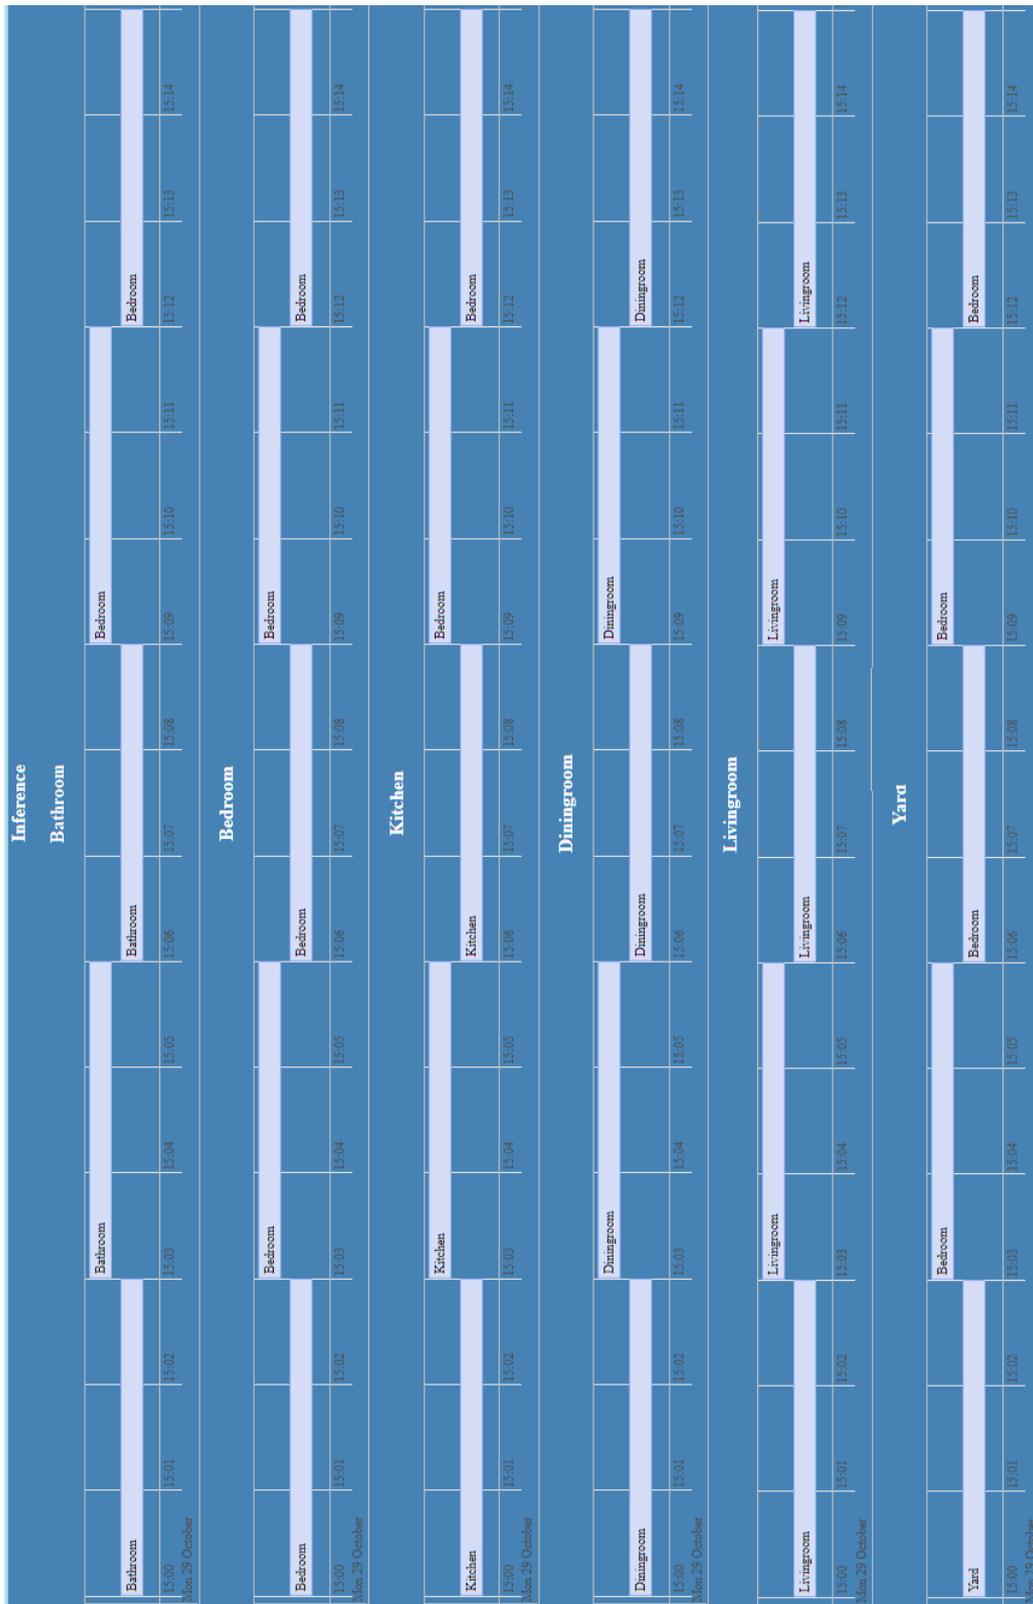


Figura 4.14: Trayectorias estimadas para el día lunes por habitación.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

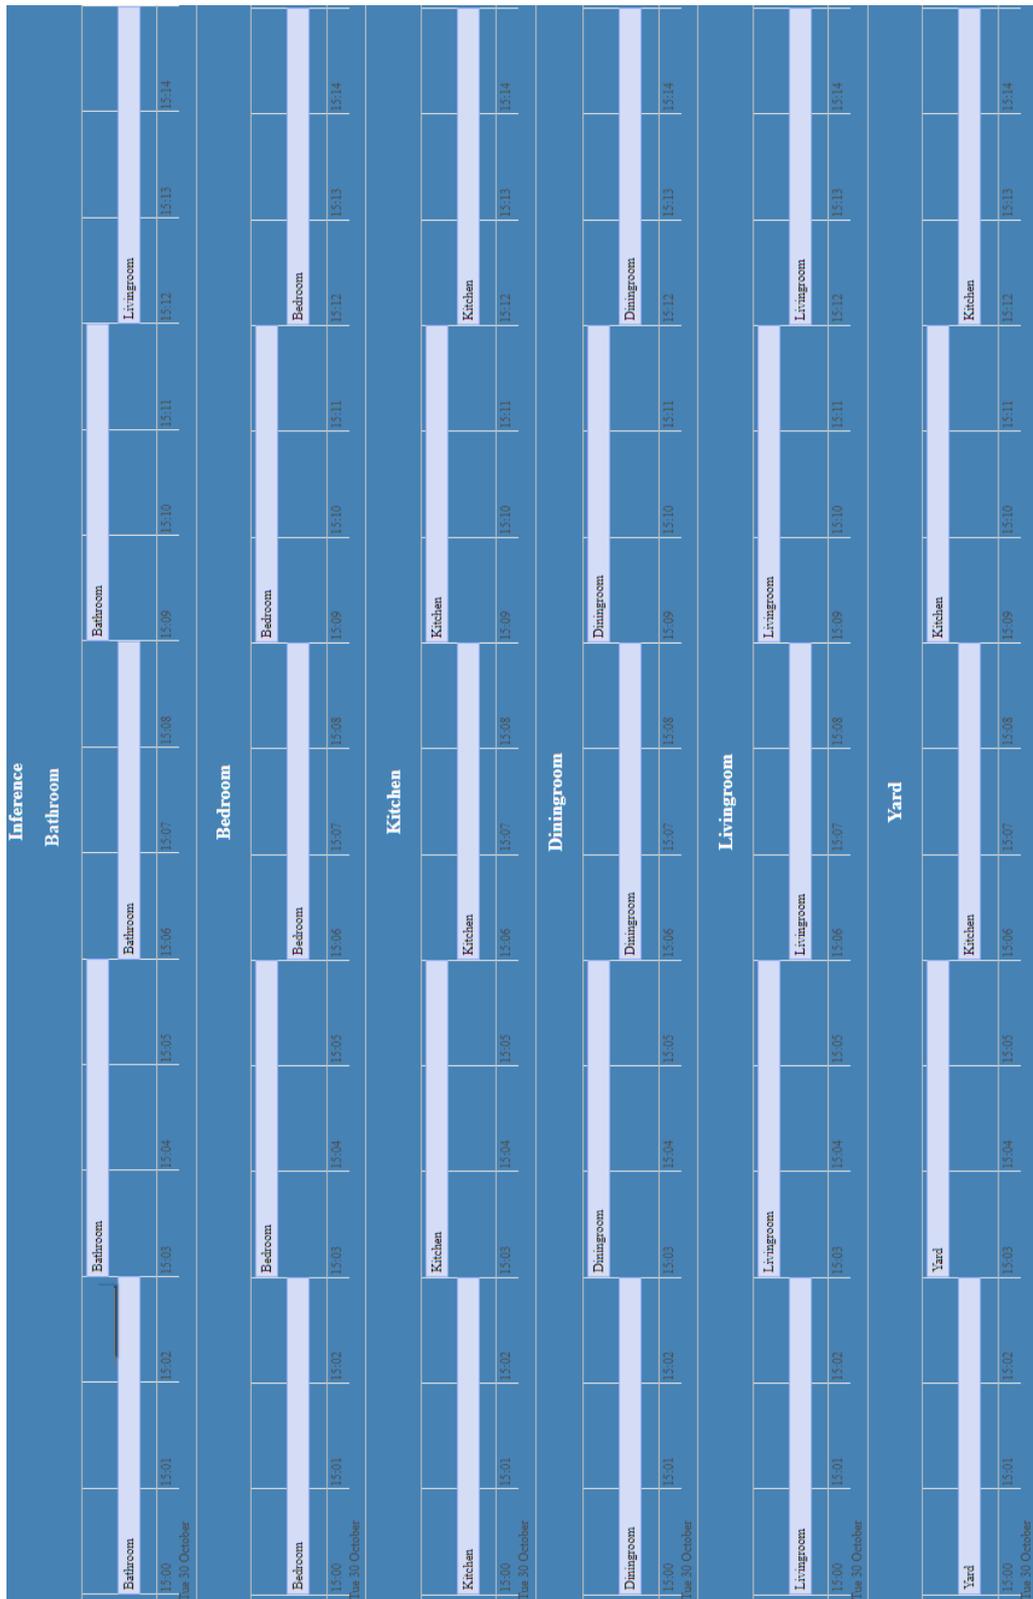


Figura 4.15: Trayectorias estimadas para el día martes por habitación.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

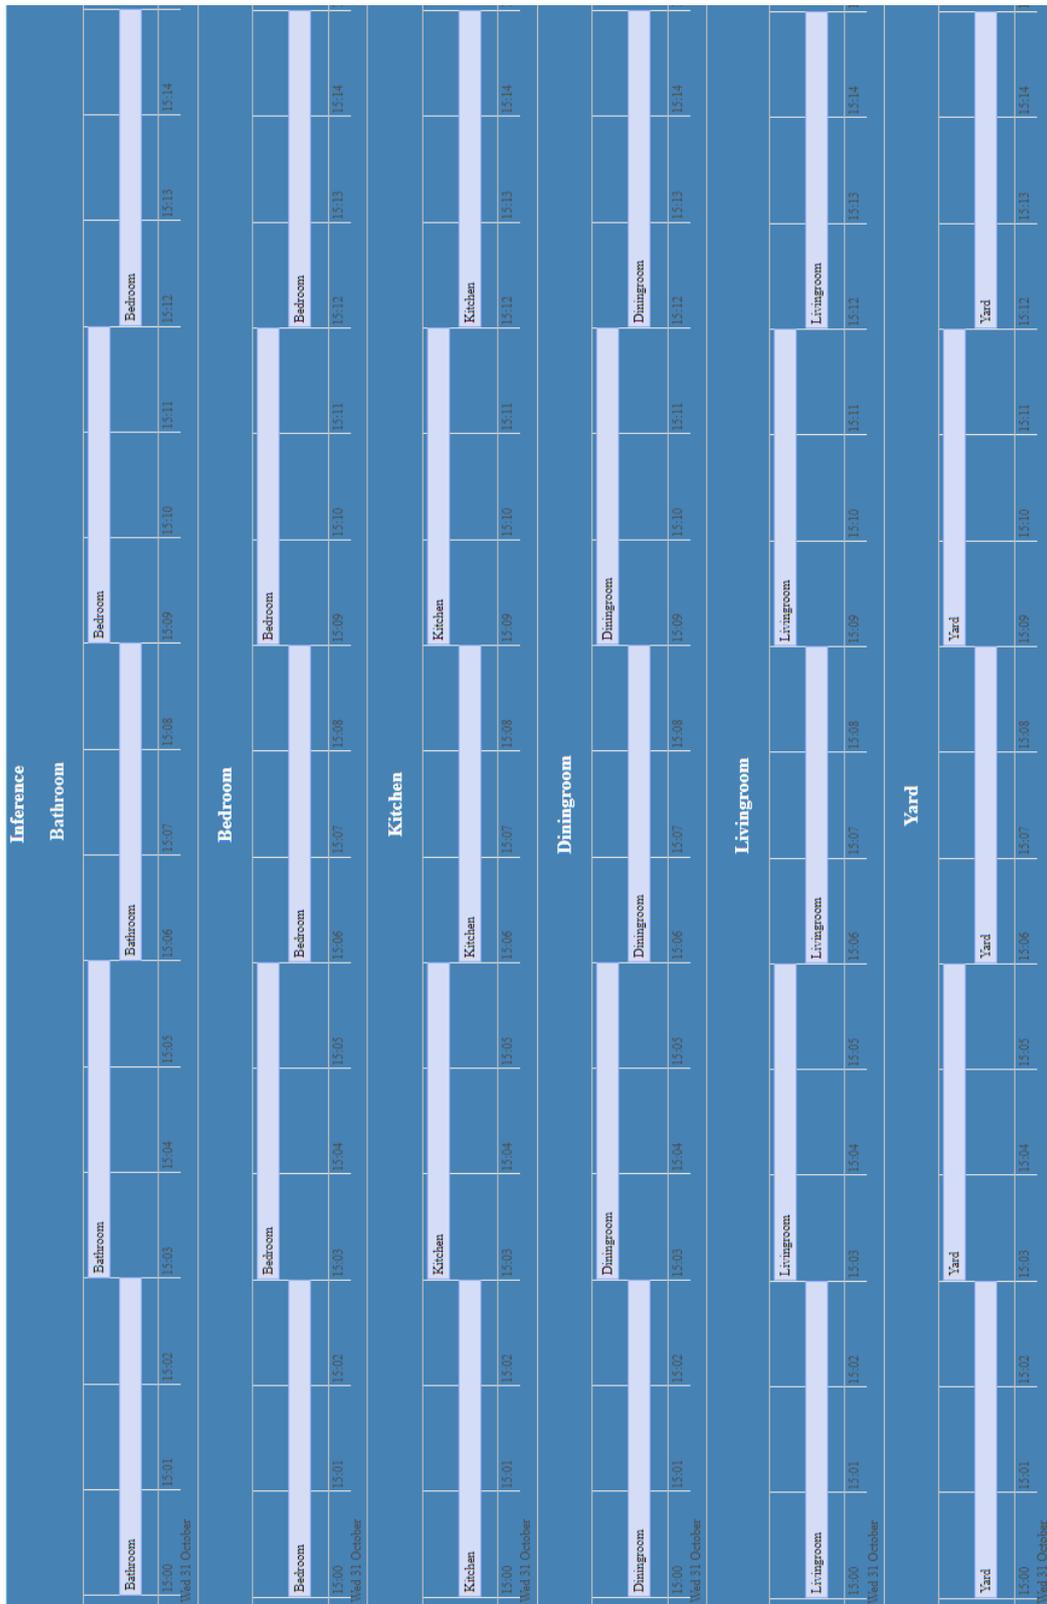


Figura 4.16: Trayectorias estimadas para el día miércoles.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

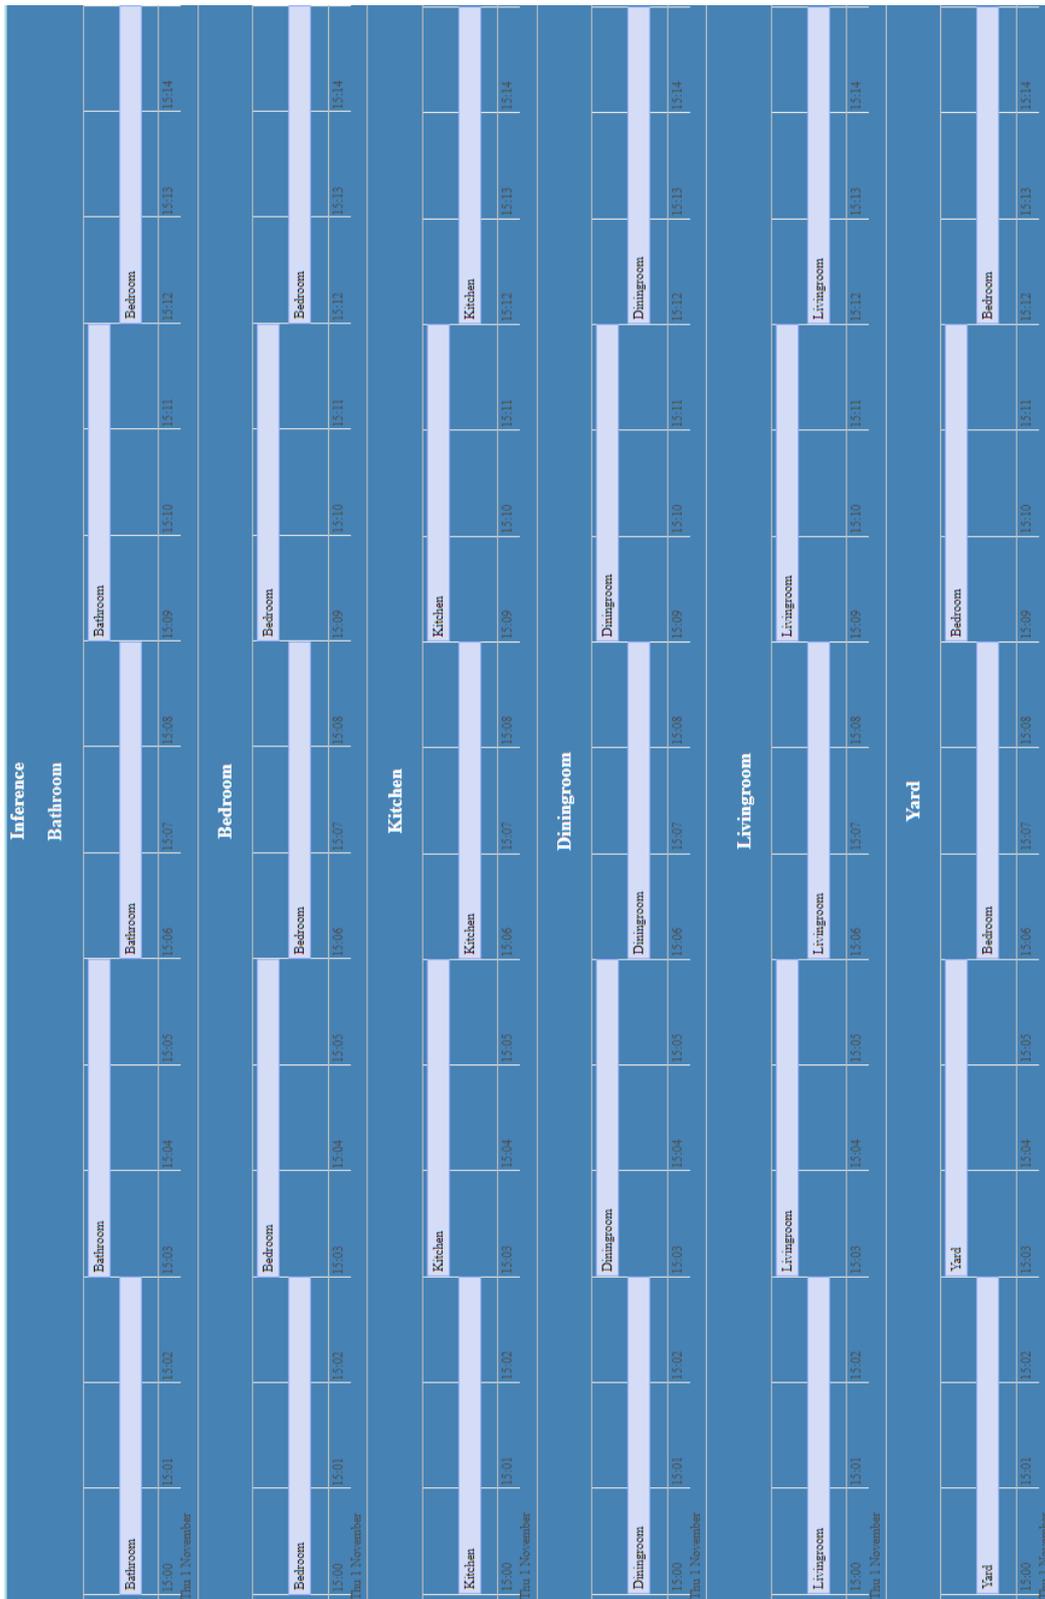


Figura 4.17: Trayectorias estimadas para el día jueves por habitación.

Como se puede observar en las secuencias anteriores, específicamente en las figuras de los patrones de desplazamiento estimados en los diferentes días, se visualiza que el patrón de movimientos seguido por el individuo en estudio es diferente según el día. Lo anterior, se deriva de la suposición de que todos los lunes se comporta igual el individuo, lo mismo sucede con el resto de los días. Por ejemplo, suponer que el individuo comienza en la habitación *Yard*; el siguiente estado sería *Bedroom* según el patrón inferido para el día lunes en comparación con los días jueves y viernes que muestran cambio de habitación hasta el tercer estado, es decir, la trayectoria es *Yard, Yard y Bedroom*. En cambio, para el día miércoles no se muestra alteración del estado en comparación con el día martes que tiende a ir a la habitación *Kitchen*. La observación anterior, se debe a que cada día se calcula una matriz de intensidad con una muestra diferente. Por lo tanto, el tiempo de permanencia esperado difiere. Por ejemplo, el día lunes se espera que la persona permanezca 2.33 minutos en el *Yard* mientras que el resto de la semana se espera un tiempo de permanencia mayor a 3 minutos. Al conocer el patrón inferido por día, los sistemas inteligentes utilizarían esta información como parámetro de entrada. Dicha información puede ayudar a mejorar la decisión de los sistemas inteligentes basándose en un método probabilístico y anticiparse a las acciones del usuario, adecuando el entorno; por ejemplo, encender la calefacción o las luces de la habitación.

Una cuestión importante es que se puede corroborar la existencia de la trayectoria inferida en el historial del individuo. En cuanto a las trayectorias inferidas enmarcadas en recuadros color vino, representan que la persona suele durar mucho tiempo en esas habitaciones, por lo tanto, no visualizamos cambios. Además, los cambios de una habitación a otra mostrados en la trayectorias inferidas (enmarcados en recuadros de color verde) existen en algún momento en el historial de las trayectorias. Lo anterior, se puede observar en las siguientes figuras que representan los días de las semanas.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

En la trayectoria pronosticada para el día lunes (ver Fig. 4.19), se puede notar que al iniciar la trayectoria en la habitación *Bedroom*, *Diningroom* y *Livingroom* se permanece ahí por 15 minutos. Lo anterior se verifica al encontrar en el historial estas habitaciones con tiempo de duración alto como se muestra en la Fig. 4.20 . También, se encontraron los cambios de estados de *Bathroom* a *Bedroom*, de *Kitchen* a *Bedroom* y de *Yard* a *Bedroom* pronosticados por la trayectoria en el historial (ver Fig. 4.20).

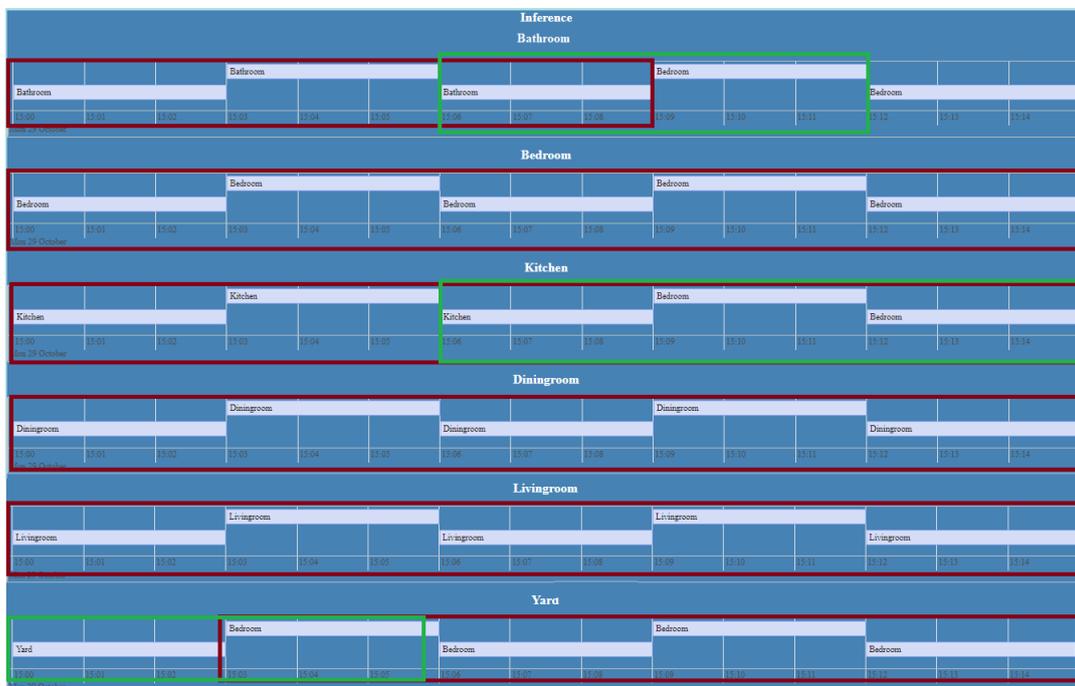


Figura 4.19: Trayectorias estimadas para el día lunes por habitación.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

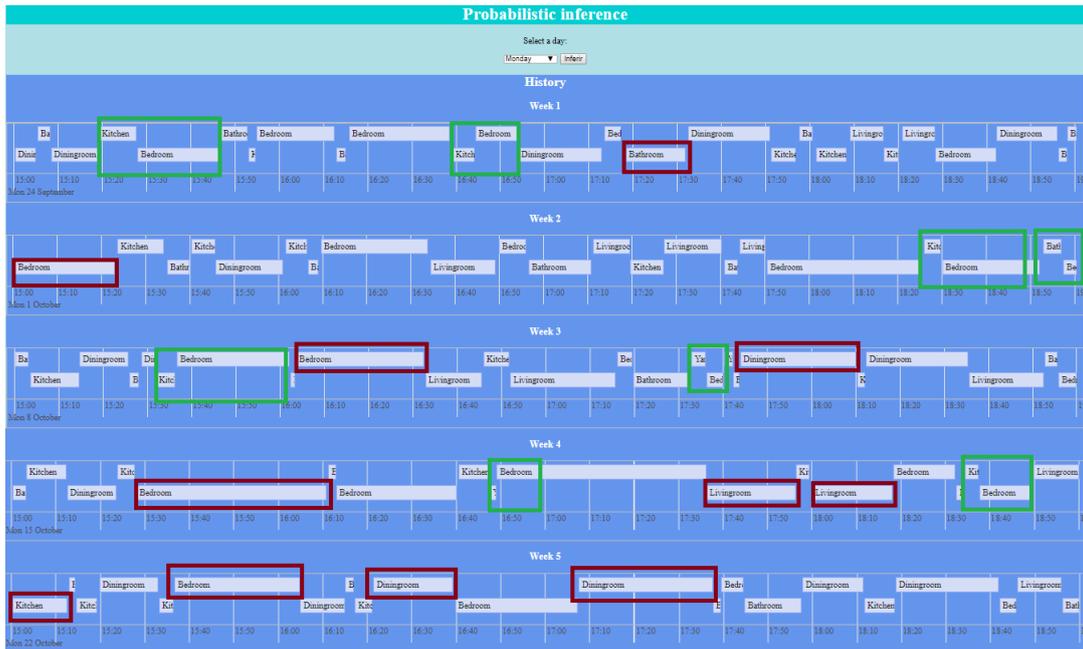


Figura 4.20: Historial de trayectorias correspondiente al día lunes.

Con respecto al martes, se aprecia que las trayectorias pronosticadas iniciando en las habitaciones *Kitchen*, *Bedroom*, *Diningroom* y *Livingroom* se estiman que el individuo pasará mucho tiempo en esas habitaciones (ver Fig. 4.21). Esas trayectorias pronosticadas son encontradas en el historial. También, se encontraron los cambios de habitación de *Bathroom* a *Livingroom* y de *Yard* a *Kitchen* (ver Fig. 4.22).

CAPÍTULO 4. PRUEBAS Y RESULTADOS

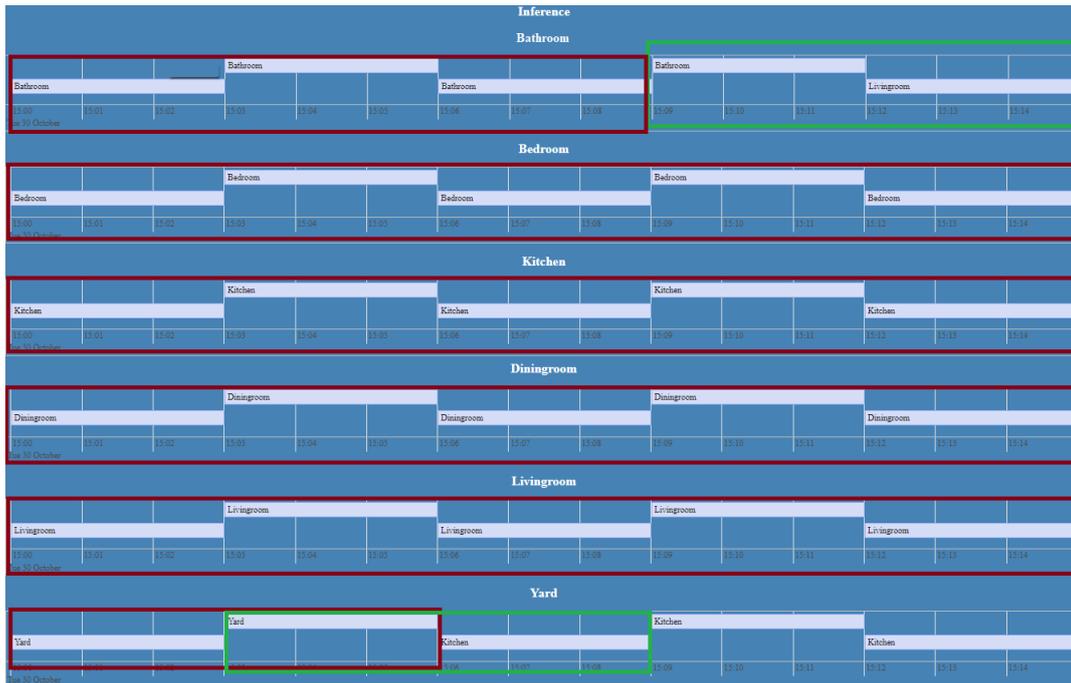


Figura 4.21: Trayectorias estimadas para el día martes por habitación.

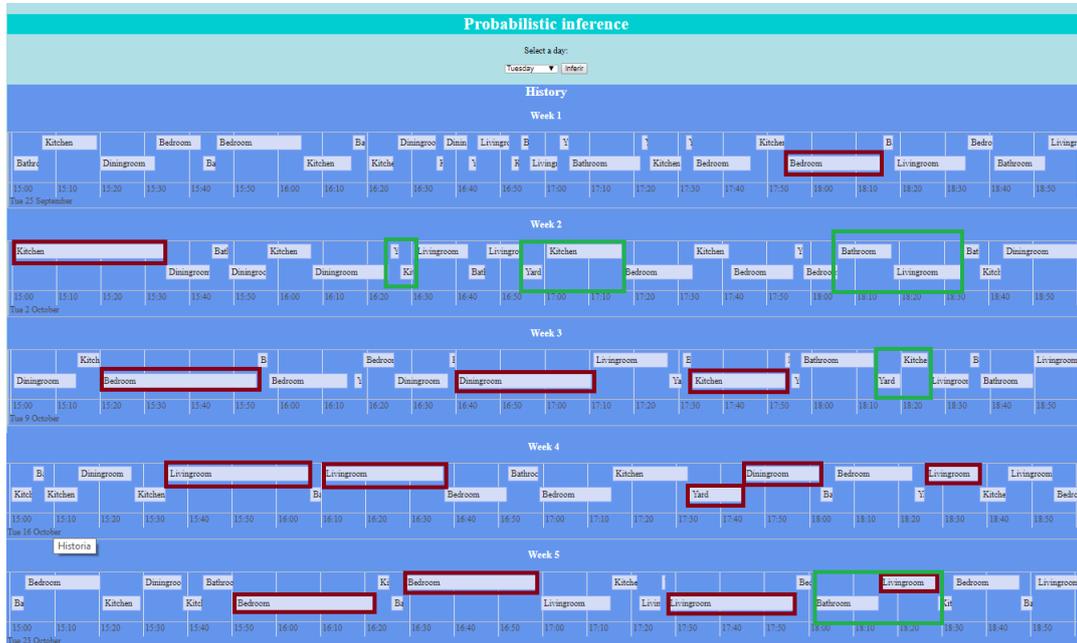


Figura 4.22: Historial de trayectorias correspondiente al día martes.

Con relación con el miércoles, solamente se puede observar un cambio de habitación si la persona inicia su trayectoria en *Bathroom* para ir a *Bedroom* (ver Fig.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

4.23). Al suponer que comienza en el resto de las habitaciones se espera que permanezca en estas. Los cambios anteriores, se hallan en el historial del miércoles (ver Fig. 4.24).

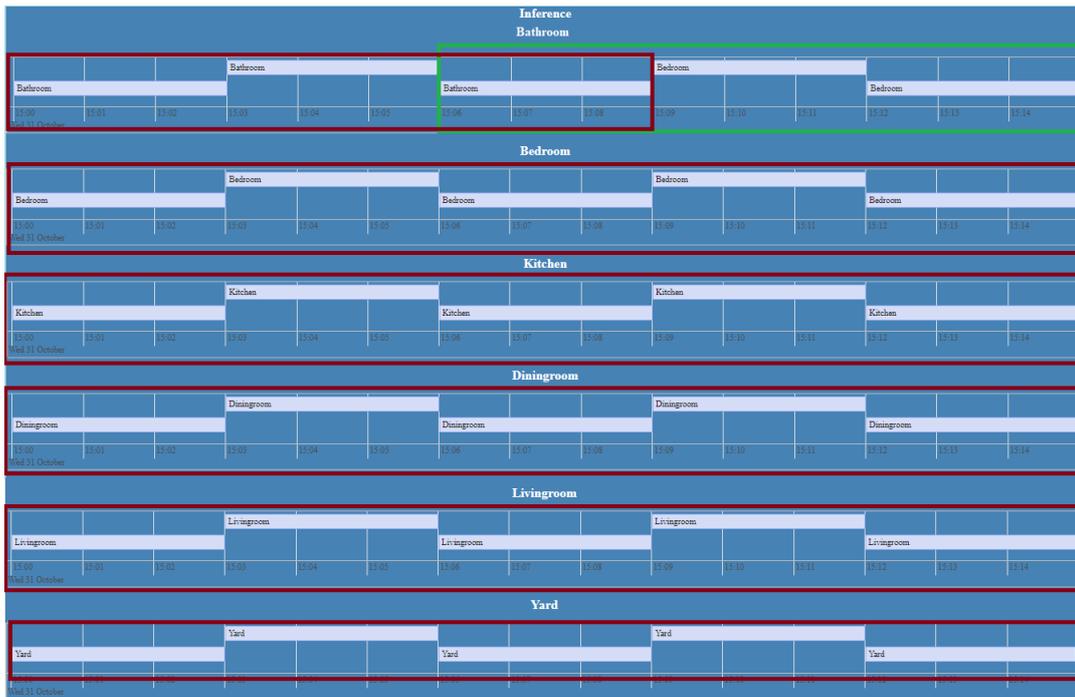


Figura 4.23: Trayectorias estimadas para el día miércoles por habitación.

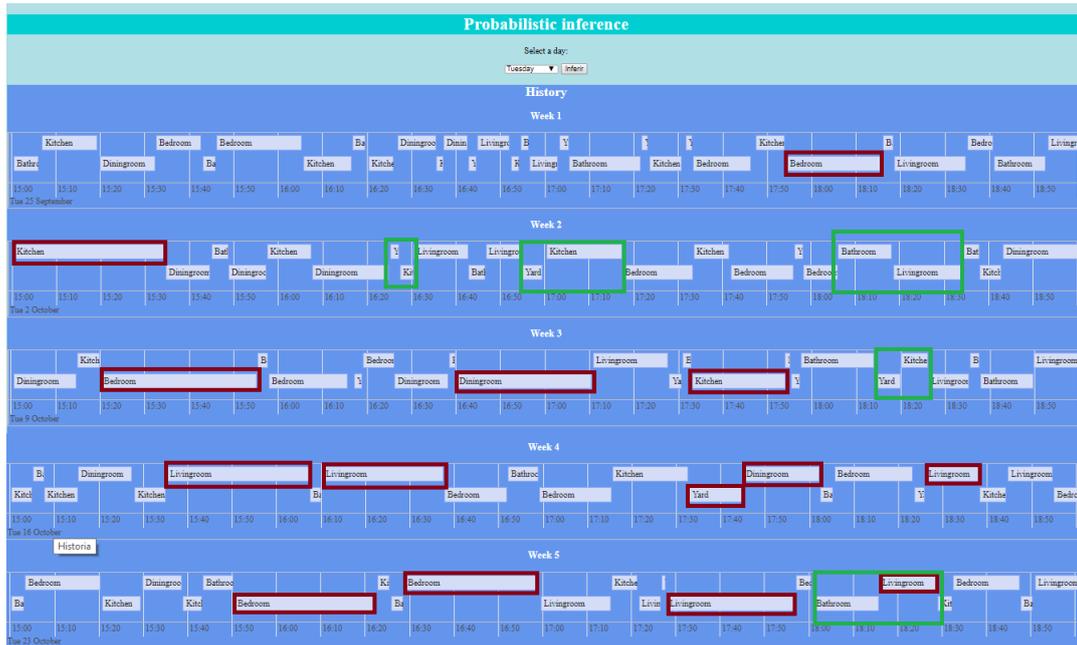


Figura 4.24: Historial de trayectorias correspondiente al día miércoles.

Por lo que concierne al jueves, en la trayectoria pronosticada se presenta que en los 15 minutos se permanece en las habitaciones que inician la trayectoria en *Bedroom*, *Kitchen*, *Diningroom* y *Livingroom*. En el caso de la trayectoria que comienza en las habitaciones *Yard* y *Bathroom*, se observan cambios en la trayectoria como son de *Bathroom* a *Bedroom* y de *Yard* a *Bedroom* (ver Fig. 4.25). Los sucesos anteriores se detectaron en el historial de trayectorias (ver Fig. 4.26).

CAPÍTULO 4. PRUEBAS Y RESULTADOS

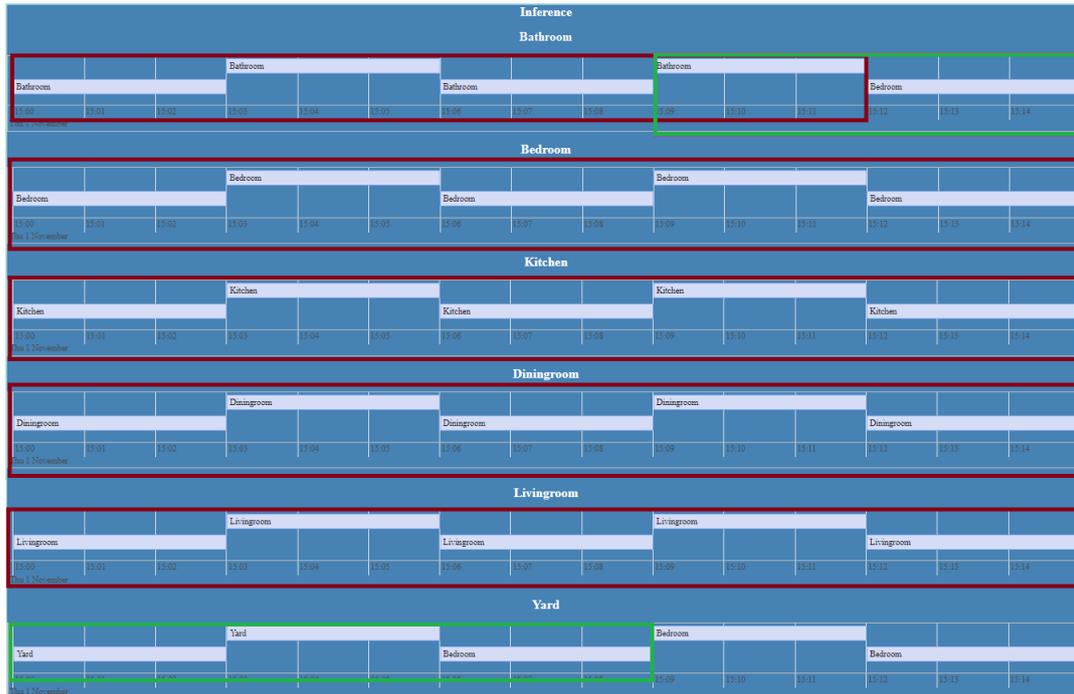


Figura 4.25: Trayectorias estimadas para el día jueves por habitación.

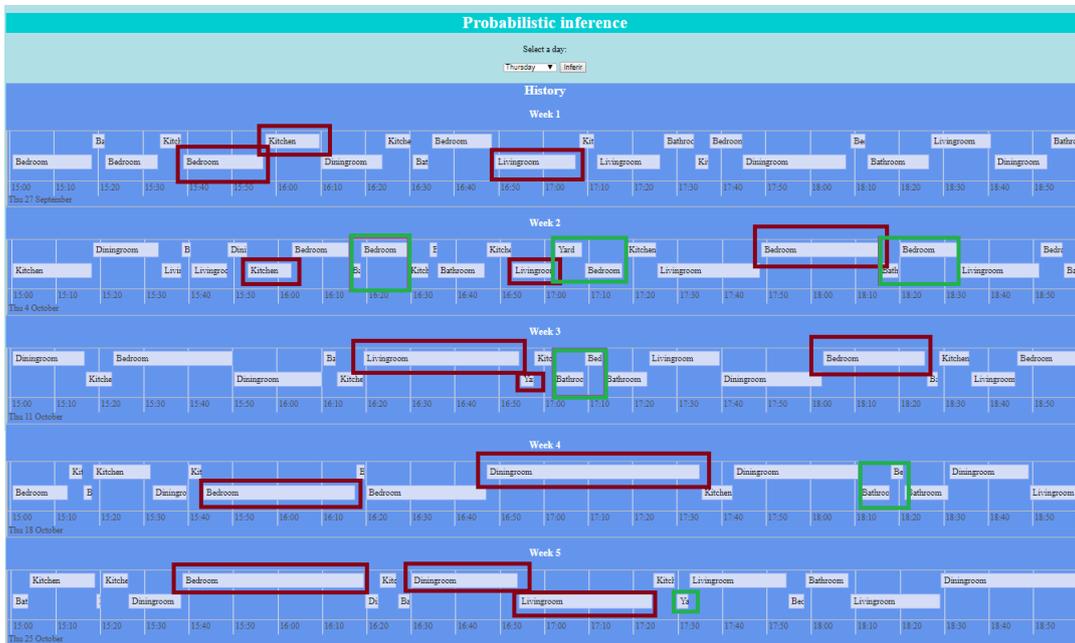


Figura 4.26: Historial de trayectorias correspondiente al día jueves.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

En cuanto al viernes, en la trayectoria pronosticada se muestra que se permanece los 15 minutos en las habitaciones *Bedroom*, *Kitchen*, *Diningroom* y *Livingroom*. Además, se observan cambios entre *Bathroom* a *Livingroom* y *Yard* a *Bedroom* como se muestra en Fig. 4.27. Lo mencionado previamente, se detecta en el historial (ver Fig. 4.28).

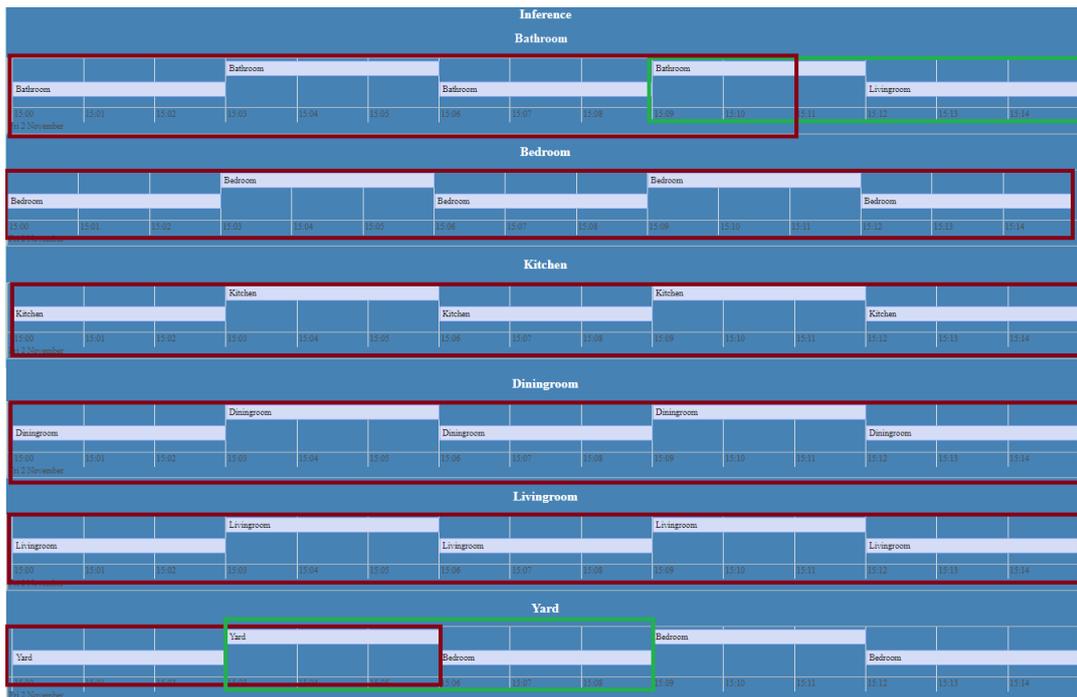


Figura 4.27: Trayectorias estimadas para el día viernes por habitación.

CAPÍTULO 4. PRUEBAS Y RESULTADOS

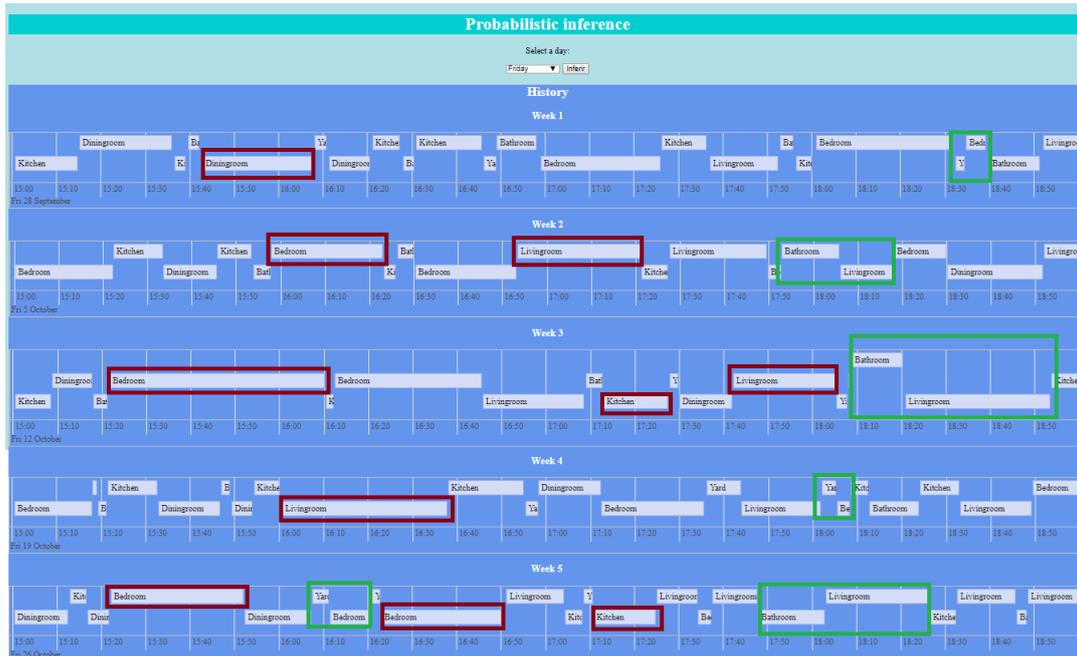


Figura 4.28: Historial de trayectorias correspondiente al día viernes.

Al final, se obtiene una interfaz (Ver Fig. 4.29) que permite visualizar: el historial de las trayectorias en el apartado History, y en el fragmento de Inference se muestra las trayectorias inferidas tomando en cuenta el estado inicial en las distintas habitaciones.

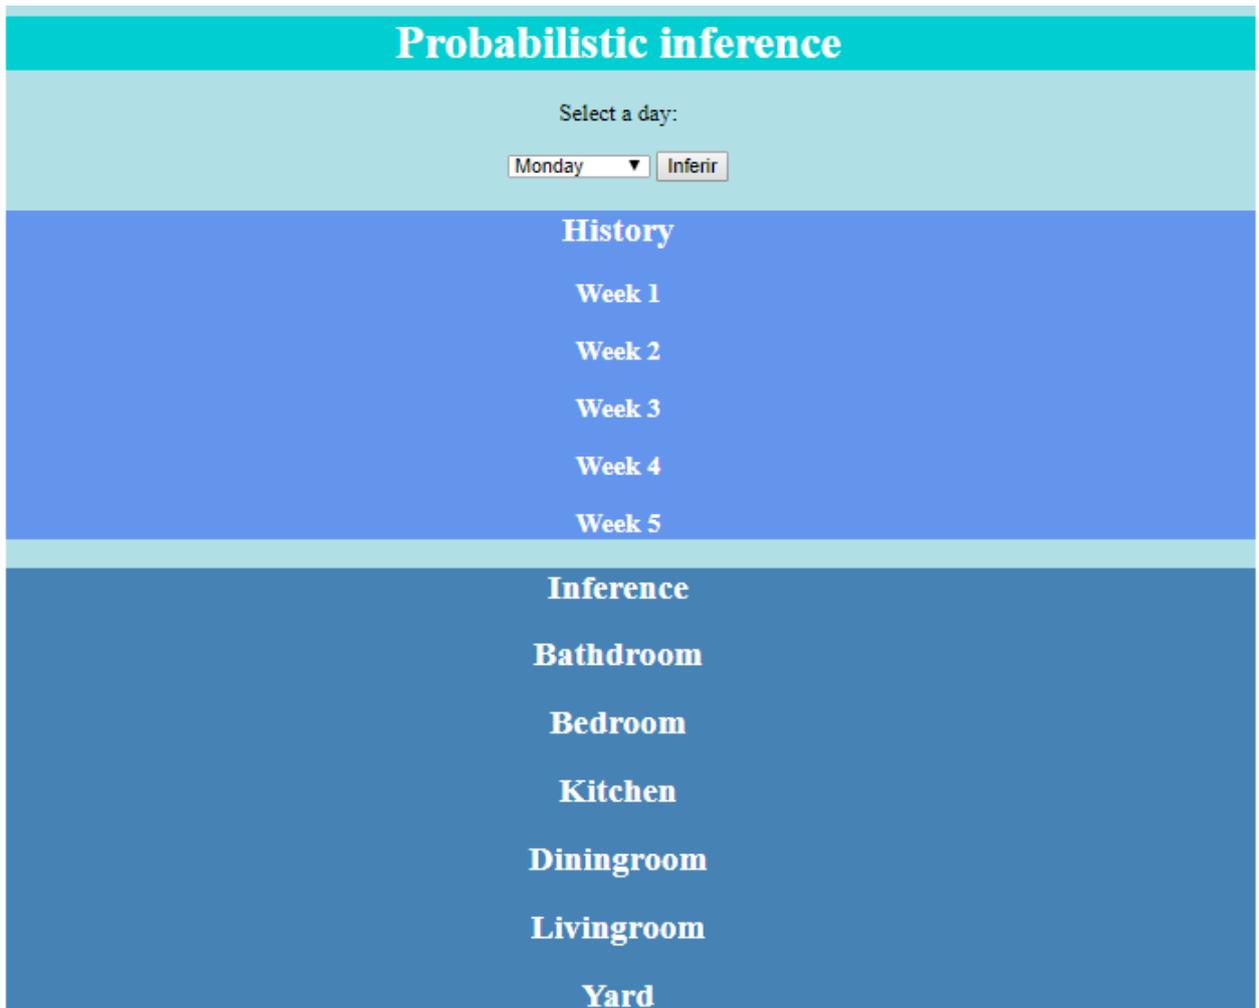


Figura 4.29: Interfaz principal.

Capítulo 5

Conclusiones y trabajos a futuro

En la actualidad la población concentrada en el segmento del adulto mayor, es decir personas con edad mayor a 60 años, se encuentra en proceso de crecimiento según los estudios demográficos llevado a cabo por el INEGI y las estimaciones de la OMS. Debido al incremento poblacional, en este segmento surgen problemáticas que impiden el desarrollo adecuado del adulto mayor, por lo tanto, conlleva a encontrar soluciones que permitan una mejor calidad de vida.

Existe un área denominada AAL, la cual tiene como objetivo primordial el prolongar la calidad de vida del adulto mayor en un ambiente independiente, de manera que el individuo pueda vivir en un ambiente seguro; lo anterior es posible en un ambiente inteligente. La clave fundamental para este ambiente es poder anticiparse a los movimientos del adulto mayor, tanto en la ubicación de la persona en su hogar, así como la actividad que realiza para lograr una asistencia más acertada.

Por lo anterior, en este proyecto de tesis se propuso el desarrollo de un modelo probabilístico que permita obtener el patrón de desplazamiento, a nivel habitacional, de los adultos mayores en el interior de su hogar. Para conseguirlo se planteó la implementación de procesos estocásticos, específicamente el uso de la cadena de Markov en tiempo continuo. Dicho modelo, es el motor primordial

para el funcionamiento del módulo de inferencia del patrón de desplazamiento. Por cuestiones de tiempo, se pospone para trabajo a futuro obtener el patrón de desplazamiento a nivel actividad.

La prueba experimental se realizó como una prueba de concepto, debido a que la tecnología empleada para la obtención de la base de datos llega a ser tediosa para el adulto mayor. Por consiguiente, la base de datos se conforma con información obtenida de un individuo que vive de manera independiente en su hogar. La base de datos generada contiene información del monitoreo de 6 habitaciones con permanencia de 5 semanas, específicamente de lunes a viernes, en un periodo de tiempo con duración de 4 horas.

Los objetivos planteados en el trabajo de tesis se cumplen con el desarrollo del módulo de inferencia de patrón de desplazamiento, dado que se consiguió obtener el modelo probabilístico que permite aproximar numéricamente el valor de los parámetros y, posteriormente calcular el patrón de desplazamiento. También, se realizó la verificación que los datos correspondan a una cadena de Markov y que el comportamiento del individuo es homogéneo. Además, se añade una previa visualización del patrón de desplazamiento.

Los resultados obtenidos en la tesis son satisfactorios, dado que existe un potencial en la implementación de las cadenas de Markov en tiempo continuo para la estimación del patrón de desplazamiento, y en efecto motiva a continuar con este enfoque para la estimación del patrón de desplazamiento. No obstante, como trabajo a futuro se sugiere:

- Integrar el módulo de patrón de desplazamiento, a nivel habitacional, al proyecto de tesis en [8], creando solamente una misma plataforma.
- Permitir que el módulo de patrón de desplazamiento, a nivel habitacional, actualice los parámetros según el historial de los registros, ser más autónomo

y ejecutarse de manera continua.

- Realizar un módulo de patrón de desplazamiento, a nivel actividades, basado en métodos de procesos estocásticos.
- Verificar la homogeneidad con pruebas estadísticas.
- Verificar con pruebas estadísticas la constancia del patrón de comportamiento según el día de la semana.
- Hacer que el módulo de patrón de desplazamiento, a nivel habitacional, pueda detectar cambios en la conducta y emitir una alarma, para recalcular los parámetros de la cadena de Markov con base en el historial que pertenezca al mismo proceso, es decir, tal vez desechar información ya antigua y obtener los datos pertinentes al nuevo patrón de comportamiento.

Anexos

Diagrama de componentes

El diagrama de componentes de la inferencia del patrón de desplazamiento está compuesto por el apartado de presentación y lógica que se describen a continuación:

El apartado de presentación contiene un módulo:

- El módulo interfaz de usuario proporciona una interfaz que genera la visualización gráfica del historial de trayectorias y los patrones pronosticados iniciando en las diferentes habitaciones.

El apartado de lógica contiene la interacción de los diferentes módulos con el objetivo de inferir el patrón de desplazamiento conformado por los siguientes módulos:

- Administrador de datos: usa el script `obtenerDatosFormato.R` para obtener la información de la base de datos (de OPAIEH) para ser procesados para la interfaz del cliente Web inferencia. De igual manera, adapta la información en el formato requerido para la validación y el motor de inferencia del patrón.
- Motor de validación: implementa el algoritmo contenido en `validacionScript.R` que permite validar la información obtenida del módulo de admi-

nistrador de datos.

- Motor de inferencia del patrón: utiliza el algoritmo contenido en InferenciaScript.R que permite la creación del patrón de desplazamiento. Además, genera el archivo correspondiente para el módulo cliente web inferencia.
- El administrador de archivos gestiona la información generada por el Motor de inferencia del patrón y el administrador de datos cuando el módulo de interfaz de usuario solicita cierto dato.

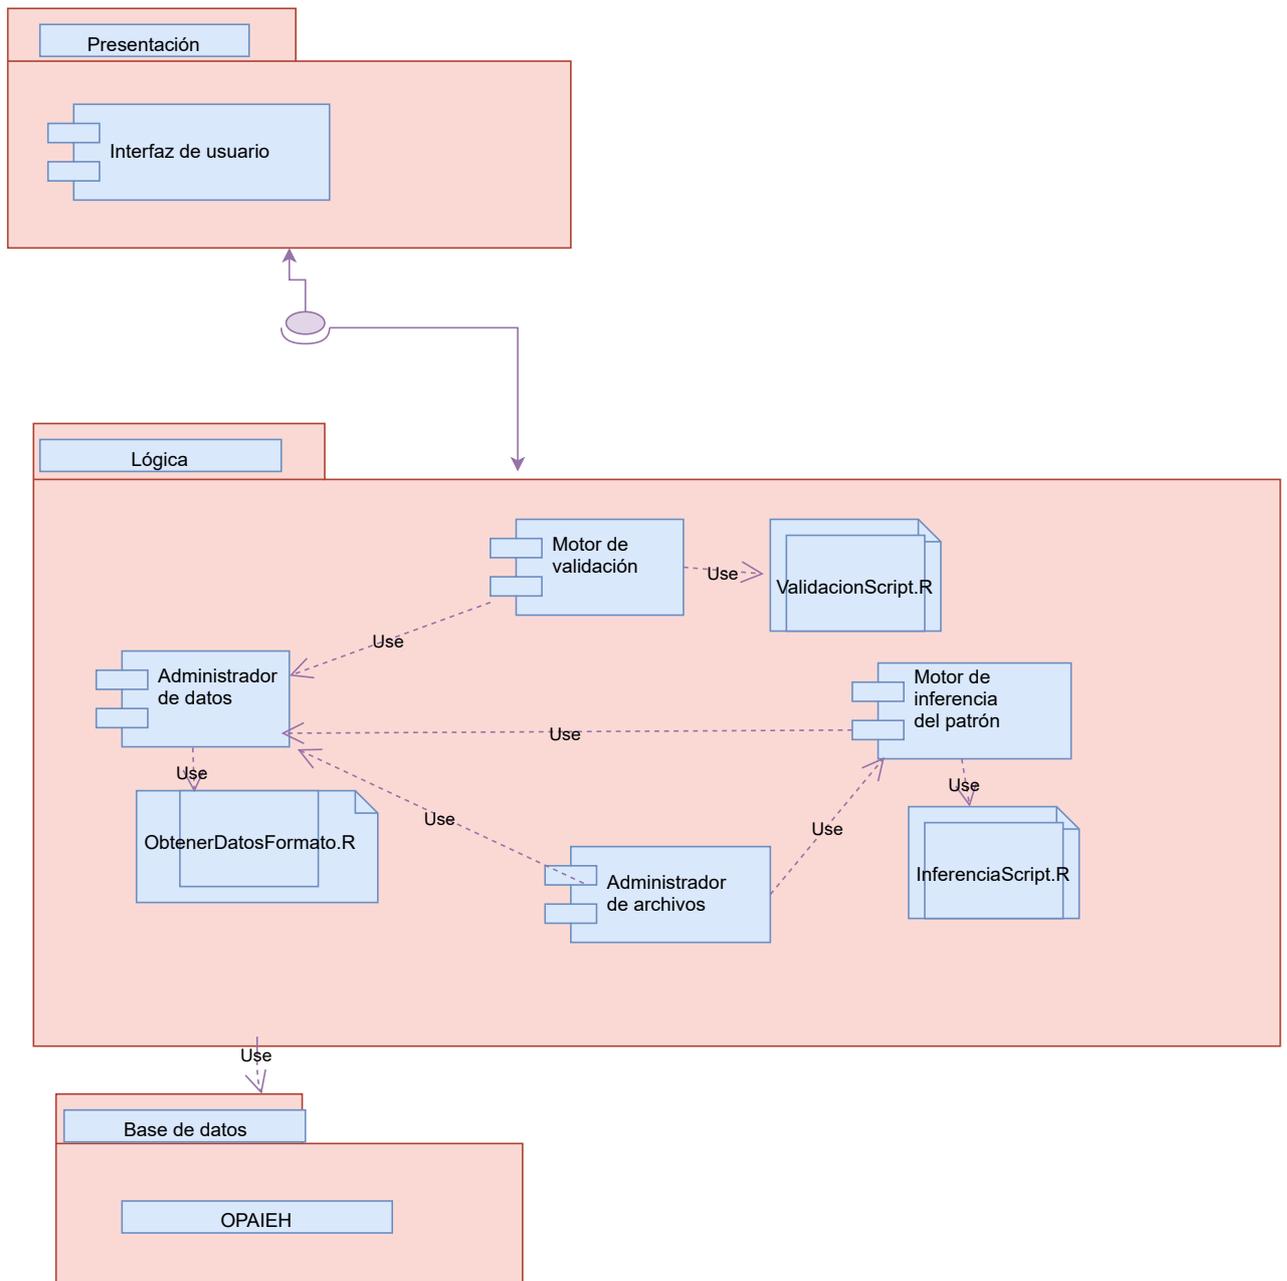


Figura 5.1: Diagrama de componentes: Inferencia del patrón de desplazamiento.

Bibliografía

- [1] ALAM, M. R., REAZ, M. B. I., ALI, M. A. M., SAMAD, S. A., HASHIM, F. H., AND HAMZAH, M. K. Human activity classification for smart home: A multiagent approach. In *2010 IEEE Symposium on Industrial Electronics and Applications (ISIEA)* (Oct 2010), pp. 511–514.
- [2] ALVARADO, A., AND SALAZAR, N. Análisis del concepto de envejecimiento. *Gerokomos* 25 (06 2014), 57–62.
- [3] BESAG, J., AND MONDAL, D. Exact goodness-of-fit tests for markov chains. *Biometrics* 69, 2 (2013), 488–496.
- [4] BLADT, M., AND SORENSEN, M. Statistical inference for discretely observed markov jump processes. *Journal of the Royal Statistical Society. Series B (Statistical Methodology)* 67, 3 (2005), 395–410.
- [5] BOSQ, Q., AND NGUYEN, H. *A course in Stochastic Process: Stochastic Models and Statistical Inference*. Springer, 1996.
- [6] BRDICZKA, O., LANGET, M., MAISONNASSE, J., AND CROWLEY, J. L. Detecting human behavior models from multimodal observation in a smart home. *IEEE Transactions on Automation Science and Engineering* 6, 4 (Oct 2009), 588–597.
- [7] CARRILLO, C., AND MONTALVO, J. R. G. Plataforma no-intrusiva para la asistencia del adulto mayor en actividades en el hogar. Tech. rep., Universidad Autónoma de Yucatán, 2017.
- [8] CARRILLO ANTONIO, C. Plataforma no intrusiva para el reconocimiento de actividades al interior del hogar de los adultos mayores. Master’s thesis, Universidad autónoma de yucatán, 2018.

- [9] CHAN, M., HARITON, C., RINGEARD, P., AND CAMPO, E. Smart house automation system for the elderly and the disabled. In *1995 IEEE International Conference on Systems, Man and Cybernetics. Intelligent Systems for the 21st Century* (Oct 1995), vol. 2, pp. 1586–1589 vol.2.
- [10] CHEN, L., OKEYO, G., WANG, H., STERRITT, R., AND NUGENT, C. A systematic approach to adaptive activity modeling and discovery in smart homes. In *2011 4th International Conference on Biomedical Engineering and Informatics (BMEI)* (Oct 2011), vol. 4, pp. 2192–2196.
- [11] CHU, S. R., SHOURESHI, R., AND TENORIO, M. Neural networks for system identification. *IEEE Control Systems Magazine* 10, 3 (April 1990), 31–35.
- [12] DUONG, T. V., BUI, H. H., PHUNG, D. Q., AND VENKATESH, S. Activity recognition and abnormality detection with the switching hidden semi-markov model. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)* (June 2005), vol. 1, pp. 838–845 vol. 1.
- [13] GHAHRAMANI, Z. An introduction to hidden markov models and bayesian networks. *IJPRAI* 15 (02 2001), 9–42.
- [14] GUBNER, J. A. *Probability and Random Processes for Electrical and Computer Engineers*. Cambridge University Press, 2006.
- [15] HARRIS, C., AND CAHILL, V. Exploiting user behaviour for context-aware power management. In *WiMob'2005), IEEE International Conference on Wireless And Mobile Computing, Networking And Communications, 2005.* (Aug 2005), vol. 4, pp. 122–130 Vol. 4.
- [16] HOEY, J., POUPART, P., VON BERTOLDI, A., CRAIG, T., BOUTILIER, C., AND MIHAILIDIS, A. Automated handwashing assistance for persons with dementia using video and a partially observable markov decision process. *Computer Vision and Image Understanding* 114, 5 (2010), 503 – 519. Special issue on Intelligent Vision Systems.
- [17] HONG, Y., KIM, I., AHN, S. C., AND KIM, H. Activity recognition using wearable sensors for elder care. In *2008 Second International Conference on Future Generation Communication and Networking* (Dec 2008), vol. 2, pp. 302–305.

- [18] INEGI. Estadística a propósito del día internacional de las personas de edad. [http : //www.inegi.org.mx/saladeprensa/aproposito/2017/edad2017_Nal.pdf](http://www.inegi.org.mx/saladeprensa/aproposito/2017/edad2017_Nal.pdf), 2017.
- [19] KIM, E., HELAL, S., AND COOK, D. Human activity recognition and pattern discovery. *IEEE Pervasive Computing* 9, 1 (Jan 2010), 48–53.
- [20] KRUMM, J., HARRIS, S., MEYERS, B., BRUMITT, B., HALE, M., AND SHAFER, S. Multi-camera multi-person tracking for easy living. In *Proceedings Third IEEE International Workshop on Visual Surveillance* (July 2000), pp. 3–10.
- [21] LEO, M., MEDIONI, G., TRIVEDI, M., KANADE, T., AND FARINELLA, G. Computer vision for assistive technologies. *Computer Vision and Image Understanding* 154 (09 2016).
- [22] LEON-GARCIA, A. *Probability, Statistics, and Random Processes for Electrical Engineering*. Pearson Education, Inc., 2008.
- [23] LI, R., LU, B., AND McDONALD-MAIER, K. D. Cognitive assisted living ambient system: a survey. *Digital Communications and Networks* 1, 4 (2015), 229 – 252.
- [24] LOTFI, A., LANGENSIEPEN, C., AND ELBAYOUDI, A. Interpretation of behaviour evolution in activities of daily living. In *Proceedings of the 8th ACM International Conference on Pervasive Technologies Related to Assistive Environments* (New York, NY, USA, 2015), ACM, pp. 84:1–84:2.
- [25] MIHAILIDIS, A., CARMICHAEL, B., AND BOGER, J. The use of computer vision in an intelligent environment to support aging-in-place, safety, and independence in the home. *IEEE Transactions on Information Technology in Biomedicine* 8, 3 (Sep. 2004), 238–247.
- [26] NIDHIL, K. J., SREERAJ, S., VIJAY, B., AND BAGYAVEERESWARAN, V. System identification using artificial neural network. In *2015 International Conference on Circuits, Power and Computing Technologies [ICCPCT-2015]* (March 2015), pp. 1–4.
- [27] NORRIS, J. *Markov Chains*. Cambridge University, 1996.

- [28] OMS. 10 datos sobre el envejecimiento y la salud. <http://www.who.int/features/factfiles/ageing/es/>, 2017.
- [29] OMS. Programa de la oms para entornos adaptados a las personas mayores. <http://www.who.int/ageing/projects/agefriendlycitiesprogramme/es/>, 2017.
- [30] PAOLA, A. D., FERRARO, P., GAGLIO, S., RE, G. L., MORANA, M., ORTOLANI, M., AND PERI, D. An ambient intelligence system for assisted living. In *2017 AEIT International Annual Conference* (Sept 2017), pp. 1–6.
- [31] PETZOLD, J., PIETZOWSKI, A., BAGCI, F., TRUMLER, W., AND UNGERER, T. Prediction of indoor movements using bayesian networks. In *Proceedings of the First International Conference on Location- and Context-Awareness* (Berlin, Heidelberg, 2005), LoCA'05, Springer-Verlag, pp. 211–222.
- [32] PEYTON, Z., AND PEEPLES, J. *Principios de probabilidad, variables aleatorias y señales aleatorias*. McGrawHill, 2006.
- [33] PFEUFFER, M. ctmc: An R Package for Estimating the Parameters of a Continuous-Time Markov Chain from Discrete-Time Data. *The R Journal* 9, 2 (2017), 127–141.
- [34] RAJARSHI, M. *Statistical Inference for Discret Time Stochastic Processes*. New Delhi:Springer, 2013.
- [35] RASHIDI, P., AND COOK, D. Keeping the resident in the loop: Adapting the smart home to the user. *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on* 39 (10 2009), 949 – 959.
- [36] RASHIDI, P., AND COOK, D. J. Com: A method for mining and monitoring human activity patterns in home-based health monitoring systems. *ACM Trans. Intell. Syst. Technol.* 4, 4 (Oct. 2013), 64:1–64:20.
- [37] REAZ, M. Artificial intelligence techniques for advanced smart home implementation. In *Acta technica corviniensis* (2013), vol. VI, pp. 51–57.
- [38] SALAH, A. A., KRÖSE, B. J. A., AND COOK, D. J. Behavior analysis for elderly. In *Human Behavior Understanding* (Cham, 2015), A. A. Salah, B. J. Kröse, and D. J. Cook, Eds., Springer International Publishing, pp. 1–10.

- [39] SAMUEL, A. L. Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development* 3, 3 (July 1959), 210–229.
- [40] SANCHEZ, V., PFEIFFER, C. F., AND SKEIE, N.-O. A review of smart house analysis methods for assisting older people living alone. *Journal of Sensor and Actuator Networks* 6 (09 2017).
- [41] YATES, R., AND GOODMAN, D. *Probability and Stochastics Processes: A Friendly Introduction for Electrical and Computer Engineers*. John Wiley and Sons, 2005.
- [42] YIN, G., AND BRUCKNER, D. Data analyzing and daily activity learning with hidden markov model. In *2010 International Conference on Computer Application and System Modeling (ICCASM 2010)* (Oct 2010), vol. 3, pp. V3–380–V3–384.
- [43] YIN, J., ZHANG, Q., AND KARUNANITHI, M. Unsupervised daily routine and activity discovery in smart homes. In *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (Aug 2015), pp. 5497–5500.
- [44] ZHANG, C., AND GRUVER, W. A. Distributed agent system for behavior pattern recognition. In *2010 International Conference on Machine Learning and Cybernetics* (July 2010), vol. 1, pp. 204–209.
- [45] ZISBERG, A., YOUNG, H. M., AND SCHEPP, K. Development and psychometric testing of the scale of older adults’ routine. *Journal of Advanced Nursing* 65, 3 (2009), 672–683.