

# Jornadas de Automática

## Detección de actividades mediante modelos ocultos de Markov jerárquicos

Gómez-Ramos, R.<sup>a,b,\*</sup>, Duque-Domingo, J.<sup>b</sup>, Zalama, E.<sup>a,b</sup>, Gómez-García-Bermejo, J.<sup>a,b</sup>

<sup>a</sup>Centro Tecnológico CARTIF, Boecillo, 47151 Valladolid, España.

<sup>b</sup>ITAP-DISA, Universidad de Valladolid, 47002 Valladolid, España.

**To cite this article:** Gómez-Ramos, R., Duque-Domingo, J., Zalama, E., Gómez-García-Bermejo, J. 2024. Detection of activities using hierarchical hidden Markov models. *Jornadas de Automática*, 45. <https://doi.org/10.17979/ja-cea.2024.45.10778>

### Resumen

En los últimos años, el interés en el desarrollo de tecnologías avanzadas para detectar y analizar las actividades y los patrones de comportamiento de las personas mayores en sus hogares ha crecido, con el objetivo de mejorar su salud y bienestar. Este artículo explora el uso de Modelos Ocultos de Markov Jerárquicos (HHMM) para abordar estos desafíos. Los HHMM permiten la representación y análisis de secuencias temporales de actividades, capturando tanto variaciones a corto plazo como estructuras jerárquicas complejas en los comportamientos humanos. Se presenta una arquitectura que incluye sensores no intrusivos y un robot social para la monitorización y atención de personas mayores en sus viviendas. Se han expuesto los principios matemáticos del modelo HHMM y la ejecución de sus algoritmos de predicción. El sistema se ha probado en cinco viviendas reales durante dos meses, proporcionando como resultado los patrones de comportamiento de los usuarios con el fin de detectar las posibles anomalías que pueden ocurrir.

**Palabras clave:** Métodos bayesianos, Modelos de series temporales, Control basado en eventos, Control basado en el conocimiento, Informática centrada en el ser humano

### Detection of activities and behavioural patterns using hierarchical hidden Markov models.

### Abstract

In recent years, interest in the development of advanced technologies to detect and analyse the activities and behavioural patterns of elderly individuals in their homes has grown, with the aim of improving their health and wellbeing. This article explores the use of Hierarchical Hidden Markov Models (HHMM) to address these challenges. HHMMs allow for the representation and analysis of temporal sequences of activities, capturing both short-term variations and complex hierarchical structures in human behaviours. An architecture is presented that includes non-intrusive sensors and a social robot for the monitoring and care of elderly individuals in their homes. The mathematical principles of the HHMM model and the execution of its prediction algorithms are described. The system has been used in five real homes over a period of two months, resulting in the identification of the users' behavioural patterns to detect potential anomalies that may occur.

**Keywords:** Bayesian methods, Time series modelling, Event-based control, Knowledge-based control, Human-centered computing

## 1. Introducción

En los últimos años, se ha producido un creciente interés en el desarrollo de tecnologías avanzadas para la detección y análisis de actividades y patrones de comportamiento en di-

versas poblaciones, incluyendo personas mayores, pacientes en rehabilitación y trabajadores en entornos industriales (Bholla and Vishwakarma, 2024). Este interés surge de la necesidad de mejorar la calidad de vida, la seguridad y la eficiencia en estos contextos mediante el uso de tecnologías inteligentes. El

\*Autor para correspondencia: raugom@cartif.es  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

reconocimiento de actividades humanas (HAR) surge como una necesidad a la hora de realizar una supervisión no intrusiva dentro de espacios controlados, como puede ser el interior de una vivienda o una residencia de personas mayores (Nagpal et al., 2023).

Los sistemas HAR actúan como vigilantes expertos a la hora de decodificar los patrones de las rutinas diarias de las personas mayores con notable precisión. Al discernir los patrones de comportamiento de una persona mayor a lo largo del día, surge una gran cantidad de información relevante sobre su salud, facilitando intervenciones proactivas y planes de cuidado personalizados (Gaikwad et al., 2023). La monitorización en tiempo real de las actividades entre las personas mayores tiene una inmensa importancia para salvaguardar su bienestar. Los sistemas HAR pueden detectar anomalías como caídas o desviaciones de los patrones de comportamiento típicos, desencadenando intervenciones oportunas o alertas a los cuidadores o profesionales médicos (Schrader et al., 2020).

El uso de Modelos Ocultos de Markov Jerárquicos (HHMM) ha emergido como una técnica prometedora para abordar estos desafíos (Wang et al., 2023a). Este tipo de modelos permite la representación y análisis de secuencias temporales de actividades, capturando tanto las variaciones a corto plazo como las estructuras jerárquicas más complejas en los comportamientos humanos. Los HHMM ofrecen una capacidad única para modelar la dinámica y las transiciones entre diferentes estados de actividad, proporcionando una visión detallada y precisa de los patrones de comportamiento (Glennie et al., 2023). La detección y análisis de actividades mediante HMMH no solo permiten identificar actividades cotidianas como caminar, comer o dormir, sino que también pueden detectar patrones anómalos o peligrosos, como caídas o comportamientos inusuales que podrían indicar problemas de salud. Este tipo de análisis es crucial en la atención a personas mayores, donde la monitorización continua y la rápida respuesta a emergencias pueden marcar la diferencia entre una vida independiente y la necesidad de cuidados constantes.

Este artículo explora el uso de los HHMM para la detección de actividades y patrones de comportamiento en diferentes viviendas reales de personas mayores independientes. Se presentan métodos y algoritmos desarrollados para la implementación de estos modelos, así como estudios de caso que demuestran su eficacia en la monitorización y análisis de comportamientos humanos. Las principales contribuciones del presente artículo son las siguientes: (i) La capacidad de realizar HAR en tiempo real de las principales actividades que una persona mayor puede llevar a cabo en su vivienda. (ii) Revisión de las principales metodologías existentes para realizar HAR, reconociendo e identificando sus fortalezas y debilidades, así como los principales métodos para detectar patrones de comportamiento y anomalías. (iii) Diseño de una arquitectura de ecosistema ambiental inteligente en la que se combinan sensores, actuadores, robots sociales y los modelos HAR desarrollados, para el cuidado y la atención de las personas mayores. (iv) El sistema se ha probado en un total de 5 viviendas reales durante 2 meses de duración.

El artículo se ha estructurado de la siguiente forma: En la Sección 2 se explican los diferentes sistemas HAR existentes para supervisar las actividades de personas mayores en función del tipo de tecnología empleada y los principales méto-

dos de detección de patrones de comportamiento y anomalías. La Sección 3 detalla el método elaborado para realizar HAR, distinguiendo entre la arquitectura desarrollada para poder reconocer las actividades, así como los diferentes principios matemáticos de los modelos HHMM desarrollados. La Sección 4 muestra los resultados obtenidos al aplicar el método en 5 viviendas reales. Por último, la Sección 5 recoge las valoraciones y ventajas del sistema desarrollado, así como los posibles trabajos futuros que pueden surgir del presente artículo.

## 2. Sistemas de reconocimiento de actividades

### 2.1. Tecnología empleada para realizar HAR

En el campo del cuidado de personas mayores, la integración del Internet de las Cosas (IoT) ha revolucionado los enfoques de monitorización y asistencia en entornos domésticos. Con la proliferación de dispositivos IoT en el hogar, como sensores de movimiento y cámaras, la recopilación de datos en tiempo real sobre el entorno de vida de los adultos mayores se ha vuelto más accesible (Wilson and Atkeson, 2005).

Se han propuesto varios enfoques para realizar HAR en el hogar. Una vía explora sistemas de reconocimiento de video que emplean cámaras RGB estratégicamente posicionadas en toda la casa (Golestani and Moghaddam, 2020). Alternativamente, algunas propuestas apuestan por la utilización de datos audibles capturados a través de una red de micrófonos, ya que ciertas actividades pueden discernirse mediante el análisis auditivo (Jung and Chi, 2020). No obstante, la adopción de tales soluciones basadas en imágenes y audio a menudo no cuentan con el apoyo de los usuarios debido a preocupaciones significativas sobre la privacidad. Otras metodologías se basan en la interpretación de señales de sensores vestibles, incluyendo rastreadores de actividad o sensores de teléfonos inteligentes (Sousa Lima et al., 2019). Sin embargo, del mismo modo que sucede con las cámaras y los micrófonos, los usuarios no aceptan este tipo de tecnología, ya que no se encuentran cómodos portando este tipo de tecnología durante todo el día. En cambio, existen soluciones que se encargan de monitorizar el ambiente y los diferentes eventos que suceden dentro de la vivienda a través de sensores inalámbricos discretos (Ramos et al., 2022). Este tipo de sistemas se encargan de capturar diferentes eventos que suceden en el interior de la vivienda, como apertura de puertas o condiciones ambientales. Estas soluciones son óptimas para los usuarios finales ya que no necesitan ninguna intervención ni altera el transcurso de su día a día. Para desarrollar el sistema del presente artículo se han empleado los siguientes tipos de sensores: presencia en estancias, apertura de puertas, vibración, temperatura, humedad, consumo eléctrico e iluminación.

### 2.2. Patrones de comportamiento y anomalías

Al realizar HAR con personas mayores también hay que considerar los posibles patrones de comportamiento anómalos, los cuales pueden ser indicativos de problemas de salud o deterioro cognitivo. Según (Paudel et al., 2018), las anomalías en el comportamiento se pueden clasificar en tres subgrupos: actividades inusualmente cortas o largas, desviaciones temporales o espaciales, y alteraciones en la secuencia de actividades. Por ejemplo, la reducción de las horas de sueño puede ser un indicador de que el usuario no se encuentra en buen

estado de salud. Novak et al. en (Novák et al., 2013) clasifica estas anomalías según el tiempo dedicado a cada actividad, identificando actividades realizadas en horarios inusuales, duraciones demasiado largas y actividades demasiado cortas. La hipótesis principal en estos estudios es que las personas mayores siguen patrones estables en sus actividades, y las anomalías se detectan modelando estos patrones primero y luego identificando desviaciones. Se utilizan varios métodos de aprendizaje automático (ML) para modelar y detectar patrones, entre ellos los métodos generativos como los modelos ocultos de Markov (HMM), que son efectivos con datos limitados y consideran el contexto temporal (Li et al., 2023). Los métodos probabilísticos, como las distribuciones acumulativas y los métodos Bayesianos, son adecuados para actividades de larga duración, pero no para volúmenes pequeños de datos (Konios et al., 2019). Los métodos discriminativos, como las máquinas de vector soporte (SVM), buscan límites entre clases pero pueden producir falsos positivos con grandes volúmenes de datos (Nawal et al., 2023). Los métodos de agrupamiento o “clustering”, son útiles sin necesidad de etiquetar datos, aunque son sensibles a la escala de los datos de entrada (Jethanandani et al., 2020). Por último, los métodos basados en reglas utilizan la información del experto pero son susceptibles a señales ruidosas (Howedi et al., 2020).

### 3. Análisis del método

#### 3.1. Descripción de la arquitectura desarrollada

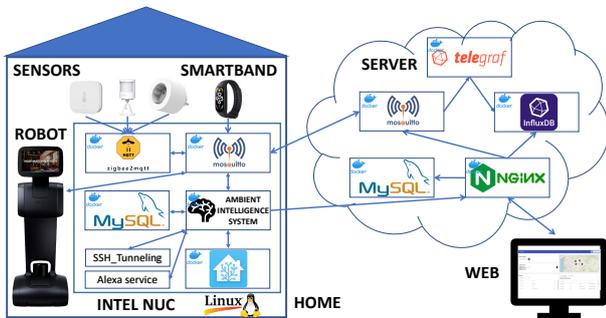


Figura 1: Diagrama de la arquitectura desarrollada y las comunicaciones entre la vivienda, el servidor y la aplicación web.

Se ha desarrollado una arquitectura para implementar un sistema de inteligencia ambiental para monitorizar las actividades de las personas mayores. Esta arquitectura incluye varios componentes clave tal y como se puede observar en la Figura 1. En primer lugar, una red de sensores no intrusivos recopila información sobre los eventos que suceden en la vivienda y las condiciones ambientales para que el módulo HAR detecte las actividades del usuario. Además, se utilizan pulseras de actividad para monitorizar en tiempo real la salud del usuario, proporcionando datos sobre patrones de sueño, conteo de pasos y parámetros médicos como la frecuencia cardíaca y niveles de oxígeno. Un robot social apoya a los usuarios y mejora su seguridad, con funciones como diálogos, videollamadas o búsqueda del usuario en situaciones de emergencia. Además, puede proporcionar juegos y ejercicios

cognitivos. Este robot tiene capacidades de navegación y proporciona conversaciones fluidas. También cuenta con una aplicación que incluye juegos, videoconferencias y una interfaz amigable para personas mayores. Por último, el robot cuenta con reconocimiento facial. A pesar de que el uso de la cámara del robot puede parecer invasivo, no ha afectado a la comodidad de los usuarios, ya que se encuentran seguros ante la presencia del robot.

El sistema también incluye un concentrador de señales (NUC) que coordina las comunicaciones entre los componentes, detecta las actividades y anomalías, y gestiona la configuración del sistema, ya que está conectado a un servidor externo. El servidor, por su parte, almacena datos históricos del sistema, se comunica con el NUC para enviar comandos y recupera la información en tiempo real. Además, alberga una aplicación web para interactuar con los elementos del sistema. Para coordinar estos componentes, se utilizan contenedores Docker y un módulo Zigbee2MQTT para manejar las señales de los sensores no intrusivos. La información se recopila y procesa mediante un broker Mosquitto, que se conecta al servidor replicando las señales de la casa. El robot social se comunica bidireccionalmente mediante mensajes Message Queuing Telemetry Transport (MQTT).

Un módulo de inteligencia ambiental procesa esta información y ejecuta acciones, como dirigir al robot o activar alarmas. El NUC incluye una base de datos MySQL y utiliza Home Assistant para manejar dispositivos y automatizaciones locales. Además, se integra con dispositivos Alexa y usa un servicio de Tunelización SSH para una comunicación segura entre el NUC y el servidor. El servidor también emplea contenedores Docker para alojar complementos como Telegraf, que almacena datos en una base de datos InfluxDB y configura la solución en una base de datos MySQL, mientras que NGINX aloja la aplicación web para la interacción con el sistema.

#### 3.2. Módulo de detección de actividades: principios matemáticos

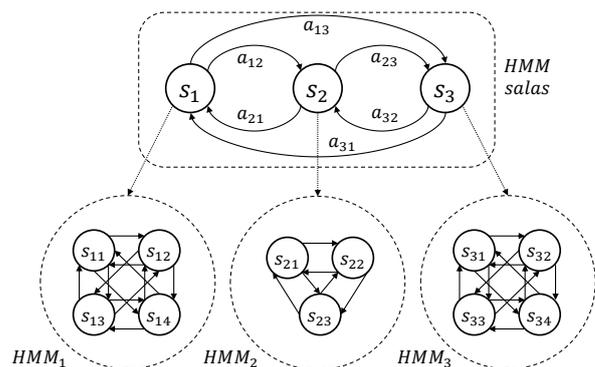


Figura 2: Modelo oculto de Markov jerárquico para la detección de actividades y estancias.

Para realizar HAR en las viviendas, se ha desarrollado un HHMM basado en dos niveles funcionales: una capa HMM encargada de reconocer la sala en la que se encuentra el usuario y, en función de la localización, diversas capas HMM que se encargan de extraer la actividad que se está realizando en el momento de la detección. Estos dos niveles funcionales se pueden observar en la Figura 2.

- HMM salas: Este modelo se corresponde con la parte superior del diagrama. En este modelo, cada uno de los estados ocultos  $s_i$  se corresponde con las posibles salas que componen la vivienda. Para esta parte del modelo, las observaciones  $o_k$  se corresponden con las señales proporcionadas por los diferentes sensores de evento con los que cuenta la instalación (PIR, contacto y vibración). En este caso, no se tienen en cuenta los sensores ambientales, ya que no pueden desencadenar un cambio de estancia por ellos mismos.
- HMM actividades: Se corresponde con la parte inferior de diagrama. Los estados ocultos  $s_{ii}$  equivalen a las diferentes actividades que puede desarrollar el usuario en una estancia determinada. Las observaciones  $o_{ik}$  se corresponden con las señales de los sensores que se encuentran en esa estancia. A este grupo pertenecen, además de los sensores que capturan eventos, los sensores que monitorizan el ambiente (temperatura, consumo eléctrico o humedad).

La toma de decisiones basada en el patrón de comportamiento de los usuarios se ha realizado de forma manual. Es decir, una vez que se tiene la duración media de las actividades realizadas por el usuario, se envía una señal de activación o alarma si la duración de la actividad difiere de la media en un rango de tiempo establecido manualmente.

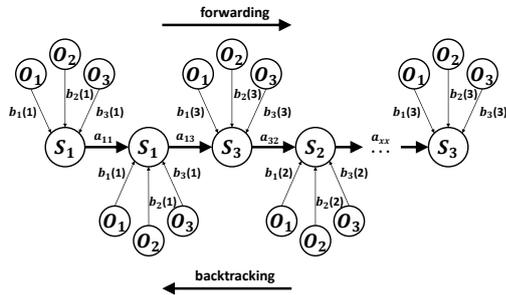


Figura 3: Diagrama de transiciones entre los estados ocultos  $s_i$  y aplicación de algoritmo HAR basado en las observaciones  $o_k$ .

Para calcular la actividad en un instante de tiempo  $t$ , se ha considerado el uso de un método de cálculo que utiliza avance y retroceso, tal y como se puede ver en la Figura 3 (Gómez-Ramos et al., 2023). Este método computa el componente de avance (o “forwarding”) a medida que se reciben eventos de sensores, mientras que el componente de retroceso (o “backtracking”) se calcula utilizando los  $n$  eventos posteriores. Una vez que se obtienen ambos componentes para un instante de tiempo  $t$ , se realiza una ponderación entre ellos y se elige la actividad con la mayor probabilidad. Este tipo de algoritmos son útiles a la hora de optimizar el funcionamiento del modelo, ya que la componente de retroceso se encarga de minimizar una función de pérdida y, posteriormente, el objetivo es ajustar los parámetros internos del modelo. Sin embargo, dado que el volumen de datos en esta fase no es lo suficientemente elevado como para hacer una optimización adecuada, se ha eliminado la componente de retroceso. Esta decisión simplifica el comportamiento del modelo y permite su uso en tiempo real, ya

que no hay que esperar a recoger eventos futuros para realizar predicciones.

Se ha elaborado el Algoritmo 1 para calcular la secuencia más probable de estados ocultos. El índice  $t$  representa el tiempo discreto en el proceso, mientras que  $N$  indica el número total de estados en modelo HMM. Cada estado en el modelo está representado por la variable  $x_n$ . La ruta de supervivencia  $sp_{nt}$  se refiere a la secuencia ordenada de los estados visitados desde el inicio hasta el tiempo  $t$ , terminando en el estado  $x_n$ . El algoritmo tiene una longitud de truncamiento  $T$ , que indica el punto en el cual se toma una decisión respecto a la ruta más probable. Las métricas  $\pi_n$ ,  $a_{nm}$  y  $b_n$  representan la probabilidad del estado inicial, la probabilidad de transición entre estados y la probabilidad de observación para cada estado, respectivamente. La métrica  $\Gamma_{nt}$  se calcula como el producto de las métricas mencionadas a lo largo de la ruta de supervivencia  $sp_{nt}$ , desde el inicio hasta el tiempo  $t$ , para determinar la ruta más probable en cada paso temporal.

**Algorithm 1** Algoritmo HAR para la transición entre los diferentes estados ocultos

---

```

1: - Etapa 1: Inicialización.
2:  $t = 0$ ;
3: for  $n = 1$  to  $N$  do
4:    $\Gamma_{n0} = \ln \pi_n$ ;
5:    $sp_{n0} = []$ ;
6: end for
7: - Etapa 2: Cálculo.
8: for  $t = 1$  to  $T$  do
9:   for  $n = 1$  to  $N$  do
10:     $\text{máx\_val} = -\infty$ ;
11:    for  $m = 1$  to  $N$  do
12:       $\text{temp} = \Gamma_{m,t-1} + \ln a_{nm} + \ln b_n$ ;
13:      if  $\text{temp} > \text{máx\_val}$  then
14:         $\text{máx\_val} = \text{temp}$ ;
15:         $\text{argmax\_m} = m$ ;
16:      end if
17:    end for
18:     $\Gamma_{nt} = \text{máx\_val}$ ;
19:     $sp_{nt} = \text{Append}[sp_{\text{argmax\_m}, t-1}, n]$ ;
20:  end for
21: end for
22: - Etapa 3: Decisión.
23:  $\text{máx\_val} = -\infty$ ;
24: for  $n = 1$  to  $N$  do
25:   if  $\Gamma_{nt} > \text{máx\_val}$  then
26:      $\text{máx\_val} = \Gamma_{nt}$ ;
27:      $\text{argmax\_n} = n$ ;
28:   end if
29: end for
30:  $sp_T = sp_{\text{argmax\_n}, T}$ ;

```

---

#### 4. Experimentación

El sistema se ha desplegado en 5 viviendas de usuarios reales durante 2 meses de duración total. Estos usuarios son personas de avanzada edad con un nivel de independencia bastante alto. Se han estudiado las actividades a monitorizar para cada usuario de forma conjunta con familiares y/o cuidadores.

Para poder obtener los patrones de comportamiento de todos los usuarios, se han elaborado unas gráficas de caja y bigotes que muestran el número de horas diarias que se ha realizado cada actividad inferida por el algoritmo durante los dos meses de duración (Figura 4). El diagrama está compuesto por tres componentes: la caja, los bigotes y los puntos fuera de los bigotes. La caja muestra el rango intercuartílico de los datos, que representa el 50 % central de los valores. El borde inferior de la caja es el primer cuartil (Q1), bajo el cual se encuentra el 25 % de los datos, y el borde superior es el tercer cuartil (Q3), bajo el cual se encuentra el 75 % de los datos. La línea dentro de la caja indica la mediana, que divide los datos en dos partes iguales. Los bigotes se extienden desde los bordes de la caja hasta los valores extremos calculados como 1.5 veces el rango intercuartílico por encima de Q3 o por debajo de Q1. Los puntos fuera de los bigotes son considerados valores atípicos. De los diagramas se puede extraer que las actividades con las cajas más pequeñas se corresponden con las actividades con duraciones más estables, como puede ser la actividad de “Comer”. Del mismo modo, se pueden extraer las actividades con mayor desviación. Por ejemplo, en la vivienda 5, la actividad más variable es “Dormir”.

En la Tabla 1 aparece un resumen de los resultados obtenidos para cada vivienda al calcular la media y la desviación típica para cada una de las actividades detectadas. Las actividades que no se han detectado en cada vivienda debido a que los usuarios no podían realizar dicha actividad por sí mismos sin necesitar una ayuda externa, y las actividades que los propios usuarios, familiares y/o cuidadores han rechazado la monitorización, se han representado en la tabla con un “-”.

## 5. Conclusiones

En el presente artículo se ha presentado la elaboración de un sistema de detección de actividades humanas mediante la aplicación de HHMM. Este sistema está basado en una arquitectura que integra sensores no intrusivos, un robot social que apoya al usuario en su día a día, y se comunica en tiempo real con un servidor que configura y recoge los datos. Los sistemas HAR utilizando sensores no intrusivos son de especial interés a la hora de cuidar el bienestar de las personas mayores.

El sistema se ha probado con 5 viviendas reales durante un total de 2 meses. Esta fase de pruebas ha proporcionado como resultado los patrones de comportamiento de los usuarios de las viviendas analizadas, permitiendo conocer la duración de las actividades que pueden realizar y su variabilidad.

A la vista de los resultados obtenidos, como trabajo futuro, se propone establecer un sistema que considere como anomalías las actividades que difieran del patrón de comportamiento personalizado para el usuario analizado, mediante la aplicación de técnicas de aprendizaje por refuerzo o métodos similares.

## Agradecimientos

La investigación que se presenta en este trabajo ha recibido financiación del proyecto ROSOGAR (PID2021-123020OB-I00) financiado por MCIN/ AEI / 10.13039/501100011033 / FEDER, UE, y del proyecto EIAROB Financiado por Consejería de Familia of the Junta de Castilla y León - Next Generation EU.

## Referencias

- Bhola, G., Vishwakarma, D. K., 2024. A review of vision-based indoor har: state-of-the-art, challenges, and future prospects. *Multimedia Tools and Applications* 83 (1), 1965–2005.
- Gaikwad, S., Bhatlawande, S., Shilaskar, S., Solanke, A., 2023. A computer vision-approach for activity recognition and residential monitoring of elderly people. *Medicine in Novel Technology and Devices* 20, 100272.
- Glennie, R., Adam, T., Leos-Barajas, V., Michelot, T., Photopoulou, T., McClintock, B. T., 2023. Hidden markov models: Pitfalls and opportunities in ecology. *Methods in Ecology and Evolution* 14 (1), 43–56.
- Golestani, N., Moghaddam, M., 2020. Human activity recognition using magnetic induction-based motion signals and deep recurrent neural networks. *Nature communications* 11 (1), 1551.
- Gómez-Ramos, R., Duque-Domingo, J., Zalama, E., Gómez-García-Bermejo, J., 2023. An unsupervised method to recognise human activity at home using non-intrusive sensors. *Electronics* 12 (23), 4772.
- Howedi, A., Lotfi, A., Pourabdollah, A., 2020. An entropy-based approach for anomaly detection in activities of daily living in the presence of a visitor. *Entropy* 22 (8), 845.
- Jethanandani, M., Sharma, A., Perumal, T., Chang, J.-R., 2020. Multi-label classification based ensemble learning for human activity recognition in smart home. *Internet of Things* 12, 100324.
- Jouini, R., Houaidia, C., Saidane, L. A., 2023. Hidden markov model for early prediction of the elderly’s dependency evolution in ambient assisted living. *Annals of Telecommunications* 78 (9), 599–615.
- Jung, M., Chi, S., 2020. Human activity classification based on sound recognition and residual convolutional neural network. *Automation in Construction* 114, 103177.
- Konios, A., Garcia-Constantino, M., Christopoulos, S.-R., Mustafa, M. A., Ekerete, I., Shewell, C., Nugent, C., Morrison, G., 2019. Probabilistic analysis of temporal and sequential aspects of activities of daily living for abnormal behaviour detection. In: 2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBD-Com/IOP/SCI). IEEE, pp. 723–730.
- Li, Y., Yang, G., Su, Z., Li, S., Wang, Y., 2023. Human activity recognition based on multi-environment sensor data. *Information Fusion* 91, 47–63.
- Nagpal, D., Gupta, S., Kumar, D., Illés, Z., Verma, C., 2023. goldenager: A personalized feature fusion activity recognition model for elderly. *IEEE Access*.
- Nawal, Y., Oussalah, M., Fergani, B., Fleury, A., 2023. New incremental svm algorithms for human activity recognition in smart homes. *Journal of Ambient Intelligence and Humanized Computing* 14 (10), 13433–13450.
- Novák, M., Jakab, F., Lain, L., 2013. Anomaly detection in user daily patterns in smart-home environment. *J. Sel. Areas Health Inform* 3 (6), 1–11.
- Ordóñez, F. J., de Toledo, P., Sanchis, A., 2015. Sensor-based bayesian detection of anomalous living patterns in a home setting. *Personal and Ubiquitous Computing* 19, 259–270.
- Paudel, R., Eberle, W., Holder, L. B., 2018. Anomaly detection of elderly patient activities in smart homes using a graph-based approach. In: *Proceedings of the 2018 International Conference on Data Science*. pp. 163–169.
- Ramos, R. G., Domingo, J. D., Zalama, E., Gómez-García-Bermejo, J., López, J., 2022. Sdhar-home: A sensor dataset for human activity recognition at home. *Sensors* 22 (21), 8109.
- Saives, J., Pianon, C., Faraut, G., 2015. Activity discovery and detection of behavioral deviations of an inhabitant from binary sensors. *IEEE Transactions on Automation Science and Engineering* 12 (4), 1211–1224.
- Schrader, L., Vargas Toro, A., Konietzny, S., Rüping, S., Schäpers, B., Steinböck, M., Krewer, C., Müller, F., Güttler, J., Bock, T., 2020. Advanced sensing and human activity recognition in early intervention and rehabilitation of elderly people. *Journal of Population Ageing* 13, 139–165.
- Sousa Lima, W., Souto, E., El-Khatib, K., Jalali, R., Gama, J., 2019. Human activity recognition using inertial sensors in a smartphone: An overview. *Sensors* 19 (14), 3213.
- Wang, X., Liu, J., Moore, S. J., Nugent, C. D., Xu, Y., 2023a. A behavioural hierarchical analysis framework in a smart home: Integrating hmm and probabilistic model checking. *Information Fusion* 95, 275–292.
- Wang, Y., Wang, X., Arifoglu, D., Lu, C., Bouchachia, A., Geng, Y., Zheng, G., 2023b. A survey on ambient sensor-based abnormal behaviour detection for elderly people in healthcare. *Electronics* 12 (7), 1539.
- Wilson, D. H., Atkeson, C., 2005. Simultaneous tracking and activity recognition (star) using many anonymous, binary sensors. In: *International Conference on Pervasive Computing*. Springer, pp. 62–79.

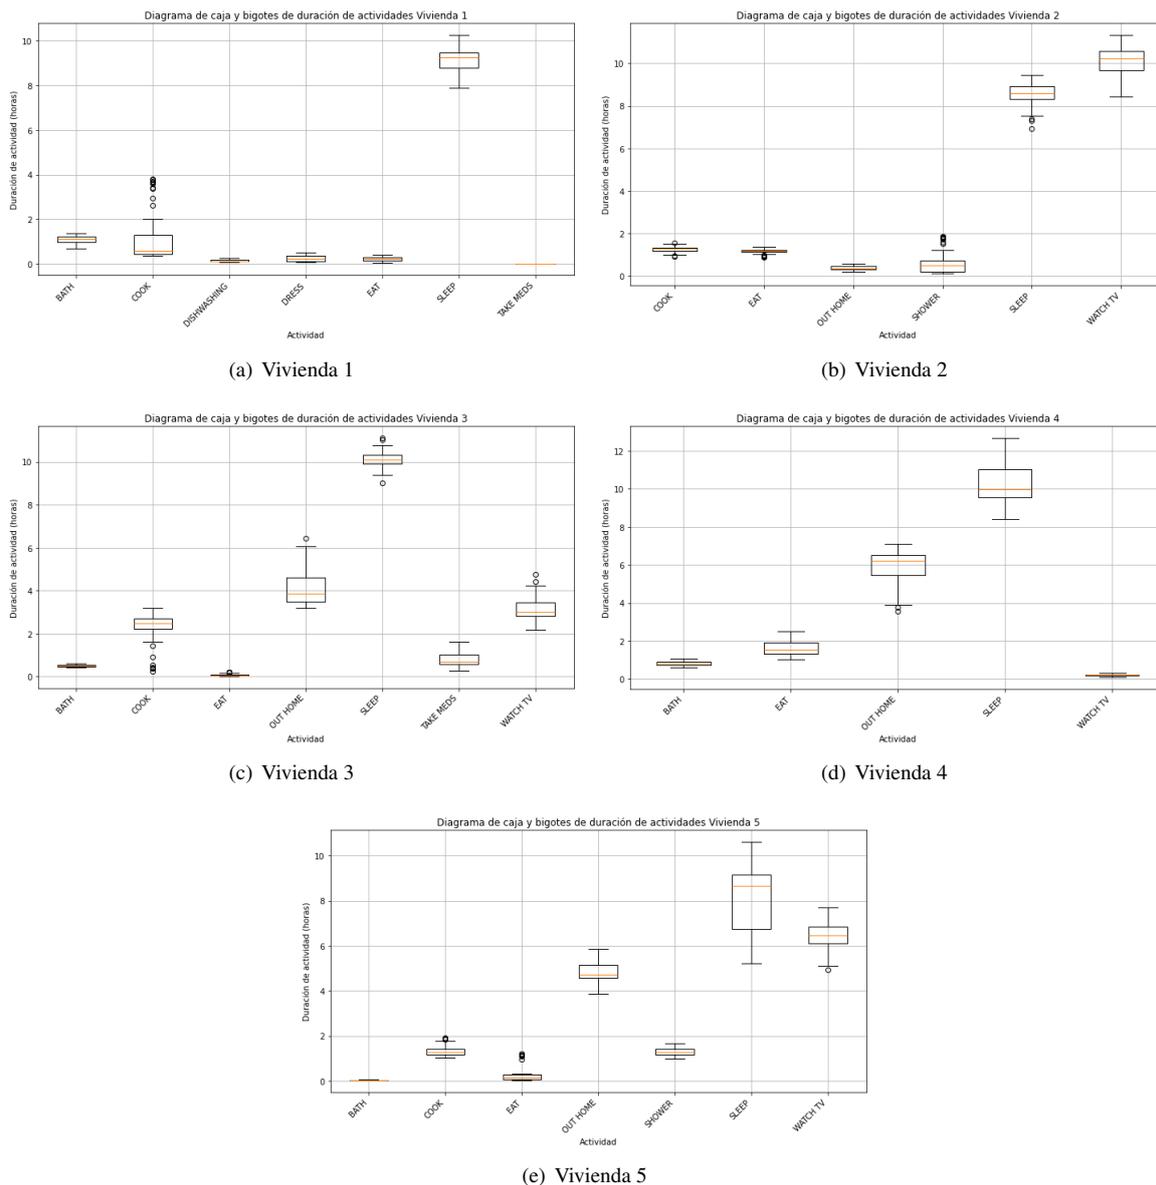


Figura 4: Diagramas de caja y bigotes de duración de actividades por día para las 5 viviendas reales analizadas durante 2 meses.

Actividad	Vivienda 1 (h)	Vivienda 2 (h)	Vivienda 3 (h)	Vivienda 4 (h)	Vivienda 5 (h)
Actividad en el baño	1,07 ± 0,51	-	0,52 ± 0,20	0,83 ± 0,31	0,04 ± 0,05
Cocinar	1,64 ± 3,80	1,24 ± 0,62	1,96 ± 1,29	-	1,36 ± 0,49
Lavar los platos	0,14 ± 0,17	-	-	-	-
Vestirse	0,21 ± 0,32	-	-	-	-
Comer	0,21 ± 0,35	1,13 ± 0,43	0,08 ± 0,09	1,77 ± 0,89	0,28 ± 1,07
Salir de casa	-	0,34 ± 0,45	4,31 ± 1,84	6,05 ± 2,43	4,72 ± 2,25
Ducharse	-	0,59 ± 1,13	-	-	1,28 ± 0,56
Dormir	8,66 ± 3,45	8,44 ± 2,30	10,22 ± 2,01	9,98 ± 2,59	7,92 ± 2,85
Tomar medicinas	0,01 ± 0,02	-	0,84 ± 1,37	-	-
Ver televisión	-	10,26 ± 2,29	3,07 ± 2,12	0,22 ± 0,29	6,56 ± 2,10

Tabla 1: Media y desviación típica (en horas) de duración de actividades para las 5 viviendas reales analizadas durante 2 meses.