

# Detección Robusta de Tags RFID usando Hidden Markov Models

Javier del Río Toledano, Jose Lopez Vicario, Antoni Morell

{javier.delrio, jose.vicario, antoni.morell}@uab.cat

Wireless Information Networking (WIN), Universitat Autònoma de Barcelona (UAB).

Edifici Q. Escola d'Enginyeria, Carrer de les Sitges, Cerdanyola del Vallès (08193 Barcelona).

**Resumen**—Hidden Markov Models (HMMs) have proven to be powerful tools for modeling sequential data across various applications. This paper explores their use in RFID-based tag detection, focusing on improving accuracy and robustness in environments affected by signal noise and interference. We propose a methodology that leverages the probabilistic nature of HMMs to classify and predict RFID tag readings, thereby enhancing detection reliability. The effectiveness of the approach is evaluated through simulations, demonstrating its potential for improving modern RFID reader performance. Our results indicate that HMMs can significantly improve detection precision, providing a more reliable solution for RFID applications. Additionally, we analyze the impact of model parameters and propose optimizations to enhance performance in dynamic scenarios. This research is a first step towards improved RFID systems by integrating probabilistic models.

## I. INTRODUCCIÓN

Los sistemas RFID (Radio Frequency Identification) permiten la identificación y seguimiento de objetos mediante los conocidos tags (etiquetas electrónicas) que se adhieren a los mismos. Un sistema RFID se compone básicamente de dos elementos: los propios tags y el lector. Existen tanto sistemas activos en los que los tags disponen de energía para emitir como sistemas pasivos. En estos últimos, el lector emite una onda electromagnética y el tag se alimenta con la propia energía recibida. Cada tag dispone de una pequeña memoria donde almacenar un identificador que nos permita luego distinguir los objetos transmitiendo ese identificador al lector. El mecanismo de comunicación en sistemas pasivos se basa en el mecanismo de backscattering (retrodispersión) y consiste en que el tag refleja la señal que recibe del lector pero aplicándole algún tipo de modulación para poder comunicar al lector su identificador. En sistemas activos, los tags pueden transmitir directamente sin necesidad de alimentarse previamente [1], [2].

Las aplicaciones de los sistemas RFID son múltiples y en muchos ámbitos. En el ámbito industrial por ejemplo se contempla su uso para detección, localización y seguimiento de productos donde los tags actúan como sensores de muy bajo coste, como puede ser el caso de una cadena de montaje automatizado [3] o incluso en entornos agrícolas [4]. Otro ámbito de aplicación de los RFID es en el comercio y en este caso también es necesario tener sensores baratos que permitan una detección o incluso una localización precisa [5].

En este trabajo nos centramos en los sistemas RFID pasivos, que son los que permiten un menor coste en el etiquetaje. Aunque se ha hecho mucha investigación y los sistemas han evolucionado considerablemente en los últimos años, quedan aún desafíos por cubrir, siendo quizá los más destacados los

que se derivan de los propios problemas de propagación e interferencias [6] y los relacionados con la lectura de múltiples tags. En el momento que un lector inicia el proceso llamado de interrogación para recibir respuesta de los tags, estos responderían en un primer momento en tiempos parecidos, causando así colisiones entre las propias etiquetas. Existe un mecanismo de tipo ALOHA para mitigar colisiones pero con eficiencia moderada [7], por lo que existe todavía mucho margen de mejora.

Aquí presentamos un trabajo inicial de lo que se pretende llevar a cabo en el futuro y que consiste en resolver o mitigar los problemas existentes en un entorno dinámico en el que las etiquetas se encuentran en movimiento, lo cual añade dificultades respecto al escenario estático. Sería el ejemplo de una cadena de montaje o el de una cinta transportadora de la caja del supermercado como se puede ver en la figura 1. Para ello, nos apoyaremos en herramientas de inteligencia artificial y reconocimiento de patrones para añadir una capa de software que dé robustez al propio sistema RFID. Además, se pretende que sea fácil de ajustar a los distintos entornos y computacionalmente moderado. Empezamos por un sistema muy simple de una sola etiqueta donde vemos que un modelado a través de cadenas ocultas de Markov nos permite capturar la secuencialidad que hay en el patrón de datos generados en contraposición a soluciones que no tienen en cuenta dicha secuencialidad.

## II. DESCRIPCIÓN DEL SISTEMA

### A. Sistema modelado

Se considera una antena RFID como sistema emisor y receptor, situada frente a una cinta transportadora con una secuencia de etiquetas RFID que van poniéndose sobre la cinta de manera secuencial y no superpuesta. Cada etiqueta entra




Fig. 1. Escenario RFID dinámico.

en el cono de emisión de la antena y se registra una lectura de Received Signal Strength Indicator (RSSI). Se supone que las etiquetas se suceden con espacio entre ellas pero sin solaparse entre sí.

Se modela un sistema con dos estados fundamentales: presencia (P) y ausencia (A) de la etiqueta RFID en el cono de emisión. La presencia o ausencia de la etiqueta es considerada como un evento aleatorio con una probabilidad determinada de aparecer o desaparecer, y de mantenerse en cada uno de los estados. Las observaciones se realizan a través de medidas de potencia, cuyas distribuciones estadísticas se supone que cambiarán significativamente al cambiar el estado. Se asume ruido blanco sin interferencia y la potencia emitida por el tag es alterada por ruido y efectos de *shadowing*.

### B. Descripción matemática

La distribución de la potencia del ruido en (1) contiene la variable aleatoria  $x(n)$  que sigue una distribución  $\chi^2$  con dos grados de libertad. La potencia recibida  $P_r(n)$  en (2) contiene  $P_t$ , la potencia a la que emite la antena agregando todas las ganancias, la aplicación de Friis en los recorridos de ida y vuelta además del efecto de *shadowing*, que sigue una distribución log-normal, es decir, se trata de una distribución normal de media nula en escala logarítmica. Dado que se asume ruido incorrelado con la señal, la potencia resultante cuando el tag esta presente será la suma de las dos potencias  $P_{tag}(n) = P_r(n) + P_w(n)$ .

$$P_w(n) = \sigma_w^2 \cdot x(n) \quad (1)$$

$$P_{r_{dB}}(n) = P_{t_{dB}} + 40 \log \left( \frac{c}{4\pi df} \right) + \psi_{dB}(n) \quad (2)$$

## III. CADENAS OCULTAS DE MARKOV

### A. Fundamentos

Los modelos de cadenas ocultas de Markov (HMM en inglés), nos son especialmente convenientes pues nos permiten buscar la secuencia de estados ocultos más probables para una secuencia de observaciones teniendo en cuenta la naturaleza secuencial derivada de modelar un estado oculto, que en nuestro caso se traduciría en tener en cuenta en la propia formulación del problema la imposibilidad de que una etiqueta aparezca y desaparezca continuamente. Las observaciones son en este caso las medidas de potencia y los estados son la presencia o ausencia de un tag. Una HMM con funciones de densidad de probabilidad de las observaciones continuas tiene una serie de parámetros que la caracterizan:

- Matriz de transición  $A$  que modela las probabilidades de cambiar de un estado a otro o mantenerse en el mismo.
- Vector de probabilidades iniciales  $\pi$ .
- Función de densidad probabilidad escogida  $\mathfrak{R}$  para las observaciones sabiendo ee estado. En nuestro caso optamos por modelar con distribución normal.
- Parámetros de la función de probabilidad escogida. Para nosotros media  $\mu$  y varianza  $\sigma^2$  de la distribución normal.

### B. Métodos

Las HMM incorporan métodos computacionalmente eficientes para resolver los problemas de puntuación de secuencia (inferencia en términos de probabilidad), etiquetado de secuencia (determinar el estado más probable). Para ver un desarrollo más exhaustivo referirse a [8] y [9]. Para este estudio se utilizan los tres métodos.

1. *Puntuación de secuencia*: La puntuación de secuencia consiste en calcular la probabilidad de esta para un modelo dado. Primero debemos introducir  $b$  que se define como

$$b_i(O_t) = \mathfrak{R}(O_t, \mu_i, \sigma_i^2) \quad (3)$$

donde  $O_t$  representa la observación en el tiempo  $t$ .

También requerimos introducir  $\alpha_t(i)$  que se define como la probabilidad de la secuencia parcial hasta el instante  $t$  y para un estado  $S_i$ :

$$\alpha_t(i) = P(O_1 O_2 \dots O_t, q_t = S_i | \lambda) \quad (4)$$

Es un proceso recursivo donde primero se inicializa cada  $\alpha_1(i)$ :

$$\alpha_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N \quad (5)$$

Y se calcula el siguiente marginalizando el estado anterior:

$$\alpha_{t+1}(j) = b_j(O_{t+1}) \sum_{i=1}^N \alpha_t(i) a_{ij} \quad (6)$$

Por último se marginaliza el último estado:

$$P(O|\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (7)$$

2. *Etiquetado de secuencias*: El etiquetado consiste en buscar la secuencia de estados más probable para unas observaciones y un modelo  $P(Q|O, \lambda)$ . Nosotros tratamos de maximizar la probabilidad de toda la secuencia de estados y para ello se utiliza el algoritmo de Viterbi.

Se inicializan dos variables para guardar el mejor resultado y otra para guardar el mejor camino:

$$\delta_1(i) = \pi_i b_i(O_1), \quad \psi_1(i) = 0$$

Se aplica el algoritmo de manera recursiva para  $1 \leq j \leq N$ .

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(O_t), \quad 2 \leq t \leq T \quad (8)$$

$$\psi_t(j) = \operatorname{argmax}_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] \quad 2 \leq t \leq T \quad (9)$$

Dado que las observaciones no son infinitas se acaba sin transición:

$$P(Q, O|\lambda) = \max_{i \leq i \leq N} [\delta_T(i)] \quad (10)$$

$$q_T = \operatorname{argmax}_{1 \leq i \leq N} [\delta_T(i)] \quad (11)$$

Se aplica entonces *backtracking* para obtener la secuencia de estados:

$$q_t = \psi_{t+1}(q_{t+1}), \quad T - 1 \leq t \leq 1 \quad (12)$$

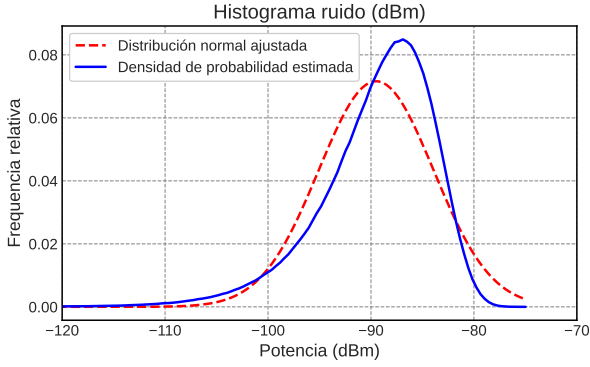


Fig. 2. Histograma del ruido en función de la potencia en dBm. Se añade la estimación de la distribución normal ajustada.

3. *Estimación de parámetros:* El proceso de estimación de parámetros para un HMM es un caso particular del algoritmo esperanza-maximización (EM) conocido como Baum-Welch. Este algoritmo genera a partir de un modelo previo uno nuevo que aumenta la probabilidad de unas observaciones de entrenamiento. Para encontrar los nuevos parámetros se trata de maximizar la función  $Q$  para cada parámetro:

$$Q(\lambda, \lambda') = \sum_{Q \in \mathcal{Q}} \log P(O, Q|\lambda)P(O, Q|\lambda') \quad (13)$$

Donde  $\mathcal{Q}$  es conjunto de todas las posibles secuencias de longitud  $T$ .

Este algoritmo lo utilizamos para estimar los parámetros que no se conocen:  $A$ ,  $\pi$ .

### C. Implementación

1. *Escala:* Hemos seleccionado como distribución de las emisiones la gaussiana. Algorímicamente es una distribución ampliamente estudiada y para la que disponemos de métodos computacionalmente eficientes. Por otro lado, las distribuciones con las que trabajamos, tanto en el caso de sólo ruido como en el caso de recibir señal de una etiqueta, se aproximan razonablemente bien a la distribución gaussiana como se puede apreciar por ejemplo en el caso de solo ruido en la figura 2.

2. *Fijar distribución:* Podemos aplicar un *fitting* del modelo a una secuencia de datos. Al intentarlo, nos encontramos con un problema de las HMM y es que para distribuciones solapadas tenderá a errar separando únicamente según un lindar o suponiendo que toda la secuencia proviene de un solo estado. Para aliviar este defecto podemos fijar la distribución mediante mediciones donde el estado es conocido y estimar el resto de parámetros a parte. Esto ofrece mejores resultados para las mismas condiciones. Como se puede observar en la figura 3, la predicción del HMM en la detección de una secuencia temporal de observaciones de RSSI es muy acertada con una precisión del 95,87%. Sin fijar la distribución previamente esta decae en más de un 30%. Este acercamiento abre la puerta a utilizar distintas funciones de densidad de probabilidad sin la necesidad de modificar el algoritmo Baum-Welch.

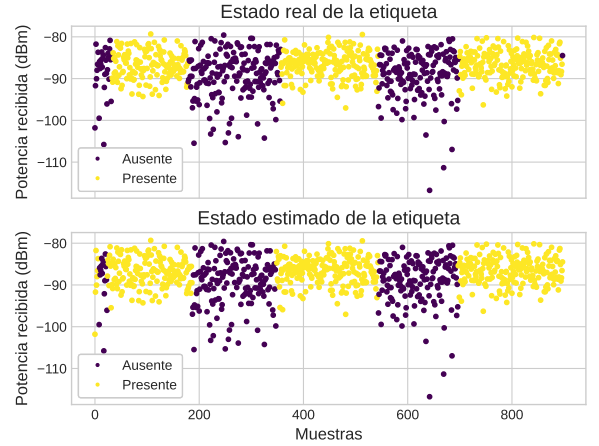


Fig. 3. Comparación entre emisiones y estados, reales y predichos, cuando se realiza un *fitting* del modelo para distribuciones muy parecidas, distancia de 0,6 metros. Los puntos representan RSSI y se les asigna el color según si esa observación corresponde con la presencia o ausencia de un tag.

3. *Múltiples modelos:* Utilizando el algoritmo Baum-Welch estimamos el resto de parámetros. Este algoritmo maximiza localmente los parámetros del modelo en un enfoque de máxima verosimilitud (ML), por lo que para evitar problemas de localidad estimamos varios modelos partiendo de inicios aleatorios y los evaluamos según quien asigna la mayor probabilidad a la secuencia en cuestión. No elimina el problema de localidad, pero lo mitiga.

## IV. METODOLOGÍA

Además de las HMM, utilizaremos como método de comparación una estimación de máxima verosimilitud (*Maximum Likelihood Estimation*) partiendo de conocer la distribución de probabilidad de cada estado y seleccionando el máximo entre las distribuciones. Nótese que con esto suponemos que los estados son independientes entre ellos y por lo tanto no se tiene en cuenta la naturaleza secuencial de los datos.

### A. Parámetros utilizados

Para evaluar la validez y precisión del modelo al realizar cambios fijamos los valores de todos los parámetros que consideramos que no deberían cambiar.

- Agregación de potencia transmitida y ganancias:  $P_t = 2$  W
- Frecuencia de RFID UHF:  $f = 915$  MHz
- Varianza *shadowing*:  $\sigma_{\psi_{dB}}^2 = 3$  dB
- Potencia de ruido:  $\sigma_{w_{dB}}^2 = -90$  dBm

Estos parámetros son arbitrarios y modificables en la simulación. El criterio que utilizaremos para determinar mejoras será la precisión en función de la distancia. A mayores distancias la distribución de las muestras entre los estados presente o ausente se irán solapando y asemejando más. Llegará un punto en el que el modelo será incapaz de distinguir entre los dos y discriminará según un lindar o supondrá todas las muestras de un mismo estado.

### B. Generación de datos

Los datos de entrenamiento se generan de manera aleatoria siguiendo una distribución uniforme con 1000 transiciones

con una media de 100 muestras por transición, dando un total de 100.000 muestras. Dependiendo del estado de la muestra se genera ruido o ruido más señal del tag. Las muestras de ruido y de señal siguen las ecuaciones 1 y 2.

### C. Caso MLE

En el caso MLE se han comparado múltiples distribuciones de probabilidad encontrando que la que mejor se adaptaba era una distribución beta escalada y localizada. Se utiliza el módulo de estadística *scipy.stats* que realiza un ajuste de los parámetros aplicando MLE. Una vez obtenidos se generan 100 secuencias de prueba para promediar la precisión.

### D. Caso HMM

En el caso HMM se genera la misma secuencia de entrenamiento y se fijan los parámetros del modelo de interés, el número de estados, la media y la varianza de cada estado. Se crea, entrena y evalúa cada modelo, conservando el mejor en todo momento. Una vez entrenado se generan secuencias de prueba para promediar la precisión.

Para realizar el *fitting* se indica un número de iteraciones del algoritmo Baum-Welch, en nuestro caso 1000 y la mejora mínima que se espera entre evaluaciones entre iteraciones,  $10^{-10}$ , si la mejora es menor se detiene la ejecución.

## V. RESULTADOS

Los resultados se han obtenido tras 10 iteraciones de *fitting* distintas para los modelos y para 100 secuencias de prueba por modelo. Se presenta el promedio de estas 10 iteraciones en la figura 4. Observamos una superioridad del método HMM hasta que las distribuciones empiezan a solaparse casi completamente, alrededor de los 0,8 metros, donde empieza a fallar de manera muy similar al acercamiento MLE. El método MLE no aprovecha la relación entre muestras y, por lo tanto, obtiene peores resultados aunque el ajuste de la función de densidad de probabilidad sea más adecuado. En la figura 4 se ve por ejemplo como a una distancia de 0,6m, la precisión con HMM aumenta más del 35 % respecto al caso MLE.

## VI. CONCLUSIONES

En este trabajo se modela un escenario dinámico con etiquetas RFID entrando y saliendo de la zona de detección del lector. Hemos desarrollado y evaluado la capacidad de los HMM para distinguir de manera robusta entre presencia y ausencia de etiqueta. El modelado con HMM presenta una ventaja clara frente al modelado MLE, dado que HMM incorpora la naturaleza secuencial existente en el escenario. La combinación de técnicas de procesamiento de señales y análisis estadístico ha permitido modelar, simular y evaluar nuestro acercamiento. Como referencia, a una distancia de lectura estándar, conseguimos mejorar la precisión en la detección por encima del 35 %.

Este es un trabajo inicial y en futuras investigaciones el objetivo será atacar los problemas inherentes en RFID, es decir, cuestiones de propagación e interferencias así como el abordar múltiples tags. Esto se tendrá en cuenta para modelar los patrones de datos que debe esperar una HMM adaptada a este entorno y se pretende conseguir una mejora respecto a usar únicamente los mecanismos de contención.

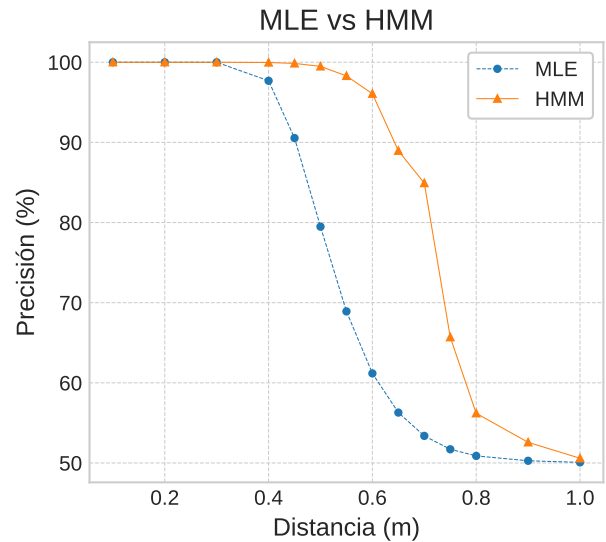


Fig. 4. Comparación de la precisión entre método MLE y HMM para distintas distancias. La precisión es un promediado entre distintos modelos entrenados y probados con secuencias distintas.

## AGRADECIMIENTOS

Esta publicación es parte del proyecto PID2022-139929NB-I00, financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE. Este trabajo también ha recibido apoyo de la Generalitat de Catalunya en el marco del Proyecto 2021 SGR 00197.

## REFERENCIAS

- [1] K. Finkenzeller, *RFID Handbook: Fundamentals and Applications in Contactless Smart Cards and Identification*, 2nd ed., Wiley Publishing, 2003.
- [2] R. Want, *An Introduction to RFID Technology*, IEEE Pervasive Computing, vol. 5, no. 1, pp. 25-33, 2006.
- [3] A. E. Peters, S. Juliet, J. Anitha, *Revolutionizing Car Assembly Line Efficiency Using Multi-Object Detection and Tracking*, International Conference on Artificial Intelligence For Internet of Things (AIIoT), Vellore, India, 2024.
- [4] B. D. B. Chowdhury, S. Masoud, Y. J. Son, C. Kubota, R. Tronstad, *A Dynamic HMM-Based Real-Time Location Tracking System Utilizing UHF Passive RFID*, IEEE Journal of Radio Frequency Identification, vol. 6, pp. 41-53, 2022.
- [5] M. Hauser, M. Griebel, F. Thiesse, *A hidden Markov model for distinguishing between RFID-tagged objects in adjacent areas*, IEEE International Conference on RFID (RFID), Phoenix, AZ, USA, pp. 167-173, 2017.
- [6] A. Bekkali, S. Zou, A. Kadri, M. Crisp, R. V. Penty, *Performance Analysis of Passive UHF RFID Systems Under Cascaded Fading Channels and Interference Effects*, IEEE Transactions on Wireless Communications, vol. 14, no. 3, pp. 1421-1433, 2015.
- [7] X. Xiong, W. Wang, T. Yang, G. Mao, *A survey on RFID anti-collision strategies: From avoidance to recovery*, Computer Networks, vol. 257, 2025.
- [8] L. R. Rabiner, *A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition*, Proceedings of the IEEE, vol. 77, pp. 257-286, 1989.
- [9] J. A. Bilmes, *A gentle tutorial of the EM algorithm and its application to parameter estimation for Gaussian mixture and hidden Markov models*, 1998.