

基於毫米波雷達的居家行為與安全監測系統

Millimeter-Wave Radar-Based Home Behavior and Safety Monitoring System

王能中 陳禹潔 鍾雅軒 許芊瑜 許乃懿 林心怡

國立聯合大學 資訊工程學系

苗栗市南勢里聯大2號

ncwang@nuu.edu.tw

{U1224019, U1224006, U1224008, U1224009, U1224018}@o365.nuu.edu.tw

摘要

隨著獨居人口與居家安全需求增加，如何在兼顧隱私的情況下即時掌握居家活動狀態，成為智慧家庭的重要課題。本研究設計一套基於毫米波雷達的居家行為與安全監測系統，利用非接觸式感測取得人體活動資訊，並結合雷達訊號處理、深度學習、網頁平台與 LINE Bot 通知機制。系統將原始 ADC 訊號轉換為 RDM、RAM 與 REM 特徵圖，再輸入 ResNet-18 結合 BiLSTM 模型進行行為辨識。實驗結果顯示，模型準確率達 86.98%，可辨識日常活動與跌倒事件，並提供即時警示功能。

關鍵詞：毫米波雷達、居家安全、行為辨識、跌倒偵測、深度學習

Abstract

With the increasing number of people living alone and the growing demand for home safety, how to monitor home activities in real time while protecting privacy has become an important issue in smart home applications. This study designs a millimeter-wave radar-based home behavior and safety monitoring system. The system uses non-contact sensing to obtain human activity information and integrates radar signal processing, deep learning, a web platform, and LINE Bot notifications. Raw ADC signals are converted into RDM, RAM, and REM feature maps, and then classified by a ResNet-18 and BiLSTM-based model for activity recognition. Experimental results show that the model

achieves an accuracy of 86.98%, indicating that it can recognize daily activities and fall events, while providing real-time alert functions.

Keywords: millimeter-wave radar, home safety, activity recognition, fall detection, deep learning

1. 簡介

本研究設計一套基於毫米波雷達的居家行為與安全監測系統，透過非接觸式雷達感測技術取得使用者於居家環境中的位置與行為狀態，並利用深度學習模型進行即時辨識。當系統偵測到跌倒等異常事件時，可透過網頁平台與 LINE Bot 通知家屬或相關人員，以提升獨居人士的居家安全。

1.1 研究背景

獨居人士若在家中發生跌倒或其他突發狀況，可能因無法即時求助而延誤處理。傳統攝影機雖能提供影像資訊，但容易造成隱私疑慮；穿戴式裝置則可能因忘記配戴或電量不足而中斷監測。因此，具備非接觸、保護隱私且不受光線影響的毫米波雷達，適合應用於居家安全監測。

1.2 研究動機

本研究希望建立一套不依賴攝影機與穿戴裝置的監測方式，在保護使用者隱私的同時，仍能即時掌握居家活動狀態。毫米波雷達可透過人體反射訊號取得距離、速度與角度資訊，並分析行走、站立、坐下、躺下與跌倒等行為，因此適合作為本

系統的核心感測技術。

1.3 相關研究

近年來，毫米波雷達已被應用於人體活動辨識與跌倒偵測等研究[1][2]。相關方法常將雷達訊號轉換為 Range-Doppler Map 或 Range-Azimuth Map 等特徵圖，再使用機器學習或深度學習模型進行分類。傳統方法如 SVM、MLP 架構較簡單，但較不擅長處理連續動作變化；CNN、LSTM、BiLSTM 與 ConvLSTM 等模型則可分別學習空間特徵與時間序列特徵，因此常用於人體行為辨識任務[2][6]。

2. 系統內容

本系統以毫米波雷達作為主要感測設備，結合現場邊緣端電腦進行訊號處理與模型推論，並透過網路將數據上傳至後端伺服器與資料庫，最後整合網頁平台與 LINE Bot 通知機制，建立一套完整的居家行為與安全監測系統。系統可即時取得使用者於室內的位置與行為狀態，並在偵測到跌倒等異常事件時發送警示通知。

2.1 系統架構

本系統主要分為感測端、邊緣運算端(包含兩台獨立運算主機)、後端伺服器與資料庫、網頁平台與 LINE Bot 五個部分。感測端使用兩台毫米波雷達分別進行居家行為辨識與人體空間定位。

本系統採用分布式邊緣運算(Distributed Edge Computing)架構，為了分流高頻寬的雷達數據與高負載的運算任務，現場部署了兩台邊緣端電腦獨立進行數據處理：

- 行為辨識邊緣電腦(電腦 A)：連接行為辨識雷達與 DCA1000 擷取模組，負責接收原始 ADC 訊號並將其轉換為 RDM、RAM 與 REM 特徵圖，隨後執行深度學習推論。

為了確保系統即時性與穩定性，電腦 A 內部串接流程採用了雙執行

緒異步架構：

- 接收執行緒：專責透過 UDP Socket 監聽 Port 4098，持續接收來自 DCA1000EVM 傳送的原始 ADC 封包。將封包組裝為完整一幀後放入佇列，整個過程不執行任何運算，確保接收端永遠不會因處理延遲而造成封包遺失。
- 處理執行緒：從佇列中取出資料，依序執行訊號前處理與模型推論，即使推論耗時較長也不影響接收端的運作。

兩條執行緒透過容量為 50 幀的佇列解耦，若佇列已滿則主動丟棄最舊的幀，確保系統不會因緩衝堆積而產生延遲。此架構經 60 分鐘連續運作測試驗證，UDP 封包遺失率為 0%、實際幀率穩定維持 10 fps、每幀平均處理時間為 36 ms，具備穩定的即時監控能力。

- 人體定位邊緣電腦(電腦 B)：連接定位雷達以接收室內點雲資料，負責執行 ROI 範圍過濾、SNR 雜訊篩選與 DBSCAN 聚類演算法，即時計算出使用者在空間中的座標位置。

當兩台邊緣端電腦分別完成「行為辨識」與「座標定位」的運算後，各自透過網路(Web API)將最終的行為類別、空間座標與異常告警事件等結構化數據，同步發送並寫入遠端的後端伺服器關聯式資料庫(MariaDB)中。

後端伺服器主要負責資料存取管理。網頁平台則透過 WebSocket 連線，即時從伺服器資料庫整合這兩台電腦傳來的行為與定位數據，在畫面上可視化呈現動態軌跡、當前行為與統計圖表。當資料庫被

寫入跌倒等高風險事件時，伺服器將觸發 LINE Messaging API，主動推播警示訊息至已綁定之使用者端。

在雷達感測配置方面，本系統將毫米波雷達(AWR1843AOPEVM) + 數據擷取卡(DCA1000)架設於距地面約 1.6 公尺處，並向下傾斜約 15 度，以涵蓋人體不同姿態變化。



圖一：系統架構圖。

2.2 開發環境

現場運算端(本地電腦)使用 Python 進行雷達資料處理與模型推論，並透過 mmWave Studio 搭配 DCA1000 收集原始 ADC 資料[5]。雲端環境部署於 GCP VM (Linux Ubuntu)，後端採用 Python Flask 建立 Web API，並以 MariaDB 儲存行為紀錄、座標、使用者資料與警告事件。前端網頁使用 HTML/CSS/JS 製作，透過 WebSocket 即時更新資料，並整合 LINE Messaging API 進行異常通知。

2.3 相關技術

本系統利用 FMCW 毫米波雷達進行非接觸式感測。雷達發射連續調頻訊號，並分析反射回波以取得距離、速度與角度資訊[4]，具備居家隱私保護優勢。

訊號處理階段，系統將原始 ADC 資料轉換為三種特徵圖：距離-都卜勒圖(RDM)呈現距離與速度變化、距離-方位圖(RAM)提供水平角度資訊、距離-仰角圖(REM)補充垂直姿態特徵。

行為辨識採用 ResNet-18 結合 BiLSTM 的深度學習模型。由 ResNet-18 擷取特徵圖的空間資訊[3]，再由 BiLSTM 學習連續動作的時序變化，以辨識 walk、stand、sit、lay、fall、null 與 transition 等行為類別。

3. 系統功能

本章介紹本系統所提供的主要功能，透過這些功能，使用者與照護者能即時掌握居家活動狀態。

3.1 雷達監測系統

雷達監測系統包含人體定位與行為辨識兩項功能，分別運行於現場的兩台邊緣端主機中：

- 人體定位(電腦 B)：透過定位雷達取得室內點雲資料，經由 ROI 過濾、SNR 篩選與 DBSCAN 聚類演算法計算位置座標，並加入追蹤穩定機制以降低姿勢變化產生的跳動。
- 行為辨識(電腦 A)：採用時空特徵融合架構，利用 ResNet-18 平行提取三路特徵圖的多維空間特徵，再將連續幀的空間特徵向量封裝為時間序列送入 BiLSTM，捕捉動態行為的時序關聯，最後由 Softmax 層輸出行為類別。

3.2 即時監測與輔助功能

- 即時監測：顯示使用者目前的行為狀態與座標位置，並在偵測到跌倒等危險事件時，與定位數據進行時序對齊，即時發送網頁警示與 LINE 通知。
- 行為總覽：依照選擇的時間區間，統計各類行為的發生時間與比例，並以圖表方式協助使用者與照護者了解日常活動分布。
- 警告事件查詢：以表格方式記錄過去發生的異常事件歷史，包含事件類型、位置與發生時間，方便使用者回溯危險事件。
- LINE Bot 通知：提供帳號綁定、狀態查詢與異常事件主動推播，使用者亦可透過 LINE 圖文選單直接查詢狀態或解除警報。

4. 系統實作成果

本系統的系統實作成果包含「前端系統」、「LINE Bot 通知系統」，說明如下。

4.1 前端系統

前端系統包含主畫面、登入介面、行為總覽、生活軌跡、警告事件歷史、註冊功能及 LINE 綁定功能。使用者可透過網頁全面掌握居家安全狀況。

4.2 首頁

首頁即時顯示使用者目前的行為動作與座標位置。當系統偵測到跌倒等異常事件時，畫面會跳出警告通知；危機排除後，使用者可點擊按鈕解除警報，同步更新處理狀態。



圖二：網站首頁。

4.3 登入與註冊介面

登入介面供使用者輸入帳號密碼進入系統。為提升安全性，系統採用密碼雜湊方式進行驗證，避免密碼以明文形式儲存。註冊介面則提供管理者建立家屬或照護人員帳號，使多人可共同使用系統進行居家安全監測。




圖三：登入介面。



圖四：註冊介面。

4.4 行為總覽

此功能可依查詢時間區間，彙整各行為狀態的發生時間與比例，並以圖表呈現活動時間佔比、警報次數及行為時序變化，協助快速了解活動狀況與異常分布。



圖五：行為總覽介面。

4.5 生活軌跡

此功能依時間區間彙整室內空間軌跡與活動數據，並以視覺化儀表板呈現各區域停留時間佔比、異常事件熱區、日常移動總距離及夜間活動頻率，方便評估活動量變化趨勢。




圖六：生活軌跡介面。

4.6 警告事件歷史

警告事件歷史介面會以表格詳實記錄過去所有異常事件之類型、發生位置與時間。點擊「檢視軌跡」功能，系統將於圖台上動態重現異常發生前 5 秒的位置變化，協助追溯事發經過。

警告事件歷史			
事件類型	開始日期	結束日期	
全部類型	yyyy/mm/dd	yyyy/mm/dd	查詢 清除條件
發生時間	發生位置	事件狀態	操作
2026-06-01 02:33:41	衣帽間	異常	檢視軌跡
2026-06-01 02:32:40	外出	異常	檢視軌跡
2026-05-31 21:00:13	外出	異常	檢視軌跡
2026-05-31 15:00:58	外出	異常	檢視軌跡
2026-05-31 14:21:28	寢房	異常解除	檢視軌跡
2026-05-31 09:29:43	外出	異常	檢視軌跡
2026-05-30 23:50:10	外出	異常	檢視軌跡
2026-05-30 22:53:55	寢房	異常解除	檢視軌跡
2026-05-30 21:34:16	寢房	異常解除	檢視軌跡
2026-05-30 17:35:41	外出	異常	檢視軌跡

圖七：警告事件歷史介面。



圖八：發生異常前的位置變化。

4.7 LINE Bot 通知系統

包含帳號綁定、警告通知、狀態查詢與解除警報。使用者綁定後，系統偵測到跌倒等異常會主動推播訊息；使用者亦可透過 LINE 圖文選單查詢狀態或解除警報，提供即時通知管道。



圖九：警告通知。



圖十：LINE Bot 圖文選單。



圖十一：狀態查詢。



圖十二：解除警報。

4.8 模型實驗結果

本系統以 SVM、MLP、CNN、BiLSTM、ConvLSTM 與 ResNet-18 + BiLSTM 進行比較，其中 ResNet-18 用於空間特徵擷取[3]，BiLSTM 用於時間序列建模[2]。實驗結果顯示，本研究所採用的 ResNet-18 + BiLSTM 模型表現最佳，Accuracy 達 86.98%，Precision 達 85.50%，Recall 達 84.17%，F1-score 達 84.68%。結果顯示結合空間特徵擷取與時序建模的方法，能有效提升日常活動與跌倒事件的辨識效果。

5. 結論

本系統成功實現了一套「基於毫米波雷達的居家行為與安全監測系統」。透過分布式邊緣運算技術，系統能在不使用攝影機與穿戴裝置的前提下，由現場電腦即時辨識使用者的行為狀態與室內位置。使用者可透過網頁查看目前狀態、歷史總覽與警告紀錄；當偵測到異常事件時，能透過 LINE Bot 即時發送通知。整體而言，本研究透過毫米波雷達與深度學習模型，有效提升了獨居人士居家安全監測的即時性與便利性。

表 1：各行為辨識模型之效能對比。

Models	Metrics (%)			
	Accuracy	Precision	Recall	F1-score
SVM	83.99%	84.65%	79.41%	81.06%
MLP	79.93%	82.24%	76.69%	78.75%
CNN	82.80%	81.05%	81.63%	80.83%
BiLSTM	81.36%	81.06%	77.83%	79.04%
ConvLSTM	76.82%	75.68%	74.43%	74.73%
ResNet-18 + BiLSTM (ours)	86.98%	85.50%	84.17%	84.68%

參考文獻

- [1] A. S. Fard, M. Mashhadigholamali, S. Zolfaghari, et al., “Lightweight FMCW radar framework for human activity recognition under limited data conditions,” Scientific Reports, Vol. 16, 9650, 2026.
- [2] H. Li, A. Shrestha, H. Heidari, J. Le Kernec, and F. Fioranelli, “Bi-LSTM Network for Multimodal Continuous Human Activity Recognition and Fall Detection,” IEEE Sensors Journal, Vol. 20, pp.1191–1201, 2020.
- [3] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [4] Texas Instruments, “Programming Chirp Parameters in TI Radar Devices,” Application Report SWRA553A, Texas Instruments, 2017. Available: <https://www.ti.com/lit/an/swra553a/swra553a.pdf>.
- [5] Texas Instruments, “AWR1843AoP EVM User’s Guide,” User’s Guide SPRUIX8, Texas Instruments. Available: <https://www.ti.com/lit/ug/spruix8/spruix8.pdf>.
- [6] X. Shi, Z. Chen, H. Wang, et al., “Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting,” Advances in Neural Information Processing Systems, Vol. 28, 2015.