

2025年臺灣國際科學展覽會 優勝作品專輯

作品編號	100021
參展科別	工程學
作品名稱	基於LSTM行為與活動力之樂齡關懷系統
得獎獎項	三等獎

就讀學校	新北市立新北高級中學
指導教師	謝進生 陳思樺
作者姓名	李芷蓁 廖姿婷 蕭羽蓁

關鍵詞 樹莓派、LSTM、樂齡關懷

作者簡介



我們是新北高中的蕭羽蓁、廖姿婷、李芷蓁(依照片由左到右排序)，因為高一的選修課程，我們發現自己對於工程類充滿熱忱，我們秉持科學探究的精神，全心全力投入作品的研究。過程中，我們學會了思考與解決問題，從挑戰中成長，也得到許多成就感。

感謝所有教授與師長們不辭辛勞的指導以及協助，讓我們累積許多寶貴的經驗與能力，並有機會朝更遠大的目標前進。

2025 年臺灣國際科學展覽

研究報告

區 別:

科 別: 工程學科(一)

作品名稱: 基於 LSTM 行為與活動力之樂齡關懷系統

關鍵詞: 樹莓派、LSTM、樂齡關懷

編 號:

(編號由國立臺灣科學教育館統一填列)

摘要

本研究開發基於 RNN 和 LSTM 的獨居者居家行為監控系統，利用樹莓派、多種無侵入式感測器及鏡頭實現獨居者日常活動的實時監控與情緒評估。系統收集各感應器數據，透過 LSTM 進行學習與預測，並使用隨機森林演算法分析行為狀態，提供客製化數據處理與預測性能優化。

長期數據收集可觀察獨居者的活動力及情緒變化，早期發現健康風險，針對現有求救設備頻繁異常通知的問題，我們開發了能夠識別長期身心狀況變化的監測系統，並整合人體紅外線感應器、都卜勒雷達感應器、日夜感測器等技術，透過 Python 程式及 MQTT 進行數據收集與處理。模型訓練使用 SQLite 資料庫數據，經過多次測試選擇最佳參數以提高預測準確度，隨機森林演算法也強化決策準確性。

通過長期的數據收集和分析，本系統能夠觀察並預測獨居者的活動力和情緒的變化，早期發現獨居者的身心健康是否有風險。

The current study aims at using a Raspberry Pi, combine with multiple simple sensors, to monitor the activity data of elderly individuals living alone. The system collects data by the sensors, learns and predicts the data using an LSTM (Long Short-Term Memory) network, and then employs a random forest algorithm to analyze the user's behavior. Customized data processing is performed for different individuals. Our homemade Python program communicates with each node via MQTT to collect data on the activities of the solitary elderlies. When the sensor is triggered, it will record the current time and the sensor results. The responses are stored in the SQLite database and daily activity changes can be observed. Through long-term data collection, our system can observe changes in the elderlies' activity levels, behavior, and emotional states, allowing early detection of potential health risks for them. The selection of weighted models of forest algorithms enables them to accurately predict and judge potential health risks and behavioral abnormalities. The system is mainly used in home behavior monitoring for single-person households. It provides an efficient solution for single-person households, hoping to combine LSTM prediction with randomness to improve elderly care.

壹、前言

一、研究動機：

根據內政部不動產資訊平台統計，2022 年全戶僅一名 65 歲以上長者居住的住宅數共 52.8 萬戶，這個數據顯示在少子化影響下，越來越多人主動選擇獨居，人期盼過著自主有尊嚴的生活。而且這個數字還在持續增加，只是獨居者儘管還能自理日常生活，一旦發生緊急狀況，第一時間往往難以被外界發現或主動求救。

目前防止獨居者意外作法有很多：最普遍是安裝多台攝影機監控，但事實情況是很少有家人可以 24 小時盯著螢幕看，大都是有空時才看一下，當意外發生時剛好盯著螢幕的機率微乎其微。所以就衍生第四台公司、保全公司健康照護專案，這些有設備功能有：低干擾生理量測、全天候諮詢電話、緊急求助按鈕、隨身呼叫器、電子圍籬功能、跌倒偵測系統(從智慧手機到各種傾斜偵測)、各種不活動偵測裝置(例如智慧床墊)，都可以做到緊急通知等功能。但是普遍存在異常通知過於頻繁的缺點，如右圖 1 所示上百次的異常通知，造成監控者無法放心的情形。



圖 1、異常偵測警示次數圖
(由第一作者所攝)

另外，獨居者常因社會支持體系相對薄弱，生活自理困難，或因經濟問題、產生疏離感，進而產生憂鬱症，而憂鬱症如果長期得不到治療，可能會導致自殺等嚴重後果。所以我們想要研究如何在不特別干擾使用者的情況下，改變鏡頭的用處，對使用者進行情緒辨識和各項特徵偵測技術，再應用大數據建立深度學習模型，發展出一套能監測人體行為之照護與監測系統，當異常事件發生時能夠於給予各種有效支援。

二、研究目的：

- (一) 分析基於 LSTM 的智慧健康照護系統在行為監測方面的可行性。
- (二) 透過自製感測器所收集的行為及鏡頭偵測的情緒資料，分析其日常行為間的關係以及異常行為數據變化。
- (三) 提高隨機森林演算法在監測系統中的準確度，使系統做出具有可靠性的決策。
- (四) 評估系統在實際健康照護環境中的效能，包括準確性和預測能力，並測試其對異常事件的檢測和反應能力。

三、文獻探討：

隨著醫療科技進步，人類壽命不斷提高，根據內政部戶政司人口統計資料，自 109 年到 111 年資料顯示如下表 1，65 歲以上老年人口逐年提升，並預計於 2025 年邁入超高齡社會，也就是老年人口比例超過 20%。

表 1、109-111 年度台灣人口性別及五歲年齡分組人數統計表

年度	性別	65~69	70~74	75~79	80~84	85~89	90~94	95~99	100+	65 以上統計	總人口數	比例
111	男	706,423	518,346	264,996	195,255	101,502	49,654	13,356	2,197	1,851,729	11,499,136	16.1%
	女	783,315	597,360	328,734	272,997	161,331	69,556	18,067	2,704	2,234,064	11,765,504	19.0%
	計	1,489,738	1,115,706	593,730	468,252	262,833	119,210	31,423	4,901	4,085,793	23,264,640	17.6%
110	男	696,974	476,519	256,442	192,117	102,595	52,177	13,336	2,099	1,792,259	11,578,696	15.5%
	女	768,486	546,437	319,156	268,252	155,913	68,318	17,573	2,639	2,146,774	11,796,618	18.2%
	計	1,465,460	1,022,956	575,598	460,369	258,508	120,495	30,909	4,738	3,939,033	23,375,314	16.9%
109	男	687,090	420,487	262,423	185,500	104,537	52,093	12,345	1,877	1,726,352	11,673,765	14.8%
	女	758,749	481,862	326,070	259,923	150,891	65,011	16,092	2,365	2,060,963	11,887,471	17.3%
	計	1,445,839	902,349	588,493	445,423	255,428	117,104	28,437	4,242	3,787,315	23,561,236	16.1%

資料來源：內政部戶政司 (第一作者自行整理)

隨著高齡化與少子化影響，越來越多老人選擇自己居住，再加上都會區房價高且坪數不大，子女結婚後希望保留自主空間，或種種原因離開家庭，傳統三代同堂越來越少見。再加上很多老人不願意入住安養機構，寧願獨自生活。

根據內政部不動產資訊平台統計，111 年第三季僅老年人口居住宅數已超過 69 萬宅，其中獨居老人宅數超過 7 成，高達 52.87 萬宅如下表 2，相對去年比例逐年增加，顯示高齡獨居者照護問題日益嚴重。

表 2、全國僅老人人口居住宅數表 單位：宅

	110Q3	110Q4	111Q1	111Q2	111Q3	相對上季(%)	相對去年同季(%)
老人人口居住總宅數	642,635	656,027	671,844	680,038	695,300	2.24	8.20
一名老人人口宅數	488,499	498,697	510,871	517,901	528,717	2.09	8.23
二名老人人口宅數	143,452	146,909	150,914	152,121	155,846	2.45	8.64
三名(含)以上老人人口宅數	10,684	10,421	10,059	10,016	10,737	7.20	0.50

資料來源：內政部不動產資訊平台 112 年第三季住宅資訊統計

根據衛生福利部國民健康署 108 中老年身心社會生活狀況長期追蹤調查報告結果顯示，54 歲以上中老年人中有 77.1% 至少罹患一種慢性疾病，年齡層越高則罹病項目數也越多，75 歲以上族群至少罹患一種慢性疾病之百分比超過九成（92.4%）。這也顯示隨著年齡增長，獨居老人終究會因自然老化，或各項慢性病導致面臨生活無法自理的問題，再加上心理及社交層面的問題，在孤獨的感受下，更增加獨立生活的風險。

隨著 104.6.30 通過的長期照顧服務法授權 8 個子法中，「老人福利服務提供者資格要件及服務準則」第 27 條明定緊急救援服務由下列單位提供：

- (一) 醫療機構、護理機構、醫療法人。
- (二) 老人福利機構、身心障礙福利機構。
- (三) 公益社團法人、財團法人、社會團體。
- (四) 保全業

根據以上，各縣市政府也可據此法規與相關單位簽訂執行緊急救援服務，隨著物聯網演進，各種科技照護的設備如雨後春筍般發展，時至今日各項 AIOT 智慧照護方案與產品越來越多，遠端照護人員可利用穿戴式裝置即時監控，設定老人生理數據異常標準，當偵測到數據異常會立即發出警告，醫療人員可立即前往協助，這些主動式的照護設備往往可以在第一時間發揮救急作用。

但是根據 EET 電子工程專輯(2022)穿戴式裝置的定位追蹤有何優缺點文章中提到，穿戴式裝置也有以下缺點：續航時間不佳、使用者需額外攜帶比較麻煩或容易遺忘、網路連接受限導致回報延遲、個人資料很容易被攔截造成個資外洩、容易丟失或被竊，一段時間後資料正確性存疑，單價過高等疑慮；然而更嚴重的是異常報告太頻繁，以及解讀不一。李順裕教授也舉例說明，人一天心跳將近 10 萬筆，而心律不整發生次數可能小於 100 筆，且往往出現在晚上與睡眠時間，無法透過人工進行分析，而其他諸如跌倒偵測的判讀意外警訊每天上百筆等，造成監測者麻痺的現象。Anthea Chuang(2021)在 EET TIMES 穿戴式醫療裝置正夯專輯文章中提到，消費性與醫療性穿戴式裝置雖然功能相似，但其測得資料的「可靠性」卻有明確的不同，相關專家也認為，「感測器融合」是提升精確度的有效方式，整合不同感測器接收的資訊，進行更多面向的情境感知與生物資訊探測，可提升系統的精準度。

奇美醫學中心精神科主治醫師高霈馨曾指出，隨著台灣人口老年化，老年心智疾患值得也需要被注意。老年憂鬱症盛行率高達 7~21%，女性比率高於男性。住院、安置機構、罹患中風、心肌梗塞或癌症的年長者更可能高達四成有憂鬱症。

多數年長者在面臨親人或朋友過世、退休後經濟壓力變大、家庭衝突、社會支持減少、疾病的衝擊下，憂鬱便悄然而至，因為症狀不似年輕族群典型，加之擔憂就醫造成子女負荷，往往病人到精神科就醫時，症狀已持續數月之久，症狀也更為嚴重。

而老年憂鬱症對失智症的影響更不容小覷，多數的臨床研究都證實，隨著年紀增長，憂鬱影響認知功能的程度越大，後續發生失智的風險越高。在老年憂鬱議題中最為棘手的便是自我傷害或是自殺的發生。高於 65 歲以上人口族群自殺死亡率是全年齡層中最高的。合併多種身體疾病、罹癌、缺乏家庭或社會支持、個性悲觀或極端、合併藥物或酒精濫用的病人都是自殺的高風險族群。

老年憂鬱症導致病人個人或家庭心理、經濟層面的重大影響，早期發現早期治療，儘早改善病人憂鬱症狀並減輕甚至恢復病人的失能狀態，是很重要的觀念。政府近年也積極推動憂鬱症的防治，對疾病預防、辨識、治療、復健都有相當程度的投入，在自殺防治更是不遺餘力的推行。

中醫科學院望京醫院心理科醫生王亞娜也表示，憂鬱症的發病是長期負面情緒積累所導致的，並非是突然發病，患者常常會在生活中會不經意地將一些口頭禪掛在嘴邊。

(一)好煩呀：

輕度憂鬱症的人群往往抗壓能力比較低，稍微遇到一點打擊就會變得很沮喪，對生活失去信心，而且只會把好煩呀煩死了這句話掛在嘴邊。

(二)睡不著：

經常說自己睡不好覺，80%憂鬱症患者在早期都存在一定程度的睡眠問題。

(三)好無聊呀：

憂鬱症的患者對什麼都提不起興趣，他不喜歡和人相處，不想出門，不知道自己要做什么，也不想去做任何事情，感覺極度地空虛。

(四)活著沒意思：

對生活失去希望，感覺自己的人生樣樣不如意，樣樣不如別人，覺得活著太累，這種想法持續久了慢慢地就會產生一些輕生的想法。

從以上文獻分析發現：一個人的身心健康狀況單憑數值型的檢測是不夠的，而且數值型資料是無法檢查日常生活行為當中的隱藏問題，若想要了解生理訊號與健康資訊，人工智慧辨識是不可或缺的技術。經由感測器所蒐集的行為資料，透過整合與建立模型，有助於患者在病情發作之前找出不規則的地方。除了監測之外，對異常行為分析更是人工智慧可提供協助之處。

遞歸神經網路(RNN)強大的地方在於它允許輸入與輸出的資料不只是單一組向量，而是多組向量組成的序列，由於 Simple RNN 的記憶效果不夠好，無法記住長期的資料，所以發展出長短期記憶(Long Short Term Memory)的循環神經網路如下圖二，在神經單元中加入了遺忘，更新，以及輸出三個步驟，進而大幅提高了其在長期記憶的表現。這些步驟如同下圖的紅色圓圈(原文為 gate 表示閥的意思)，再透過數學函數來控制有多少的資料會被更新到單元狀態 (cell state) 中。單元狀態是最上方的水平線，連接所有的神經單元。




圖 2、傳統的 RNN 模型(左)與 LSTM 模型(右)的示意圖

(來源：Google 神經網路)

LSTM 中間的神經單元變得較為複雜，並會將過去時間點的資料統整為一筆長期記憶資料(Memory cell)，所以擅長於任何和時間有關的資訊，本組認為適合應用在本研究多種感測器、穿戴裝置所發展的人工智慧中，藉由特徵提取建立模型，分析並找出每天行為間的差異，發展分析模式，期能檢查出不規則的異常行為。

貳、 研究設備與器材

表 3、研究設備與器材

名稱	規格	數量
開發板	Raspberry Pi 4 Modle B	2個
TF卡	32GB	1張
金屬散熱殼		依照感應器個數
電源供應器		依照感應器個數
轉接線	Micro HDMI 轉 HDMI	1條
開發板	ESP8266	依照感應器個數
開發板	ESP32	1個
人體紅外線感應器		數個
都卜勒雷達感應器		數個
日夜感測器		數個
紅外線遙控接收器		數個
紅外線遙控器		數個
語音辨識器		數個
各式線材		數條
鋰電池	3.7V	依照感應器個數
鏡頭	Raspberry Pi Camera Board v1.3	1個

參、研究過程或方法

為了提供即時的緊急支援和長期監測，確保獨居者在家中的安全，我們需要實時監測獨居者的生命體徵、行為監測、人流監控、情緒辨識和語音識別，在不特別干擾使用者的情況下，應用大數據和深度學習偵測辨識，發展出一套能夠監測人體活動之照護與警報系統。因此我們選用樹莓派(Raspberry Pi 4 Model B)做為開發板，並結合人體紅外線感應器、都卜勒雷達感應器、日夜感知器、紅外線遙控接收器、語音辨識器和樹莓派鏡頭，追蹤獨居者的活動、收集資料，識別其潛在的緊急情況，如果識別到異常行為，將會傳送 LINE 訊息或直接給予語音回饋。

一、樹莓派(Raspberry Pi 4 Model B)




圖 3、樹莓派示意圖 (來源：Google 樹莓派 4)

- (一) 用Broadcom 2711四核心晶片 Quad-core Cortex-A72 64-bit SoC，單核心時脈達 1.5GHz，和 Pi3B+ 使用的 BCM2837B0 比，有三倍速快。
- (二) 四種記憶體(LPDDR4 SDRAM)大小可選擇，分別是 1GB, 2GB, 4GB, 和 8GB。
- (三) 乙太網路(Ethernet)達 True Gigabit Ethernet。
- (四) 支援藍牙 5.0 (Bluetooth 5.0)。
- (五) 兩個 USB 3.0 和 兩個 USB 2.0。
- (六) 支援雙銀幕輸出，解析度可達 4K。
- (七) 使用 VideoCore VI，可支援 OpenGL ES 3.x。
- (八) 可硬體解 4Kp60 HEVC 影片。

二、人體紅外線感測器（PIR Motion Sensor）

人體紅外線感測器（PIR）是常見的警報器元件之一，主要用途做為人體紅外線偵測，因為人體紅外線感測器外殼有一片多層鍍膜可以阻絕大部分紅外線，只讓溫度接近 36.5 度的波長的紅外線通過，所以當使用者進入感應區域時，感應器會檢測到紅外線變化，又因為人體本身發射紅外線和面積較大，容易被感測到，所以適合用來做為人體移動偵測，並且具有高靈敏度和低功耗的優勢，使它成為我們用來監測人體活動的理想選擇。



圖 4、人體紅外線感測器
(來源：Google)




圖 5、人體紅外線實作圖 (由第一作者所攝)

如上圖 5，在 Serial 視窗中，只要手掌經過感應器，它會依照指示發送訊息
”有東西在動！”

我們將人體紅外線設置於各種空間，來監測使用者是否存在於這個空間，例如；臥室、廚房、客廳、浴廁、玄關……等。我們也測得感應器的可偵範圍在三米以內，因此依照範圍大小，在半徑三公尺的條件下加以安裝數個感測器。

三、都卜勒雷達感應器（Doppler Radar Sensor）

Doppler 基於都卜勒效應，通過檢測目標物體引起的微小頻率變化來實現運動偵測。其原理是雷達產生出高功率電磁波經由天線輻射出去形成所要的雷達波。當發射出去的雷達波在空間中掃描，碰到目標後部分反射之回波經過濾波、放大等程序，推斷目標物體的運動狀態，偵測目標是否存在，進而決定其距離、方向、高度、速度和其他資訊，並藉雷達顯示器加以顯示出來。



圖 6、都卜勒感應器
(來源：Google)




圖 7、都卜勒感應器實作圖（由第一作者所攝）

在 Serial 視窗中，只要將物品由感應器上方經過，它就會出現我的指示” Detective” 一般情況下則是出現 “Not Detective”

Doppler 感應器具有高靈敏度、遠距離偵測、不受光線影響等優點，使其在室內和室外環境中均有很好的表現，可方便地整合到各種應用中，提供高效的動態偵測和警報功能，因此我們選用都卜勒感應器，並將其安裝於各個出入口的上方，紀錄使用者在不同空間的進出。

四、日夜感測器(光敏電阻)

光敏電阻器是一種感光式電阻器，當光敏電阻器受到光照射的時候，它的電阻器值會降低，因為光能使材料裡的電子脫離原子成為自由電子，所以增加了材料的導電性。因此當光的強度很高時，電阻器值就會很低。



圖 8、日夜感測器
(來源：Google)




圖 9、日夜感測器實作圖 (由第一作者所攝)

基於光敏電阻對光線強度的敏感度，使其隨著環境的光亮程度改變自身的電阻值，光越強阻值越小；反之，光越弱，阻值越大。感知器透過測量光敏電阻的電阻值，判斷周圍環境的光線強度。

因此在我們的系統中，我們將日夜感知器，安裝在照明燈具下方以及窗框上，用來判斷使用者是否有開關燈的動作和開窗的動作。

五、紅外線遙控接收器

紅外線遙控器的應用也是一種無線訊號傳輸，由於紅外線遙控裝置具有體積小、功耗低、功能強、成本低等特點，採用紅外線遙控不僅完全可靠而且能有效地隔離電氣干擾。



圖 10、紅外線遙控接收器
(來源：Google)



圖 11、紅外線遙控實作圖 (由第一作者所攝)

我們系統會選用是因為在我們生活中大部分的遙控器皆是使用紅外線，我們想要利用這個理由，來記錄使用者在使用遙控設備的頻率以及次數，因此在我們的系統中，將此裝置放置於任何使用紅外線遙控器的接收器周圍，例如：電視機、冷氣、電風扇……等等。來判斷使用者是否有使用遙控的功能，並加以記錄。

六、語音辨識器

我們將 ESP32-Voice 聲控板整合了 ESP32 和 32 位元的 RSIC 晶片，透過高感度麥克風收集聲波，並使用 DSP 指令集進行 AI 語音辨識。它能夠協助獨居者，向外界發出最即時的呼救訊息。

目前我們系統中輸入的語音辨識內容有，緊急求救：求救、救命、救我、119，負面關鍵字：好煩呀、睡不著、好無聊、活著沒意思，在語音辨識器接收到以上指令時，就會發送 LINE 訊息給綁定者，或直接給予語音安撫。




圖 12、語音辨識器示意圖
(由第一作者所攝)

圖 13、語音辨識器實作圖
(由第一作者所攝)

七、Raspberry Pi Camera Board v1.3 鏡頭

我們使用的是 Raspberry Pi 相機板直接插入 Raspberry Pi 上的 CSI 連接器。再使用 OpenCV，搭配 Deepface 第三方函式庫，偵測人臉後，即時辨識出該人臉的情緒反應，我們再選用 Deepface 函式庫其中的負面情緒(angry、fear、sad...等)，若 5 秒內偵測到大於 13 次的負面情緒，那麼就會進入到 SQLite 的資料庫裡，計一次，每 5 秒重置。




圖 14、情緒辨識實測圖 (由第一作者所攝)

八、神經網絡選用

(一) 循環神經網絡 (RNN)

RNN 適用於序列數據，通過在隱藏層之間建立循環連接，隱藏層的神經元負責記憶先前時間的信息，用以捕捉序列的上下文，反饋先前時間的信息，CNN 則是主要應用於處理圖像和空間數據，利用卷積層和池化層來檢測和提取圖像，能夠有效地捕捉局部特徵。研究結果，RNN 具有記憶的功能，可以記憶通過的訊息，例如：時間順序等，適用於有順序性的資料。




圖 15、RNN 運算過程圖 (來源：Google RNN 圖)

(二) 長短期記憶神經網路(LSTM)

由於 Simple RNN 的記憶效果不夠好，因為它對時間序列中的先前信息的記憶能力有限，且 RNN 是一種遞歸計算的模型，難以進行並行計算，這導致在處理大量數據時計算效率較低，訓練的過程相對複雜，容易受到數據的初始化、學習速率等影響，可能會需要更多的時間和計算資源。




圖 16、LSTM 運算過程圖
(來源：Google LSTM 圖)

為了我們系統可以有更準確、快速、完善的計算資料，我們選用基於它的缺點進行改進的神經網路之一，長短期記憶神經網路(Long SHORT Term Memory，LSTM)。

在 LSTM 中，它包含了三個主要關鍵技術，分別是遺忘閘(forget gate)、輸入閘(input gate)和輸出閘(output gate) 這些閘的作用是控制資訊的流動，允許模型選擇性地遺忘或者記住之前的信息，使 LSTM 能夠有效地捕捉長期相依性，進行活動預測，期望能在早期發現獨居者的活動力是否下降，甚至健康狀態是否異常。

(三) 門控循環單元 (GRU)

GRU 在 RNN 的基礎、LSTM 的構想上進行了改進簡化，GRU 的結構相對簡單，它通過合併一些 LSTM 中的結構元素，減少了模型的參數數量，提高了計算效率。GRU 的輸入/輸出結構和普通的 RNN 相似，其運算性能較好，使用資源也較少。

不過，我們最終還是選擇長短期記憶神經網路 LSTM，因為 LSTM 細胞狀態的概念可以更好的處理我們資料的長序列，還因為 LSTM 三個門的設計，可以更好的控制我們信息的流動，雖然以運算結果來看，GRU 和 LSTM 差不多，不過相較於 GRU，LSTM 結構較複雜，使用的資




圖 17、GRU 運算過程圖
(來源：Google GRU 圖)

源也比較多，另外，LSTM 較 GRU 早很多年發表，歷經多年實測，GRU 年輕許多，還需要更多的驗證，所以除非是硬體算力不足，才要考慮 GRU。

(四) 調整天數與準確度的關係

表 4、運算天數測試圖 (由第一作者所製)

時間	LSTM Type	天數	測試天數	訓練天數	訓練次數	MSE
Aug-23	Stacked	10	6	24	30	0.131
Sep-23	Stacked	10	6	24	30	0.123
Oct-23	Stacked	10	6	24	30	0.128
Nov-23	Stacked	10	6	24	30	0.105
Dec-23	Stacked	10	6	24	30	0.111
Jan-24	Stacked	10	6	24	30	0.124
Aug-23	Stacked	15	6	24	30	0.103
Sep-23	Stacked	15	6	24	30	0.06
Oct-23	Stacked	15	6	24	30	0.092
Nov-23	Stacked	15	6	24	30	0.092
Dec-23	Stacked	15	6	24	30	0.08
Jan-24	Stacked	15	6	24	30	0.101
Aug-23	Stacked	20	6	24	30	0.029
Sep-23	Stacked	20	6	24	30	0.025
Oct-23	Stacked	20	6	24	30	0.024
Nov-23	Stacked	20	6	24	30	0.027
Dec-23	Stacked	20	6	24	30	0.026
Jan-24	Stacked	20	6	24	30	0.024
Aug-23	Stacked	25	6	24	30	0.881
Sep-23	Stacked	25	6	24	30	0.423
Oct-23	Stacked	25	6	24	30	0.754
Nov-23	Stacked	25	6	24	30	0.198
Dec-23	Stacked	25	6	24	30	0.09
Jan-24	Stacked	25	6	24	30	0.41

接下來研究最佳運算天數，第一次實驗以 10、15、20、25 天來實驗，因為預測本身得到的結果會有些許誤差，所以在實驗時將做五次，若是三次的誤差非常大，代表此模型或輸入值不可靠，而實驗後得到的結果如表 4。

以結果來看屬於 20 天的的結果最佳，均方誤差(MSE)為最低，並且沒有出現極端的數據誤差，因此我們再針對 20 天左右做更細部的實驗，以求得最佳之天數如表 5。

表 5、最佳運算天數 (由第一作者所製)

時間	LSTM Type	天數	測試天數	訓練天數	訓練次數	MSE
Aug-23	Stacked	18	6	24	30	0.121
Sep-23	Stacked	18	6	24	30	0.058
Oct-23	Stacked	18	6	24	30	0.075
Aug-23	Stacked	19	6	24	30	0.021
Sep-23	Stacked	19	6	24	30	0.058
Oct-23	Stacked	19	6	24	30	0.041
Aug-23	Stacked	20	6	24	30	0.029
Sep-23	Stacked	20	6	24	30	0.025
Oct-23	Stacked	20	6	24	30	0.024
Aug-23	Stacked	21	6	24	30	0.041
Sep-23	Stacked	21	6	24	30	0.032
Oct-23	Stacked	21	6	24	30	0.048
Aug-23	Stacked	22	6	24	30	0.081
Sep-23	Stacked	22	6	24	30	0.051
Oct-23	Stacked	22	6	24	30	0.064

最後測試 18-22 天數，發現在 20 天時，其均方誤差為最低，有較佳的準確度，因此在之後的運算我們使用 20 天作為系統的運算天數，利用 20 天預測下一天的方式進行。

肆、研究結果與討論

一、系統運作流程

經過先前之不斷研究與規劃，本系統之發展與組成架構以生命體徵系統、行為偵測系統、人流監控、情緒辨識以及語音識別所組成，我們針對我們所設想的五大部分，進行感測器的選用，並且利用感測器的使用來針對使用者進行動態的行為定義，最終我們的整個系統可以偵測活動力是否下降抑或長期行為出現偏差。

系統的感測器、循環神經網路、資料庫經過我們不斷地設計與規劃，我們分析感測器可感應的範圍，規劃安裝位置，整合人體紅外線感測器、紅外線偵測、日夜光敏感

測、都卜勒感測器，而為了使本系統之準確度最佳化，於循環神經網路當中進行 LSTM 的運算及預測，能在早期發現獨居者的活動力是否下降，並預測各個感應器所觸發的頻次，在透過隨機森林演算法對 LSTM 所預測的數據進行決策，判斷是否有行為出現偏差，如果活動力低於閾值又或者是行為出現偏差的話，系統會透過 Make IFTTT 發送求救訊息至 LINE。同樣在語音識別的部分，如果語音感測器收到負面情緒，會直接進行語音回饋，像是撥放音樂等等，若是收到求救訊息，那麼語音感測器就會透過 Make IFTTT 發送 LINE 訊息給綁定者。




圖 18、系統流程圖 (由第一作者所製)




圖 19、系統連接圖 (由第一作者所製)

上圖 19 是我們研究的系統連接圖，主要是五個感應器(人體紅外線、都卜勒感應器、日夜感測器、紅外線遙控感應器、鏡頭)透過 WIFI 連接樹莓派，將感測器收到的數據資料傳送到資料庫中儲存，而語音感測器是我們系統中「被動」感測及發送，它同樣也是透過 WIFI 發送訊息，也就是說，在使用者發出求救音訊或是負面情緒的抒發，才會觸發感測器進行語音的回饋或是訊息的發送。

利用 WIFI 傳送，MQTT 接收資料後，存到 SQLite 的資料庫，經過 LSTM 的預測，和隨機森林的決策，來判斷活動力值及行為數據是否出現異常，如果出現異常，那麼樹莓派會呼叫 Make IFTTT，傳送 LINE 訊息。

二、感應器實際放置位置及其用途

為了盡可能地達成精準的識別，降低辨別失誤率，也就是說，將人體感測器、都卜勒感應器、光敏電阻、紅外線遙控，放在最明顯能夠進行辨別使用者行為處。我們使用 Tinkercad 房間模擬，而圖 20 中的箭頭符號就是我們的構想中，感測器的安裝處。




圖 20、感應器放置位置構想圖 (由第一作者所製)

最後我們也前往獨居者的家中加裝感應器，如圖 21，並記錄相關數據。




圖 21、感應器實際放置圖（由第一作者所攝）

我們將人體紅外線感測器放置於房間的牆上高處，記錄使用者是否待在這個空間。將光敏電阻放在照明燈具下方和窗戶上方，記錄使用者開關燈和開關窗的舉動。將紅外線遙控感測器安裝在電視上方，使用者在操控紅外線遙控器時，就可以被記錄下來。我們將都卜勒感應器裝在門上方的中間，像是自動門一樣，當使用者經過時，便可以記錄下來。下圖 22，我們為此系統製作了一個模型。



圖 22、感測器擺放模型（由第一作者所攝）

三、資料收集階段

我們使用了自製的 Python 程式，通過 MQTT 與各節點通信，收集獨居者的各項生活活動數據。這些數據包括日夜感測器資料、都卜勒感測器、紅外線感測器、人體紅外線感測器和鏡頭等。所有收集到的數據都儲存在 SQLite 資料庫中，以便後續分析和處理。

SQLite 與一般 Server/Client 結構的資料庫不同，SQLite 被整合在應用程式當中，為一種嵌入式的資料庫。

首先，先在樹莓派裡，利用 DB Browser for SQLite 建立資料庫及資料表，隨後執行下圖 23 的程式，其中，S1 代表都卜勒感測器，用來記錄使用者在不同空間的進出情況、S2 代表人體紅外線感測器，用來監測使用者是否存在於這個空間、S3 代表紅外線遙控感測器，用來記錄使用者在使用紅外線遙控的情形、S4 代表日夜感知器(光敏)，用來判斷使用者是否有開關燈的動作和開窗的動作、S10 則是代表語音辨識器，在使用者喊出關鍵字時，就可以有對應的措施、S11 則代表鏡頭，用來辨識使用者的情緒。



圖 23、接收資料程式圖 (由第一作者所攝)

透過 MQTT Broker 收集各節點的資料，再將資料儲存在 SQLite 資料庫，當感應器觸發時，將會記錄當下的時間及觸發的感應器並儲存在 SQLite 資料庫，我們可以從資料庫看到觸發的時間以及觸發哪一種感應器，但 S10 與其他感測器略有不同，它跳的數字代表不同的關鍵字。

右圖 24，為資料庫及圖畫面。

s1	s2	s3	s4	s5	s6	s7	s8	s9	s10	s11	location	number	createdAt
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:56:55
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:01
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:06
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:11
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:16
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:22
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:27
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:32
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:37
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:42
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:47
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:53
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:57:58
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:58:03
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:58:08
0	0	0	0	0	0	0	0	0	0	1	1	1	2024-06-09 16:58:13

感應器編號

是否觸發感應器

時間

圖 24、資料存於資料庫實際圖 (由第一作者所攝)

我們為此自製網頁來收集長期行為數據資料，再經過不同使用者的數據提供，日積月累下來，我們就會擁有龐大的數據資料量，而那些資料量可以提供我們未來系統的優化以及學術研究。




圖 25、收集行為資料網頁(由第一作者所攝)

四、模型訓練階段

(一) RNN

這個 SimpleRNN 循環遍歷 SQLite 資料庫數據，長度為 21 天。樣本將包含 20 天的特徵和第 21 天作為標籤。設定 80% 的數據將用於訓練，剩下的 20% 用於測試。將特徵和標籤數據分割為訓練集和測試集。

向模型中添加一個 SimpleRNN 層，並且這一層有 256 個神經元。添加一個 Dense 層作為輸出層，只有一個神經元，用於預測下一時間點的值。設定損失函數為均方誤差 (MSE)。模型的訓練將最小化預測值和實際值之間的均方誤差。使用訓練數據對模型進行訓練，批量大小設為 100，訓練 30 筆。

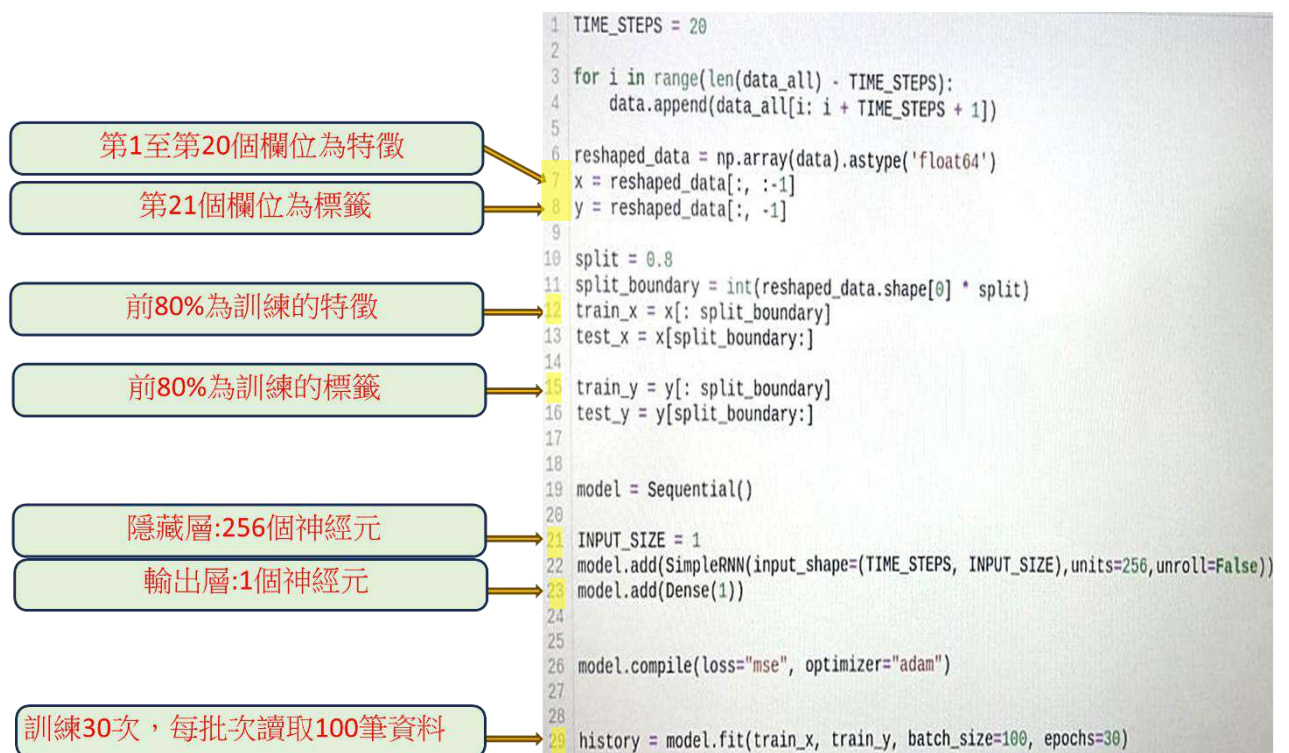


圖 26、RNN 訓練程式圖 (由第一作者製)

我們選取最後 20 條時間序列數據，換而言之就是利用最近的 20 天數據來預測下一個時間點(第 21 天)，模型是在縮放後的數據上訓練的，所以進行預測時也需要對輸入數據進行相同的縮放處理，數組重塑成適合模型輸入的形狀。這裡的形狀是指樣本數(感測器所取得的數據)、時間(日期)、特徵(進行預測的數據)，利用訓練好的模型進行預測，預測「明日」的數據。




圖 27、RNN 預測 程式圖 (由第一作者製)

我們使用訓練好的模型對測試集進行預測。使其返回一個預測值數組，因返回值可能為一個多維數組，為了確保包含所有預測值，因此將形式重塑為一維數值，再將數據還原標準化。接著使用 matplotlib 庫繪製預測值，其中' b: '指定藍色的點線，並在同一個塗上繪製真實值指定' r- '為紅色的點線，最後打開窗口，就可以得到繪製的資料。

```
Epoch 1/30
3/3 [=====] - 4s 81ms/step - loss: 0.6455
Epoch 2/30
3/3 [=====] - 0s 71ms/step - loss: 0.1587
Epoch 3/30
3/3 [=====] - 0s 71ms/step - loss: 0.0528
Epoch 4/30
3/3 [=====] - 0s 71ms/step - loss: 0.0584
Epoch 5/30
3/3 [=====] - 0s 74ms/step - loss: 0.0495
Epoch 6/30
3/3 [=====] - 0s 70ms/step - loss: 0.0365
Epoch 7/30
3/3 [=====] - 0s 71ms/step - loss: 0.0426
Epoch 8/30
3/3 [=====] - 0s 70ms/step - loss: 0.0313
Epoch 9/30
3/3 [=====] - 0s 74ms/step - loss: 0.0362
Epoch 10/30
3/3 [=====] - 0s 75ms/step - loss: 0.0293
Epoch 11/30
3/3 [=====] - 0s 70ms/step - loss: 0.0335
Epoch 12/30
3/3 [=====] - 0s 72ms/step - loss: 0.0277
Epoch 13/30
3/3 [=====] - 0s 74ms/step - loss: 0.0308
Epoch 14/30
3/3 [=====] - 0s 73ms/step - loss: 0.0268
Epoch 15/30
3/3 [=====] - 0s 74ms/step - loss: 0.0270
Epoch 16/30
3/3 [=====] - 0s 75ms/step - loss: 0.0268
Epoch 17/30
3/3 [=====] - 0s 71ms/step - loss: 0.0268
Epoch 18/30
3/3 [=====] - 0s 78ms/step - loss: 0.0260
Epoch 19/30
3/3 [=====] - 0s 72ms/step - loss: 0.0258
```

圖 28 ▲模型訓練過程損失值 (誤差)
(由第一作者製)




圖 29、RNN 預測 / 實際 程式圖 (由第一作者製)




圖 30、RNN 預測 / 實際 圖 (由第一作者製)

從圖 30 可以發現，預測線和實際線準確的數值存在一定的落差，但整體來說趨勢是一樣的，由此可知，RNN 可以用來作為系統的運算，但是在準確率上會有落差，甚至也會造成過擬合的風險。

(二) LSTM 長短期記憶網絡

LSTM 與 RNN 的程式較為相似，在這個部分，我們將展示與 RNN 不同的地方，LSTM 會將過去時間點的資料統整為一筆長期記憶資料，我們將 LSTM 用 SQLite 資料庫數據，長度為 21 天。樣本將包含 20 天的特徵和第 21 天作為標籤。設定 80% 的數據將用於訓練，剩下的 20% 用於測試，模型的訓練將最小化預測值和實際值之間的誤差。




圖 31、LSTM 訓練圖 1 (由第一作者所製)

模型中我們添加了兩個具有 50 個單位元的長短期記憶 LSTM 層，第一個 LSTM 層會返回整個序列的輸出給下一層，用於堆疊 LSTM 層，第二個只返回序列的最後一個輸出給全連接層。

我們進行堆疊 LSTM 層的實驗，測試堆疊多少層及多少神經元的誤差值最低，如下圖 32 就是我們針對不同個數及層數堆疊的研究。

	指標	1層	2層	3層	4層
30個神經元	訓練MSE	0.046	0.041	0.040	0.048
	驗證MSE	0.045	0.042	0.039	0.050
	測試MSE	0.044	0.048	0.042	0.049
40個神經元	訓練MSE	0.039	0.036	0.028	0.042
	驗證MSE	0.038	0.029	0.029	0.039
	測試MSE	0.03	0.033	0.025	0.045
50個神經元	訓練MSE	0.041	0.021	0.038	0.038
	驗證MSE	0.04	0.028	0.034	0.032
	測試MSE	0.039	0.024	0.039	0.035
60個神經元	訓練MSE	0.042	0.030	0.039	0.042
	驗證MSE	0.046	0.021	0.041	0.036
	測試MSE	0.040	0.029	0.035	0.049

圖 32、堆疊 LSTM 實驗圖 (由第一作者所製)

我們發現在兩層且 50 個神經元及三層 40 個神經神經元時誤差值較低，但由於 3 層 40 個神經元的計算成本較高，訓練較複雜一般硬體無法負荷，且層數及神經元越高越容易發生過擬合風險。

Keras 框架建立的 LSTM 模型，旨在處理時間序列數據。這個模型由兩層 LSTM 層和兩層 Dense 層組成。第一層 LSTM 層將時間序列的輸入序列化後傳遞給第二層 LSTM 層，後者則輸出最後一步的結果以供 Dense 層處理。添加了一個包含 25 個神經元的 Dense 層（全連接層），該層主要負責將前面 LSTM 層提取出的特徵進行線性組合，再輸出至最後一層含 6 個神經元的 Dense 層，來對 6 個不同的目標值進行預測。這個模型經過 Adam 優化器的訓練和 MSE 損失函數的調整，讓預測結果更接近真實值。

```

model = Sequential()
model.add(LSTM(50, return_sequences=True, input_shape=(x_train.shape[1], x_train.shape[2])))
model.add(LSTM(50, return_sequences=False))
model.add(Dense(25))
model.add(Dense(6))

model.compile(optimizer='adam', loss='mse')

```

圖 33、LSTM 訓練圖 (由第一作者製)

使用 matplotlib 庫繪製預測值，其中藍色的點線為真實值，橘色的點線道表驗證的值，黃色的點線則是預測值，最後打開窗口，就可以得到繪製的資料，由圖可見，預測值和驗證值圖形象近，相較 R N N 的誤差較小，可以得知長短期記憶的 L S T M 較適合用於長期照顧。




圖 34、LSTM 訓練 / 驗證 / 預測 圖 (由第一作者製)

最終，我們系統選擇直接採用 LSTM 作為我們系統的活動力預測，為了搭配隨機森林演算法，進行更為準確的行為偏差決策，我們調整了 LSTM 的輸出值，如下圖 35。

```
doppler_prediction = predictions[:, 0]
pir_sensor_prediction = predictions[:, 1]
ir_remote_prediction = predictions[:, 2]
day_night_sensor_prediction = predictions[:, 3]
camera_emotion_prediction = predictions[:, 4]
total_activity_prediction = predictions[:, 5]
```

→ 分別獲取6個輸出值

輸出結果

```
print("Doppler Sensor Predictions (是否經過):", doppler_prediction)
print("PIR Sensor Predictions (是否存在這個空間):", pir_sensor_prediction)
print("IR Remote Predictions (遙控設備的頻率及次數):", ir_remote_prediction)
print("Day/Night Sensor Predictions (開燈、開窗):", day_night_sensor_prediction)
print("Camera Emotion Predictions (情緒辨識):", camera_emotion_prediction)
print("Total Activity Predictions (總活動力值):", total_activity_prediction)
```

圖 35、LSTM 輸出圖 (由第一作者所製)

我們將 LSTM 設置成輸出六個值，分別輸出五個感測器的預測值以及總活動力值，其中不同的感測器也代表不同的動態行為。活動力值若是低於閾值將會發送警報，其他的輸出結果將會變成新的資料提供給隨機森林進行決策的資料依據。

五、隨機森林演算法

程式使用 pandas 套件讀取存有感測器觸發頻次的 Excel 檔案，並從中提取欄位 a1 到 a4 以及 a11 作為特徵變數（輸入值 X），而 ans 欄位則作為目標變數（輸出標籤 y）。此數據預處理的目的是將資料轉換為模型可以處理的格式，接下來，將資料集分為訓練集與測試集，其中訓練集佔 80%，測試集佔 20%，並設置 random_state=42 以確保資料分割的隨機性可以重現。接著，程式設置了不同的 tree_counts 參數，這個參數表示隨機森林模型中樹的數量，數值範圍從 10 到 350 不等，用來測試不同數量的決策樹對模型準確度的影響。

程式進一步使用迴圈建立多個隨機森林分類模型，針對每個 tree_counts 的數值進行模型訓練，並利用測試集進行預測，最後將每次的準確度結果儲存在 accuracies 清單中。這樣的多模型測試方式有助於選出最佳的模型參數，以便後續進行最佳化調整，下圖 35 展示了如何載入資料並進行隨機森林分類模型的訓練與測試過程。

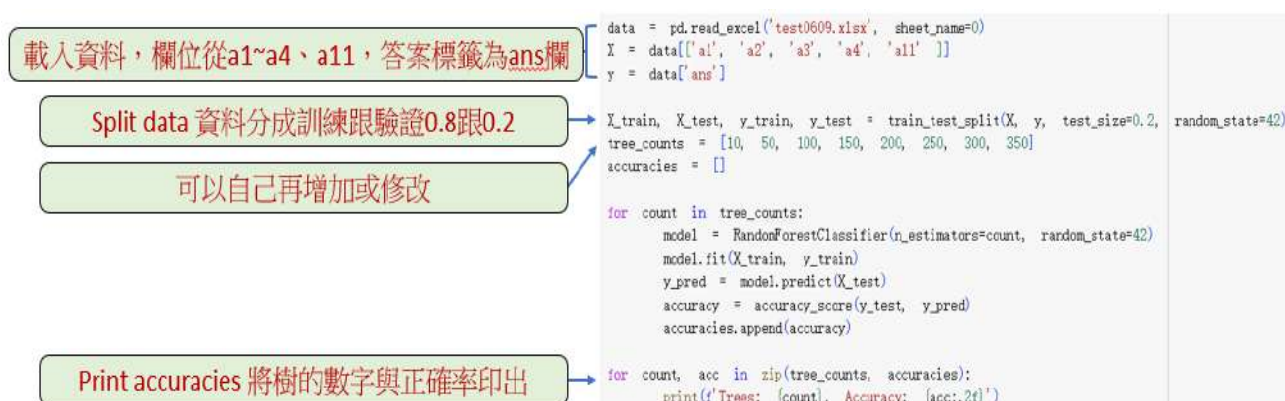


圖 36、隨機森林演算法程式圖（由第一作者所製）

先從 `accuracies` 清單中找出最高準確度的索引 `best_model_index`，對應的樹數為 `tree_counts` 中的最佳參數，再利用該樹數重新訓練隨機森林模型，以確保最佳的參數能在完整的訓練集上進行訓練，這個步驟的目的是確保所選模型在訓練和測試過程中均具備穩定的性能表現，並且應用中可以維持最佳準確度。程式將最佳模型以 `joblib` 套件儲存為 `best_model.joblib` 檔案，此檔案的儲存形式是二進位制格式，可以有效保存模型結構和訓練結果，方便日後的快速載入與應用，另外，程式還使用 `print` 語句輸出檔案的儲存路徑，提醒使用者已成功保存最佳模型。透過這種方式，使用者在實際應用中就可以直接載入該模型進行預測，不用重新訓練模型，節省了計算資源和時間成本。總的來說，圖 37 用來選擇準確度最佳的模型並將其儲存。




圖 37、客製化模型決策圖（由第一作者所製）

X 軸表示隨機森林中的樹數量，Y 軸則代表模型的準確性。根據圖中數據，當樹的數量為 50 時，準確性為 0.84，隨後在 100 棵樹時達到 0.87，再增加至 200 棵樹時，準確性達到最高值 0.88，然而，在超過 200 棵樹後，準確性開始趨於穩定，沒有顯著提升，保持在 0.87 至 0.88 之間。從這張圖可以得出結論，隨機森林模型在樹的數量達到一定程度後，其性能不再顯著提升，因此，增加更多的樹並無顯著效果。選擇適當的樹數（200 棵）不僅能達到較高的準確性，還能節省計算資源。同時我們也因應不同的使用者會有不一樣的情況，樹的棵樹可以自行改變以及調整。如下圖 38，隨著樹的數量增加，隨機森林模型在預測中的準確性變化。




圖 38、準確率與決策樹棵樹關係圖 (由第一作者所製)

X 軸表示最大深度的值，Y 軸則表示模型的準確性。圖中顯示當最大深度增加到 13 時，模型的準確性達到最高值 0.94，當深度超過 13 之後，準確性下降並穩定在 0.93，這說明模型過深的樹可能會導致過擬合現象，從而降低模型的泛化能力。根據這張圖，最佳的最大深度應選擇在 13，這樣可以達到較高的準確性，同時避免過擬合，使得模型在訓練時能達到最佳的預測性能，如下圖 39，隨著隨機森林中最大深度的改變，模型的準確性如何變化。




圖 39、準確度與最大深度關係圖 (由第一作者所製)

這張圖是一棵決策樹的視覺化，展示了隨機森林模型中的單一決策樹如何對數據進行分割與分類。如下圖 40，樹的每個節點根據不同的特徵進行分割，節點內的 gini 值代表該節點的不純度，值越小表示該節點的資料越集中於某一類別，分裂效果越好；samples 表示該節點中的資料數量，而 value 則顯示每一類別的分佈。

透過這棵樹可以觀察到，模型首先進行初步分割，將資料分為多個分支，每個分支根據其他特徵進一步分割，以達到最佳分類效果，最後，葉節點顯示每個類別的分類結果與樣本分布，使得模型的決策過程更加透明，方便使用者進行調整。




圖 40、演算法決策樹圖 (由第一作者所製)

六、主動安全監護機制實現

在系統中，我們實現了一個安全監護機制，當系統檢測到獨居者狀態異常、活動力降低時，被動觸發 made ifttt 發送訊息到 line 通知相關人員。此外，我們還提供了聲控觸發發送訊息的功能，以供緊急情況下的主動干預。

(一)從程式輸出指令

```
urllib.request.urlopen("https://hook.eu2.make.com/18vuxg9d2w7cr5x2rlmnya8kubprstdw")
else:
    cmd = ""

if (cmd != ""):
    exeSqlCmd(cmd)
```

圖 41、呼叫程式網址圖 (由第一作者攝)

在樹莓派上，輸入一個 Python 的程式，使得 MQTT 接收到使用者的求救指令可以透過程式，開啟網址至 Make IFTTT，透過 IFTTT 創建兩個應用程式之間的橋樑，由 LINE 發出訊息求救，如圖 42，即為 LINE 所接收到的畫面。



圖 42、LINE 接收到訊息畫面圖 (由第一作者攝)

除了主動發送訊息外，我們在 LSTM 的程式尾端都有一個判斷是否發送訊息的程式，我們觀察了每天的活動力數值大約的所在範圍，再去設定活動力的閾值，當其低於閾值時他會發送訊息至 LINE，此模式主要是為了異常檢測，這種異常可能是需要立即關注和處理的，幫助防範可能的風險或問題，判斷是否活動力下降，透過對歷史數據的分析和觀察預測和應對未來可能的情况。

```
ACTIVITY_THRESHOLD = 90

if pred_activity < ACTIVITY_THRESHOLD:
    print("活動量低於閾值，可能存在緊急情況，發送求救訊息。")
    url = "https://example.com"
    webbrowser.open(url)
else:
    print("活動量正常，無需發送求救訊息。")
```

圖 43、加權後數值異常發送警報 程式圖 (由第一作者製)

LSTM 為基礎的預測系統，專注於從各類感測器的數據中預測行為和活動力。此系統的流程首先收集各種感測器的資料，這些資料經過 LSTM 模型的處理後，會產生不同的輸出結果，在圖 44 中，輸出分成兩個主要方向：一方面是對 a1 到 a4 和 a11 這些變數的預測值，這些預測值再經由隨機森林決策演算法進行判斷，最終形成對行為偏差進行判斷；另一方面，系統會基於活動力的相關指標來進行活動力的判斷。這樣的架構讓 LSTM 模型能夠處理多變且複雜的感測器數據，同時結合隨機森林的決策能力，達到對行為和活動的準確分類與預測。




圖 44、警訊息發送流程圖 (由第一作者所製)

而我們的感測器則有分為兩個方面，一個是求救，例如:「救命、救我」等，當語音辨識器收到求救關鍵字，就會立即發送 LINE 訊息；如果是接收到負面情緒的關鍵字，例如:「好煩阿、睡不著」等，則會直接進行語音回饋，撥放音樂之類的，緩和使用者的情緒。語音感測器的功能都是可隨著不同的使用者進行適當的調整，使語音感測器可以發揮更大的實用價值。




圖 45、語音觸發後傳送訊息之流程圖 (由第一作者所製)

伍、結論

一、長期數據觀察

本系統利用樹梅派搭配各項感測器監測和鏡頭的情緒辨識，以及自行訓練的 LSTM 進行循環運算，將每天收集到的資料儲存到我們建立的 SQLite 資料庫，透過長期觀察數據是否有異常，讓使用者可以提早發現潛在的問題。

二、活動力的預測

本系統由 LSTM 的長短期記憶網路，使系統預測更為準確，利用自行訓練的長短期記憶 LSTM 進行活動力的預測，再加上我們對預測天數的訓練數據，將天數設為前 20 天預測隔天的模式，可有效降低系統的損失率。

三、行為偏差的決策

根據感應器所觸發的次數以及使用者的需求，自行調整隨機森林演算法，設定樹的最大深度參數 max_depth 從 10~110，10~24 做測試，最後透過隨機森林演算法去選擇適合使用者的模型，使其更能有效決策判讀。

四、樂齡關懷及回饋

語音感測器提供了主動的求救，和即時的回饋，它可以使我們的系統具備緊急時候的訊息發送，還可以在使用者低落的時候，直接進行語音的回饋。

本系統目前主要應用在獨居者居家行為監控，為獨居者提供了一個高效的解決方案，希望能以 LSTM 預測的方式，並結合隨機森林演算法加權模型的選擇，使其能夠準確地預測及判斷潛在的健康風險以及行為異常，達到樂齡關懷。

陸、參考文獻資料

1. 李仰慈(2023 年 1 月) 獨居老人的困境與長期照顧，失智老人，第 77 期， p6-p13
2. 衛生福利部國民健康署((111 年 3 月),) 108 中老年身心社會生活狀況長期追蹤調查成果報告，臺灣老人研究叢刊系列十四 p15-p16
3. 高霈馨 (檢索日期：2023 年 11 月 15 日) 老年憂鬱症盛行率高達 7~21% 自殺死亡率逐年增加 <https://reurl.cc/qV4gbq>
4. Charlene Wan (2022 年 04 月 15 日) 穿戴式裝置的定位追蹤有何優缺點？
<https://reurl.cc/4rvZVv>
5. Chris Olah (檢索日期：2023 年 11 月 16 日) Understanding LSTM Networks
<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
6. Frank(檢索日期：2023 年 11 月 16 日) 紅外線人體感測器之控制原理與應用
<https://reurl.cc/mM4a6M>
7. Ceiling Tsai (檢索日期：2023 年 11 月 20 日) Arduino 筆記(28)：都卜勒雷達感應器 RCWL-0516 微波雷達感應開關模組 <https://atceiling.blogspot.com/2017/08/arduinorcwl-0516.html>
8. 光敏電阻(檢索日期：2023 年 11 月 22 日) <https://reurl.cc/aq8QR9> _
9. 瘋狂創客 (檢索日期：2023 年 11 月 20 日) Arduino 光敏電阻使用教學
<https://reurl.cc/LWLv9a>
10. EVERLIGHT 億光電子 (檢索日期：2023 年 11 月 20 日) 接收紅外線感遙控器
<https://reurl.cc/xaAx0N>
11. IT 邦幫忙 dogdog (2020 年 09 月 08 日) 樹莓派簡介 [Day1 - 樹莓派簡介 - iT 邦幫忙::一起幫忙解決難題，拯救 IT 人的一天 \(ithome.com.tw\)](#)
12. ALEX' SPOT (檢索日期：2023 年 11 月 25 日) 樹莓派鏡頭 <https://reurl.cc/NQ91Np>
13. 建立嵌入式資料庫(檢索日期：2023 年 11 月 25 日)[\[Python\] 使用 sqlite3 模組建立嵌入式資料庫 - Clay-Technology World \(clay-atlas.com\)](#)
14. 莉森揪(檢索日期：2023 年 11 月 28 日) RNN 術式解析 <https://reurl.cc/RqEA5D>
15. Chung-Yi(檢索日期：2023 年 11 月 29 日) ML 入門 (十七) 隨機森林(Random Forest)

<https://reurl.cc/OMLgX9>

16. STEAM 教育(檢索日期：2023 年 11 月 29 日) Deepface 情緒辨識

<https://reurl.cc/nN42L1>

【評語】 100021

1. 本計畫以機電系統來建構一個監控關懷獨居老人的智慧生活空間，利用多樣化的感測器，來確認老人家的生理心理狀態。所著手議題的確為目前社會上的大問題。
2. 本計畫最大的疑慮，在於獨居老人是否願意處於被監控的空間環境內，他所提供的回覆，也或許和過去背景具有極大的關連性。這是社會科學的問題，但的確為本計畫是否可被執行的關鍵
3. 目前的成果仍落在機電整合層級，確認各部分具有功能，尚未實際佈建到獨居老人的生活空間，佈建時，應考慮衍生許多目前尚未考量到的問題，建議應走完最後一里路，確認本系統在技術面的可行性。
4. 在資料集中，有多少資料是來自獨居者狀態異常、活動力降低的狀況？
5. 建議應報導實際上與預測到的健康風險以及行為異常，最終的混淆矩陣與資料數，以評估整體的正確性與可用性。

6. 作品對於問題之描述與文獻之回顧有良好說明但建議可增加不同深度學習模型於相似應用之比較。有關 LSTM 之訓練，應說明訓練資料取得之方式，標註之方式，資料之內容與數量，測試之作法，混淆矩陣與相關指標等。