

國立清華大學 電機工程學系

實作專題研究成果摘要

Millimeter-Wave Beam Prediction:
Adaptive Extended Kalman Filter

毫米波波束預測—自適應調整的

擴展卡爾曼濾波器

專題領域：通訊領域

組 別：B609

指導教授：劉光浩

組員姓名：洪麒凌、曾子豪

研究期間：2025年2月1日至2025年11月1日止，共9個月

摘要

毫米波 (mmWave) [1] 是頻譜範圍介於 30 到 300 GHz 之間的電磁波。由於毫米波擁有大量的頻寬資源，在應用上能有效提升通訊系統的容量及傳輸速度。且毫米波的短波長使得天線體積大幅縮小，有利於 MIMO (multi-input multi-output) 技術的應用。面對日益增長的資料流量需求，加上中低頻段的頻譜資源有限，毫米波被視為 5G/6G 的關鍵技術之一。

然而，相較於其他頻段的電磁波，毫米波因為波長較短，更容易受到環境的影響造成訊號的衰減，因此在過往在毫米波波段的應用上並不普及。為了解決這項缺點，「波束成形 (Beamforming)」是不可或缺的訊號處理技術。波束成形會使用多跟天線，透過調整天線的排列分布和傳輸訊號的振幅及相位，將傳輸訊號能量集中在指定的方向，以此抵銷毫米波傳輸過程中的訊號衰減。

不過由於基地台和用戶設備之間的通訊通道會隨時間變化，因此我們需要設計一種演算法能夠預測目前的最佳傳輸方向以達到最佳的通訊品質，這種技術稱為「波束追蹤 (Beam Tracking)」。^[2]

本次專題延續過去的研究架構^{[3][4]}，以擴展卡爾曼濾波器 (Extended Kalman Filter, EKF) 為基礎，在過程中計算標準化創新平方 (Normalized Innovation Squared, NIS)，並以 NIS 為判斷標準，自適應的調整卡爾曼增益及過程雜訊，藉此觀察是否能達到更好的預測結果。

1. 背景介紹

如何在高移動性環境有效進行波束追蹤 (Beam Tracking)，是當前毫米波通訊系統的研究重點之一。傳統的波束對準多採用掃描式或表格式搜尋，但其時間成本與開銷過高。為此，本研究即以過去架構[3][4]為基礎，進一步設計 AKF (Adaptive Kalman Filter) 進行改良。

2. 研究方法

2.1. 系統模型

本次研究背景設定為一個單一基地台 (Base Station, BS) 和單一用戶設備 (User Equipment, UE) 的毫米波通訊架構。其中 BS 端擁有 M 根天線構成的 uniform linear array (ULA)，而 UE 端擁有單一天線。

在時間為 t 時 BS 和 UE 之間的通道可以用以下數學式表示：

$$\mathbf{H}_t = \sum_{l=1}^L \alpha_{t,l} \mathbf{a}(\phi_{t,l})$$

其中 L 為通道的數量， $\alpha_{t,l}$ 和 $\phi_{t,l}$ 分別代表通道增益和發射角 (Angle of Departure, AoD)， $\mathbf{a}(\phi) = \frac{1}{\sqrt{M}} [1 e^{j2\pi d \sin(\phi)/\lambda} \dots e^{j(M-1)2\pi d \sin(\phi)/\lambda}]$ 為 ULA 的 steering vector， d 和 λ 分別代表天線間的距離和傳輸訊號的波長。假設 $s \in \mathbb{C}$ 為 BS 傳送的訊號，在時間為 t 時 UE 接收到的訊號可以表示為：

$$\mathbf{y}_t^{(q)} = \mathbf{H}_t^T \mathbf{f}_q s + z_t$$

其中 $|s| = 1$ 且 z_t 是 additive white Gaussian noise (AWGN)， $\mathbf{f}_q = \frac{1}{\sqrt{M}} [1 e^{j2\pi q/Q} \dots e^{j(M-1)2\pi q/Q}]$ 是含有 Q 個碼字的碼簿中第 q 個碼字的 beamforming vector。

由於 BS-UE 之間的通道會隨時間變化，我們需要決定最佳的波束以對齊 AoD，這裡定義 beamforming gain $G_t = |\mathbf{H}_t^T \mathbf{f}_q|^2$ ，在時間為 t 時最佳波束的 index q_t^* 為：

$$q^*(t) = \underset{q \in \{1, 2, \dots, Q\}}{\operatorname{argmax}} G_t$$

一般來說 $q^*(t)$ 可以直接透過 beam scanning 的方式取得，就是直接量測每個方向

的 beamforming gain 找到最佳的 index，但這個方式需要耗費大量的時間及能量，在 UE 快速移動時或 Q 過大時每個時間點都使用 beam scanning 太過不切實際。更好的做法是搭配 beam tracking（見 Fig. 1），根據上一刻輸出的波束方向及接收到的訊號，透過演算法或機器學習的方式決定下一刻的波束方向。




Fig. 1：時域上的波束對齊架構

本次研究中我們嘗試追蹤時長 4 秒的 UE 移動軌跡，以 1 毫秒為單位進行一次 beam tracking，每 0.1 秒進行一次 beam scanning。Beam scanning 的方式為多訊號分類演算法（Multiple Signal Classification、MUSIC），而 beam tracking 階段以擴展卡爾曼濾波器搭配自適應調整更新模型來預測波束方向。

2-2. 擴展卡爾曼濾波器模型

離散型卡爾曼濾波器（Discrete Kalman Filter，DKF）[5]是一種用來估計離散時間下系統狀態的演算法。根據線性的狀態方程和量測方程，預測系統下個時間點的狀態且取得量測值，同時量化狀態和量測的不確定度，最後根據兩者的不確定程度進行加權，得到更準確的估測結果。此濾波器的特點在於其遞迴架構，運作時會在預測階段和更新階段之間交替運行，僅需使用前一時刻的估測結果及目前的量測資訊，無須儲存大量歷史數據。

擴展卡爾曼濾波器（Extended Kalman Filter，EKF）是 DKF 的變體，傳統的卡爾曼濾波器只適用於線性系統，而 EKF 可以應用在非線性系統。EKF 的主要作法是將非線性狀態轉移及量測模型透過泰勒展開式線性化，取其一階導數向來估算雅可比矩陣（Jacobian Matrix），將非線性系統近似為線性方程。

首先假設狀態轉移模型和量測模型分別為：

$$x_k = f(x_{k-1}) + w_{k-1}, \quad w_{k-1} \sim \mathcal{N}(0, Q_{k-1})$$

$$z_k = h(x_k) + v_k, \quad v_k \sim \mathcal{N}(0, R_k)$$

其中 x_k 為在 k 時刻的狀態向量， f 是非線性狀態轉移方程， w_{k-1} 是在 $k-1$ 時刻的狀態雜訊， z_k 為在 k 時刻的量測向量， h 是非線性量測方程， v_k 是在 k 時刻的量測雜訊。

EKF 的流程分為兩步驟：預測階段和更新階段

預測階段：

$$\hat{x}_{k|k-1} = f(\hat{x}_{k-1|k-1})$$

$$F_k = \left. \frac{\partial f}{\partial x} \right|_{x=\hat{x}_{k-1|k-1}}, \quad P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + Q_{k-1}$$

$\hat{x}_{k|k-1}$ 和 $\hat{x}_{k|k}$ 分別為先驗和後驗估計狀態， F_k 是狀態轉移方程 f 的雅可比矩陣， $P_{k|k-1}$ 和 $P_{k|k}$ 分別為先驗和後驗狀態估計誤差協方差矩陣（Covariance Matrix）， Q_{k-1} 是狀態雜訊協方差矩陣。

更新階段：

$$\hat{z}_{k|k-1} = h(\hat{x}_{k|k-1}), \quad \tilde{y}_k = z_k - \hat{z}_{k|k-1},$$

$$H_k = \left. \frac{\partial h}{\partial x} \right|_{x=\hat{x}_{k|k-1}}, \quad S_k = H_k P_{k|k-1} H_k^T + R_k,$$

$$K_k = P_{k|k-1} H_k^T S_k^{-1}, \quad \hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k \tilde{y}_k,$$

$$P_{k|k} = (I - K_k H_k) P_{k|k-1}$$

$\hat{z}_{k|k-1}$ 是估計量測， \tilde{y}_k 被稱為創新（Innovation）或殘差（Residual），就是真實量測和估計量測的誤差， H_k 是量測矩陣 h 的雅可比矩陣， S_k 是創新協方差矩陣， R_k 是量測雜訊協方差矩陣， K_k 是卡爾曼增益， I 是單位矩陣。

2-3. 自適應調整

2-3.1. 監測量：正規化創新平方

在更新階段，我們額外加入正規化創新平方（Normalized Innovation Squared, NIS）的計算。NIS 是一種統計工具，主要用來評估濾波器的一致性。在濾波器是一致的假設下，NIS 會近似於卡方分布（Chi-square Distribution），自由度等於量測值的維度。NIS 的計算方式如下：

$$NIS_k \triangleq \tilde{y}_k^T S_k^{-1} \tilde{y}_k$$

除了以上特性，由於 NIS 公式中內含創新 \tilde{y}_k ，若某次預測時發現 NIS 及劇變大，可視為 UE 移動導致通道變化，進而調整更新階段的參數。

2-3.2. 過程雜訊自適應

由於 NIS 會近似於卡方分布，這裡以卡方分布的分位數作為調整的上下界。當量測維度 $m = 1$ 時，NIS 的期望值為 1，依據 95% 的信心區間（顯著水準 $\alpha = 0.05$ ）的卡方分布表，可以得到：

$$\chi_{1,0.025}^2 = 0.00098, \quad \chi_{1,0.975}^2 = 5.024$$

因此我們將 NIS 的合理範圍設定為 $[0.001, 5.024]$ 。若 NIS 長期落在此區間，表示濾波器之預測與量測的統計特性一致；若持續高於上界，則代表模型對雜訊的估計過於樂觀；反之如果長期低於下界，則表示濾波器過度保守。

所以在更新階段，模型會根據 NIS 的值自動調整狀態雜訊協方差矩陣 \mathbf{Q}_k 的大小，若 NIS 高於上界，模型會放大雜訊；若 NIS 低於下界，則會縮小雜訊，公式如下：

$$\mathbf{Q}_k = \begin{cases} \alpha \times \mathbf{Q}_k & NIS > 5.024 \\ \mathbf{Q}_k & 0.001 \leq NIS \leq 5.024 \\ \frac{1}{\alpha} \times \mathbf{Q}_k & NIS < 0.001 \end{cases}, \quad \alpha \in [1, 3]$$

2-3.3. 卡爾曼增益膨脹

在本模型中，狀態向量包含通道增益 $\alpha_{t,l}$ 和發射角 $\phi_{t,l}$ 。在原始架構中，由於參數的設定使得模型傾向於調整通道增益來修正狀態，使得模型幾乎不會調整發射角。為了修正這個問題，我透過 NIS 的變化來捕捉預測不準確的時刻，嘗試去歸類此次預測不準是由於通道增益變化還是 UE 移動導致非最佳 AoD，並動態調整卡爾曼增益。

首先在每次更新時記錄了前 20 個時刻的 NIS，取出中位數並與當前時刻的 NIS 做比較。若當前 NIS 大於中位數的 5 倍，則視為狀態急遽變化導致 NIS 突然升高，此時啟動診斷機制。

如果 $NIS > 5 \times \text{median}(\text{前 20 個時刻的 NIS}) \Rightarrow$ 啟動診斷機制

診斷機制中系統會進行小角度搜尋，在預估角度 $\phi_k \pm \Delta\theta$ 的方向重新計算創新，若創新顯著下降（模擬中使用 40% 作為判斷標準），則將此次預測不準診斷為角度偏差導致。

$$\tilde{\mathbf{y}}_k = \mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1}, \quad \tilde{\mathbf{y}}_{k,\text{new}} = \mathbf{z}_{k,\phi=\phi_k \pm \Delta\theta} - \hat{\mathbf{z}}_{k|k-1}$$

如果 $\tilde{\mathbf{y}}_k - \tilde{\mathbf{y}}_{k,\text{new}} \geq \gamma \tilde{\mathbf{y}}_k, \gamma = 0.4 \Rightarrow$ 診斷為角度偏差問題

如果是角度問題，在下個時刻的更新階段中會調整卡爾曼增益，將通道增益的部

份調小，並將 AoD 的增益調大，並在接下來的幾個時刻回歸到原本的卡爾曼增益，公式如下：

$$K_k = \beta_k (\mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1})$$

如果診斷不是角度問題， $\beta_k = 1$

如果在時間點 k 診斷是角度問題

$$\beta_{t,\text{channel}} = \begin{cases} 0.3 & t = k \\ 0.3 + \frac{t-k}{4} \times 0.7 & k+1 \leq t \leq k+4 \\ 1 & t \geq k+5 \end{cases}$$

$$\beta_{k,\text{angle}} = \begin{cases} 2.5 & t = k \\ 2.5 - \frac{t-k}{4} \times 1.5 & k+1 \leq t \leq k+4 \\ 1 & t \geq k+5 \end{cases}$$

2-4. 參數設定及資料產生

本次研究使用 DeepMIMO[6]產生毫米波通道所需的資料，並使用 Scenario O1（見 Fig. 2）模擬整個通訊過程的環境。

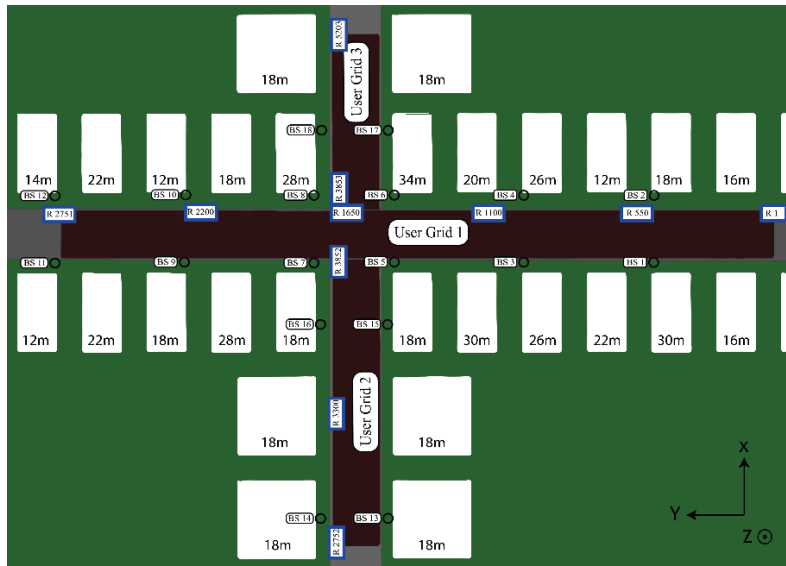


Fig. 2 : DeepMIMO Scenario O1 的俯視圖

2-4.1. BS 端設定

如 Fig. 2 中所示，整張地圖共有 18 個 BS，但本次實驗只會用到 BS1。其餘參數請參見 Table. 1 或參考資料。

Table. 1 : BS 端所使用參數

Parameter	Value
載波頻率 f_c	28 GHz
傳輸頻寬	50 MHz
BS 的天線數量 M	64
波束總數 Q	64
天線間距 d	0.5λ
雜訊指數 (noise factor)	5 dB
BS 傳輸能量	30 dBm
通道數量 L	5

2-4.2. UE 端移動軌跡設定

UE 的移動範圍會被限制在 Fig. 1 中 User Grid 1 (UG1) row 100 ~ 900 (R100 ~ R900) 之間。UE 會隨機出現在此範圍中的一處，並以初速度 $v(m/s)$ 、加速度 $a = 0.2v(m/s^2)$ 往隨機方向 $\theta \in [0, 2\pi]$ 移動。若 UE 超出範圍，則不使用該資料並重新生成軌跡。

3. 研究結果

本次實驗要比較兩種模型：(a) 原始架構的 EKF、(b) 自適應的 EKF。設定 6 種不同的初速度 $v = 5, 10, 15, 20, 25, 30 m/s$ 來進行模擬，每個速度都有 2650 個 UE 軌跡檔案用來模擬和驗證，每個檔案都是事先生成的。

準確度的計算方式是將每個時刻的預測方向的 beamforming gain 和最大的 beamforming gain 做比較，再將同一速度下每個檔案中每個時刻的準確直取平均，得到的圖為 Fig. 3，計算公式如下。

$$accuracy_{n,t} = \frac{G_{n,t,predicted}}{G_{n,t,max}}$$

$$total\ accuracy = \sum_{n=1}^{2560} \sum_{t=1}^{4001} accuracy_{n,t}$$

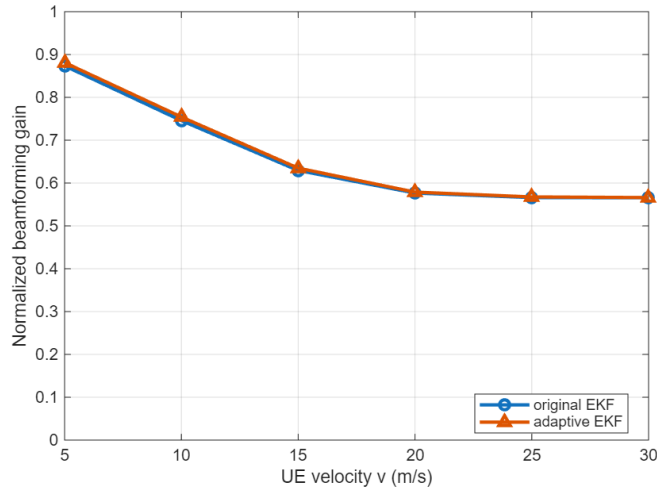


Fig. 3 : (a) 原始架構的 EKF 和 (b) 自適應的 EKF 在不同速度下的平均準確率

由上面的圖可以得出兩個結論：第一，當 UE 的速度增加時，整體的預測表現降低。由於速度的增加會使通訊通道的改變更加劇烈，因此增加了預測的困難度。第二，原始架構的 EKF 和自適應的 EKF 相比，準確率幾乎一模一樣，僅有在低速度時才有少許提升，從這能看出目前設計的自適應模型還有許多可以進步的空間。

為了確認自適應更新的機制有沒有問題，我們從每個速度的模擬中統計了 3 個數值：(1) N_{TP} ：有角度變化且有被正確診斷為角度問題的時間點數量、(2) N_P ：被診斷為角度問題的時間點數量、(3) N_T ：有角度變化的時間點數量，這裡的「有角度變化」指的是根據 UE 的移動軌跡，最佳波束方向改變的時刻。根據統計得到的值，我們計算出了以下的比率，並做成折線圖 Fig. 4。

(a) 所有被診斷為角度問題的時間點中，真正有角度變化的比例 = $\frac{N_{TP}}{N_P}$

(b) 所有有角度變化的時間點中，有被診斷為角度問題的比例 = $\frac{N_{TP}}{N_T}$

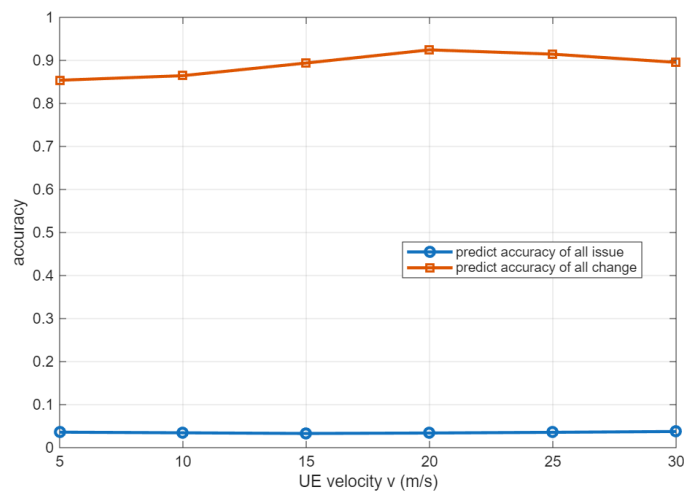


Fig. 4：在不同時間下的 (a) 所有被診斷為角度問題的時間點中，真正有角度變化的比例和 (b) 所有有角度變化的時間點中，有被診斷為角度問題的比例

從圖中可以發現大部分的角度變化問題都有被診斷出來，但實際上佔有比例很少，被診斷出角度問題的時間點極大部分都不是角度有變化的，可能都是通道變化造成的。從這可以知道我們必須修改診斷的條件，排除為通道變化的可能性，以提升診斷的命中率。

4. 結論

本次專題，以過去的研究做為基本架構，加入了自適應機制，比較並觀察預測表現提升的幅度。

從實驗結果中可以發現速度變化會影響預測準確性，UE 速度越快通道變化更迅速，預測就越容易失準。從自適應更新的部分，我們發現 NIS 作為監測量是可以運作的，但在篩選出真正的角度問題的過程中，需要有更多的條件或限制，讓系統能夠提升診斷的準確性。此外，雖然低速度的情況下，準確率有些微提升，但自適應更新的參數和機制還有待調整，以達到更有效率的狀態更新。

面對現今頻寬資源不足的情況下，發展出能夠實際應用的毫米波波束追蹤技術非常重要，在往後的研究中也許能夠透過更換模型，像是無跡卡爾曼濾波器 (Unscented Kalman filter, UKF) 或是機器學習的方式，得到更好的追蹤性能。

5. 參考資料

- [1] I. A. Hemadeh, K. Satyanarayana, M. El-Hajjar and L. Hanzo, "Millimeter-wave communications: physical channel models, design considerations, antenna constructions, and link-budget," in *IEEE Communications Surveys & Tutorials*, vol. 20, no. 2, pp. 870-913, 2018.
- [2] S. H. Lim, S. Kim, B. Shim, and J. W. Choi, "Deep learning-based beam tracking for millimeter-wave communications under mobility," *IEEE Trans. Commun.*, vol. 69, no. 11, pp. 7458–7469, Nov. 2021.
- [3] H.-C. Lin and K.-H. Liu, "Low Overhead Beam Alignment for Mobile Millimeter Channel Based on Continuous-Time Prediction," in *Proc. IEEE WCNC*, Dubai, UAE, pp. 931–936, Apr. 2024.
- [4] 模型架構參考：<https://github.com/kuanghaoliu/Adaptive-online-beam-alignment>

[5] Bar-shalom, Y., Li, X. R., & kirubarajan, T. (2001). *Estimation with Applications to Tracking and Navigation* (1st ed.). Wiley-Interscience.

[6] DeepMIMO 網站：<https://www.deepmimo.net/>

6. 心得

在這次的實作專題中，我們學到了很多通訊領域的知識與技術，例如毫米波通訊、波束成形與波束預測，還有 MATLAB 的模擬實作練習。這些內容在大學部其他課程中幾乎接觸不到，很慶幸自己參與了這個專題，讓我們對相關概念有更深入的理解。

特別感謝劉光浩教授在這兩個學期的指導。上學期進行論文閱讀時，教授在每次討論都會確認我對基礎概念與論文內容的理解是否正確，並提醒論文撰寫的重點；下學期進入實作階段後，當我遇到瓶頸，教授也適時提供可行的方向與建議，讓我們能持續推進。這次專題讓我們了解了波束預測的相關技術與理論，同時也讓我們習得了理論在實作上運用的重要性，讓我們在未來研究所的學習打下了一定的基礎。