

國立清華大學 電機工程學系

實作專題研究成果摘要

mmWave Beam Prediction

Impact of Frequency Bands and User Equipment

Velocity on Prediction

毫米波波束預測

不同頻段與使用者設備移動速率對預測的影響

專題領域：通訊領域

組別：B601

指導教授：劉光浩 教授

組員姓名：李冠穎 謝孟紋 戴靖巨

研究期間：2025 年 3 月 至 2025 年 11 月止，共 9 月

摘要

6G 通訊時代追求著更高的傳輸速率、更低的延遲，相對的需要以更大的頻寬來承載資料量，此時便需要尚未被廣泛運用的高頻毫米波(mmWave)頻段，以獲得足夠的頻寬，但使用毫米波將遭遇許多挑戰，諸如訊號衰減迅速、穿透力弱等。為降低訊號傳輸的困難，波束成形(beamforming)是可能的解決辦法之一。波束成形是透過大規模的天線陣列將訊號能量集中成窄而強的波束，而為求節省資源，波束的發射方向必須精準朝向接收者，決定波束方向的方式稱為波束預測(beam prediction)，本專題探討的問題是利用機器學習預測最佳波束方向的可行性，並透過週期性的重新訓練機制，以適應使用者移動後的通道變化，避免預測誤差過度累積。

本專題將探討波束追蹤與波束預測在使用三種不同載波頻率下的通道增益比對，以了解何種情況下可以達到最佳波束成形功效。

結果顯示，在高頻段或使用者高速移動時波束增益衰減較大，在連續預測過程中，資料準確度亦會逐漸下滑，顯示波束預測的錯誤是會逐漸累積的。

一、 研究動機

目前 6G 通訊領域追求極高的傳輸速率和極低的延遲，這都建立在擁有更大的頻寬基礎上。一般認為，能提供足夠頻寬的關鍵頻譜，即為高頻的毫米波 (mmWave) 頻段。

然而，高頻毫米波面臨路徑損耗 (Path loss) 大、訊號衰減迅速且穿透力弱等挑戰。為解決此訊號傳輸困境，波束成形 (Beamforming) 技術成為關鍵解決方案。具體而言，透過大規模天線陣列 (Massive MIMO) 技術，可將訊號能量集中，形成高增益的窄波束以提升傳輸距離。

雖然波束成形能增強訊號，但傳統尋找最佳波束的波束掃描 (Beam Scanning) 技術，需要基地台與使用者頻繁交換訓練訊號 (Pilot Signals) 以進行全域搜索。這種方式不僅耗時，且隨著波束數量的增加，大量的訓練訊號將嚴重佔用傳輸資源，導致傳輸效率降低。因此，為了減少訓練訊號傳送頻率並加速連結建立，我們導入波束預測 (Beam Prediction) 技術。

為求在減少訓練訊號的同時，仍能精準且快速地鎖定最佳波束，我們採用機器學習演算法進行主動式預測。此專題將比較在三種不同載波頻率 (Carrier Frequency) 與使用者端六種移動速度下，波束預測後的通道增益表現，藉此提供未來實現波束通訊技術之具體指引。

二、 研究原理

由於毫米波的頻寬高，而路徑損耗(path loss)與頻率平方成正比，導致毫米波傳輸時的功率損耗特別嚴重。

我們使用 MATLAB 的 Phased Array System Toolbox 模擬相位陣列天線 (Phased Antenna Array) 的響應(response)，以 4×4 的均勻平面陣列(UPA，Uniform Plane Array)為例，仰角固定為 20 度。

我們可以得知，天線間的距離越大，孔徑(Aperture)越大，意味著會產生較明顯的主波束(Main Lobe)，使波束的方向性與接收到的增益更佳。但與此同時，產生的柵狀瓣(Grating Lobes)越明顯，這會使系統分辨主波束的能力下降。此外，

柵狀瓣會浪費傳輸的能量，還會干擾到其他用戶。

基於以上幾點， $d = \lambda/2$ 是折衷的選擇，既沒有太嚴重的柵狀瓣，同時也保留了主波束。後續模擬的天線陣列使用 $d = \lambda/2$ 的均勻線性陣列(ULA, Uniform Linear Array)。

三、研究方法

1. 系統模型

在本專題中，假設一個由 $M \times 1$ 的 ULA 天線陣列所組成的基地台(BS, Base Station)，與一個擁有一根天線的使用者端(UE, User Equipment)進行毫米波通訊，通道模型在時間為 t 時如下

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

其中 \mathbf{H}_t 是大小為 $M \times 1$ 的通道矩陣， L 是通道的總路徑數， $\alpha_{t,l}$ 是第 l 條路徑的通道增益， $\phi_{t,l}$ 是天線發射訊號的角度(AoD, angle of departure)， $\mathbf{a}(\phi_{t,l})$ 則是大小為 $M \times 1$ 的 ULA 轉向向量 (steering vectors)

$$\mathbf{a}(\phi_{t,l}) = \frac{1}{\sqrt{M}} [1, e^{j2\pi d \sin(\phi_{t,l})/\lambda}, \dots, e^{j(M-1)2\pi d \sin(\phi_{t,l})/\lambda}]^T$$

其中 d 是天線之間的距離， λ 是傳輸訊號的波長。

在上述通道模型下，使用者端的一根天線接收到的訊號大小為

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

其中 s 是基地台所傳送的資訊，且 $s \in \mathbb{C}$, $|s| = 1$ ， \mathbf{z}_t 是平均為零，變異數為 σ^2 的高斯雜訊(AWGN, additive white Gaussian noise)， \mathbf{f}_q 是第 q 個波束的波束成形向量 (beamforming vector)

$$\mathbf{f}_q = \frac{1}{\sqrt{M}} [1, e^{j2\pi q/Q}, \dots, e^{j(M-1)2\pi q/Q}]^T, \quad q = 1, 2, \dots, Q$$

且 $\mathbf{f}_q \in \mathbb{C}^M$ ，其中 Q 是波束的總數。

由於使用者會移動，通道的 AoD 也會隨之改變，因此基地台需要不斷更新波束成形向量來對準 AoD。因此我們定義波束成形增益 (beamforming gain)

$$G_t = |\mathbf{H}_t^T \mathbf{f}_q|^2$$

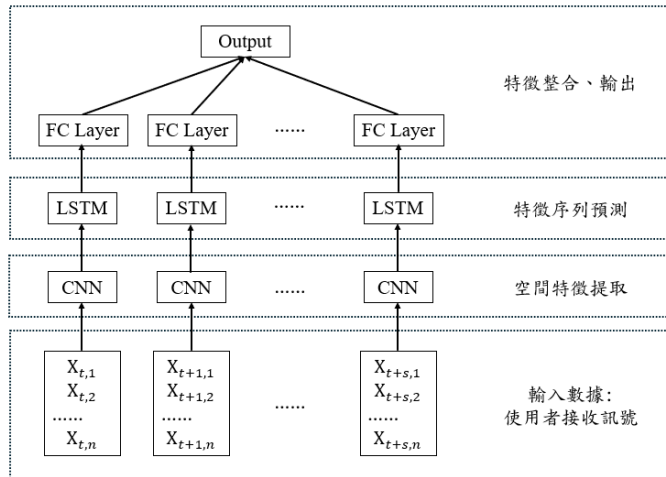
並找出在時間為 t 時，具最大波束成形增益的最佳波束(beam index)

$$q_t^* = \operatorname{argmax}_{q \in \{1, 2, \dots, Q\}} G_t$$

最佳波束可透過波束掃描(beam scanning)獲知，基地台使用所有可用的波束成形向量發送訓練訊號，使用者端再測量相應的波束成形增益。但這種方法消耗在訓練訊號的頻寬與時間隨波束數量增加而上升。為解決此問題，波束追蹤(beam tracking)採用少數訓練訊號修正波束，找到最佳的波束成形方向。

然而，傳統的追蹤技術仍需持續傳送訓練訊號進行修正。為了進一步降低訓練開銷，本研究將波束選擇視為一個時間序列預測問題。由於使用者移動軌跡與波束變化具有高度的時間相關性，適合利用深度學習模型學習其特徵，以預測未來的最佳波束。

我們使用 LSTM 模型進行深度學習波束訓練，模型結構如圖一所示



圖一、LSTM 結構圖

模型將輸入資料(使用者接收訊號)傳送至 CNN 提取空間特徵向量，再將每個時間點的 CNN 輸出聚合成一個特徵向量，並將其輸入至 LSTM 層。LSTM 層為核心的時序模型，負責學習通道特徵與訓練時間點的關係，最後進到整合層中的全連接層(FC Layer)輸出預測結果。

2. 模擬環境介紹

模擬使用排成 1×64 ULA 直線陣列的天線，在平面道路上，模擬不同速度下

直線移動的使用者。

我們使用 DeepMIMO [1]產生通道資訊(channel information)供機器學習使用。DeepMIMO 是相關領域廣泛使用的模擬器，用射線追蹤(ray tracing)的方式模擬無線訊號傳播過程，以獲得接近實際的資料集。

模擬場景使用 Scenario O1[2]的場景。

3. 模擬參數設定

3-1 基地台(BS, Base Station)設定[3]

本次實驗只使用 BS1 基地台，如圖二紅圈所示。

BS1 基地台參數設定如表一所示

表一、BS 參數

參數	值
載波頻率 f_c	3.5GHz、28GHz、60GHz
傳輸頻寬	50 MHz
基地台天線數量 M	64
波束總數 Q	64
天線間距 d	0.5λ
波束追蹤所需波束數量 S	11
雜訊指數(noise factor)	5 dB
基地台傳輸能量	30dBm
通道多路徑數量	5

3-2 使用者設備(UE, User Equipment)設定[3]

我們設定使用者在 User Grid 1 上直線移動，並將移動範圍限制在 row 100~250 之間(R100~R250)，如圖二虛線方框所示。



圖二、BS1 基地台以及 row 100~250 範圍

使用者設備將會隨機出現在此範圍中的隨機一處 x_0 ，並以運動速度 v (m/s)，加速度 $a = 0.2v$ (m/s²) 往隨機方向 $\theta \in [0, 2\pi]$ 移動，因此使用者在時間 t 的位置由公式表示

$$x(t) = x_0 + vt + \frac{1}{2}at^2$$

若使用者設備超出限制範圍的話，會從範圍另一端邊緣重新出現，沿著相同方向和相同路徑前行，因此軌跡會是同一條直線，且不會超出限制範圍。

四、 模擬結果分析


本專題模擬採用三個載波頻率：3.5 GHz、28 GHz、60 GHz 以及不同移動速度：5、10、15、20、25、30 (m/s) 作為變數，比較不同情況下的增益變化。

在效能評估指標方面，我們採用標準化波束成型增益 (NBG, Normalized Beamforming Gain)。其定義為預測波束的接收功率與經由全域掃描所得之最佳波束接收功率的比值，數值範圍為 0 到 1，數值越接近 1 代表預測結果越接近理想最佳值，能有效反映波束預測的準確度。

我們設定使用者連續移動經過 1000 個採樣點 (基於 DeepMIMO 網格間距，相

當於連續移動約 200 公尺，總時長隨速度而定)。為了避免預測誤差隨時間過度累積，系統設定在第 0、100、200、.....、900 個時間點時，執行週期性波束校準 (Periodic Beam Alignment)。意即在這些特定時刻，系統將暫停預測，轉而透過波束掃描 (Beam Scanning) 重新鎖定當下的最佳波束，以校準使用者位置並重置累積誤差。

1. 在同一頻率下，比較六個速度，1000 個時間點的總趨勢



圖三、不同速度下 1000 個點的趨勢 (數據採用高斯平滑處理，視窗長度 50)。

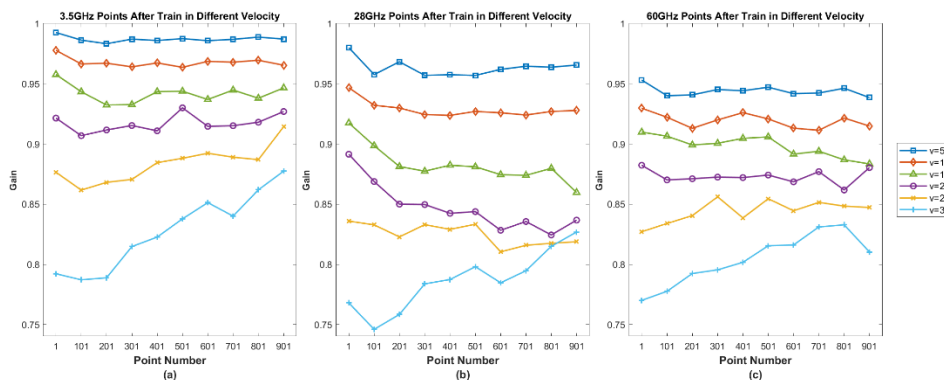
頻率分別為(a) 3.5GHz (b) 28GHz (c) 60GHz

由圖三可以觀察到頻率與速度對預測效能的影響。首先，在相同速度下，載波頻率越低 (如 3.5GHz)，波束成形增益維持得越好。這是因為低頻訊號對應的波束寬度 (Beamwidth) 較寬，對於使用者移動造成的位置誤差容忍度較高；反之，高頻 (如 60GHz) 波束極窄，極些微的位置偏移便會導致對準失敗，使增益大幅下降。

其次，在速度影響方面，隨著移動速度加快，通道狀態隨時間變化的程度加劇，導致過去的訓練資料不再能代表當下的通道特徵，使得模型難以僅憑過去的資訊準確推算出未來的波束方向，造成預測誤差迅速擴大，增益曲線呈現快速下滑的趨勢。

最後，結果顯示 LSTM 模型在低速移動下，能將所有頻段的通道增益維持在約 0.9 以上，證明其處理低速動態通道的能力。然而在高速移動（如 30 m/s）的情境下，增益衰減極為顯著，尤其是在 60GHz 高頻段，這顯示單純的預測在高速場景仍有極限，需依賴更頻繁的波束校準來維持連線品質。

2. 比較 10 個執行波束校準的時間點



圖四、在同一頻率下，比較六種速度的 10 個點

(a) 3.5 GHz、(b) 28 GHz、(c) 60 GHz

理論上，每當系統執行波束掃描後，應能重新鎖定最佳路徑，使通道增益回復至該時刻的理想最大值。因此，這 10 個剛完成校準的時間點（即第 1、101、201……、901 點），其標準化增益理應維持在接近 1 的水準。

然而，根據圖四(a)(b)(c)的數據顯示，在低速移動($v=5, 10, 15$ m/s)時，後續校準點（如第 901 點）與初始校準點（第 1 點）相比，增益呈現微幅下降的趨勢。我們推測這是因為 LSTM 模型在長時間運行過程中，雖然定期輸入了新的校準資訊，但模型內部的隱藏狀態仍累積了部分無法完全消除的誤差，導致回歸能力的些微衰退。

至於在高速移動($v=15, 20, 25, 30$ m/s)的情境下，趨勢變得不規則，甚至出現不減反增的現象。這主要歸因於 DeepMIMO 模擬場景的範圍限制與循環特性。由於訓練資料範圍設定在 row 100~250，當使用者高速移動並脫離此範圍後，因場景的循環機制，使用者會進入另一端的訊號環境，恰好對應到模型仍能捕捉的特徵，導致增益意外回升。

我們可以發現當移動速度較慢時，因使用者位置變化幅度小，三種頻率的預測準確度皆十分良好。然而，隨著速度加快，頻率越高的情境下（如 60GHz），

效能衰退越明顯。

造成此現象的主因在於頻率與波束寬度 (Beamwidth) 的物理關係。根據天線陣列原理，當載波頻率上升 ($f \uparrow$)，其波長隨之變短($\lambda \downarrow$)，在固定陣列孔徑下，這將導致所形成的波束寬度變窄(Beamwidth \downarrow)。

相較於低頻段較寬的波束，高頻段的窄波束對位置誤差的容忍度極低。當使用者高速移動時，其位移量很容易超過一個波束寬度的覆蓋範圍，導致接收端無法對準波束中心，使接收功率急遽下降。實驗結果顯示，在最極端的高速高頻情境下，標準化增益甚至可能減少至約 75%，顯示窄波束特性在高頻通訊移動性支援上的挑戰。

3. 在 28GHz 的頻率、速度 $v=5$ 下，比較每次訓練後的增益損耗

表二、在 28GHz 的頻率、速度 $v=5$ 下，每次訓練後最初及最末時間點的增益損耗

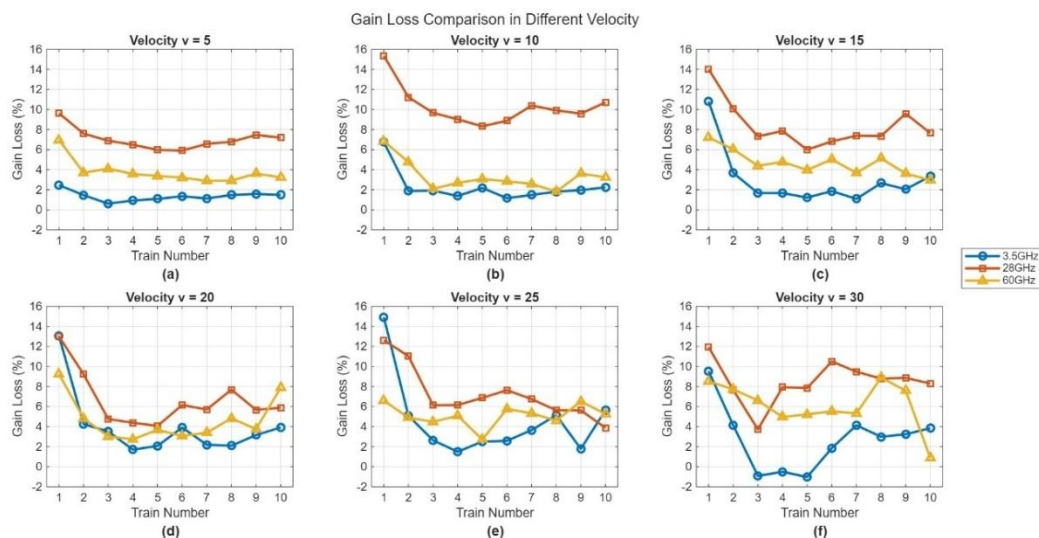
第 n 次訓練	1	2	3	4	5	6	7	8	9	10
增益損耗 (%)	9.62	7.60	6.89	6.49	5.97	5.91	6.57	6.78	7.46	7.20

從表二中可以觀察到，在十次波束掃描(Beam Scanning)後，各區間內的波束增益皆呈現逐漸損耗的趨勢。這是由於隨著時間推移，波束預測的累積誤差導致波束無法完全回到最佳狀態，因此從第二次掃描後的曲線趨勢變得十分接近。

值得一提的是，第一次掃描區間的曲線趨勢與後續有顯著差異。這是因為第一次預測是模型在尚未受到累積誤差影響下的基準結果，因此其增益衰退的幅度與後續次數相比最為明顯。

此外，數據顯示第一次區間的增益損耗最大(9.62%)。這是因為在該區間的起始點，系統擁有最完美的波束對準狀態 (增益為整份測試資料中的最大值)。然而，隨著連續預測的時間增加，預測準確度下降，導致波束成形增益逐漸降低至該區間的最低點。由於起始點(最大值)與結束點的落差最大，因此相減後的增益損耗(Gain Loss)數值便成為十次掃描過程中的最大值。

4. 在不同頻率或不同速度下，比較增益損耗



圖五、在六種不同速度下，各頻率每次訓練的增益損耗

(a) $v = 5$ (b) $v = 10$ (c) $v = 15$ (d) $v = 20$ (e) $v = 25$ (f) $v = 30$

從圖五可以觀察到，增益損耗整體來說隨著訓練次數增加而降低。如我們依毫米波的特性所預期的，低頻的波束穿透力較好、路徑損耗較小且涵蓋範圍大，因此較低頻率(3.5GHz)下增益損耗較小。

但在在比較慢的速度時($v = 5, 10, 15$)，頻率 60 GHz 的增益損耗反而比頻率 28 GHz 的增益損耗小，推測是因為使用者位置變化幅度較小，較高頻率也還能夠很好的預測路徑；而在較快的速度($v = 15, 20, 25, 30$)時，大多就如同預期般，因為較高頻率的波束所涵蓋的範圍較小，越高的頻率下增益損耗越大。

五、 結論

透過以 DeepMIMO 資料模擬毫米波通道在 Scenario O1 環境下的波束情況，並使用 LSTM 模型進行波束預測，分析並比對各項數據後，我們得出以下幾項結論：

1. 在相同移動速度下，高頻段波束由於路徑損耗，得到的波束增益會較小，亦即波束預測準確度較差。
2. 在相同頻段下，高速移動的使用者端會使波束較難對準並預測位置，使得

到的波束增益降低。

3. 隨著時間的推移，波束預測的資料的錯誤性會逐漸累積，導致較後段時間點的波束在重新訓練完對準後準確性不如以往。
4. 在相同速度下，高頻的波束由於穿透力較差、路徑損耗較大且波束涵蓋的範圍較小，因此增益損耗也較大。

因此我們能推論出，使用較低頻率的載波、較慢的接收端移動速度、以及利用能夠自我修復誤差的模型，都能幫助使用者獲得較好的傳輸效率；反之則會遭致較差的效果。

六、心得

本次專題中我們了解到毫米波波束成形在 6G 通訊領域的目的與做法。從一開始閱讀相關研究資料，學習到毫米波的物理性質與相對的傳輸限制，到中期模擬波束的方向性與增益，最後使用 DeepMIMO 模擬不同頻段下的高移動性場景，再應用到 LSTM 深度學習模型進行資料的訓練與測試。從不同的頻段與速度對比分析下我們觀察到毫米波波束成形的傾向，更進一步知曉 few beams 分類對波束預測計算成本的效益。

感謝劉光浩老師於這一年的教導，老師在每次專題討論皆會關心我們對論文內容的掌握程度，對於我們提出的問題也會詳細的解惑，此外，老師會用心閱讀我們繳交的報告，並提點撰寫研究報告的要點，最後實作時老師也提供了很多提示與想法，這種種幫助使我們成功實作出專題成果。

七、參考資料

- [1] DeepMIMO, 網站: <https://www.deepmimo.net>
- [2] DeepMIMO scenario O1 top view,
網站: <https://www.deepmimo.net/scenarios/v2/o1>
- [3] 參數設定參考: <https://github.com/kuanghaoliu/Adaptive-online-beam-alignment>
- [4] 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.
- [5] H. -C. Lin and K. -H. Liu, "Low Overhead Beam Alignment for Mobile Millimeter Channel Based on Continuous-Time Prediction," 2024 IEEE Wireless Communications and Networking Conference (WCNC), 2024, pp. 1-6.
- [6] 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.