

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 with the  
Assistance of UE Location**

毫米波波束預測：使用者設備的位置  
資訊對預測的影響

專題領域：通訊領域

組 別：B419

指導教授：劉光浩 教授

組員姓名：陳威旭

研究期間：2024年2月19日 至 2024年11月25日止，共10個月

# 1. 研究簡介

毫米波 (mmWave) [3] 是一種頻譜範圍落在 30 到 300 GHz 之間的電磁波。由於毫米波擁有大量的頻寬，這種資源能夠更近一步的增加通訊系統的容量以及傳輸的速度。且毫米波的短波長還能幫助降低天線的大小，讓基地台可以設置更多的天線，採取更多的 MIMO (multi-input multi-output) 技術。然而，毫米波的短波長也存在著嚴重的缺點，相對其他較低波長的電磁波，毫米波更容易受外在環境的影響而產生訊號的衰減。這項缺點的存在導致毫米波在過去並不普及。

為了解決這項缺點，「波束成形 (Beamforming)」這個訊號處理技術 [3] 將變得不可或缺。波束成形將會使用多根天線，藉由改變每根天線所傳輸之訊號的振幅或相位，使得訊號之間產生建設性干涉及破壞性干涉，以達到將傳輸訊號能量集中在某個特定的方向。不過因為基地台 (BS) 和用戶設備 (UE) 之間的通訊通道並非靜止不變，因此我們需要藉由一些方法讓 BS 知道現在該往哪個方向傳輸以達到最佳的通訊品質。這些方法將於「2-1. 系統模型」中介紹。

現在雖然有多位研究人員嘗試尋找有效預測波束的方法，但目前仍有許多待進步的空間。舉例來說，該如何延長預測的有效時間，或者是該如何將模型運用在更多、更廣的情境裡。本次研究將試著藉由將 UE 的位置當作模型額外的特徵 (feature)，以達到更加良好的預測結果。

## 2. 研究方法

### 2-1. 系統模型

在本專題，我們考慮一個擁有一個基地台 (BS) 和一個使用者設備 (UE) 的毫米波網路架構。其中 BS 端擁有一個含有  $M$  根天線構成的 uniform linear array (ULA)，而 UE 端擁有一根天線。

毫米波的通道在時間為  $t$  可以用以下數學式來表示：

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

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)，

$\mathbf{a}(\phi) = \frac{1}{\sqrt{M}} [1 e^{j2\pi d \sin(\phi)/\lambda} \dots e^{j(M-1)2\pi d \sin(\phi)/\lambda}]$  是 ULA 的 steering vector， $d$  和  $\lambda$  分別代表天線之間的距離和傳輸訊號的波長。假設  $s \in \mathbb{C}$ ,  $|s|=1$  為 BS 所傳送的訊號，則 UE 所接收到的訊號可表示為：

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

$\mathbf{w}_t$  為在時間點為  $t$  的雜訊(AWGN)， $\mathbf{f}_q = \frac{1}{\sqrt{M}} [1 e^{j2\pi q/Q} \dots e^{j(M-1)2\pi q/Q}]$  是第  $q$  個 beam 的 beamforming vector， $Q$  為 beam 的總數。

由於我們需要決定最佳的波束以對齊 AoD，因此我們定義 beamforming gain  $G_t = |\mathbf{H}_t^T \mathbf{f}_q|^2$ ，而在時間點為  $t$  時最佳的波束的 index  $q_t^*$  定義為：

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

我們可以藉由 beam scanning 的方式，也就是藉由直接量測每個 beamforming vector 的 beamforming gain 得到最佳的 index，但是這個方式需要消耗大量時間傳輸不必要的資訊，太過耗時，尤其是在  $Q$  很大的時候。因此，有一些較有效率的方式: beam tracking 和 beam prediction [4, 5]。由於 UE 的移動不會從一個地方瞬間跳到另一個很遠的地方。與其掃描所有可能的波束，這兩個方法只需選擇少量的波束去做決定，這些波束的選擇通常會與上一次所選擇的波束有關。然而兩個方法的差異在於 beam tracking 會持續追蹤通道隨時間的改變，而 beam prediction 則是藉由每次收到的訊號來做最佳波束的預測。

## 2-2. 機器學習模型

如 Fig. 2-1，首先 UE 會藉由 beam tracking 的方法將接收到的訊號  $\mathbf{y}_{t_n}$  和上一次預測的 beam index 決定這次預測所需要選擇的波束  $\mathbf{Y}(t_n) = [\mathbf{y}_{t_n}^{(q)}]_{q \in \mathcal{S}}$ ， $\mathcal{S}$  代表所有可能的 beam 的 label。接著， $\mathbf{Y}(t_n)$  將會輸入到卷積神經網路(CNNs)中，取出資料初步的特徵  $\mathbf{x}(t_n)$ 。這些特徵將會進一步的放入長短期記憶(LSTM)模型中，得到更深入的特徵資料。再來，LSTM 的 hidden state  $\mathbf{s}(t_n)$  會輸入到一個 Fully connected layer (FC layer) 中，而 FC layer 的輸出  $\hat{\mathbf{o}}(t_n)$  會再輸入進一層 softmax 函數中，轉換成一串的機率資料  $\mathbf{o}(t_n) =$

$[\mathbf{o}_{t_n}^{(q)}]_{q \in \mathcal{S}}$ 。這些機率代表著第  $q$  個波束是最佳波束的可能性。因此，預測出來的波束 index 可以用以下數學式來表示：

$$q_{t_n}^* = \operatorname{argmax}_{q \in \mathcal{S}} \mathbf{o}(t_n)$$

UE 會將預測出來的波束 index  $q_{t_n}^*$  回傳給 BS，BS 收到後就可以使用所預測出的波束進行通訊。

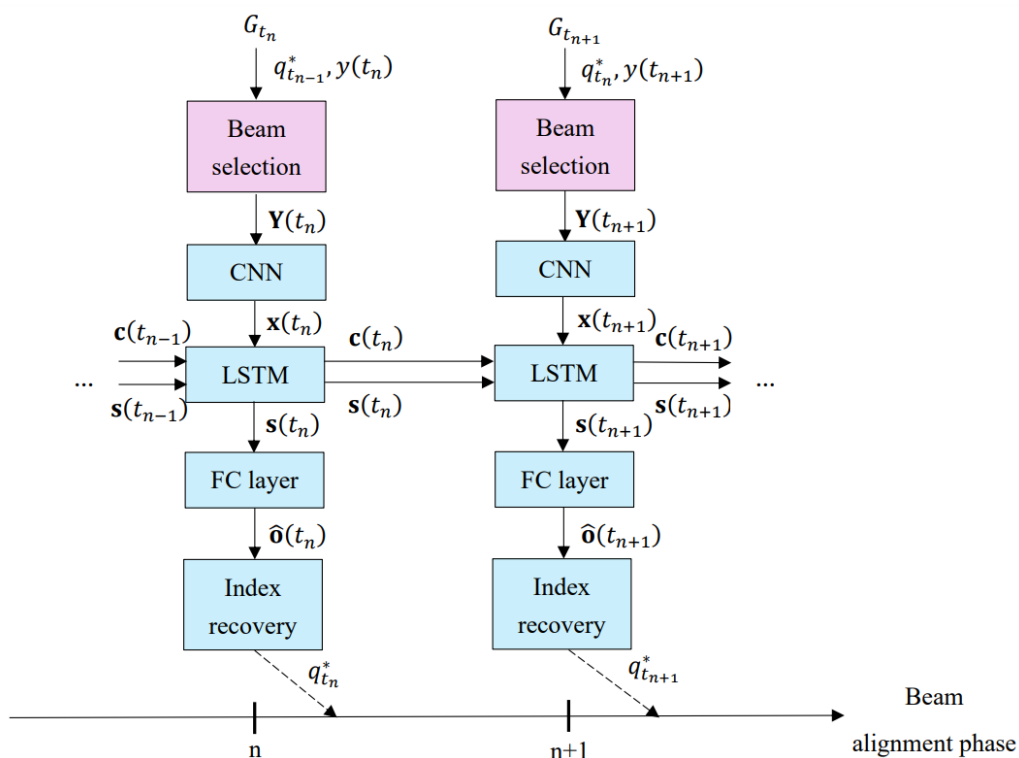


Fig. 2-1: 機器學習模型流程圖

### 3. 研究結果

#### 3-1. 參數設定及資料的產生

本次實驗使用 DeepMIMO [1] 產生機器學習所需要的資料，並且使用了 Scenario O1 (見 Fig. 3-1) 模擬整個通訊過程的環境。

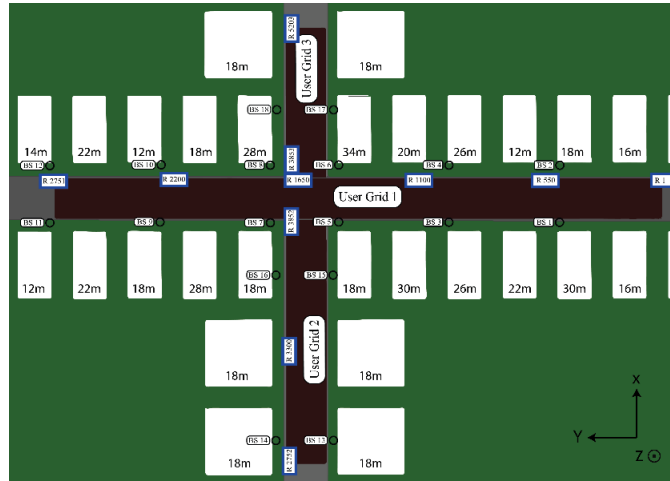


Fig. 3-1: DeepMIMO Scenario O1 的俯視圖

### 3.1.1. BS 端設定

雖然如 Fig. 3-1 所示，整張地圖總共有 18 個 BS，但本次實驗只會用到 BS1。其餘參數請參見 Table 3-1 或參考資料 [2]。

Table 3-1: BS 端所使用之參數

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 $d$	$0.5\lambda$
Beam tracking 所需波束數量 $S$	11
雜訊指數(noise factor)	5 dB
BS 傳輸能量	30dBm
通道數量 $L$	5

### 3.1.2. UE 端移動設定

UE 的移動範圍會被限制於 Fig. 3-1 中 User Grid 1 (UG1) row 100 ~ 900 (R100 ~ R900) 之間。UE 將會隨機出現在此範圍中的隨機一處，並以初速度為  $v$  (m/s)，加速度  $a = 0.2v$  (m/s<sup>2</sup>) 往隨機方向  $\theta \in [0, 2\pi]$  移動。若 UE 超出限制範圍內的話則不使用該資料並重新以同樣的規則產生資料。

UE 的位置資訊，我們會用以下公式進行計算

$$[x(t) \ y(t)] = [x_0 \ y_0] + s(t) \times [\cos\theta \ \sin\theta]$$

$x(t)$ ,  $y(t)$  分別是 UE 在時間為  $t$  時的  $x$ ,  $y$  座標， $x_0$ ,  $y_0$  分別是 UE 最初位置的  $x$ ,  $y$  座標。 $\theta$  是 UE 的移動方向， $s(t) = vt + \frac{1}{2}at^2$  是利用等加速度公式計算 UE 的位移大小。我們會在實驗中以每 0.01 秒 1 次的取樣頻率，額外將此資料當作模型的特徵，觀察模型的預測表現有何影響，預測的總時長則設為 1 秒鐘。

### 3.1.3. UE 端模型設定

我們首先會讓模型的輸入放進三層 Conv2D layer 裡面，初步取出資訊的特徵。之後輸入進一層 LSTMcell 中，利用 LSTM 模型進行更進一步的特徵提取。最後輸入一層 FC layer，決定最適合的波束。

在模型的 learning rate 方面，我們將使用 Adam optimizer 來調整 learning rate 的大小，最初的 learning rate 設為  $3 \times 10^{-5}$ 。

UE 端詳細的 layer 參數以及模型的 hyperparameter 將分別列於 Table 3-2 和 Table 3-3 之中。

Table 3-2: Layer 的參數

Layer	Output size	Activation
$3 \times \text{Conv2D}$	$32 \times 256 \times 10$	ReLU
LSTMcell	$32 \times 256$	Sigmoid, tanh
FC	$32 \times 11$	Softmax

Table 3-3: 模型的 hyperparameter

Parameter	Value
Training epochs	60
Batch size	32
Initial learning rate	$3 \times 10^{-5}$
Minimum learning rate	$10^{-7}$
Learning factor	0.5
Default input sequence length	10

## 3-2. 實驗結果

本次實驗將分成三種狀況討論，1. noise power = -104 dBW，此為參考資料 [2] 中之參數設定，2. noise power = -94 dBW，3. noise power = -84 dBW。每一種狀況又考慮了初速度  $v$  為(a) 10 m/s、(b) 15 m/s、(c) 20 m/s 三種情型，結果如 Fig. 3-2 – Fig. 3-4 所示。

### 3.2.1. Noise power = -104 dBW

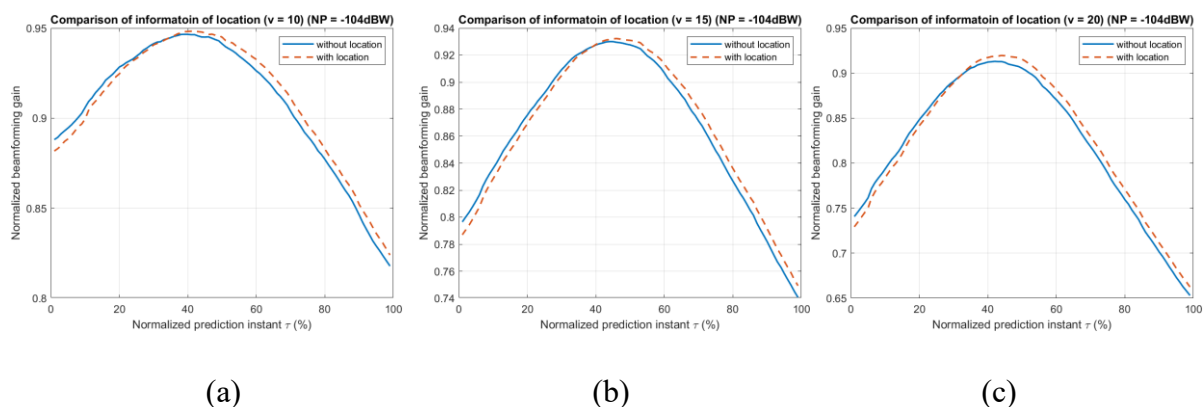


Fig. 3-2: 在 noise power = -104 dBW 的狀況下，藉由測量每個預測時間點的 beamforming gain  $G_t$ ，比較有無位置資訊的表現。UE 的初速度為 (a) 10 m/s (b) 15 m/s (c) 20 m/s

### 3.2.2. Noise power = -94 dBW

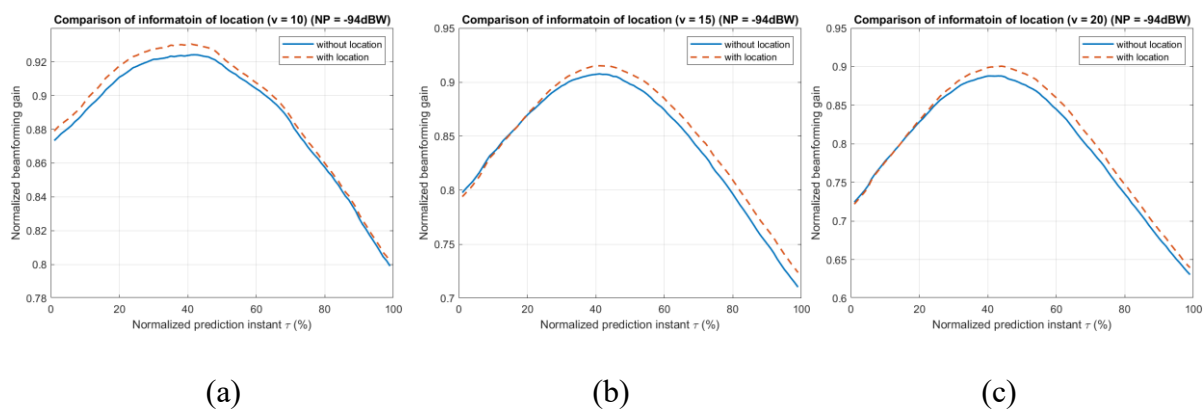


Fig. 3-3: 在 noise power = -94 dBW 的狀況下，藉由測量每個預測時間點的 beamforming gain  $G_t$ ，比較有無位置資訊的表現。UE 的初速度為 (a) 10 m/s (b) 15 m/s (c) 20 m/s

### 3.2.3. Noise power = -84 dBW

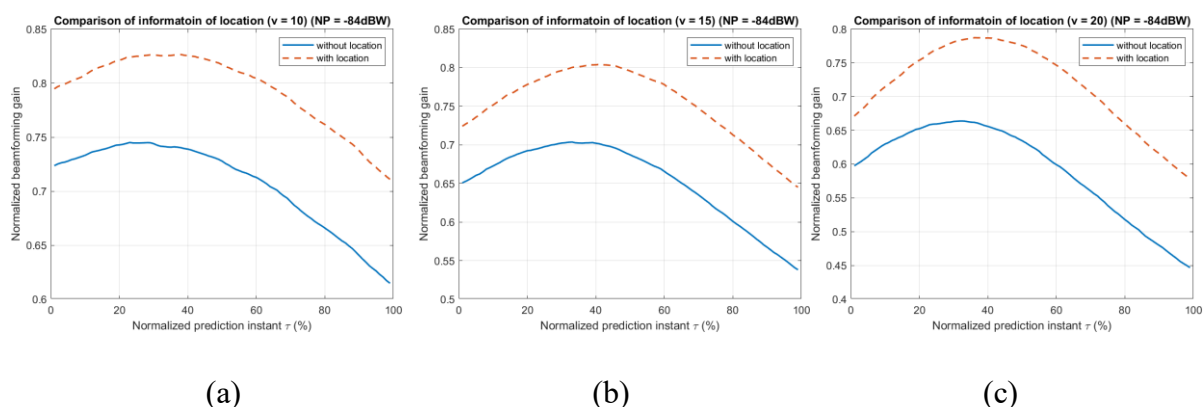


Fig. 3-4: 在 noise power = -84 dBW 的狀況下，藉由測量每個預測時間點的 beamforming gain  $G_t$ ，比較有無位置資訊的表現。UE 的初速度為 (a) 10 m/s (b) 15 m/s (c) 20 m/s

從上面的結果可以觀察到以下兩個結論。第一，當 UE 的速度增加時，整體的預測表現將會降低。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，隨著 SNR 的降低，雖然整體的表現會降低，但是加了位置資訊的影響會變得更加明顯。在高 SNR 的狀況下，對於模型來說接收訊號已具有足夠的資訊去做預測，因此位置這個輔助資訊沒有辦法再提升預測的表現。而當我把 noise power 降低 20 dBW 時，模型會受到接收訊號之雜訊的影響，沒辦法做足夠準確的預測。此時若我使用位置的資訊輔助時，就可以有效的增加預測的準確度。

下圖 Fig. 3-5 統計了在不同速度時，模型成功預測出最準確的波束的機率。可以觀察到，UE 速度的增加會降低預測的準確度。並且隨著 noise power 的增加，雖然整體表現會下降，但是有無位置資訊的差異越加明顯。亦可驗證上述的推論。

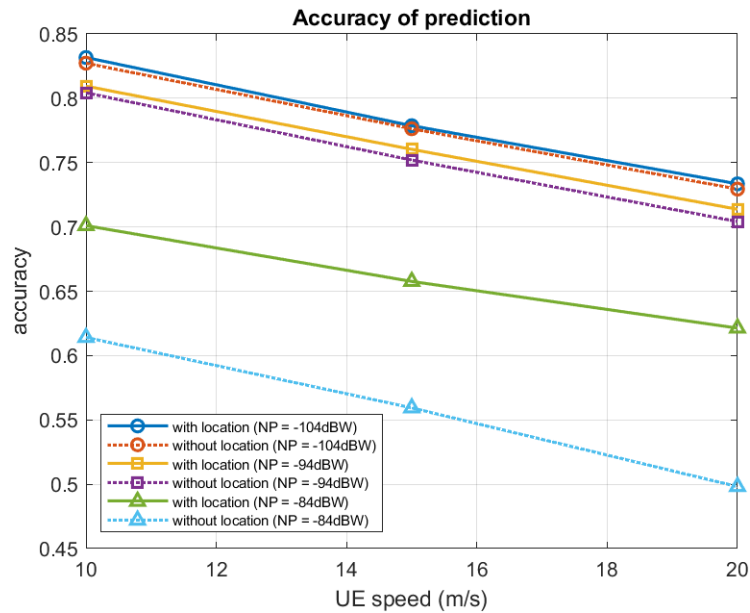


Fig. 3-5: 不同條件下，預測準確度對 UE 初速度的作圖

## 4. 結論

本次專題，研究了如何使用 LSTM 模型做波束的預測，並試著在模型中增加位置的資訊，比較有無這項資訊的差異。

在這次的研究中，可以觀察到增加位置的資訊在低 SNR 的狀況有較顯眼的效果。但在 SNR 較高的狀況則沒有顯著的差異。由於額外傳輸位置的資訊必然要花費更多的時間，因此在實作時，或許可以根據 UE 當下的狀況，改變是否要額外運用位置的資訊。像是在收訊較差的空間裡，UE 接收到的訊號肯定較為薄弱，此時 UE 可以藉由判斷當下的收訊情形，去做適應性的調整，達到更加的通訊品質。

另外，在本次實驗中，我們是用物理的方式去直接得到位置的資訊。不過在實作上，比較實際的作法可能須借助額外的儀器，例如 GPS 或者雷達等。用這些方式位置的資訊在實作上必定會存在著雜訊及誤差，這些影響會對預測產生多大的影響？這個疑問需要待未來更精密的研究才可得知。

## 5. 參考資料

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

- [2] 參數設定參考: <https://github.com/kuanghaoliu/Adaptive-online-beam-alignment>
- [3] 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.
- [4] 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.
- [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. 心得

在本次的實作專題中，我學習到了不少通訊領域的知識以及技術，像是毫米波通訊、波束成形、波束預測等。這些知識都是我在大學部的其他課程中幾乎學習不到的，因此我很慶幸自己參加了這個專題，讓我對這些知識有更深入的了解。

非常感謝劉光浩教授在這兩個學期下來專題的指導，在上學期的論文閱讀時期，教授在每次的討論會與我確認對論文相關基礎知識的理解是否是正確的。也會提點我關於論文撰寫的一些要點。而在下學期開始進入實作的部分，在我遇到瓶頸的時候，教授也會適時的提供一些可以參考的想法。

這次的實作專題我是獨自一人進行的，除了指導教授之外沒有其他的人可以跟我討論。不過由於自己也不能太過依賴教授，因此會有許多時間需要獨自來解決問題。雖然存在著許多的不安感，不過我仍然堅持到了現在，也因此學習到了許多。