

國立清華大學 電機工程學系

實作專題研究摘要

Channel Estimation and Application
of 6G Communication:

Microwave Beam Tracking

6G 通訊通道狀態預測與應用：

毫米波波束追蹤

專題領域： 通訊領域

指導教授：劉光浩

組員姓名：鄭任佑、林采衡

研究期間：2024年2月21日至2024年11月4日止，共9個月

摘要

本專題研究旨在解決毫米波通訊中的波束追蹤問題，特別針對 DeepMIMO 數據集中的 O1 場景進行深入探討，並聚焦於操作頻率為 28GHz 的情境下進行測試和優化。現有的解決方案多集中於使用數學模型與傳統演算法來預測最佳波束，這些方法在較簡單的場景下能夠提供不錯的效果，然而，在動態環境中，其預測的精確性往往無法達到令人滿意的水準。隨著無線通訊系統越來越需要在複雜且變化多端的環境下運行，這些傳統方法的局限性變得更加明顯。儘管近年來機器學習技術的應用為波束追蹤問題提供了顯著改善，但該技術仍有許多方面需要進一步優化。因此，本研究提出了一種採用新型機器學習模型的解決方案，旨在能夠更靈活地應對非線性和高噪聲的動態環境，從而進一步提升波束追蹤的效果。

在具體的研究過程中，我們使用 MATLAB 工具將 DeepMIMO 數據集內關於 O1_28 場景的通道信息轉換為 MIMO 系統接收到的輸入信號，並生成對應的預期最佳波束，這些數據被用作訓練和測試模型的基礎。此外，Python 被選作主要的深度學習模型訓練與測試平台。核心的深度學習模型架構，我們選擇了液態神經網路 (Liquid Neural Networks, LNN)，這是一種能夠動態適應時間序列數據的新型深度學習模型，其優勢在於能夠有效地處理高度非線性、變化快速的環境，並且具備較高的訓練效率和推理能力。並對整體模型架構進行實驗與調整，包含內部神經網路層的連接方式與參數配置，並反覆進行測試驗證。

結果顯示，相較於現有的機器學習模型，我們的研究成果展現出在波束預測準確度和波束成形增益上的顯著提升。即便在更加複雜的場景中，LNN 依然展現出在適應能力方面強大的優勢，無論是針對波束追蹤的精確性還是穩定性，均有出色的表現。

1. Introduction

1-1. Research Background

毫米波通訊具備高頻寬和低延遲的優勢，是5G與6G通訊技術發展的重要基石。然而，由於毫米波具有高損耗的特性，因此必須依賴波束成形（beamforming）來提升增益。在實際應用中，波束成形的對齊過程面臨諸多挑戰，特別是在動態環境中，如何有效地進行波束追蹤與預測同時降低傳輸信號的開銷成為亟待解決的問題。傳統演算法如 ARIMA 和 Extended Kalman Filter 在某些場景中雖能提供合理的性能，但在面對快速變化和非線性特徵時，其效果往往有限。相比之下，機器學習方法（如長短期記憶網路 RNN、LSTM 和 LSTM-ODE）更能適應此類複雜環境，並在波束追蹤效果上顯示出顯著優勢。

1-2. Research Purpose

本研究的目標是利用機器學習技術實現更穩定且適應性更強的波束追蹤，同時提升波束成形的增益。參考文獻[4]指出，液態神經網路（Liquid Neural Networks, LNN）在波束追蹤任務中的潛力超越了傳統的長短期記憶網路（LSTM）。因此，我們將 LNN 應用於毫米波波束預測的場景，並進行相關實驗驗證。我們使用 DeepMIMO 數據集[7]進行模型的訓練與測試，該數據集模擬了多種無線通訊場景中的通道特徵，例如環境障礙物、移動物體和不同基站部署。基於實驗室提供的程式環境[6]，完成了機器學習所需的數據預處理。本研究模型由 LNN Cell 組成，其基礎單元 CfCCell 參考自 NCPS（Neural Circuit Policies）[5]。我們針對 LNN 模型架構進行設計、調整與優化，並在不同場景與速度條件下進行測試。最終結果顯示，LNN 在波束追蹤準確度上全面超越了 LSTM-ODE，實現了在複雜場景中的高效表現。

2. Research Methodology

2-1. System Model And Problem Description

在毫米波通訊中，基地台 (BS, Base Station) 和使用者 (UE, user equipment) 之間的通道如下所示：

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

\mathbf{H}_t 是在時間 t 的毫米波通道， L 是路徑的數量， $\alpha_{t,l}$ 是路徑增益 (path gain)， $\Phi_{t,l}$ 是 AoD (angle of departure)， $\mathbf{a}(\Phi_{t,l})$ 則是 BS 中天線陣列的 steering vector。在此通道中，UE 所接收到的訊號是：

$$\mathbf{y}_t^{(q)} = \mathbf{H}_t \mathbf{f}_{qS} + \mathbf{z}_t$$

\mathbf{f}_q 是第 q 個 beamforming vector，而 BS 會根據 beamforming gain $G_t = |\mathbf{H}_t \mathbf{f}_q|^2$ ，選出有最大 beamforming gain 的 beamforming vector 以達成最大增益，參考自[3]。

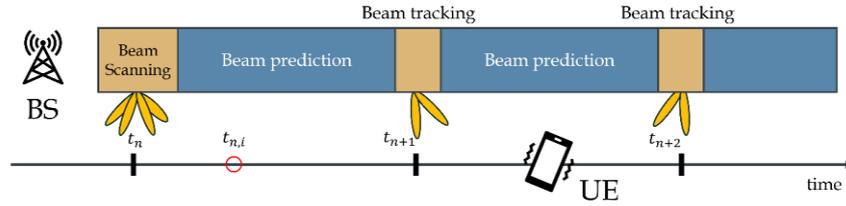


Fig. 1: Beam tracking scheme

Fig. 1 為波束追蹤的進行模式。整個模式分為 Beam alignment stage 和 Beam prediction stage。Beam alignment stage (包含 beam scanning 與 beam tracking) 是 BS 從各個波束直接傳送 pilot symbol 到 UE，並從 UE 的回饋直接得知哪一個波束有最大的 beamforming gain 的過程。雖然這樣可以精準取得最佳波束，但傳送 pilot symbol 時無法進行資料傳輸，因此會浪費頻寬與時間。為了減少資源浪費，將整段通訊的過程分為 N 個週期為 T 的時間槽，每個時間槽開頭一段時間進行 beam alignment 取得足夠資訊後，剩下時間則是 Beam prediction stage，以預測的方式選出最佳波束。

如 Fig. 1 所示，當時間 t 在第 n 個時間槽和第 $n+1$ 個時間槽中間時，可以表示將其標準化表示成：

$$t_{n,i}, i = \frac{t - t_n}{T}$$

藉由前 n 個 time slot 所取得的資訊 \mathbf{Y}_n ，可以將我們的任務目標描述如下：

$$q^*(t_{n,i}) = \underset{q \in \mathcal{S}}{\operatorname{argmax}} G_{t,i} = \mathbf{S}(\mathbf{Y}_n, i)$$

$\mathbf{S}(\cdot)$ 是 classification 的方法，以此方法找到 beamforming gain 最大的波束，也就是最佳的波束。 $\mathbf{S}(\cdot)$ 的部分則是我們希望去實作出來的部分，借助機器模型的力量，我們所研究的是以 LNN (Liquid Neural Networks) 為基礎設計的波束預測模型，目標是能有比現有方法如演算法 (ARIMA、Extended Kalman Filter... 等)、常見的長短期記憶機器學習模型 (RNN、LSTM、LSTM-ODE... 等) 更好、更穩定的預測效果。

2-2. Dataset Generation And Preprocessing

我們使用 DeepMIMO[7] 平台的數據集進行模型的訓練與測試。DeepMIMO 是一個開放的毫米波 (mmWave) 和大規模 MIMO (Massive MIMO) 通訊數據集，提供了大量的數據，用來模擬不同無線通訊場景中的通道特徵。我們使用的場景為 O1_28 (Outdoor 1, 28GHz) 與 Boston5G_28，參數如下所示：

Table 1:
Parameters of scenarios

Parameters	O1_28	Boston5G_28
Carrier frequency f_c	28 GHz	28 GHz
Number of BS	12	1
Bandwidth	50 MHz	50 MHz
Number of BS antennas	64	64
Number of UE antennas	1	1
Number of beams Q	64	64
Number of probing beams S	11	11
Antenna spacing d	0.5λ	0.5λ
Number of paths	5	5
Location range of users	Row 1~2751	Row 812~1622
Number of users	497,931	482,545

(Reference: [7])

如 Table 1所示，O1_28為較為簡單的場景，大部分通訊皆為 LoS (Line-of-Sight) 的情況；Boston5G_28則是較為複雜的場景，由於基地台數量僅僅一個再加上高樓林立，導致通訊大部分是 NLoS (Non-Line-of-Sight) 的情況。

我們將下載下來的數據集透過 Matlab，切分出 training dataset、validation dataset 以及 testing dataset。進行 Model training 和 Model validation 時，時間槽的週期 $T = 100ms$ ，每一個時間槽有十個預測點進行 beam prediction，共十個時間槽，總耗時1s；Model testing 時，除了每一個時間槽增加到一百個預測點以外，其他皆相同。最後我們將測試結果換算得出 Beamforming gain 與波束預測的正確率進行結果評估與分析。

2-3. LNN-Based Beam Prediction Model

我們的波束預測模型是基於 LNN (Liquid Neural Networks) [8]所設計。LNN 的機制模仿了神經突觸的時間變化行為，使得該網路能夠在連續時間數據處理中表現出色。LNN 有著動態適應性強、高效的時間序列建模能力、高效的訓練和推理能力等優點，非常適合應用在 beam tracking 等時間序列預測的問題上。LNN 的基本原理在於模擬神經元的活動：

$$\frac{dx(t)}{dt} = -\frac{x}{\tau} + s(t)$$

$$s(t) = f(i(t))(a - x(t))$$

$x(t)$ 是突觸後神經元的膜電位， $i(t)$ 是刺激， $s(t)$ 是非線性的突觸神經元， $f(\cdot)$ 是非線性的突觸釋放， a 是突觸反轉電位， τ 是時間常數。不同於類似的微分模型 LSTM、LSTM-ODE 需要解複雜的微分運算，LNN 經過向量化和近似後可以

得到一個 closed-form 的表達式，進而減少運算複雜度：

$$x(t) = \sigma(-f(x(t), i(t); \theta_f)t) \odot g(x(t), i(t); \theta_g) + [\bar{1} - \sigma(-f(x(t), i(t); \theta_f)t)] \odot h(x(t), i(t); \theta_h)$$

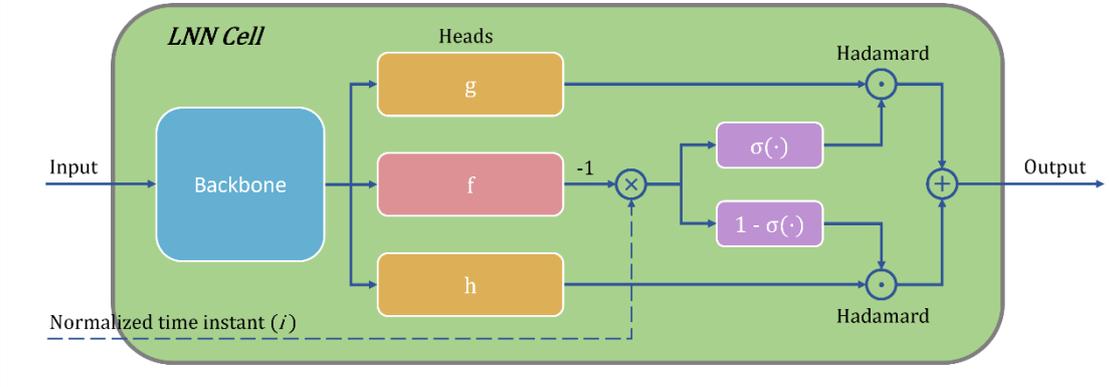


Fig. 2: Architecture of LNN Cell

LNN Cell 的架構如上圖 Fig. 2 所示，在 normalized time instant i 時，input (input x 和前一個 hidden state 接合) 傳入 LNN Cell，先經過 Backbone (一個由 Tanh 激活 feedforward neural network，用以進一步提取特徵以供後續使用)，再經過 $f(\cdot)$ 、 $g(\cdot)$ 、 $h(\cdot)$ 三個 head，其中 $f(\cdot)$ 是 liquid time constant 函數，負責時間連續的門控，決定狀態更新的速度和依賴。 $g(\cdot)$ 、 $h(\cdot)$ 則是 LNN Cell 中非線性的部分，提供 LNN Cell 不同的非線性路徑來更新 hidden state，使其能在動態環境有更好的學習。我們所使用的 LNN Cell 是 NCPs (Neural Circuit Policies)[5] 的 wired_cfc_cell。

LNN 還有一個獨有的機制 wiring[9]。這是一種特殊的稀疏連接演算法，能夠動態適應隨時間變化的數據，並以最小的記憶體使用量有效處理長期依賴關係，與全連接 (fully connected) 相比，wirings 能在較低計算成本下運行。我們使用 NCPs[5] 實作 LNN 的 wiring 構造，以達到更能適應動態變化的目的。

NCPs 的 Wiring 靈感來源於秀麗隱桿線蟲 (*C. elegans nematode*) 的神經系統連線圖。該線蟲的神經系統中，許多神經迴路由一個獨特的四層網路拓撲結構所建構。它們通過感覺神經元 (Sensory neurons) 接收環境觀察信號，並將這些信號傳遞給中間神經元 (Inter neurons) 和指令神經元 (Command neurons)，進而生成輸出決策。最終，這一決策會傳遞到運動神經元 (Sensory neurons)，來驅動其肌肉進行動作。

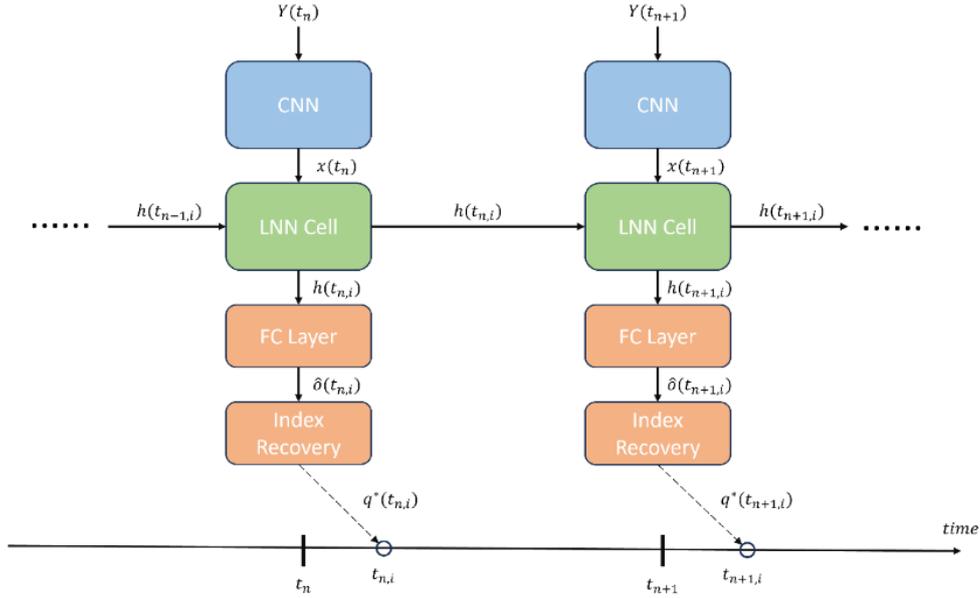


Fig. 3: Flowchart of LNN-based Beam Tracking Scheme

Fig. 3 是我們的模型架構圖與進行波束預測的流程。在時間 $t_{n,i}$ 時， $Y(t_n)$ 代表在第 n 個時間槽收到的 pilot symbols，在經過卷積神經網路 (CNN) 提取出特徵向量 $x(t_n)$ 後，LNN Cell 結合 $x(t_n)$ 和上一個的時間槽位於同一時刻的隱藏狀態 $h(t_{n-1,i})$ ，生成新的隱藏狀態 $h(t_{n,i})$ 。 $h(t_{n,i})$ 在經過丟棄層 (dropout layer) 和全連接層 (fully connected layer) 後，將透過 SoftMax 函式來判斷出最佳波束。同時也將被下一個時間槽的 LNN Cell 結合當下的特徵向量生成隱藏狀態 $h(t_{n+1,i})$ 。有別於直接隨著時間傳遞 hidden state 的作法，我們所使用的傳遞方式能在進行波束預測時也考慮到之前所有時間槽的資訊，進而學習到之前所有時間槽所提出的特徵以得到更好的預測效果。實驗結果也驗證了此猜想，且是模型效果的關鍵因素，大大影響模型的預測能力。Table 2 為我們模型參數，Table 3 則是進行機器學習與模擬的參數。

Table 2:
Layer parameters

Layer	Output size	activation
$3 \times \text{Conv2D}$	$32 \times 256 \times 10$	ReLU
LNN Cell	32×64	lecun_tanh
FC	32×11	SoftMax

Table 3:
Simulation parameters

Parameters	Value
Training epoches	60
Batch size	32
Initial learning rate	3×10^{-4}
Minimum learning rate	10^{-7}

Learning factor	0.5
Default input sequence length	10
Time slot duration T	100ms
Dropout	0.3

3. Experimental Results

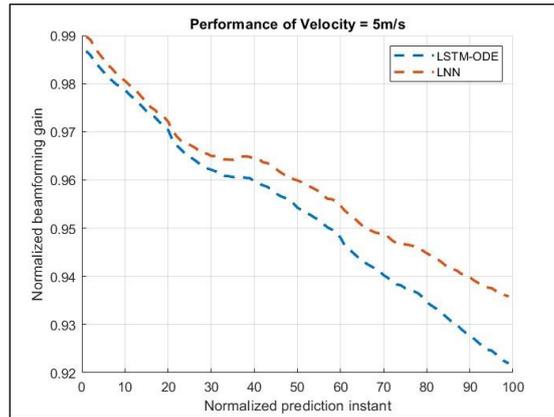


Fig. 4: Beamforming gain
(Velocity = 5m/s)

Fig. 4是 UE 速度為5m/s 時在 O1_28情景測量的波束成形增益，縱軸為波束成形增益(與原傳送增益標準化，最大值為1)，橫軸為時間(將一個時間槽週期標準化)。可以發現，不論是使用 LSTM-ODE 還是 LNN 進行波束預測，波束成形增益都會隨著時間下降。這是因為隨著時間過去，使用者(UE)會離最初的位置越遠，通道的情況也會有更多的變數，導致預測效果越來越低。

在我們的模擬結果中，LNN 在所有的速度 (5~30m/s) 都表現出優於 LSTM-ODE 的波束成形增益與準確率。這也驗證了 LNN 的動態適應能力對波束預測的幫助，以及我們所採取的模型架構對波束預測結果有帶來如預期的正向效果。

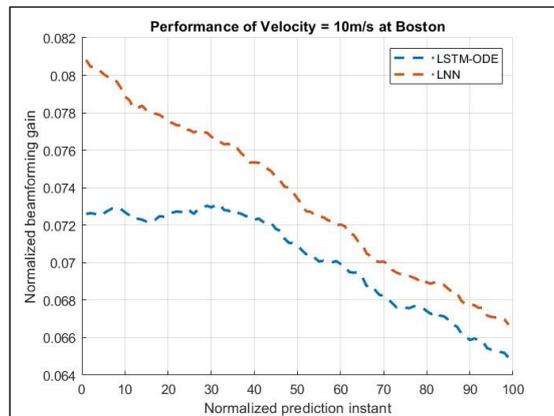


Fig. 5: Beamforming gain in Boston5G_28
(Velocity = 10m/s)

Fig. 5是在 Boston5G_28、UE 速度為10 m/s 的情況下所測量出的波束成形增益。在為複雜的場景 (Boston5G_28) 下，由於 Boston5G_28中多數使用者位於非直視性(NLoS)區域，訊號的不穩定造成雖然預測準確度高，但是波束成形增益卻偏低的狀況。儘管如此，LNN 在此不穩定的環境中波束成形增益與預測準確率仍優於 LSTM-ODE。再度驗證了 LNN 的適應能力對波束預測的幫助，以及我們所採取的模型架構對波束預測結果有帶來如預期的正向效果。

4. Conclusion

在此專題計畫中，我們成功應用了液態神經網絡 (Liquid Neural Networks, LNN)，並在毫米波通訊中的波束追蹤任務上展現出優於現有方法的準確性和穩定性。與傳統方法相比，LNN不僅在簡單場景中能夠實現卓越的預測性能，在更加複雜、多變的場景中同樣表現出色，展現了其良好的適應能力和廣泛的應用潛力。這些實驗結果突顯了LNN技術在提升6G通訊中的波束成形和追蹤技術方面的潛在價值，表明其具有廣泛應用於未來通訊技術領域的可能性，不僅能提升現有系統的性能，也為6G及其後續發展提供了新的技術途徑。

5. Review and reflections

在為期一學年的專題中，我們從閱讀文獻瞭解波束追蹤基本原理到最後運用液態神經網路實作出成功的波束預測模擬，我最大的收穫是慢慢培養了問對問題的勇氣與技巧。因為我們採用的機器學習模型和實驗室學長研究的方法略有不同，有些實作上碰到的問題並不能直接透過學長教學而解決，但藉著查找更多資料以了解問題本身，我們最終還是達成了理想的成果。

最後我想感謝劉光浩教授讓我們參與此專題並提供研究室的資源，並在我們整個研究模擬過程中給予適時的建議，和我們一起思考改善的方法。

6. Reference

- [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 Proceedings of the IEEE Wireless Communications and Networking Conference (WCNC), Dubai, UAE, Apr. 21-

24, 2024, pp. 1-6, IEEE, 2024. doi:10.1109/WCNC52438.2024.1234567.

- [4] Zhu, F., Wang, X., Huang, C., Jin, R., Yang, Q., Alhammadi, A., Zhang, Z., Yuen, C., & Debbah, M. (2024). Robust Continuous-Time Beam Tracking with Liquid Neural Network. arXiv. <https://doi.org/10.48550/ARXIV.2405.00365>:contentReference[oaicite:0]{index=0}:contentReference[oaicite:1]{index=1}.
- [5] mlech26l, "ncps," GitHub. [Online]. Available: <https://github.com/mlech26l/ncps/tree/master>. [Accessed: Oct. 5, 2024].
- [6] K. Liu, "Adaptive-online-beam-alignment," GitHub. [Online]. Available: <https://github.com/kuanghaoliu/Adaptive-online-beam-alignment>. [Accessed: Oct. 5, 2024].
- [7] DeepMIMO, "A Dataset for Millimeter-Wave and Massive MIMO Applications," [Online]. Available: <https://www.deepmimo.net/>. [Accessed: Oct. 5, 2024].
- [8] Ramin Hasani, Mathias Lechner, Alexander Amini, Daniela Rus, Radu Grosu, "Liquid Time-constant Networks," <https://doi.org/10.48550/arXiv.2006.04439>
- [9] Mathias Lechner, Ramin M. Hasani, Alexander Amini, Thomas A. Henzinger, Daniela Rus and Radu Grosu, "Neural circuit policies enabling auditable autonomy," *nature machine intelligence* | VOL 2 | OCTOBER 2020 |642-652|. <https://doi.org/10.1038/s42256-020-00237-3>.