

國立中正大學電機工程研究所

碩士論文

條件式生成器於可重構智慧面

多規格相位分布即時生成之研究

**A Condition-Based Generator for Real-Time
Multi-Specification Phase Distribution Generation
in Reconfigurable Intelligent Surfaces**

The logo of National Central University is a blue circular emblem with a stylized white 'N' and 'C' intertwined in the center. The emblem is surrounded by a blue border with decorative elements.

研究生：顏俊儀

指導教授：劉立頌 博士

中華民國 一百一十五 年 六 月

誌謝

首先，要特別感謝我的指導老師劉立頌教授，兩年的研究所生涯中學習到許多不同的知識和觀念，不管是在上課或者是開會，都嚴謹地灌輸我們重要的知識，並細心糾正我們的每一個小錯誤，以促進我們的學術成長，讓我擁有獨當一面的能力。另外也時常鼓勵我們參加各種學術研討會和講座，以吸收最新的知識並激發我們將來應用於職場的潛力。

同時也非常感謝口試委員邱志義教授與林士程教授，在百忙之中參與我們的口試，並對我的碩士論文提出寶貴的修改建議，指出了我在實驗設計與結果呈現上思慮未周之處，使整體論文的論證更加完整、嚴謹。

在 6G 的合作計畫中，衷心感謝佑誠學長，在我對研究主題感到迷惘時，提供了許多寶貴的建議，對我的碩士論文研究的方向給予了很大的幫助。

感謝實驗室的學長奇倫、宇堙、鵬予、柏廷、亮潛、楓賢和子濤，在實驗室事務及課業問題上，他們都給予了我很大的幫助。我也要特別感謝奇倫及鵬予學長，在我還不太了解 6G 以及 RIS 的時候給了我很多的指點，常常過來關心我的研究狀況與提供建議，讓我在研究中能有更多的想法。再來要特別感謝宇堙學長，不管是在實驗室的大小事或是助教上，都給了我很大的幫助，也總是陪著我們一起打遊戲還有打 Apex 上大分。

非常感謝我的同學祐廷、維文、瑋宥、岳儒及惠螢，在碩士生涯互相討論新方法以及論文相關研究。再來感謝我的 6G 研究好夥伴祐廷及維文，一起解決了研究上大大小小的事情，也在開會時互相給予許多的建議與支持，渡過了很多的難關，平常還會一起打 Apex 積分以及機器人訓練場，每把都打得非常過癮。然後感謝瑋宥在各項事務上給了我很多的建議與幫助，平常也一起去吃了很多中正附近沒吃過的店，吃得很開心，還會跟我一起打戰棋，常常拿了很多把第一。還有感謝岳儒在平常討論時都會給我很直觀的建議，然後還有幫我拍了一張帥氣的照片讓我當大頭照，讚。最後感謝惠螢在專題展網頁卡 Bug 時給了很多的幫助，

讓我成功解掉不少的問題。同時，感謝學弟妹信睿、穎麒、子翔、泓瑋和育鉸，他們在研究及口試給予了許多幫助及不同的觀點。

還要感謝 HL 陪伴了我的碩士生活，不管是在做研究或是心情低潮的時候給了我很多溫暖的情緒支持與鼓勵，總是陪著我渡過了許多的難關，讓我能夠全心全意的認真完成我的碩士研究，順利畢業。

最後感謝我的家人，給了我不管是經濟上或是情感上的支持，讓我能夠不用顧慮日常的開銷，專心致志地完成學業和論文。



摘要

本論文針對第六代行動通訊 (6G) 環境對可重構智慧面 (RIS) 所提出之即時、動態與多規格相位生成需求，提出一套基於條件式生成方法之深度學習框架，命名為條件式生成器 (Condition-Based Generator)，用於即時生成各種客製化角度規格之二值化相位分布。本研究以入射角與反射角組合作為模型之動態輸入，並於網路架構中導入特徵線性調變機制 (FiLM)，使單一模型得以於同一組權重內承載大量角度規格之相位映射關係，藉此克服既有方法須針對個別規格重新訓練之限制。於訓練流程中，本研究以陣列因子公式建構物理引導損失函數，並將 Gumbel-Sigmoid 量化機制整合至單階段端到端之訓練流程，同時參考硬體層之隨機相位預編碼概念，於量化前疊加固定之隨機遮罩以抑制 1-bit 量化所致之鏡像波束。針對多波束高自由度場景，本研究另提出啟發式神經網路混合訓練機制，以突破龐大離散規格於訓練後期所遭遇之收斂瓶頸。於驗證方面，本研究同時以陣列因子公式與 Ansys HFSS 電磁模擬評估生成品質，並將模型部署至 NVIDIA Jetson AGX Orin 邊緣運算裝置以量測其即時推論能力。實驗結果顯示，本研究模型能以單一模型涵蓋多種單波束與多波束規格並展現良好之泛化能力，於邊緣裝置上維持毫秒等級之推論速度，且電磁模擬結果與理論公式解大致吻合，驗證本方法於設計靈活性、即時性與貼近真實硬體驗證等面向之有效性。

中文關鍵字：可重構智慧面、相位分布即時生成、條件式生成器、深度學習、即時推論、邊緣運算

Abstract

To address the requirements of real-time, dynamic, and multi-specification phase generation imposed by reconfigurable intelligent surfaces (RIS) in sixth-generation (6G) communication environments, this thesis proposes a deep learning framework based on a conditional generation approach, termed the Condition-Based Generator, for the real-time generation of binarized phase distributions across diverse customized angular specifications. The proposed method takes the combination of incident and reflection angles as the dynamic input to the model, and incorporates a Feature-wise Linear Modulation (FiLM) mechanism into the network architecture, enabling a single model to encode the phase-mapping relationships of a large number of angular specifications within one set of weights, thereby overcoming the limitation of existing methods that must be retrained for each individual specification. During training, an array-factor formulation is employed to construct a physics-guided loss function, and a Gumbel-Sigmoid quantization mechanism is integrated into a single-stage end-to-end training pipeline. Inspired by the pre-coding concept at the hardware level, a fixed random mask is superimposed prior to quantization to suppress the mirror beam induced by 1-bit quantization. For high-degree-of-freedom multi-beam scenarios, a heuristic-neural hybrid training mechanism is further proposed to break through the convergence bottleneck encountered in the late training stage caused by the vast discrete specification space. For validation, the generation quality is evaluated using both the array-factor formulation and Ansys HFSS electromagnetic simulation, and the model is deployed on an NVIDIA Jetson AGX Orin edge computing device to measure its real-time inference capability. Experimental results show that the proposed model covers a wide range of single-beam and multi-beam specifications within a single model and exhibits strong generalization, sustains millisecond-level inference speed on the edge

device, and yields electromagnetic simulation results that closely match the theoretical formulation, validating the effectiveness of the proposed method in terms of design flexibility, real-time capability, and hardware-faithful verification.

Keywords: reconfigurable intelligent surface, real-time phase distribution generation, condition-based generator, deep learning, real-time inference, edge computing



目錄

摘要.....	iv
Abstract.....	v
目錄.....	vii
圖目錄.....	x
表目錄.....	xi
第一章 緒論.....	1
第二章 文獻探討與問題定義.....	3
2.1 電磁面鏡與陣列天線理論公式.....	3
2.2 人工智慧方法於相位分布設計.....	6
2.2.1 啟發式演算法.....	7
2.2.2 卷積神經網路.....	8
2.2.3 人工智慧生成方法比較.....	9
2.3 深度神經網路於相位分布的即時設計.....	11
2.3.1 監督式學習.....	11
2.3.2 非監督式學習.....	13
2.4 二值化相位分布量化探討.....	14
2.5 問題定義與總結.....	15
第三章 研究方法.....	19
3.1 研究架構.....	20
3.2 相位分布設計流程.....	21
3.3 模型架構.....	22
3.3.1 角度條件編碼.....	23
3.3.2 初始投影模組.....	24


3.3.3	上採樣模組與特徵線性調變.....	25
3.4	量化機制於訓練流程改善	27
3.4.1	隨機相位預編碼策略.....	28
3.4.2	二值化量化機制.....	29
3.4.3	溫度退火策略.....	32
3.5	模型改善.....	33
3.5.1	單波束損失函數.....	33
3.5.2	多波束損失函數.....	38
3.5.3	啟發式神經網路混合訓練機制.....	40
3.5.4	模型改善總結.....	43
3.6	模型驗證	44
3.6.1	陣列因子與電磁模擬之容忍範圍.....	44
3.6.2	理想增益之物理推導.....	45
3.6.3	性能度量之計算方法.....	48
3.7	即時推論方法	49
3.7.1	模型部署與環境設定.....	50
3.7.2	推論流程.....	51
第四章	實驗.....	54
4.1	實驗環境說明	54
4.2	實驗設計與結果	57
4.2.1	實驗一 單波束於不同規格下之相位分布生成效果探討.....	58
4.2.2	實驗二 混合訓練方法於模型的提升能力實驗.....	82
4.2.3	實驗三 多波束於不同規格下之相位分布生成效果探討.....	88
4.2.4	實驗四 模型於邊緣裝置上之即時推論能力.....	96
4.2.5	實驗五 模型生成相位分布之電磁模擬驗證.....	100

4.3 實驗總結	107
第五章 結論與未來展望	109
參考文獻	111
附錄一、 其餘多波束不同規格之相位分布生成指標統計	114



圖目錄

圖 2-1 電磁面鏡單元結構與排列示意圖	4
圖 2-2 輻射場型示意圖	6
圖 3-1 方法架構圖	21
圖 3-2 條件式相位分布生成方法訓練流程圖	22
圖 3-3 條件式生成器架構圖	23
圖 3-4 初始投影漸進式升維示意圖	25
圖 3-5 FiLM 流程示意圖	27
圖 3-6 區域劃分示意圖	34
圖 3-7 啟發式神經網路混合式訓練虛擬碼	41
圖 3-8 計算性能度量示意圖	49
圖 3-9 性能度量數值圖	49
圖 3-10 整體推論流程圖	52
圖 3-11 硬體流程圖	52
圖 3-12 推論時間量測流程圖	53



表目錄

表 2-1 不同人工智慧生成方法之比較.....	10
表 2-2 當前問題與預計改進方法	18
表 3-1 核心問題與本研究對應之解決方案	19
表 3-2 陣列因子公式和電磁模擬容忍區間數值	45
表 3-3 16×16 半功率波束寬對應的增益值	46
表 3-4 32×32 半功率波束寬對應的增益值	47
表 3-5 多波束情境下的理想增益對照表	48
表 4-1 訓練腳本設定之規格參數範圍	56
表 4-2 使用者可輸入角度參數	57
表 4-3 單波束輸入角度規格表	59
表 4-4 16×16 參數組合其一之生成結果	60
表 4-5 16×16 參數組合其二之生成結果	61
表 4-6 16×16 參數組合其三之生成結果	62
表 4-7 16×16 參數組合其四之生成結果	63
表 4-8 16×16 參數組合其五之生成結果	64
表 4-9 16×16 參數組合其六之生成結果	65
表 4-10 16×16 參數組合其七之生成結果	66
表 4-11 16×16 參數組合其八之生成結果	67
表 4-12 16×16 參數組合其九之生成結果	68
表 4-13 16×16 參數組合其十之生成結果	69
表 4-14 32×32 參數組合其一之生成結果	70
表 4-15 32×32 參數組合其二之生成結果	71
表 4-16 32×32 參數組合其三之生成結果	72
表 4-17 32×32 參數組合其四之生成結果	73

表 4-18 32×32 參數組合其五之生成結果	74
表 4-19 32×32 參數組合其六之生成結果	75
表 4-20 32×32 參數組合其七之生成結果	76
表 4-21 32×32 參數組合其八之生成結果	77
表 4-22 32×32 參數組合其九之生成結果	78
表 4-23 32×32 參數組合其十之生成結果	79
表 4-24 不同方法之單波束相位分布生成結果比較	80
表 4-25 混合式訓練方法可調參數範圍	83
表 4-26 Batch 大小測試結果	84
表 4-27 翻轉單元數量測試結果	85
表 4-28 迭代次數測試結果	86
表 4-29 原始訓練與混合訓練方法之訓練結果比較	87
表 4-30 多波束輸入角度規格表	90
表 4-31 雙波束生成結果	91
表 4-32 三波束生成結果	92
表 4-33 四波束生成結果	93
表 4-34 寬波束生成結果	94
表 4-35 訓練設備上之模型推論時間測試	97
表 4-36 於無設定環境的邊緣裝置上之模型推論時間測試	97
表 4-37 於有設定環境的邊緣裝置上之模型推論時間測試	98
表 4-38 單波束相位分布生成時間比較表	98
表 4-39 單波束公式解與電磁模擬之比較結果	101
表 4-40 雙波束公式解與電磁模擬之比較結果	102
表 4-41 三波束公式解與電磁模擬之比較結果	103
表 4-42 四波束公式解與電磁模擬之比較結果	104
表 4-43 寬波束公式解與電磁模擬之比較結果	105

第一章 緒論

在第五代行動通訊技術 (5G) 與未來第六代行動通訊技術 (6G) 之發展中，毫米波頻段因其頻率高、波長短而具備極大之頻寬優勢，惟其繞射能力較差且路徑損耗較高，導致電磁波於傳播過程中易受障礙物遮蔽而產生訊號衰減與通訊盲區。為克服此一限制，電磁面鏡 (Reflectarray) 與可重構智慧面 (Reconfigurable Intelligent Surface, RIS) 逐漸成為重要之解決方案，其透過調控大量反射單元之相位以實現波束成形 (Beamforming)，將入射電磁波精確導向目標方向，進而改善訊號品質並擴展覆蓋範圍。

隨著通訊規格邁向 6G，系統對於極低訊號延遲與高動態波束追蹤能力之要求日益嚴苛，意即系統須能依終端使用者之即時方位動態切換相位分布。然而過往研究多著重於單一固定規格之最佳化，此類方法雖能生成趨近最佳解之相位分布，卻普遍面臨生成時間過長與支援規格過於單一之問題，難以滿足動態環境下之即時推論需求。此外，既有研究於驗證階段多沿用陣列因子公式所預設之無窮遠遠場假設，與實際硬體部署時收發距離有限之近場情境存在落差，致使驗證結果未必能如實反映真實環境下之效能表現。

為解決上述挑戰，本研究提出一套基於條件式生成方法之深度學習模型，命名為條件式生成器 (Condition-Based Generator)，專用於即時生成各種客製化角度規格之二值化相位分布。相較於傳統固定規格之設計，本研究將模型輸入轉為動態之入射角與反射角組合，並於網路架構中導入特徵線性調變 (Feature-wise Linear Modulation, FiLM) 機制，使單一模型能依不同角度組合動態調整內部特徵響應，進而學習空間角度與二維相位分布之間之複雜映射關係。於訓練策略上，本研究以陣列因子理論公式 (Array Factor) 作為物理層面之約束依據，並針對不同角度組合設計自定義損失函數，同時將二值化量化整合於訓練流程之中以對應 1-bit 硬體限制。最終本研究將模型部署於 NVIDIA Jetson AGX Orin 邊緣運算裝置，以實測其於資源受限環境下之即時推論能力，並依實際 RIS 硬體之設計參

數，於電磁模擬軟體中採用收發距離 2.75 公尺之近場條件進行驗證，使驗證情境更貼近真實部署環境。

本論文共分為五個章節。第一章為緒論，說明研究背景、動機與目的，並概述整體論文之篇章架構。第二章為文獻探討與問題定義，回顧人工智慧方法應用於電磁面鏡相位分布設計之相關研究，分析既有方法於即時生成需求下所遭遇之技術瓶頸，並據此定義本研究欲解決之核心問題。第三章為研究方法，依第二章所定義之問題提出對應之解決方案，涵蓋整體研究架構、條件式生成器之模型設計、量化機制與訓練流程之改善，以及模型驗證與性能評估之方法。第四章為實驗，透過五項實驗系統性驗證模型於設計靈活性、訓練收斂、即時性與貼近真實硬體驗證四個面向之表現。第五章為結論與未來展望，總結本研究之成果並提出後續可行之優化方向。



第二章 文獻探討與問題定義

第一章闡述了毫米波頻段因高頻低繞射特性所造成的通訊盲區問題，並指出電磁面鏡與可重構智慧面是有效的波束成形解決方案。隨著行動通訊規格邁向第六代，系統對動態波束追蹤能力與極低訊號延遲的需求日益迫切。本研究旨在設計一套可即時生成相位分布的方法，針對各種入射角與反射角組合產出客製化輻射場型，且無需依賴大量預生成之資料集。

本章架構安排如下，2.1 節介紹電磁面鏡之基本架構與本研究採用的陣列天線理論公式 (Array Factor)，並說明其如何應用於電磁面鏡的相位分布設計，2.2 節分析人工智慧方法在相位分布設計中的應用，涵蓋啟發式演算法與卷積神經網路之比較，2.3 節探討深度神經網路於相位分布即時設計的相關研究，分別就監督式學習與非監督式學習兩路徑進行文獻回顧，2.4 節針對二值化相位分布的量化問題進行深入討論，2.5 節則綜整上述各節之技術瓶頸，精確定義本研究所欲解決之核心問題，並說明本研究方法之設計動機。

2.1 電磁面鏡與陣列天線理論公式

在現代 5G 與未來 6G 通訊技術中，毫米波等高頻段技術因其頻率高、波長短的物理特性，具備極大的頻寬優勢。然而，高頻電磁波低穿透力與高路徑損耗的固有限制，導致訊號在傳播過程中極易受障礙物遮蔽，從而引發非視線傳播 (Non-Line of Sight, NLOS) 問題與通訊盲區 [1],[2]。若僅靠大量增設基地台來彌補覆蓋率的不足，將大幅增加網路基礎建設之成本。

為解決上述問題，電磁面鏡成為一種高效的波束成形解決方案 [3]。電磁面鏡整合了傳統反射面天線 (Reflector Antenna) 與相控陣列天線 (Phased Array Antenna) 的優勢，能夠突破傳統司乃爾定律 (Snell's Law) 的角度限制，將入射電磁波精確引導至客製化的反射方向。其基本運作原理係透過大量反射單元 (Unit Cells) 所組成的陣列平面，藉由動態調整各單元的結構尺寸或電性參數，對電磁波反射時的相位偏移 (Phase Shift) 進行精密控制，進而實現波束成形與波

束轉向 (Beam Steering)，有效擴展訊號覆蓋範圍並提升整體通訊品質。

本研究採用研究團隊所設計的電磁面鏡單元結構 [4],[5]，其排列方式如圖 2-1 所示。該結構透過改變單元中特定金屬貼片的狀態來調整對應單元的反射相位，當面鏡上所有單元都調整到合適的相位後，即可達成預期的波束成形效果。在單元的設計上，常見的可重構電磁面鏡可分為單極性與雙極性兩類，單極性設計只能對單一通道進行相位控制，雙極性設計則能同時支援兩個獨立的通道，並且可以在不同通道之間切換。本研究所使用的單元屬於雙極性設計，因此能夠依需求在不同通道間切換，讓同一面鏡得以對應更多元的使用情境，在波束控制上也具備更高的彈性。




圖 2-1 電磁面鏡單元結構與排列示意圖

為建構具備特定波束成形能力的電磁面鏡，首要任務是計算並設定陣列各單元所需的相位值。在給定訊號源位置及期望波束反射方向的條件下，面鏡上第 i 個單元所需之理想相位 ϕ_{RA} 可透過公式 (1) [6] 計算求得：

$$\phi_{RA} = k_0[R_i - (x_i \cos \phi_b + y_i \sin \phi_b) \sin \theta_b] - 2\pi N \quad (1)$$

公式 (1) 引入變數 $2\pi N$ 作為相位週期的整數倍補償項，旨在將計算所得的相位差精確規範於 $[0^\circ, 360^\circ)$ 區間之內。關於波動特性，電磁波傳播之波數

(Wavenumber) 定義為 $k_0 = \frac{2\pi}{\lambda}$ ，其中 λ 為對應頻率之波長。索引下標 i 對應面鏡上第 i 個單元， R_i 代表訊號源與該單元之間的幾何距離。由於本研究選用饋源喇叭天線 (Feedhorn) 作為訊號源，其輻射波形為球面波，導致各單元與訊號源的幾何距離各不相同；為此公式 (1) 計算所有單元對應的距離並彙整為一距離矩陣。此外， (x_i, y_i) 定義了第 i 個單元在面鏡平面上的空間位置座標，而 (θ_b, φ_b) 則以球座標角度描述期望反射波束的方向。透過公式 (1) 之運算，可精確計算各單元在特定角度組合下所對應的相位值，完成電磁面鏡相位分布之設計。

在計算出電磁面鏡的相位分布後，為驗證其波束成形效果，通常需引入陣列天線理論 (Array Antenna Theory) 計算遠場輻射場型 (Radiation Pattern)。將公式 (1) 所求得的單元相位 ϕ_{RA} 代入陣列因子 (Array Factor, AF) 公式 [7]：

$$AF(\theta, \varphi) = \sum_{m=1}^M \sum_{n=1}^N e^{jk_0 d (m \sin \theta \cos \varphi + n \sin \theta \sin \varphi)} \cdot e^{j\phi_{RA}} \cdot e^{-jk_0 R_i} \quad (2)$$

在公式 (2) 中， $AF(\theta, \varphi)$ 定義為陣列因子， M 與 N 分別表示電磁面鏡在行與列方向上的單元數量， d 代表相鄰單元間距。其餘參數如波數 k_0 、反射波束方向的球座標角度 (θ, φ) 以及訊號源與第 i 顆單元之距離 R_i ，其物理意義均與公式 (1) 相同。

透過公式 (1) 與 (2) 的運算，首先將目標反射波束之球座標與空間幾何距離帶入公式 (1)，推導出對應的相位分布；隨後將此相位分布結果帶入公式 (2) 進行陣列因子計算，最終獲得完整的輻射場型。藉由觀察輻射場型的結果，可以分析數項關鍵性能度量以驗證設計是否達標。如圖 2-2 所示，圖表之 y 軸表示不同角度下之訊號強度， x 軸則代表 θ 角度，範圍設定於 -90° 至 90° ，並以 0.5° 為間隔進行採樣，共計 361 個數值。在此輻射場型中，可同步評估主波束 (Main Beam)、半功率波束寬 (Half-Power Beam Width) 與旁波瓣位準 (Side Lobe Level) 等核心指標。主波束表徵了電磁面鏡在特定方位上的最大輻射強度，即其主要增益方向；半功率波束寬係指主波束功率由峰值下降 3 dB 時的角度區間，

用以界定其主要增益範圍；而旁波瓣位準則顯示了旁波瓣與主波束間的增益差異，作為衡量旁波瓣抑制能力之標準。透過對上述指標的深入分析，能有效評估電磁面鏡之性能並執行優化。公式 (2) 將於後續研究中用於模擬與分析電磁面鏡的輻射特性，藉此驗證相位分布轉化為場型後的各項參數表現。本研究將於第三章進一步闡述各性能指標的具體驗證方法，以完善整體的模型評估流程。




圖 2-2 輻射場型示意圖

2.2 人工智慧方法於相位分布設計

由 2.1 節所闡述之陣列天線理論可知，透過解析法所推導之相位分布主要適用於單一窄波束之設計，僅能控制訊號之反射方向，難以對波束寬度、旁波瓣位準等細部性能指標進行精細調控，亦無法直接合成多波束 (Multi-Beam)、形狀波束 (Shaped Beam) 等複雜之客製化輻射場型。為突破此一限制，過往研究多在理論公式之基礎上引入數學最佳化方法，例如藉由疊加原理 (Principle of Superposition) 實現多波束合成，或透過反向投影法 (Back-Projection) 將遠場場型視為孔徑電流分布之傅立葉轉換而反推所需之相位分布。

然而，當設計規格涉及嚴苛之旁波瓣抑制或非對稱多波束需求時，上述目標函數呈現高度非線性且對參數變動極為敏感，使得相位解之精確搜尋成為運算成本高昂之非凸最佳化問題。隨著人工智慧技術之蓬勃發展，研究者陸續將神經網

路方法導入高維度、非線性與離散化之相位設計問題中，以期克服傳統解析法在合成多重限制條件下輻射場型時所遭遇之技術瓶頸。

本節將回顧相位分布設計之相關文獻，2.2.1 節介紹以啟發式演算法執行最佳化迭代之研究，2.2.2 節介紹以卷積神經網路進行反向設計之方法，2.2.3 節則綜整兩類方法之優缺點，並歸納其對本研究之啟發。

2.2.1 啟發式演算法

啟發式演算法 (Metaheuristic Algorithms) 為一類針對複雜最佳化問題所設計之搜尋策略，其核心理念在於模擬自然現象、物理規律或生物演化機制，於可接受之時間成本內逼近目標問題之最佳解。相較於傳統解析法，此類演算法不依賴目標函數之具體數學性質 (如連續性或可微性)，因而特別適合處理電磁面鏡設計中常見之高維度、非線性與離散化搜尋空間。在各類啟發式方法中，演化演算法 (Evolutionary Algorithms) 具備代表性，其透過族群初始化、適應度評估、基因重組、突變以及天擇等仿生機制，驅動候選解逐步收斂至全域最佳解。在相位分布設計之應用上，演算法將每一相位單元視為一可操控之個體，藉由迭代擾動與適應度評估，最終產出符合特定輻射場型需求之相位矩陣。

在相關研究中，Chen 與 Lin 提出以灰狼最佳化演算法 (Grey Wolf Optimizer, GWO) 設計 35×35 單元之毫米波寬波束反射面 [8]；該演算法模擬灰狼族群之社會階級與協同狩獵行為，透過 α 、 β 、 δ 三類引導狼於搜尋空間中進行全域探索，展現出良好之收斂穩定性與較低之超參數敏感度。針對多波束合成，Meng 等人引入人工蜂群演算法 (Artificial Bee Colony, ABC)，藉由模擬蜜蜂尋找蜜源之協作行為對相位進行迭代擾動，成功合成指向精準且增益優異之多波束輻射場型 [9]。Teng 等人則提出兩階段迭代最佳化框架 [10]，首先運用疊加與分割原理生成場型雛型，隨後導入迭代演算法對量化後之相位值進行精細最佳化，藉以實現任意波束之高精度合成。

儘管啟發式演算法於波形合成上展現極高之靈活性與精確度，惟其核心運算機制依賴大量族群迭代與重複之適應度函數評估，且每一回合皆需重新執行陣列

因子等高複雜度之電磁運算，導致整體運算時間成本居高不下。此一高推論延遲特性，使啟發式演算法難以滿足 6G 通訊環境中毫秒等級之動態波束追蹤需求，進而促使研究者轉向具備即時推論能力之深度學習方法。

2.2.2 卷積神經網路

卷積神經網路 (Convolutional Neural Network, CNN) 為一類專為處理二維矩陣或影像資料所設計之深度學習架構。其核心機制在於透過卷積層 (Convolutional Layer) 對輸入資料進行局部特徵擷取，進而學習資料於二維空間中之結構性特徵；典型 CNN 由卷積層、池化層 (Pooling Layer) 以及負責分類或回歸輸出之全連接層 (Fully Connected Layer) 組成。於電磁面鏡相位分布設計之應用中，CNN 將相位分布視為具備空間結構規律之二維圖案，透過訓練學習目標輻射場型與相位矩陣之間的非線性映射。相較於啟發式演算法，CNN 之主要優勢在於極高之推論效率，模型訓練完成後，僅需執行單次前向傳播 (Forward Propagation) 即可於毫秒等級內輸出結果，顯著提升即時生成之可行性。

於相關文獻中，Shan 等人提出基於 VGG 架構之深層卷積神經網路 [11]，針對 48×48 單元之 1-bit 可編程超表面進行相位預測；該研究分別以反向投影法生成單波束訓練資料、以遺傳演算法生成雙波束訓練資料，模型於毫秒等級之推論時間內達到平均超過 94% 之預測準確率，驗證了 CNN 應用於相位分布逆向設計之可行性。Cui 等人則採用自編碼器 (Autoencoder) 架構 [12]，以包含振幅與相位資訊之遠場陣列序列作為輸入，並透過預訓練之解碼器扮演陣列分析器之角色，配合上、下遮罩 (Upper/Lower Mask) 約束以限制主波束與旁波瓣之輻射範圍，進而生成符合客製化場型需求之相位分布；實驗結果顯示，該方法之推論時間遠低於傳統迭代最佳化方法，且輻射場型品質亦獲提升。

本研究團隊亦於過往工作中持續探索陣列天線之逆向相位設計，並針對不同通訊情境提出多種神經網路架構。Li 等人針對電磁面鏡之物理特性，改良影像生成領域常用之生成對抗網路 (Generative Adversarial Network, GAN) 架構 [13]；該研究將電磁面鏡之設計轉化為影像生成問題，將面鏡單元視為灰階像素，並於

生成器中引入全連接層與自注意力機制 (Self-Attention) 以提升模型自由度並捕捉單元間之耦合效應，並透過插值升解析度結合殘差網路 (Residual Network) 強化細節預測，實驗結果顯示其單元尺寸預測準確度於多項性能指標上皆優於傳統設計方法。隨後，本團隊將研究範疇延伸至可重構智慧面 (RIS)。翁士勛提出基於卷積自編碼器 (CNN-based Autoencoder) 之設計框架 [14]，以相位分布與輻射場型波形作為共同輸入，利用編碼器執行特徵擷取、解碼器負責資料重建，於 10×10 RIS 陣列上實現 97.5% 之預測準確率。王騰緯則採用全連接網路架構 [15]，以陣列因子公式所合成之資料集搭配遷移學習 (Transfer Learning) 策略，強化模型於多種波束寬度需求下之泛化能力；該研究運用灰狼最佳化演算法預先生成寬波束樣本，引導模型學習更複雜之波束映射，並以陣列因子公式回推驗證其相位之物理可靠性。

承上所述之純卷積神經網路反向設計多以單次前向傳播直接生成相位分布，另有一類研究則嘗試將卷積神經網路與迭代搜尋結合，以兼顧設計品質與運算效率。Keşir 等人提出一種卷積神經網路輔助之分組迭代法 [16]，針對可重構智慧面之相位分布最佳化問題，先以僅需橫向與縱向各掃描一次之分組迭代法分別求得水平與垂直方向之組態，再將此兩組態作為輸入送入一個事先訓練完成之卷積神經網路，由網路直接生成最終之相位分布。該方法之關鍵在於以神經網路取代傳統逐單元迭代中最耗時的組合搜尋過程，使原本需要單元總數次迭代之逐元素迭代法，縮減為僅需橫向與縱向單元數相加之迭代次數。其模擬結果顯示，於 40×40 單元之可重構智慧面上，所需之搜尋步數可由 3200 步大幅降低至 160 步，且此一複雜度之顯著下降僅伴隨輕微之效能衰減。然而此類混合式方法雖能藉由神經網路加速設計流程，其整體架構仍保留迭代搜尋之環節，且每一次迭代皆須仰賴接收端之效能回饋，使其於本質上仍受限於迭代框架而難以達成真正之毫秒等級即時生成，此一限制亦為後續 2.3 節所欲突破之核心議題。

2.2.3 人工智慧生成方法比較

綜合 2.2.1 與 2.2.2 之文獻探討可知，啟發式演算法與卷積神經網路於電磁

面鏡相位分布設計上各具優勢，兩者於設計品質與運算效率之間存在根本性之取捨。就設計品質而言，啟發式演算法憑藉其全域搜尋能力，可對相位進行直接且反覆之迭代微調，並於每輪迭代透過適應度函數嚴謹評估，使輸出結果趨近物理意義上之最佳解，亦能合成複雜且精準之輻射場型。卷積神經網路雖具備強大之特徵映射能力，惟於處理訓練集中未曾出現之極端規格或高度複雜之多波束組合時，仍可能因陷入局部最佳解而導致生成品質略遜於啟發式演算法之精細迭代結果。然而，於運算效率與即時性方面，兩者呈現截然不同之特性，啟發式演算法因依賴大量個體評估與重複適應度計算，收斂速度緩慢，生成時間通常落於秒級乃至分鐘級，難以滿足 6G 通訊場景中毫秒等級動態波束切換之需求；卷積神經網路於訓練完成後，僅需執行單次前向傳播即可於毫秒等級內輸出結果，具備部署至邊緣運算裝置之潛力，從而滿足真實通訊環境中之即時控制需求。

表 2-1 不同人工智慧生成方法之比較

文獻	方法	目的	優點	缺點
[8],[9],[10]	啟發式演算法	透過不斷擾動相位並代入適應度函數計算分數，直至迭代回合結束	結果趨近於最佳解、能夠合成複雜的波型	收斂時間慢、無法即時設計
[11],[12],[13],[14],[15]	卷積神經網路	將相位分布視為圖案，從中學習其規律	推論速度快、具備即時響應能力，適合邊緣裝置部署	需要龐大的資料集、無法生成過於複雜的波型
[16]	混合式方法 (CNN+啟發式)	以 CNN 生成高品質初始解，再透過啟發式演算法跳脫局部最佳解	結合兩種方法的優點，將設計流程加速	但仍因啟發式演算法的流程而無法真正即時設計

根據表 2-1 之分析，啟發式演算法因其追求最佳解之特性，適合應用於靜態環境下之高精度場型設計，或作為生成高品質訓練資料集之輔助工具；卷積神經網路則憑藉極短之推論延遲與對非線性映射之強大擬合能力，成為動態波束追

蹤與即時通訊環境之首選方案。現有混合式方法雖能於一定程度上提升設計品質，惟仍因保留迭代最佳化框架而犧牲即時性，難以真正解決毫秒等級動態響應之需求。有鑑於此，本研究選擇以神經網路方法作為主要設計路徑，並輔以物理引導之訓練策略，以期於維持即時生成能力之同時，兼顧高品質輻射場型之設計需求。

2.3 深度神經網路於相位分布的即時設計

深度神經網路 (Deep Neural Networks, DNN) 憑藉其強大之非線性擬合能力，可將相位設計之複雜最佳化問題轉化為模型權重之映射學習任務。於推論 (Inference) 階段，模型僅需執行前向傳播即可於毫秒等級內生成對應之相位分布，符合 6G 通訊對高動態波束成形與極低延遲之要求。

依據訓練機制之差異，深度學習設計路徑可區分為監督式學習與非監督式學習兩類。監督式學習 (Supervised Learning) 以輸入資料與對應之標籤 (Label) 進行訓練，透過最小化預測結果與真實標籤 (Ground Truth) 之間之損失，使模型習得輸入與輸出之間之統計規律。非監督式學習 (Unsupervised Learning) 則不依賴預先標記之真實值資料，而是藉由資料內部之統計特性或物理約束條件 (如自定義之損失函數) 引導神經網路自主習得資料特徵並達成最佳化目標。本節將分別就上述兩類學習機制於相位分布即時設計中之應用進行文獻回顧。

2.3.1 監督式學習

於即時相位分布設計之研究中，監督式學習主要透過建構從波束規格至相位分布之直接映射模型，使網路於訓練完成後可於毫秒等級內生成符合需求之相位分布。依據輸入特徵之差異，現有監督式學習方法可大致分為兩類，其一係以角度規格作為輸入，模型直接學習角度條件與相位分布之映射；其二係以目標波束場型作為輸入，模型藉由場型反推所需之相位分布。

至於以角度規格作為輸入之方法，Wang 等人針對 RIS 輔助多用戶 MIMO (Multiple-input Multiple-output) 系統提出一種基於模型驅動神經網路之相位設計方法 [17]。該研究將入射角與反射角分別以 one-hot 編碼方式作為網路之輸入

條件，使單一模型可於不同角度組合下統一生成 RIS 之相位向量，從而避免傳統最佳化方法於每一角度組合下重新求解之高昂運算成本。為兼顧硬體實作之可行性，該方法進一步引入貪婪搜尋 (Greedy Search) 機制以處理離散化相位限制，並於多波束場型合成與旁波瓣抑制 (Reradiation Mask Constraints) 兩項目標下展現良好效能；模擬結果顯示，於僅採用 4 階離散相位之情況下，模型推論速度顯著優於傳統交替最佳化方法，且其波束成形增益僅有微幅衰減，驗證了監督式學習於即時、多波束、離散相位設計上之可行性。

至於以目標波束場型作為輸入之方法，Zhang 等人提出一套以目標波束場型為輸入之監督式學習框架 [18]，採用輕量化編碼器與解碼器結構執行相位設計，編碼器負責將高維之波束場型壓縮為低維特徵向量，解碼器則於滿足硬體限制之條件下重建對應之相位向量。為克服訓練過程中因通道資訊有限所致之收斂困難，該研究進一步提出兩階段訓練策略，首先以輔助模組於離線階段預訓練編碼器以提取穩健之場型特徵，隨後於線上階段訓練解碼器，並設計同時涵蓋主波束形狀對齊與旁波瓣抑制之複合損失函數，使模型生成之相位向量於合成場型上能精準逼近目標規格。

針對運算資源受限之終端裝置，Zhang 等人進一步提出結合自編碼器網路 (Autoencoder Network) 與知識蒸餾 (Knowledge Distillation) 之輕量化即時相位設計方法 [19]。該研究先以陣列因子先驗知識 (Prior Knowledge of Array Factor) 引導之 Inception-ResNet-V2 模型 (IR-PK) 作為高精度教師網路，負責由目標波束場型回推大規模相位分布；隨後透過知識蒸餾將教師網路之知識轉移至基於 MobileNet 之輕量化學生網路 (MD-IR-PK)，於波束合成與全息 (Hologram) 兩類任務上皆能維持精度，同時顯著降低邊緣裝置之計算負擔。

從以上相關研究可以發現，監督式學習能夠實現毫秒等級之即時相位設計，惟其性能高度仰賴訓練資料之品質與覆蓋範圍。一旦實際應用情境涉及訓練資料中未曾出現之角度組合，或需面對極為複雜之多波束場型合成，模型將難以有效外推至訓練分布之外，進而無法生成符合使用者期望之客製化相位分布。再者，

標籤資料之取得通常需事前透過最佳化演算法或全波模擬大量生成，使整體資料準備之時間成本與運算開銷成為該方法之重要瓶頸。基於上述限制，本研究團隊近年逐漸將研究方向轉向非監督式學習，藉由將電磁理論直接嵌入損失函數以擺脫對標籤資料之依賴，相關進展將於下一節詳細探討。

2.3.2 非監督式學習

非監督式學習在相位分布設計中，係以模型自主學習物理規律的方式取代對標記資料的依賴，其作法為將陣列因子等電磁理論公式直接嵌入損失函數 (Loss Function) 之中，使模型在訓練過程中演化出最佳相位分布。這種方法從根本上擺脫了繁瑣的資料標記過程，具備更高的設計靈活性與泛化潛力，尤其適合應對難以預先建立完整資料集的客製化場型需求。

在本研究團隊的既有工作中，曾俊瑋提出一種基於非監督式學習的電磁面鏡相位生成方法 [20]，以陣列因子公式建構物理引導損失函數，引導模型自主學習不同角度規格下的相位分布，無需依賴大量預生成之標籤資料。此外，蔡奇倫則延續曾俊瑋的研究架構，進一步針對二值化量化過程中的梯度估計問題，提出基於位元遷移策略的相位生成方法 [21]，有效緩解二值化操作在反向傳播中的梯度消失問題，提升了非監督式學習在量化相位設計中的訓練穩定性。除上述監督式與非監督式學習路徑外，本團隊另有研究嘗試以強化學習 (Reinforcement Learning) 之框架處理可重構智慧面之相位組態問題。Chen 等人提出一套動態深度強化學習引導之 RIS 控制方法 [28]，使代理人於與環境互動之過程中，依即時通道與使用者狀態學習最適之相位組態，並進一步將單元故障納入考量，於多使用者通訊場景下維持穩健之傳輸效能。此類方法之優勢在於能依環境回饋自適應地調整相位策略，惟其決策過程須經大量試誤與反覆之環境互動，單一相位組態之生成往往耗時達數分鐘，與監督式及非監督式學習於推論階段之毫秒等級生成相比仍有顯著差距，難以滿足 6G 通訊所要求之即時動態波束切換需求。

然而，非監督式學習的主要技術瓶頸在於物理損失函數通常具備高度非凸性 (Non-convexity)，使得訓練過程中的收斂穩定性與最終場型精確度的控制較為困

難，尤其在面對複雜多波束的客製化需求時，模型容易陷入局部最佳解，導致輻射場型品質不穩定。如何在保持無標籤訓練靈活性的同時，有效引導模型穩定收斂至高品質解，是此研究路徑仍待克服的核心挑戰。

2.4 二值化相位分布量化探討

於實際電磁面鏡之硬體實現中，為控制硬體成本與整體系統功耗，大規模 RIS 設計普遍傾向採用低位元 (Low-bit) 之離散相位量化。以 1-bit 量化為例，每一單元僅能呈現 0° 與 180° 兩種相位狀態；以 2-bit 量化為例，則可呈現 0° 、 90° 、 180° 、 270° 四種狀態。此種離散化雖大幅降低硬體複雜度與控制成本，卻不可避免地引入量化誤差，造成實際輻射場型與理想連續相位設計之間之效能落差，具體表現為主波束增益下降、旁波瓣位準上升，以及由於相位誤差之週期性所引致之量化波瓣 (Quantization Lobe, Grating Lobe)；此一波瓣於 1-bit 量化下尤為明顯，將形成位於與目標反射方向對稱方位之鏡像波束，成為硬體實作上不可忽視之效能瓶頸。針對二值化所致之效能衰減問題，本研究團隊與外部研究分別自軟體訓練策略與硬體架構設計兩個層面提出解決方案，以下分別回顧其代表性方法。

於軟體訓練策略方面，曾俊瑋提出以閾值設定 (Threshold-Based Quantization) 作為基礎之二值化方案 [20]，於模型推論階段直接以固定閾值將連續相位輸出映射至 1-bit 之離散狀態。該方法之優勢在於實作簡易、無須調整訓練流程，惟其硬性二值化過程未納入訓練反饋，致使模型輸出於量化後出現顯著效能衰減。為緩解此一問題，蔡奇倫進一步提出基於位元遷移 (Bit Migration) 之相位生成策略 [21]，將量化層直接整合至訓練流程之中，使模型於訓練階段即同步學習二值化之生成過程；透過漸進式之位元遷移機制，模型可於反向傳播中獲得有效梯度，顯著降低二值化所造成之效能衰減，並提升整體訓練之完整性。然而，該方法於面對多種複雜規格之同步訓練時，初始收斂速度仍相對緩慢。

於硬體架構設計方面，Shekhawat 等人提出隨機預編碼相位 (Pseudo-

Random Phase Pre-Coded RIS, P3RIS) 方法，以物理層面之單元設計直接破壞 1-bit 量化所致之週期性誤差 [22]。其核心概念為，於每一單元之內嵌饋線 (Inset Feed) 上引入固定但隨機之相位延遲，使原本因規律量化誤差所累積形成之量化波瓣於空間中相互抵消，進而抑制鏡像波束。該團隊以此原理設計毫米波頻段之 32×32 單元 1-bit RIS 原型，於 27.2 GHz 中心頻率下實測達成超過 10 dB 之量化波瓣抑制效果，並於 $\pm 60^\circ$ 範圍內維持高解析度之波束導向能力。此一隨機預編碼相位技術之理論基礎則由 Kashyap 等人奠定 [23]；該研究針對 1-bit 可重構反射面 (Reconfigurable Reflective Surface, RRS) 系統性地分析隨機相位延遲對量化誤差週期性之破壞機制，首次提出選擇隨機化範圍以達成最低旁波瓣位準之條件，並以 222.5 GHz 之 30×30 單元原型驗證其有效性，為後續 P3RIS 之硬體實作提供完整之依據。

綜合上述，二值化相位設計之效能衰減問題可分別由訓練流程之改良 (如位元遷移) 與硬體單元之設計 (如隨機預編碼相位) 兩面向著手，前者於模型訓練階段主動引導網路學習量化後之最佳分布，後者則自物理層面消除量化誤差之週期性。本研究於設計訓練策略時，將二值化操作整合至損失函數之計算流程之中，並針對不同角度組合設計自定義之物理約束損失，期能於維持即時推論能力之同時，有效克服二值化過程所產生之效能衰減，詳細方法將於第三章闡述。

2.5 問題定義與總結

綜合 2.1 至 2.4 節之文獻回顧，本節進一步歸納現有相位分布設計方法於即時生成需求下所共同面臨之核心技術瓶頸，並據此精確定義本研究欲解決之問題，俾與第四章所規劃之實驗設計相互對應。

第一項問題為設計靈活性不足。由 2.2 與 2.3 節之文獻可知，無論啟發式演算法或既有之深度學習方法，其相位分布之生成多針對固定之入射反射角規格進行設計與訓練，一旦設計需求超出原訓練分布，模型即難以泛化至新角度組合。然而於 6G 通訊場景中，終端使用者位置持續變動，系統須依使用者之即時方位

動態切換波束指向，固定規格之單一模型顯然無法滿足此一需求。除單波束之角度泛化外，多使用者場景更要求單一面鏡能同時將訊號導向多個方向，亦即須合成雙波束乃至多波束之複雜輻射場型，此對模型於單一權重內承載大量規格映射之能力提出更高之要求。

第二項問題為即時性受限。2.2.1 節所回顧之啟發式演算法雖能合成高品質之輻射場型，惟其依賴大量族群迭代與重複之適應度評估，單次相位設計之耗時通常落於秒級乃至分鐘級，而 2.2.2 節之混合式方法雖能藉由神經網路提供高品質初始解以縮短迭代次數，其整體流程仍受限於迭代框架，難以真正達成 6G 通訊所要求之毫秒等級動態波束切換。因此本研究所需之生成方法，應能以單次前向傳播於毫秒等級內完成相位分布之輸出，並具備部署至運算資源受限之邊緣裝置之輕量化潛力。

第三項問題為高自由度規格與離散量化所致之訓練困難。本研究採用 1-bit 量化以對應實際硬體之低位元限制，此一二值化操作使相位成為離散變數，致使物理損失函數呈現高度非凸之特性，量化所引入之誤差亦會於訓練初期形成鏡像波束而干擾收斂。甚至當訓練規格由單波束擴展至多波束時，角度組合之數量與離散搜尋空間隨之急遽膨脹，模型於訓練後期極易停滯於部分區域已達標而其餘區域仍有偏差之局部最佳解，此現象於四波束等高自由度場景尤為明顯。換言之，單純依賴梯度下降之訓練流程，難以同時克服二值化所致之非凸性與龐大規格所致之搜尋困難，因此本研究須引入一套能突破此一收斂瓶頸之訓練機制，使模型於離散且龐大之解空間中仍能穩定收斂至高品質之相位分布。

第四項問題為邊緣裝置部署之經驗不足與驗證情境之失真。現有深度學習方法多於高運算資源之 GPU 伺服器上完成訓練與驗證，鮮少針對邊緣運算平台進行模型部署與即時推論之實測，同時過往研究於電磁模擬中多沿用陣列因子公式所預設之無窮遠遠場假設，未依實際硬體之收發距離設定，導致模擬情境與真實部署之近場環境存在落差，使模擬結果未必能反映硬體實作時之效能表現。

基於上述四項核心問題，本研究欲解決之研究問題可定義如下。第一為設計

一套以入射角與反射角組合作為動態輸入之深度學習相位生成模型，使其能於單一模型內支援多種角度規格之即時生成而無須針對個別規格重新訓練，並能進一步合成複雜之多波束場型。第二為使模型能以單次前向傳播於毫秒等級內完成相位分布之推論輸出，並具備部署至邊緣運算裝置之輕量化潛力。第三為設計一套有效之訓練機制，於將二值化操作整合至訓練流程之物理約束損失之同時，克服離散量化與龐大多波束規格所共同造成之收斂瓶頸，使模型於高自由度場景下仍能穩定逼近高品質之相位分布。第四為將模型實際部署至邊緣運算裝置以驗證其即時推論能力，並依實際 RIS 硬體之設計參數，於電磁模擬中採用收發距離有限之近場條件進行場型驗證，使驗證情境貼近真實部署環境。上述四項問題與第四章五項實驗之對應關係為，第一項設計靈活性由實驗一之單波束生成與實驗三之多波束生成共同驗證，第二項即時性由實驗四之邊緣裝置推論時間量測加以驗證，第三項訓練困難由實驗二之啟發式神經網路混合訓練機制加以解決，並以其對損失收斂之改善程度作為驗證依據，第四項配合實際環境則由實驗四之邊緣部署實測與實驗五之近場電磁模擬驗證共同完成，其中實驗五並一併確認二值化量化所致之鏡像波束於貼近真實硬體之環境下確保獲得抑制。

表 2-2 當前問題與預計改進方法

問題	方法
設計靈活性不足	引入線性特徵調變並修改模型架構使其同步學習多種輸入條件
即時性受限	以深度神經網路作為主要的生成框架，透過單次前向傳播完成相位生成
多規格量化訓練困難	於訓練階段加入量化方法與隨機相位預編碼遮罩，並引入啟發式神經網路混合訓練機制來解決
設計與驗證未貼近真實環境	將模型部署於邊緣裝置進行即時推論並依實際硬體設計參數以電磁模擬軟體驗證

針對表 2-2 所提出之問題，本研究提出名為條件式生成器 (Condition-Based Generator) 之模型，於模型輸入端引入入射與反射角組合，並於網路架構中導入 FiLM 機制，使單一模型可同步學習多種動態角度規格下之相位映射關係，於訓練流程中以陣列因子公式作為物理引導損失函數，並結合二值化量化層與隨機相位預編碼遮罩以同步學習離散相位生成並抑制鏡像波束，針對多波束高自由度場景所面臨之收斂瓶頸，另引入啟發式神經網路混合訓練機制，於訓練過程中結合鄰域搜尋以突破局部最佳解，最終將模型部署至 NVIDIA Jetson AGX Orin 邊緣運算裝置以驗證其即時推論能力，並依實際 RIS 硬體之設計參數，於電磁模擬軟體中採用近場收發距離進行場型驗證。至於模型之詳細架構、訓練策略與驗證流程將於第三章完整闡述。

第三章 研究方法

延續第二章對相位分布設計現況之分析，本章針對 2.5 節所歸納之四項核心問題提出對應之解決方案。其一為設計靈活性不足，既有深度學習方法多針對固定之入射反射角規格進行訓練，難以應對 6G 通訊場景中動態變動之終端使用者方位需求。其二為即時性受限，啟發式演算法雖能合成高品質之輻射場型，惟其依賴大量族群迭代，單次相位設計之耗時通常落於秒級乃至分鐘級，難以滿足毫秒等級之動態波束切換需求。其三為高自由度規格與離散量化所致之訓練困難，實際 RIS 出於硬體成本考量普遍採用 1-bit 量化，此一離散化使相位成為離散變數並令物理損失函數高度非凸，而當訓練規格由單波束擴展至多波束時，龐大之離散搜尋空間更使模型於訓練後期容易陷入局部最佳解，難以穩定收斂至高品質之相位分布。其四為邊緣裝置部署之不足與驗證情境之失真，既有研究多停留於高運算資源之 GPU 伺服器上完成驗證，鮮少針對邊緣運算平台進行輕量化部署與即時推論之實測；且於電磁模擬中多沿用無窮遠之遠場假設，未依實際硬體之收發距離設定，使模擬情境與真實部署之近場環境存在落差。

為系統性處理上述問題，本研究提出名為條件式生成器 (Condition-Based Generator) 之即時相位分布生成框架，於模型架構、訓練機制與物理約束三個層面同步進行設計，各項設計與所欲解決之核心問題之對應關係如表 3-1 所示。

表 3-1 核心問題與本研究對應之解決方案

問題	方法
設計靈活性不足	條件式生成器架構，以入射角與反射角組合作為動態輸入，並透過特徵線性調變機制使單一模型大量學習
即時性受限	以深度神經網路作為主要的生成框架，並以單次前向傳播完成相位生成
多規格量化訓練困難	將 Gumbel-Sigmoid 量化與 P3RIS 機制整合於訓練流程中，並引入啟發式神經網路混合訓練機制
設計與驗證未貼近真實環境	將訓練完成之模型部署至 NVIDIA Jetson AGX Orin 邊緣運算裝置進行即時推論，並依實際硬體設計之近場收發距離，以電磁模擬軟體進行場型驗證

本章編排如下，3.1 節說明整體研究架構與三階段流程，3.2 節介紹本研究所建構之條件式生成器，3.3 節闡述如何將二值化量化機制與隨機相位預編碼遮罩整合至模型，3.4 節針對模型性能與訓練穩定性兩面向提出改善方案，3.5 節說明本研究所採用之模型驗證方法與性能評估指標，最後 3.6 節介紹模型部署於邊緣運算裝置之即時推論方法，涵蓋部署環境設定與整體推論流程。

3.1 研究架構

圖 3-1 呈現本研究所提出之整體流程，涵蓋模型建構、模型改善及模型驗證三個階段，各階段於本章後續節次中將分別深入闡述。

於模型建構階段，本研究承接曾俊瑋 [20] 所建立之非監督式自編碼器架構，保留以陣列因子 (Array Factor) 公式作為輻射場型計算層之設計理念，使整體訓練流程毋需任何標籤資料即可進行。為解決過往研究單一規格訓練之限制，本研究將原架構中固定形式之輸入改寫為以入射角與反射角組合所構成之條件向量，並於生成器內部各層引入特徵線性調變 (Feature-wise Linear Modulation, FiLM) 機制，使模型於同一組權重下即可承載大量角度規格之相位映射關係。生成器最終輸出端則整合 Gumbel-Sigmoid 量化機制以對應 1-bit 硬體限制，並參考 Shekhawat 等人 [22] 於硬體層所提出之 P3RIS 設計理念，於量化前疊加固定隨機之相位預編碼遮罩，藉此於軟體層破壞鏡像波束之週期性。

於模型改善階段，本研究分別自性能與穩定性兩面向強化模型表現。性能面向上，針對多波束場景之特殊需求重新設計物理引導損失函數，並透過導向矩陣預計算機制大幅縮短訓練迴圈中之物理層運算時間。穩定性面向上，本研究引入啟發式神經網路混合訓練機制，於每一訓練步驟中先以神經網路進行前向預測，再於該預測結果之鄰域內執行貪婪式相位翻轉搜尋，並將搜尋所得之優於 AI 自身輸出之解透過引導式損失回饋至模型權重之更新，使整體訓練得以持續突破局部最佳解所造成之收斂瓶頸。

於模型驗證階段，訓練完成之模型所生成之相位分布將輸入陣列因子公式以

產生對應之輻射場型，並依預先設定之容忍區間判定主波束反射角度、半功率波束寬與旁波瓣位準等關鍵指標是否符合客製化規格之需求。除陣列因子公式之快速驗證外，本研究另依實際 RIS 硬體之設計參數，於 Ansys HFSS 電磁模擬中採用收發距離有限之近場條件進行場型驗證，藉以納入單元耦合等實際物理效應，使驗證結果更貼近真實硬體之表現。此外，模型亦部署於 NVIDIA Jetson AGX Orin 邊緣運算裝置，以實際量測其於資源受限環境下之單次推論時間，驗證即時生成能力之可行性。上述陣列因子公式與電磁模擬構成場型品質之雙重驗證，邊緣裝置之推論時間量測則對應即時性之驗證。




圖 3-1 方法架構圖

3.2 相位分布設計流程

本節說明本研究相位分布設計之完整流程，如圖 3-2 所示，其核心在於以使用者定義之角度條件取代過往以陣列因子作為輸入之固定設計，使單一模型可動態處理多種規格而毋需重新訓練；就方法論而言屬反向設計 (inverse design)，即以目標規格的入射角與反射角組合做為輸入，反推出對應之相位分布，條件式生成器接收角度條件向量後即直接生成 1-bit 相位分布，毋須傳統迭代逼近，此為本方法達成毫秒級即時生成之根本原因。學習模式上承接曾俊瑋 [20] 之非監

督式架構，以陣列因子作為輻射場型計算層，訓練毋需相位標籤，透過物理訊號引導模型自行學習其規律。而量化整合上採單階段端到端架構，與蔡奇倫 [21] 之兩階段設計形成對比，其做法先訓練連續相位並凍結權重、再於其上訓練二值化相位，流程繁瑣且前階段權重成為硬性約束；本研究則將量化機制整合至同一訓練流程，使生成器與量化層同步學習量化誤差，於大規模多規格輸入下訓練更穩定。也正因二者於梯度層面高度耦合而難以獨立抽換，其必要性體現於流程之不可分割，缺少條件式生成器即失去多規格映射能力，缺少量化整合則回歸訓練後硬性量化之顯著效能衰減 [20]。而圖 3-2 的整體資料流依序為，角度條件向量經條件式生成器映射為 $N \times N$ 邏輯特徵圖，此時模型將會輸出連續相位分布，尚未離散化；接著透過 P3RIS 方法於其上疊加隨機相位預編碼遮罩得擾動後之連續相位分布，此步驟發生於量化之前，作用對象為連續數值而非已二值化之相位；最後才送入 Gumbel-Sigmoid 量化層轉為 1-bit 相位分布。其後相位分布送入物理層轉為輻射場型，與目標規格比較以計算物理引導損失並反向傳播更新參數。

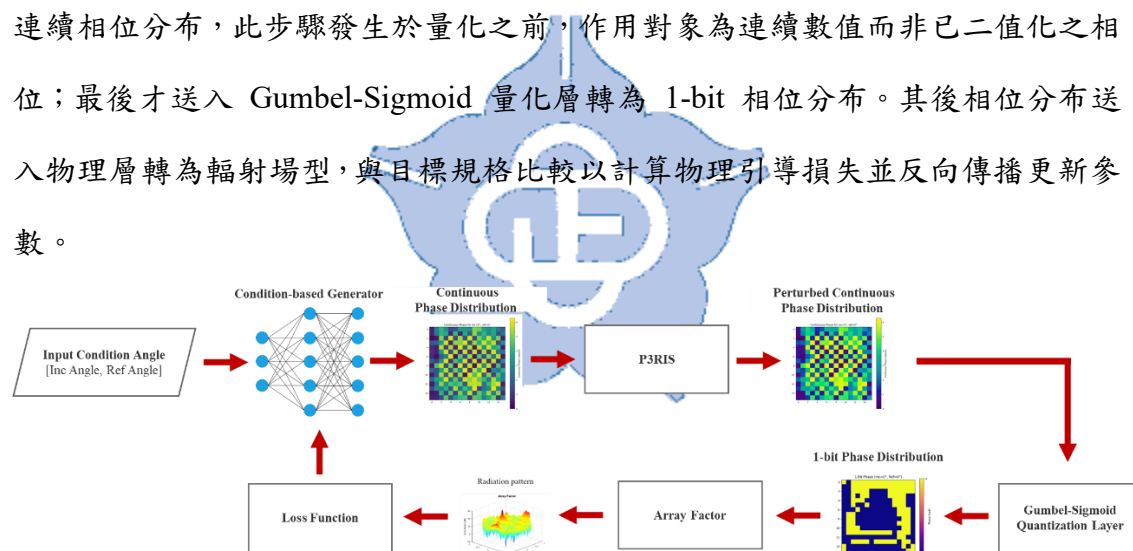


圖 3-2 相位分布生成設計流程圖

3.3 模型架構

3.2 節已說明本研究相位分布設計之整體流程，本節起自模型建構階段，逐步說明條件式生成器之具體設計。

條件式生成器之具體架構如圖 3-3 所示，可拆解為三個主要模組，分別為初始投影模組、上採樣模組與輸出層。生成器之輸出維度視 RIS 規格動態調整，本研究主要驗證 16×16 與 32×32 兩種尺寸。以下三個小節將依序說明三個

模組之設計動機與具體運作。




圖 3-3 條件式生成器架構圖

3.3.1 角度條件編碼

模型輸入之角度條件向量用於告知生成器當前之設計需求，亦即於哪一個入射角下，應將反射波束導向何處。角度條件向量之維度將依場景需求動態調整，在單波束情境下僅需一組入射角與反射角資訊，而 K 波束情境下則需同時指定 K 個反射角方向。於單波束情境，角度條件向量定義如公式 (3) 所示，其中 c_{inc} 、 c_{ref} 分別代表入射角與反射角之正規化值。為使輸入數值落於相近之數量級，本研究將原始角度依各自之最大支援角度進行縮放，如公式 (4) 所示，其中 θ_{inc} 為入射角(以度為單位，且本研究支援之範圍為 0° 至 50°)， θ_{ref} 為反射角 (支援範圍為 -60° 至 60°)。經此正規化後， c_{inc} 、 c_{ref} 兩者皆落於 $[-1, 1]$ 區間。例如當入射角 $\theta_{inc} = 30^\circ$ 、反射角 $\theta_{ref} = -45^\circ$ 時，角度條件向量為 $c = [0.6, -0.75]$ 。

而對於 K 波束也就是多波束的情境，角度條件向量定義擴展為公式 (5) 所示，向量中包含一個入射角分量與 K 個反射角分量。各反射角依公式 (6) 進行正規化，其中 $\theta_{ref,i}$ 為第 i 個目標反射角之角度值，分母選用 90° 以確保所有反射角皆能於 $[-1, 1]$ 區間內表達。本研究於四波束情境下採用之 $K = 4$ ，其角度條件向量維度為 5。

值得說明的是，將具不同物理意義之角度數值統一映射至 $[-1, 1]$ 區間，主要目的有兩個，第一個是深度神經網路之權重於初始化時通常假設輸入數值落

於相近之數量級，若入射角與反射角直接以原始度數輸入，將致使梯度更新於不同維度之間呈現極度不平衡之現象；第二個為正規化後之輸入有助於 FiLM 機制（將於 3.2.3 節介紹）依條件動態調整特徵圖時，各角度分量對網路內部特徵之影響力得以維持平衡。

$$c = [c_{inc}, c_{ref}] \in \mathbb{R}^2 \quad (3)$$

$$c_{inc} = \frac{\theta_{inc}}{50^\circ}, c_{ref} = \frac{\theta_{ref}}{60^\circ} \quad (4)$$

$$c = [c_{inc}, c_{ref,1}, c_{ref,2}, \dots, c_{ref,K}] \in \mathbb{R}^{K+1} \quad (5)$$

$$c_{ref,i} = \frac{\theta_{ref,i}}{90^\circ} \quad (6)$$

3.3.2 初始投影模組

於 3.2.1 節之角度條件向量可知，該向量維度極低如單波束情境下僅 2 維、四波束情境下也僅 5 維，然而生成器所需操作之特徵圖卻高達 $4 \times 4 \times 512 = 8192$ 維。因此直接以單一全連接層完成此一維度上升映射存在兩項主要缺陷，第一個是參數初始化時權重分布過於分散，易致訓練初期梯度不穩定；第二個是單層線性映射無法對少量輸入數值進行充分之非線性混合，使得不同角度規格於初始特徵中之區別性不足。

為緩解上述問題，本研究採用三層多層感知器 (Multi-Layer Perceptron, MLP) 進行漸進式升維，其架構流程可表示為如圖 3-4 所示；該流程中，角度條件向量 c 首先經由第一個全連接層 FC_1 升維至 256 維中間表示 h_1 ，通過 LeakyReLU 激活後，再經第二個全連接層升維至 512 維表示 h_2 ，最後經第三個全連接層映射至 8192 維之 h_3 。最終輸出 h_3 將被重塑 (reshape) 為 $4 \times 4 \times 512$ 之三維特徵圖，作為後續上採樣模組之初始輸入。

各全連接層之間皆置入 LeakyReLU 激活函數而非標準 ReLU，其原因在於標準 ReLU 於負值區域之梯度為零，當訓練初期某些神經元落入負值區域時，將永久失去更新能力；而 LeakyReLU 於負值區域保留一較小之斜率（本研究採用 0.2），使所有神經元於整個訓練流程中皆能持續接收梯度更新。此設計於本研

究之低維輸入場景下尤為重要，蓋因條件向量之每一維皆攜帶關鍵物理資訊，任何維度之資訊損失皆可能導致該角度規格下之相位生成失敗。




圖 3-4 初始投影漸進式升維示意圖

3.3.3 上採樣模組與特徵線性調變

完成初始投影後， $4 \times 4 \times 512$ 之特徵圖須經多階段上採樣 (Upsampling) 逐步放大至最終 $N \times N$ 之相位分布。本研究設計之上採樣模組 (UpsampleBlock) 由三個運算單元串連而成，以下分別說明各單元之設計動機。

第一個單元為轉置卷積層 (Transposed Convolution)，負責將特徵圖之空間解析度提升一倍。本研究採用 4×4 之卷積核搭配步幅 2，使每經一次轉置卷積後特徵圖之高與寬皆翻倍，例如自 4×4 升至 8×8 、再自 8×8 升至 16×16 。

第二個單元為卷積層，為進一步修正轉置卷積之輸出並混合鄰近特徵，於轉置卷積之後串接兩個 3×3 卷積層，使空間結構更為平滑。

第三個單元亦即本研究之關鍵設計，特徵線性調變層 (FiLM Layer)。此層之目的在於將角度條件 c 之資訊注入至特徵圖中，使生成器於不同角度規格下能呈現截然不同之中間特徵響應。

FiLM 機制源自 Meseguer-Brocal 與 Peeters [24] 於音訊源分離任務中所提出之網路控制策略，其核心構想為對特徵圖之每一通道分別學習一組由條件向量所決定之仿射參數，並以此對該通道之數值進行尺度縮放與偏移。具體而言，設特徵圖為 $F \in \mathbb{R}^{C \times H \times W}$ ，其中 C 為通道數、 H 與 W 為空間維度，則 FiLM 層

之運算定義如公式 (7) 所示， $\gamma(c) \in \mathbb{R}^C$ 為尺度向量，其每一元素 γ_c 控制第 c 個通道之激活強度； $\beta(c)$ 為偏移向量，其每一元素 β_c 控制第 c 個通道之激活基準位準； $\odot$ 表示沿通道維度之逐元素相乘 (broadcast multiplication)，即對特徵圖每一通道分別乘以對應之 γ_c ；而這兩個調變向量 $\gamma(c)$ 與 $\beta(c)$ 皆由角度條件 c 經一獨立之 MLP 子網路產生，該子網路之輸出維度為 $2C$ ，前 C 個元素作為 γ 、後 C 個元素作為 β 。

$$FiLM(F, c) = \gamma(c) \odot F + \beta(c) \quad (7)$$

為更具體地說明 FiLM 層之運作，以下將以單一通道 c 為例，設第 c 個通道之特徵圖為 $F_c \in \mathbb{R}^{H \times W}$ (即一張 $H \times W$ 之二維矩陣)，則該通道經 FiLM 層後之輸出如式(8)所示，其中 γ_c 與 β_c 為純量，該通道內之所有 $H \times W$ 個位置皆共用此一組 (γ_c, β_c) 。當角度條件 c 改變時， γ_c 與 β_c 將隨之改變，使同一通道於不同角度規格下呈現出不同之激活強度與基準位準。

$$F'_c = \gamma_c \cdot F_c + \beta_c \quad (8)$$

此一機制的深層意義在於，生成器內同一組卷積權重，在不同角度規格下可呈現截然不同的響應行為，等同於為每一角度規格動態切換出一個專屬子網路。換言之，FiLM 使原本只能處理單一規格的網路，具備依條件動態切換子網路的能力。具體的流程可參照圖 3-5 所示，以本研究訓練多種入射與反射角組合的相位分布為例，FiLM 相當於為每一組特徵圖貼上對應該角度組合的標籤，使網路得以辨識特徵圖所對應的輸入條件，也就是說將會對每個通道上的每一張特徵圖進行貼標籤的動作，這即是本研究的模型能於單一權重內承載大量規格映射的關鍵。

最終一個上採樣階段之輸出將通過 1×1 卷積層壓縮為單通道之邏輯特徵圖 $L \in \mathbb{R}^{N \times N}$ ，其每一空間位置之數值即對應該位置 RIS 單元之相位偏好程度。 L 隨後送入 3.3 節所述之量化處理流程，最終輸出為符合 1-bit 硬體規格之相位分布。




圖 3-5 FiLM 流程示意圖

3.4 量化機制於訓練流程改善

3.2 節所建立之生成器最後一層輸出為連續實數之邏輯特徵圖。然而，實際 1-bit RIS 之硬體僅支援 0° 與 180° 兩種離散相位狀態。若於訓練完成後再以資料後處理方式進行量化，將如曾俊瑋 [20] 之研究所指出，造成主波束增益顯著下降及旁波瓣位準明顯抬升之效能衰減。為此，本研究將量化層直接整合至生成器之最後階段，使量化操作參與整體訓練流程，藉此於訓練過程中即同步學習最佳之離散相位分布。

於量化整合之具體策略上，本研究與蔡奇倫 [21] 所提出之位元遷移策略 (Bit-Transition Strategy) 採取截然不同之設計理念。蔡奇倫之方法採用兩階段訓練流程，第一階段先訓練一連續相位生成模型以充分習得相位分布之基本規律，將該模型之全連接層權重遷移至量化模型並予以凍結，再於第二階段針對量化層相關之網路權重進行微調訓練。此一設計之優勢在於將相位分布學習與量化適應兩項任務解耦，使每一階段之最佳化目標較為單純，進而提升訓練穩定性。

相較之下，本研究採取單階段端到端訓練之路徑，將量化層直接置於生成器之最末端，使連續邏輯特徵與離散相位輸出於同一訓練流程中同步最佳化。此一選擇主要源自本研究之核心設計需求，由於本研究採用條件式生成架構，單一模型須同時承載大量角度規格之相位映射關係，若採用兩階段策略，則第一階段所凍結之連續相位權重將成為第二階段之硬性約束，限制 FiLM 機制 (3.2.3 節)於

量化情境下之動態調變能力。藉由將量化層整合至訓練主迴圈，本研究使量化操作所引入之離散性誤差能直接反饋至 FiLM 之條件調變參數更新中，讓模型於同一組權重內同步學習何種角度規格下、何種離散相位分布最為適合。

整合量化層所面臨之兩項主要挑戰分別為量化操作之梯度不可微分以及 1-bit 量化所引入之鏡像波束誤差。本節將分別自硬體啟發之相位預編碼策略以及可微分之量化機制兩個方向提出對應之設計。

3.4.1 隨機相位預編碼策略

在 1-bit 量化條件下，RIS 各單元僅能呈現 0° 或 180° 兩種狀態；當大規模單元同步運作時，相位誤差將在空間中呈現高度規律的週期性分布，此一週期性會在遠場形成鏡像波束 (Quantization Lobe)，亦即一個與目標反射方向對稱出現且強度幾乎與主波束相當之非預期波束。此鏡像波束不僅造成訊號能量之分散，更會於通訊系統中產生嚴重之干擾。

如第 2.4 節所述，Shekhawat 等人 [22] 提出之 P3RIS 透過於各單元之內嵌饋線 (Inset Feed) 引入固定但隨機之相位延遲，於硬體層直接打破量化誤差之週期性，有效抑制鏡像波束。本研究受此硬體技術啟發，於軟體層提出對應的隨機相位預編碼遮罩 (Pseudo-Random Phase Pre-Coding Mask)。

具體而言，本研究於生成器之邏輯特徵輸出 L 之上疊加一張隨機固定之偏移張量 M ，再將疊加後之結果送入後續之二值化處理，如公式 (9) 所定義， $L \in \mathbb{R}^{N \times N}$ 為生成器最後一層輸出之邏輯特徵圖，其每一空間位置之數值代表該位置 RIS 單元之相位偏好程度，數值愈大表示模型傾向將該單元設為 π ，數值愈小則傾向設為 0； $M \in \mathbb{R}^{N \times N}$ 為隨機相位預編碼遮罩，其每一元素皆獨立自標準常態分布 $\mathcal{N}(0,1)$ 中抽取； $I_{N \times N}$ 為 $N \times N$ 大小之單位協方差矩陣，表示遮罩中各位置之數值彼此獨立且具相同方差； L' 為疊加後之擾動邏輯特徵圖，其將直接送入後續之 Gumbel-Sigmoid 量化層。

$$L' = L + M, \quad M \sim \mathcal{N}(0, I_{N \times N}) \quad (9)$$

但該設計於本方法中，遮罩 M 僅於模型初始化階段抽取一次，而後於整個

訓練與推論流程中保持固定。換而言之， M 並非每一批次都重新隨機產生之雜訊，而是模型架構之一部分，如同卷積層之權重般具有確定性。此一設計使模型於每次推論同一角度規格時皆能產生一致之相位輸出，確保系統具備可重現性。

舉例而言，假設 RIS 大小為 4×4 ，模型初始化時抽取之遮罩為範例式 (10)，則整個訓練與推論過程中，生成器之所有邏輯特徵輸出皆會於送入二值化層之前疊加此一固定遮罩。

$$M = \begin{bmatrix} 0.32 & -1.05 & 0.78 & -0.41 \\ -0.22 & 0.91 & -1.33 & 0.56 \\ 0.18 & -0.74 & 0.45 & -0.83 \\ -1.12 & 0.29 & -0.66 & 1.07 \end{bmatrix} \quad (10)$$

此一設計帶來兩項關鍵效益，第一個為鏡像波束之早期抑制，訓練初期生成器之邏輯輸出常呈現空間規律性（例如數值由左至右單調遞增），若直接二值化將累積形成具週期性之相位分布，進而於遠場形成顯著之鏡像波束。預先疊加 M 等同於於邏輯空間中引入空間不規律性，使二值化結果於初始即不具週期性，大幅降低鏡像波束所致之初始損失。第二個為訓練效率之提升，由於鏡像波束所致之旁波瓣懲罰於訓練早期即被抑制，模型可將更多梯度更新集中於主波束指向性之最佳化，而非耗費資源處理鏡像方位之能量，顯著縮短整體訓練所需之回合數。

需特別說明的是，此處之軟體式遮罩與 P3RIS 之硬體實現方法雖原理相通，然兩者作用層次不同。P3RIS 於實體單元之饋線設計中引入隨機相位延遲；本研究則於量化前之邏輯數值空間引入隨機性。兩種途徑皆能達成破壞週期性誤差之目的，而本研究之軟體實現方式具備幾乎為零之硬體成本，且可與後續之 Gumbel-Sigmoid 量化機制無縫銜接。

3.4.2 二值化量化機制

完成隨機相位預編碼後，擾動邏輯特徵圖 L' 即進入二值化處理階段。本研究與蔡奇倫 [21] 於量化層之實現方式上同樣存在顯著差異，蔡奇倫於兩階段訓練之第二階段採用基於梯度估計之 Smooth G-STE 量化層，藉由控制量化函數於不同閾值附近之梯度行為以協助模型於凍結之連續相位權重基礎上進行細部微調；而本研究因採用單階段端到端訓練，所選用之量化機制須具備兩項條件，

第一個為全程可微分以維持梯度於整條訓練迴圈中之連貫性，第二個為支援訓練與推論模式之無縫切換以確保訓練所學能直接遷移至 1-bit 硬體部署。基於上述需求，本研究選用 Gumbel-Sigmoid 重參數化技巧 [29],[30] 作為量化機制。

1-bit 量化之最直觀實現方式為硬性二值化 (Hard Binarization)，其依數值正負直接輸出 0 或 1，其定義如公式 (11) 所示，其中 $1(\cdot)$ 為指示函數 (Indicator Function)，即當括號內之條件成立時回傳 1，否則回傳 0。

$$q_{hard} = 1(L' > 0) = \begin{cases} 1, & \text{if } L' > 0 \\ 0, & \text{if } L' \leq 0 \end{cases} \quad (11)$$

然而硬性二值化之數學特性為階梯函數 (Step Function) 其於 $L' = 0$ 處不連續、於其他處之導數恆為 0。此特性使得反向傳播時無法計算 $\frac{q_{hard}}{\partial L'}$ 之有意義梯度，進而阻斷整個梯度流動，致使生成器之權重無法更新。

Gumbel-Sigmoid 之核心設計即在於以一連續可微之函數逼近上述階梯函數，使梯度得以順利回傳。其運算可拆解為三個層次依序進行，雜訊抽取、軟性離散化、相位映射。

首先雜訊抽取之目的在於模擬離散抽樣過程中之隨機性。本研究於每一訓練批次中自標準均勻分布抽取一隨機張量，並透過兩次對數運算將其轉換為 Gumbel 雜訊張量 G ，如公式 (12) 所示，此處 $U \in \mathbb{R}^{N \times N}$ 為自標準均勻分布抽取之隨機張量，其每一元素皆獨立落於 (0,1) 區間；經兩次取對數並取負之變換後，輸出張量 G 之每一元素將服從標準 Gumbel 分布，具有零均值與輕微右偏之特性。值得注意的是，此處之 Gumbel 雜訊與 3.3.1 節之預編碼遮罩 M 有本質上的不同，預編碼遮罩 M 僅於模型初始化時抽取一次而後固定，而 Gumbel 雜訊 G 則於每一訓練批次皆重新抽取，以確保每次離散化操作皆具備獨立之隨機性。

$$G = -\log(-\log(U)), U \sim \mathcal{U}(0, 1) \quad (12)$$

軟性離散化為 Gumbel-Sigmoid 之核心步驟。將擾動邏輯特徵 L' 與 Gumbel 雜訊 G 相加後，經溫度參數 τ 縮放並送入 Sigmoid 函數，即可得到軟

性離散化結果，其定義如公式(13)所示。其中 $\sigma(x) = \frac{1}{(1+e^{-x})}$ 為標準 Sigmoid 函數，其輸出落於 (0,1) 區間，為連續可微之 S 形曲線。輸出張量 $\hat{q}_{soft}$ 之每一元素亦落於 (0,1) 區間，可詮釋為該位置應取 1 之機率。具體之輸出行為為當 $L' + G$ 數值極大為正時， $\hat{q}_{soft}$ 趨近於 1；當其極大為負時， $\hat{q}_{soft}$ 趨近於 0；當其接近 0 時， $\hat{q}_{soft}$ 則接近於 0.5。如此一來，Sigmoid 函數即扮演硬性二值化之平滑可微分替代角色，使梯度得以正常回傳。

$$\hat{q}_{soft} = \sigma\left(\frac{L'+G}{\tau}\right) \quad (13)$$

公式中之溫度參數 τ 於此扮演關鍵角色，其數值控制 Sigmoid 之飽和程度，當 τ 較小時，曲線較為陡峭，輸出貼近 0 或 1，逼近真實之二值化結果；當 τ 較大時，曲線較為平緩，輸出集中於 0.5 附近，梯度傳遞較為順暢。此一參數對訓練動態之具體影響將於 3.3.3 節進一步討論。

相位映射為運算之最終步驟，由於 RIS 單元之兩種狀態分別對應 0° 與 180° (即 0 與 π 兩種相位)，本研究將軟性離散化結果直接乘以 π 即得訓練階段之相位分布，如公式(14)所定義，該分布隨即送入物理層進行陣列因子計算。需注意此時之 ϕ 仍為 $[0, \pi]$ 區間內之連續實數，並非真正之 1-bit 離散值，其用意在於訓練過程中保留可微分特性。最後，於推論階段，模型須輸出真正符合 1-bit 硬體規格之相位，故將上述軟性運算切換為硬性二值化形式，即為 0、 π 之形式。

$$\phi = \pi \cdot \hat{q}_{soft} \quad (14)$$

由上述三個步驟可知，Gumbel-Sigmoid 量化層本身並不包含任何可透過反向傳播學習之神經網路權重。其離散化行為完全由兩項非學習性因素共同決定，其一為溫度參數 τ ，依 3.4.2 節之退火策略隨訓練回合遞減，屬預先排定之排程而非梯度學習所得，其二為每一批次重新抽取之 Gumbel 雜訊 G ，屬隨機抽樣。因此各單元究竟由 0 翻轉至 π 或反之，並非由量化層內部某組權重所控制，而是取決於該單元之連續邏輯值 L 、疊加之固定遮罩 M 與當前批次雜訊 G 三者

相加後之正負，亦即各單元存在一個等效翻轉閾值，惟此閾值並非量化層自身所學習之參數，而是隨生成器權重之更新而間接改變。正因量化層不含可學習參數，其翻轉行為完全繫於生成器之輸出，本研究方須將量化層整合為單階段端到端流程，使量化所引入之離散誤差能透過可微分之 Gumbel-Sigmoid 路徑直接回饋至生成器權重之更新，而非於量化層內另設一組獨立學習之參數。

3.4.3 溫度退火策略

3.3.2 節已說明溫度參數 τ 為 Gumbel-Sigmoid 中決定軟性離散化逼近程度之關鍵變數。然而於實際訓練中， τ 之最佳設定並非單一定值，較大與較小之 τ 各有其優劣，須視訓練階段而定。

具體而言，當 τ 較大時，Sigmoid 曲線較為平緩，軟性輸出 $\hat{q}_{\text{soft}}$ 普遍貼近 0.5。此時梯度於整個輸入範圍內皆能順暢傳遞，有利於模型於早期廣泛探索參數空間；然而軟性輸出與真實之硬性二值化結果差距甚大，致使訓練階段所最佳化之物理損失與實際部署時之損失存在明顯落差。當 τ 較小時，Sigmoid 趨近於階梯函數，軟性輸出貼近於 0 或 1，訓練階段之行為與實際部署一致，然而 Sigmoid 之飽和區梯度趨近於零，容易導致訓練停滯。

為兼顧上述兩端之優劣，本研究採用線性退火策略 (Linear Annealing)，使 τ 於訓練過程中自起始值 τ_{start} 線性下降至終止值 τ_{end} 。其運算如下式 (15)。

公式中 e 為當前訓練回合，取值自 0 至 $E - 1$ ； E 為總訓練回合數，本研究於單波束情境設定為 300，於多波束情境則分別設定為 5 (基礎訓練) 與 1000 (混合精煉訓練)。 τ_{start} 與 τ_{end} 分別代表訓練最初使用之較高溫度與訓練後期所收斂之較低溫度；式中之 $\max(\cdot, \cdot)$ 函數則用以確保 τ 不會低於 τ_{end} ，即使 $e/E > 1$ 亦然，藉此維持數值穩定性。

$$\tau(e) = \max(\tau_{\text{end}}, \tau_{\text{start}} - (\tau_{\text{start}} - \tau_{\text{end}}) \cdot \frac{e}{E}) \quad (15)$$

整體之退火動態可簡述如下，於訓練第 0 回合時 $\tau(0) = \tau_{\text{start}}$ ，模型享有最平滑之梯度，隨訓練進行， τ 依比例 $\frac{e}{E}$ 線性下降，軟性輸出逐步逼近真實二值

化；當 $e = E$ 時， τ 抵達 τ_{end} 並維持於該數值，模型於該階段已能輸出近乎硬性二值化之相位分布。

於具體參數設定上，本研究於單波束情境設定 $\tau_{\text{start}} = 5.0$ 、 $\tau_{\text{end}} = 0.1$ ；於多波束情境則設定 $\tau_{\text{start}} = 2.0$ 、 $\tau_{\text{end}} = 0.1$ 。多波束情境採用較小之起始溫度，主要原因在於該場景之物理損失函數具有更高之非凸性，過大之起始溫度將使早期訓練之軟性輸出過度偏離真實二值化結果，反而增加收斂困難度。

透過此一退火機制，模型於訓練前期可享有較平滑之梯度流以充分探索參數空間，並於後期逐步逼近真實之硬性二值化行為，使最終之訓練結果可直接遷移至實際部署而不致發生顯著之效能落差。

3.5 模型改善

於 3.3 節所建立之模型架構基礎上，本研究進一步針對訓練過程中所觀察到之物理現象進行優化。本節之內容編排如下，3.4.1 節首先介紹單波束情境下所採用之以上限遮罩為核心之損失函數，該設計承繼自蔡奇倫 [21] 之既有研究並經其驗證具備良好之收斂效果，3.4.2 節則於上述基礎上將該設計重新展開至多波束情境，此為本研究於損失函數面向上之主要貢獻，3.4.3 節介紹用於突破訓練後期收斂瓶頸之方法，啟發式混合訓練機制，最後 3.4.4 節綜合整理各項改善策略對最終模型表現之貢獻。

3.5.1 單波束損失函數

本研究承繼蔡奇倫所提出的上限遮罩損失架構 (Mask-Based Loss) 作為單波束情境下的損失設計。該架構的核心精神在於把整個輻射場型的角度軸切成三個物理意義不同的區域，並對每個區域給予不同形式的懲罰，藉此引導模型在主波束方向產生足夠的能量集中，同時在其餘角度上壓抑旁波瓣的能量溢出。

簡單來說這個損失函數要同時告訴模型兩件事，第一個是哪些角度應該越高越好，這代表主波束方向之增益越高越好；第二個是哪些角度應該越低越好，這對應到了旁波瓣方向之增益越低越好；為了讓兩件事在訓練中共存而不互相抵觸，

本研究在不同區域施加性質不同的懲罰函數，並透過後續所述的四項子損失進行處理。

本研究將對輻射場型進行區域劃分，如圖 3-6 所示，給定目標反射角 θ_{ref} 後，先在有效角度範圍 $\theta_{valid} = 90^\circ$ 內將每個採樣角劃分為三類。距離小於等於主波束容忍寬度的角度屬於主波束區，本研究將根據實驗單元大小設定對應的主波束容忍寬度 ΔML 的角度屬於主波束區 $\mathcal{M}_{ML}$ ，本研究將會根據實驗單元大小設定對應的主波束寬容忍寬度 ΔML 。於 ΔTR 的角度範圍作為主波束到旁瓣的緩衝帶，屬於過渡區 $\mathcal{M}_{TR}$ ，剩下落在有效範圍內的角度 ΔSL 則歸入旁波瓣區 $\mathcal{M}_{SL}$ 。




圖 3-6 區域劃分示意圖

對應於以上三個區域的上限遮罩 $Mask(\theta)$ 是一條分段函數，在主波束區內 $Mask$ 設為主波束目標增益 $G_{ML}^{target} = 45$ dB，要求場型必須貼近這個高度。在旁瓣區內 $Mask$ 設為旁瓣天花板 $G_{SL}^{target} = 30$ dB，要求場型必須壓在這條線之下。過渡區則在 45 dB 和 30 dB 之間按距離線性下降，作為兩個區域之間平滑連接

的緩衝帶，至於以上有關數值的合理性將會於 3.5 章節進行介紹。

接下來要介紹的 $\mathcal{L}_{upper}$ 是四項子損失中的核心，負責使場型於主波束區貼近目標增益，並於旁瓣區壓制於天花板之下。本研究定義輻射場型與遮罩之間的差值 $\Delta(\theta) = AF(\theta) - Mask(\theta)$ ，差值為正代表場型在該角度高出遮罩，差值為負則代表場型低於遮罩。由於主波束區與旁瓣區的物理意義不同，本研究對兩區採用形式不同的懲罰公式，分別以公式 (16) 與 (17) 定義其違規量。

主波束區的違規量 e_{ML} 採用絕對值雙邊懲罰並施加 $\omega_{ML} = 10$ 倍的權重，如公式 (16) 所示。使用絕對值雙邊懲罰是因為主波束的兩種偏離方向都需要修正，其中主波束低於目標代表訊號太弱而無法達到設計增益，主波束高於目標則代表能量過度集中而可能擠壓鄰近角度的設計餘裕。施加 $\omega_{ML} = 10$ 的權重則反映訓練上的優先順序，使模型在訓練早期即將資源集中於主波束的增益達成，而非旁瓣的微小違規。

$$e_{ML} = \omega_{ML} \cdot |\Delta(\theta)|, \theta \in \mathcal{M}_{ML} \quad (16)$$

至於旁瓣區的違規量 e_{SL} 採用三段式分段，如公式 (17) 所示。當差值小於等於零時，表示該角度已符合期望而不需懲罰；當差值大於零但小於 1 dB 時，本研究將懲罰值硬性設為 1；當差值大於等於 1 dB 時，則採絕對值之二倍懲罰以加強對嚴重溢出的修正。將微小違規硬性設為 1 的原因在於，0 到 1 之間的數值經平方後反而會被縮小，例如超出 0.5 dB 在平方後僅產生 0.25 的懲罰而被其他較大違規淹沒，使模型放任這類小幅度旁瓣累積並最終形成多個明顯的旁波瓣，因此以硬性設為 1 確保任何溢出天花板的角度都帶來實質懲罰。

$$e_{SL}(\theta) = \begin{cases} 0, & \text{if } \Delta(\theta) \leq 0 \\ 1, & \text{if } 0 < \Delta(\theta) < 1 \\ |\Delta(\theta)| \cdot 2, & \text{if } \Delta(\theta) \geq 1 \end{cases} \quad (17)$$

最終的上限損失 $\mathcal{L}_{upper}$ 整合兩區域的違規量，以平方平均誤差形式呈現，如公式 (18) 所示，其分母為主波束區與旁瓣區之取樣點數總和。由於主波束區之違規量已先乘上 ω_{ML} 倍權重，再經此處平方後，主波束每偏離 1 dB 所產生的損失約為旁瓣的一百倍，使模型於訓練早期即優先收斂主波束的指向性與增益。

$$\mathcal{L}_{upper} = \frac{1}{|\mathcal{M}_{ML}| + |\mathcal{M}_{SL}|} (\sum_{\theta \in \mathcal{M}_{ML}} e_{ML}(\theta)^2 + \sum_{\theta \in \mathcal{M}_{SL}} e_{SL}(\theta)^2) \quad (18)$$

僅有 $\mathcal{L}_{upper}$ 不足以處理過渡區的反彈現象，即使過渡區的絕對增益並未超過遮罩，場型仍可能在這一帶呈現先下降再上升的小鼓起，這在最終結果中會表現為主波束旁邊冒出的次要旁瓣，明顯降低設計品質，因此需要 $\mathcal{L}_{trend}$ 以方向一致性來約束過渡區的形狀。本研究定義輻射場型與遮罩在相鄰角度間的變化量 $\Delta AF(\theta) = AF(\theta + 1) - AF(\theta)$ 與 $\Delta Mask(\theta) = Mask(\theta + 1) - Mask(\theta)$ ，由於過渡區內遮罩本身是嚴格遞減的，理想場型也應隨之遞減，故當兩者變化方向不一致時即施加懲罰，定義如公式 (19) 所示。公式 (19) 的第一個條件對應遮罩遞減但場型遞增的情況，此為過渡區反彈的典型形式，其懲罰量取 ΔAF 本身；第二個條件則對應遮罩遞增但場型遞減的反向情況，此情況雖較少出現但仍應避免；至於當場型與遮罩變化方向一致時則不產生懲罰。透過這個設計，模型在過渡區內被引導關注變化趨勢的匹配而非絕對位準的貼合，可有效抑制非單調遞減所造成的額外旁波瓣。

$$\mathcal{L}_{trend} = \frac{1}{|\mathcal{M}_{TR}|} \sum_{\theta \in \mathcal{M}_{TR}} \begin{cases} \Delta AF(\theta), & \text{if } \Delta Mask(\theta) < 0 \wedge \Delta AF(\theta) > 0 \\ -\Delta AF(\theta), & \text{if } \Delta Mask(\theta) > 0 \wedge \Delta AF(\theta) < 0 \\ 0, & \text{others} \end{cases} \quad (19)$$

$\mathcal{L}_{upper}$ 雖然能確保主波束達到目標增益，但無法保證主波束是一個平滑的單峰。當主波束內部出現凹陷或雙峰結構時，平均增益仍可能達標，但波束品質會明顯下降。例如主波束中央出現一個小凹陷，雖然平均高度還在 45 dB 附近，但實際應用上代表波束被劈開成兩個小峰，半功率波束寬與指向性都會產生失真，所以再來要介紹第三個子損失來解決此問題，主波束平穩損失 $\mathcal{L}_{grad}$ 。 $\mathcal{L}_{grad}$ 透過二階差分量測主波束內部的局部曲率變化，定義如公式 (20) 所示。其中 $\Delta^2 AF(\theta) = AF(\theta + 1) - 2 \cdot AF(\theta) + AF(\theta - 1)$ 為輻射場型於 θ 處的二階差分，相當於離散版本的二階導數，能反映該位置的局部曲率。 $\mathcal{M}_{ML}^\circ$ 為主波束內部點集合，扣除頭尾兩端因二階差分無法計算的兩個點。當主波束呈現平滑單峰時，內部各點的二階差分絕對值都很小， $\mathcal{L}_{grad}$ 接近零。反之當主波束內部出現凹陷

或多峰時，這些不平滑的位置會產生大的二階差分絕對值，驅動模型修正主波束的形狀。

$$\mathcal{L}_{grad} = \frac{1}{|\mathcal{M}_{ML}| - 2} \sum_{\theta \in \mathcal{M}_{ML}^\circ} |\Delta^2 AF(\theta)| \quad (20)$$

最後介紹二值化純度正則化，它並非處理物理場型之損失，而是配合 3.3.2 節 Gumbel-Sigmoid 量化機制的輔助訊號。設 $p_{ij} = \frac{\phi_{ij}}{\pi} \in [0, 1]$ 為相位的正規化機率， $\mathcal{L}_{ent}$ 定義如公式 (21) 所示。該函數在 $p_{ij} = 0.5$ 時取最大值 0.25，在 p_{ij} 為 0 或 1 時取最小值 0。換句話說，當相位機率處於完全二值化狀態，也就是模型確定要輸出 0 或 π 時， $\mathcal{L}_{ent}$ 為零，當相位機率停留在 0.5 附近，也就是模型猶豫不決時， $\mathcal{L}_{ent}$ 達到最大值。透過懲罰中間值，這項損失推動模型在訓練後期將每個相位單元的輸出收斂至 0 或 π 之一，貼近真實的 1-bit 硬體規格。最終這四項子損失的加權和構成單波束情境下的總損失，如公式 (22) 所示。

$$\mathcal{L}_{ent} = |p_{ij}(1 - p_{ij})| \quad (21)$$

$$\mathcal{L}_{total} = \omega_U \mathcal{L}_{upper} + \omega_T \mathcal{L}_{trend} + \omega_G \mathcal{L}_{grad} + \omega_E \mathcal{L}_{ent} \quad (22)$$

本研究將前三項子損失的權重設為 $\omega_U = \omega_T = \omega_G = 1.0$ 。由於 $\mathcal{L}_{upper}$ 、 $\mathcal{L}_{trend}$ 、 $\mathcal{L}_{grad}$ 都直接對應到輻射場型的物理品質指標，使用相同權重可以維持三種物理現象在訓練中的處理平衡。 $\mathcal{L}_{ent}$ 的權重則設為 $\omega_E = 0.05$ ，明顯低於前三項。這是因為 $\mathcal{L}_{ent}$ 屬於輔助性的正則化訊號，若權重過高會在主要物理目標尚未達成時就過早壓迫模型做硬性二值化，反而干擾物理場型的學習。較低的權重讓 $\mathcal{L}_{ent}$ 在訓練早期保持安靜，等主要物理目標逐漸達成後才逐步主導模型趨向真正的 1-bit 解。

最後整理本節所用的參數設定。主波束容忍寬度根據單元大小情況分開設定，大小為 16×16 的話，則 $\Delta_{ML} = 6^\circ$ ，主波束目標增益 $G_{ML}^{target} = 45$ dB，旁瓣天花板 $G_{SL}^{target} = 30$ dB，大小為 32×32 的話，則 $\Delta_{ML} = 3^\circ$ ，主波束目標增益 $G_{ML}^{target} = 57$ dB，旁瓣天花板 $G_{SL}^{target} = 37$ dB，至於其他參數，過渡區

寬度 $\Delta_{TR} = 2^\circ$ 、有效範圍 $\theta_{valid} = 90^\circ$ ，而主波束加權 $\omega_{ML} = 10$ 、子損失權重 $\omega_U = \omega_T = \omega_G = 1.0$ 與 $\omega_E = 0.05$ ，關於主波束寬度以及增益值的設定理由將於 3.5 章節進行說明。

3.5.2 多波束損失函數

3.4.1 節所建立的損失函數針對單一目標反射角設計，目標只有一個主波束需要注意。當設計需求進入 K 波束情境後，輻射場型上同時存在 K 個目標主波束，遮罩建構的方式以及主波束目標增益的設定都需要重新調整才能反映多波束的物理特性。本研究希望多波束情境的損失能在不改動 3.4.1 節主體結構的前提下自然擴展，因此沿用相同的四項子損失與權重設定，僅針對遮罩定義與目標增益兩處進行修改。

當輻射場型上同時存在 K 個目標主波束時，每個採樣角必須同時考量其與所有目標主波束的相對位置才能正確判定其區域歸屬。本研究採用統一的最近距離準則處理這個問題，將單波束情境下的距離定義 $d(\theta) = |\theta - \theta_{ref}|$ 推廣為公式 (23) 所示的形式。也就是說每個角度 θ 只看它離最近的目標主波束有多遠，其餘較遠的目標主波束不影響其區域歸屬。這個距離一旦定義好，3.4.1 節中所有依距離判定的區域邏輯都可以直接沿用。距離小於等於 Δ_{ML} 的角度屬於主波束區，距離介於 Δ_{ML} 與 $\Delta_{ML} + \Delta_{TR}$ 之間的角度屬於過渡區，其餘有效範圍內的角度屬於旁波瓣區。對應的上限遮罩 $Mask(\theta)$ 也依此最近距離建構，在主波束區設為 G_{ML}^{target} 、在旁波瓣區設為 G_{SL}^{target} 、在過渡區間以最近主波束的距離線性遞減。

$$d(\theta) = \min_{k=1,2,\dots,K} |\theta - \theta_{ref}^{(k)}| \quad (23)$$

這個距離定義帶來兩項實作上的優勢。第一個是單波束與多波束情境共用同一套程式邏輯。當 $K = 1$ 時公式 (23) 自動退化為單波束的距離定義 $d(\theta) = |\theta - \theta_{ref}|$ ，因此 3.4.1 節定義的所有公式在多波束情境下完全保持不變，只是三個區域的角度集合規模隨主波束數量而擴大。第二個是相鄰目標主

波束的自然合併。當兩個目標主波束的角度相距小於 $\Delta_{ML} + 2\Delta_{TR}$ 時，两者的主波束區與過渡區會在 $\min$ 運算下自動合併為一個較寬的主波束覆蓋區，毋需額外撰寫重疊處理邏輯。這個性質讓損失函數能正確處理目標方向極為相近的多波束組合，不會因為遮罩衝突而產生模糊的區域歸屬。另外一種看似自然的做法是為每個目標各建一個遮罩再進行合併，但這在目標方向相近時會產生遮罩重疊衝突，且需要額外的邏輯判定每個角度究竟歸屬於哪一個主波束，而本研究採用的最近距離準則從定義上就避免了這個問題。

在區域劃分完成後於 3.4.1 節介紹的四項子損失 $\mathcal{L}_{upper}$ 、 $\mathcal{L}_{trend}$ 、 $\mathcal{L}_{grad}$ 、 $\mathcal{L}_{ent}$ 在多波束情境下的計算公式完全保持不變，只是主波束區、過渡區與旁波束區的角度集合規模因為涵蓋多個目標主波束方向而擴大，其中主波束加權 $\omega_{ML} = 10$ 、子損失權重 $\omega_U = \omega_T = \omega_G = 1.0$ 與 $\omega_E = 0.05$ 也與單波束之設定相同不變。

多波束情境下另一項需要調整的是主波束目標增益的設定。在 1-bit RIS 的物理特性下，當總波束能量分散到 K 個方向時，根據能量守恆原理，每個主波束的峰值增益會相較單波束情境下降。具體而言，對 16×16 的 1-bit RIS，單波束情境下的主波束峰值約為 45 dB， K 波束情境下的物理上限可由公式 (24) 近似估計。代入 $K = 4$ 可得 $G_{ML}^{max}(4) = 45 - 10 \cdot \log_{10}(4) \approx 39$ dB，這是四波束情境下任何相位設計都無法超越的物理上限。

$$G_{ML}^{max}(K) \approx G_{ML}^{(single)} - 10\log_{10}(K) \quad (24)$$

此一物理上限直接影響到目標增益的設定方式，倘若四波束情境下仍沿用單波束的 45 dB 目標，該目標在物理上將永遠無法達成，主波束損失將始終處於高位，使模型在不可達的目標下不斷產生持續性的偏差，反而干擾其他子損失的最佳化進度；然而若一開始就把目標設得太保守，例如直接設為物理上限 39 dB，模型則可能在訓練早期即達到目標而提前停止探索，錯失更高增益方向的最佳化機會，至於上述增益之計算方式將於 3.5 節進行說明。

為了在探索性與物理可行性之間取得平衡，本研究在多波束情境下採用兩

階段目標設定策略。第一階段為基礎訓練階段，主波束目標仍設為 45 dB，給予模型充足的最佳化探索空間，讓 FiLM 機制與角度條件之間的映射關係先穩定建立起來。第二階段為混合精煉訓練階段，將於 3.4.3 節介紹，主波束目標改為 38 dB，預留 1 dB 餘裕略低於物理上限 39 dB，讓損失函數對應到一個物理上確實可達的解，避免模型在不可達目標下產生持續偏差。

3.5.3 啟發式神經網路混合訓練機制

3.4.1 與 3.4.2 節所建立的損失函數在多數情境下可順利收斂，但本研究於實際訓練中觀察到一項現象。當模型已大致掌握角度條件至相位分布的基本映射後，訓練後期的損失常停滯於某一水準而難以進一步下降，此現象於四波束場景下尤為明顯。其根本原因有兩個，第一個是 1-bit 相位分布為離散變數，物理損失本身高度非凸。第二個是四波束的角度自由度高，多個區域同時最佳化時，模型容易卡在某些區域已達標、其他區域差強人意的局部解。離散搜尋空間極為龐大也使得僅靠梯度下降難以脫離此類局部最佳解的吸引域。

為突破這項瓶頸，本研究設計啟發式神經網路混合訓練機制 (Heuristic-Neural Hybrid Training)，將神經網路的高效擬合特性與啟發式演算法的鄰域搜尋特性結合。其核心構想是於每一訓練步驟中，先由模型產生一組相位預測，再於該預測的鄰域內以貪婪式 1-bit 翻轉搜尋找出較佳的離散解，最後將兩者的差異作為額外的引導訊號回饋至模型權重更新。整體訓練流程如圖 3-7 所示，以下對照其三個階段補充設計考量。

Algorithm 3-1: Heuristic-Neural Hybrid Training

Input: angle condition vector $\mathbf{c}$ of batch size B ;
target reflection angles $\{\theta_{\text{ref}}^{(k)}\}_{k=1}^K$;
conditional generator $\mathbf{G}_{\theta}$;
physics layer $\text{Physics}(\cdot)$ defined in Eq. (2);
mask-based loss $L_{\text{total}}(\cdot, \cdot)$ returning batch scalar loss L_{phys} and per-sample losses ℓ ;
current training epoch e and switching threshold E_{sw} ;
mutation search steps T ; flip sizes $f_{\text{early}}, f_{\text{late}}$;
guidance loss weight λ_g ; learning rate η ;
RIS array side length N , where $\Phi \in \{0, \pi\}^{N \times N}$.
Output: updated generator parameters θ .

▷ *Stage 1: Model Prediction*

```
1  $\Phi_{\text{pred}} \leftarrow \mathbf{G}_{\theta}(\mathbf{c})$ 
2  $\mathbf{P}_{\text{pred}} \leftarrow \text{Physics}(\Phi_{\text{pred}})$ 
3  $L_{\text{phys}}, \ell_{\text{pred}} \leftarrow L_{\text{total}}(\mathbf{P}_{\text{pred}}, \theta_{\text{ref}})$ 
```

▷ *Stage 2: Greedy Mutation Search (executed without gradient tracking)*

```
4  $\Phi_{\text{best}} \leftarrow \Phi_{\text{pred}}; \ell_{\text{best}} \leftarrow \ell_{\text{pred}}$ 
5  $f \leftarrow f_{\text{early}}$  if  $e < E_{\text{sw}}$  else  $f_{\text{late}}$ 
6 for  $t = 1$  to  $T$  do
7    $\Phi_{\text{mut}} \leftarrow \text{Flip}(\Phi_{\text{best}}, f)$ 
8    $\mathbf{P}_{\text{mut}} \leftarrow \text{Physics}(\Phi_{\text{mut}})$ 
9    $\ell_{\text{mut}} \leftarrow L_{\text{total}}(\mathbf{P}_{\text{mut}}, \theta_{\text{ref}})$ 
10  for each sample  $b$  with  $\ell_{\text{mut}}[b] < \ell_{\text{best}}[b]$  do
11     $\Phi_{\text{best}}[b] \leftarrow \Phi_{\text{mut}}[b]$ 
12     $\ell_{\text{best}}[b] \leftarrow \ell_{\text{mut}}[b]$ 
```

▷ *Stage 3: Guidance Loss and Weight Update*

```
13  $L_{\text{guide}} \leftarrow \frac{1}{N^2} \|\Phi_{\text{pred}} - \Phi_{\text{best}}\|_2^2$ 
14  $L_{\text{hybrid}} \leftarrow L_{\text{phys}} + \lambda_g \cdot L_{\text{guide}}$ 
15  $\theta \leftarrow \theta - \eta \cdot \nabla_{\theta} L_{\text{hybrid}}$ 
16 return  $\theta$ 
```

圖 3-7 啟發式神經網路混合式訓練虛擬碼

首先階段一為模型預測，對應演算法 3-1 第 1 至 3 行，生成器 $\mathbf{G}_{\theta}$ 依當前角度條件 $\mathbf{c}$ 輸出 1-bit 相位分布 Φ_{pred} ，並透過 2.1 節公式 (2) 的陣列因子物理層轉換為輻射場型 $\mathbf{P}_{\text{pred}}$ ，再依 3.4.1 至 3.4.2 節所定義的上限遮罩損失函數 L_{total} 計算物理引導損失 L_{phys} 。而訓練時每一個 epoch 會依 B (Batch) 大小將樣本分批抽取，每一批次同時送入數十萬筆不同角度規格之樣本。由於本研究於損失函數中同步回傳每一筆樣本各自的損失值，鄰域搜尋得以對同一批次內的所有樣本平行進行翻轉與評估，一次更新整批的最佳解，而不需逐筆重複執行，因而能有效縮短搜尋所需的時間。

階段二為貪婪式相位翻轉搜尋，對應演算法 3-1 第 4 至 12 行，此階段不進行梯度追蹤，避免搜尋過程建立特徵圖造成記憶體爆炸，同時也表示搜尋所得的 Φ_{best} 不具梯度資訊。本研究以 Φ_{pred} 為起點迭代 T 步搜尋並設 $T = 5$ 。每一

步搜尋中， $Flip(\Phi_{\text{best}}, f)$ 表示自當前最佳解隨機選取 f 個相位單元並執行 1-bit 翻轉，即 0 翻轉至 π ，或是 π 翻轉至 0，得到擾動相位 Φ_{mut} 。將擾動結果送入物理層計算其逐樣本損失 ℓ_{mut} 後，演算法針對批次內每一樣本獨立判定接受與否，僅當該樣本的擾動損失低於當前最佳損失時才更新該樣本的最佳解。這個逐樣本獨立的接受規則使每一訓練樣本皆能在其自身鄰域中尋得最佳解。

關於翻轉單元數 f 的設定，本研究依當前訓練回合 e 採前後段差異化策略，切換閾值為 $E_{\text{sw}} = 185$ 。當 $e < 185$ 時設 $f = f_{\text{early}} = 3$ 進行較大範圍的鄰域探索，當 $e \geq 185$ 時設 $f = f_{\text{late}} = 1$ 進行精細微調。值得注意的是 f 於每一訓練步驟內為固定值，並非隨同一搜尋過程中的 t 而變動，亦即同一回合內的 T 次搜尋皆使用相同的 f 值。此設計借鑑模擬退火 (Simulated Annealing) 的概念，使訓練前期具備全域探索性以擺脫局部最佳解的吸引域，訓練後期則收斂至精細微調以鞏固既有解。最後因單波束情境因搜尋空間相對較小，本研究將不啟用該機制進行訓練。

階段三為引導式損失與權重更新，對應演算法 3-1 第 13 至 16 行，由於翻轉搜尋不追蹤梯度， Φ_{best} 不具梯度資訊，無法直接用於最佳化網路權重。為將優於模型自身輸出的離散解這個知識回饋至神經網路，本研究於損失中加入引導式損失 $\mathcal{L}_{\text{guide}}$ (Guidance Loss)，以均方誤差形式衡量模型預測與啟發式最佳解的差距，如公式 (25) 所示。其中 $\frac{1}{N^2}$ 一項使損失對陣列規模具備正規化效果。

混合訓練階段的總損失為物理引導損失與引導式損失的加權和，如公式 (26) 所示。生成器參數則依梯度下降更新，學習率 η 採用與訓練主流程相同的設定。引導權重 λ_g 於多波束情境下設為 100，於單波束情境下設為 50。採用較大數值的動機在於 $\mathcal{L}_{\text{guide}}$ 為相位差的均方誤差，數值落於 $[0, \pi^2]$ 區間，原始量級遠小於 $\mathcal{L}_{\text{phys}}$ 。若不予加權，引導訊號的梯度貢獻將被物理損失完全壓制。反之若 λ_g 過大，模型會過度模仿啟發式搜尋的結果而失去自身的最佳化動力。值得補充的是，由於 Φ_{best} 不具梯度， $\mathcal{L}_{\text{guide}}$ 的梯度只會透過 Φ_{pred} 回流至 G_θ ，這

保證了引導訊號不會干擾物理層原本的梯度路徑，兩股訊號互相獨立又共同推動模型更新。

$$\mathcal{L}_{\text{guide}} = \frac{1}{N^2} \|\Phi_{\text{pred}} - \Phi_{\text{best}}\|_2^2 \quad (25)$$

$$\mathcal{L}_{\text{hybrid}} = \mathcal{L}_{\text{phys}} + \lambda_g \mathcal{L}_{\text{guide}} \quad (26)$$

3.5.4 模型改善總結

3.4 節針對訓練過程中的兩項挑戰提出對應的設計方案，第一個挑戰是輻射場型須在多項物理特性上同時達標，包含主波束指向性、半功率波束寬與旁波瓣抑制等。第二個挑戰是當規格自由度過高，模型於訓練後期容易陷入收斂瓶頸而難以繼續改善。

針對第一個挑戰，本研究於損失函數設計上採用以上限遮罩為核心的架構，並依單波束與多波束情境分別建構對應的損失函數。單波束部分承繼蔡奇倫的設計，其優點在於依不同角度區域施加差異化懲罰，使梯度訊號能精準對應每個區域所需改善的物理特性，缺點則在於四項子損失的相對權重需相互平衡，任一項過高都可能壓抑其他物理特性的學習。多波束部分以最近目標主波束的距離作為統一的區域劃分準則，優點是單波束與多波束情境共用同一套邏輯，且能自然處理相鄰波束的合併，缺點則是各波束間的增益均勻性難以僅靠損失函數保證，並且須額外考量 $10\log_{10}(K)$ dB 的物理上限，避免模型於不可達目標下產生持續性的損失偏差。

針對第二個挑戰，本研究在多波束情境下引入啟發式神經網路混合訓練機制。考量單波束情境的搜尋空間相對較小，於既有損失函數設計下即可穩定收斂，本研究未將該機制應用於單波束訓練。在四波束情境下因龐大的離散搜尋空間使梯度下降難以脫離局部最佳解，混合訓練機制將神經網路的快速擬合能力與啟發式演算法的鄰域搜尋能力整合於同一訓練流程中，有效突破收斂瓶頸。該機制的成本在於每訓練步驟的物理層運算量增為原本的六倍，包含 1 次的模型預測與 5 次搜尋的物理層呼叫，且引導權重 λ_g 需謹慎調節，過小將使引導訊號失效，過

大則使模型過度模仿啟發式搜尋結果而失去自身的最佳化動力。

整體而言，上述兩項策略形成互補架構，損失函數提供物理意義明確的訓練目標，混合訓練機制則於多波束之高難度場景下提供突破工具。實際訓練流程上，多波束場景採用兩階段策略。第一階段以多波束損失函數進行基礎訓練，使模型穩定習得角度條件至相位分布的基本映射。第二階段以第一階段的最佳權重作為起點，啟動混合訓練機制並改採契合 1-bit 四波束物理上限的 38 dB 目標，進一步精煉相位品質。

綜合本章所述各項設計，本研究所建構的條件式生成器框架在模型架構、量化整合與訓練機制三個面向皆具備完整的設計考量，可實現符合 1-bit 硬體規格的動態多規格相位生成能力。下一節將介紹本研究所採用的模型驗證方法與性能評估指標。

3.6 模型驗證

於 3.4 節完成模型改善方案之說明後，本節對應於圖 3-1 之 Model Validation 階段，介紹本研究所採用之模型驗證方法與性能評估指標。

3.6.1 陣列因子與電磁模擬之容忍範圍

本研究承繼曾俊瑋所建立的驗證框架，同時採用陣列因子公式與電磁模擬兩種方式評估模型表現。陣列因子運算速度快，適合大量規格的自動化驗證，但未納入單元耦合等實際物理現象。電磁模擬則考量上述非理想效應，於性能評估上更貼近真實硬體之物理表現。本研究以主波束反射角度、半功率波束寬、旁波瓣位準及訊號強度四項指標作為衡量基準，兩種驗證方式下的容忍範圍如表 3-2 所示。

表 3-2 陣列因子公式和電磁模擬容忍區間數值

性能度量	陣列因子公式容忍範圍	電磁模擬容忍範圍
主波束反射角度	$\pm 1^\circ$	$\pm 2^\circ$
半功率波束寬	$\pm 3^\circ$	$\pm 3^\circ$
旁波瓣位準	3 dB	5 dB
訊號強度	理想增益值 $\times 0.8$ 以上	

由表 3-2 可見，兩種驗證方式的半功率波束寬與訊號強度容忍範圍相同，僅主波束反射角度與旁波瓣位準於電磁模擬下適度放寬。此設計基於 Yang 等人 [26] 對 1-bit 反射陣列量化效應的觀察，相位量化主要會抬升旁瓣位準而幾乎不影響半功率波束寬。

3.6.2 理想增益之物理推導

訊號強度的合格判定必須先建立理想增益作為基準。理想增益並非任意設定，而是由陣列因子公式所決定的物理可達上限。本節從陣列因子的數學形式出發，逐步推導 $N \times N$ RIS 在連續相位、1-bit 量化、不同半功率波束寬與多波束情境下的理想增益值。

回顧 2.1 節公式 (2) 所定義的陣列因子 $AF(\theta, \varphi)$ ，當所有單元的相位完全對齊目標方向時，即連續相位下的理想情況，全部單元的訊號在該方向上同相相加，使陣列因子達到峰值 $|AF|_{max} = M \times N$ 。將此峰值轉換為以 dB 表示的功率增益，可得單波束峰值增益的理論上限，如公式 (27) 所示。其中第二步使用了方形陣列 $M = N$ 的條件，代入 16×16 RIS 可得 $G_{continuous} = 40 \cdot \log_{10}(16) \approx 48.16$ dB，代入 32×32 RIS 可得 $G_{continuous} \approx 60.21$ dB，此為連續相位下的物理上限。

$$G_{continuous} = 20 \cdot \log_{10}(|AF|_{max}) = 20 \cdot \log_{10}(M \cdot N) \quad (27)$$

然而本研究所探討的 RIS 採用 1-bit 量化，每個單元僅能呈現 0° 或 180°

兩種相位狀態。Yang 等人透過理論分析證明 [26]，1-bit 量化所致的主波束峰值損失約為 3.92 dB，本研究於實作上採取 -3 dB 的工程簡化估計以與訓練目標對齊，並將其納入理想增益的計算中，最終定義如公式 (28) 所示。代入兩種 RIS 規格可得 16×16 RIS 的理想增益約為 45 dB、 32×32 RIS 的理想增益約為 57 dB，此兩數值即為 3.4.1 節單波束情境下主波束目標增益 G_{ML}^{target} 的設定依據。

$$G_{ideal} = 20 \cdot \log_{10}(M \cdot N) - 3dB \quad (28)$$

公式 (28) 給出的理想增益對應於最窄的半功率波束寬，實際應用中若客製化規格指定較寬的主波束，則陣列須將相位分布調整為散焦狀態以擴展波束寬度，根據能量守恆原理，主波束峰值增益會隨之降低。經驗上當半功率波束寬倍增時，理想增益約下降 3 dB。本研究依此原理整理兩種 RIS 規格在不同半功率波束寬下的理想增益對照值，如表 3-3 與表 3-4 所示，其半功率波束寬與增益之對應數值係取自曾俊瑋所建立之增益對照指標，期望增益值欄位取理想增益值的 80%，作為訊號強度合格判定的下限門檻。

表 3-3 16×16 半功率波束寬對應的增益值

半功率波束寬	理想增益值	期望增益值 (理想增益值 $\times 0.8$)
6°	45dB	36dB
12°	42dB	34dB
24°	39dB	31dB
48°	36dB	29dB

表 3-4 32×32 半功率波束寬對應的增益值

半功率波束寬	理想增益值	期望增益值 (理想增益值 $\times 0.8$)
3°	57dB	46dB
6°	54dB	43dB
12°	51dB	41dB
24°	48dB	38dB

當設計需求進入 K 波束情境時，輻射場型須將總能量分配至 K 個目標方向。在能量守恆的限制下，每個主波束所分得的能量降為單波束情境的 $\frac{1}{K}$ ，對應於峰值增益下降 $10 \cdot \log_{10}(K)$ dB [27]。據此推得多波束情境下的理想增益公式，如公式 (29) 所示。代入 16×16 RIS、 $K = 4$ 的情境可得 $G_{ideal}^4 \approx 45 - 6.02 \approx 39$ dB，此為四波束情境下任何 1-bit 相位設計都無法超越的物理上限。本研究於 3.4.2 節所述的兩階段訓練策略中，第二階段的主波束目標 38 dB 即依此推導值預留約 1 dB 的訓練餘裕。表 3-5 整理兩種 RIS 規格於不同波束數量下的多波束理想增益值。

$$G_{ideal}^K = G_{ideal} - 10 \cdot \log_{10}(K) \text{ dB} \quad (29)$$

由表 3-5 可見，隨波束數量增加，每個主波束可達的峰值增益持續下降，且下降幅度服從 $10 \cdot \log_{10}(K)$ 的對數關係。此一物理特性使多波束情境的訓練目標必須相應調整，否則模型將在不可達的目標下產生持續性的損失偏差。

表 3-5 多波束情境下的理想增益對照表

波束數量	能量分散衰減	理想增益值	期望增益值 (理想增益值× 0.8)
1	0.00dB	45.00dB	36.00dB
2	3.0dB	42.00dB	33.60dB
3	4.8dB	40.20dB	32.16dB
4	6.0dB	39.00dB	31.20dB

3.6.3 性能度量之計算方法

本研究之性能度量依下列方式計算各項指標。半功率波束寬之計算先尋找主峰值，並以峰值減 3 dB 作為閾值，收集所有超過此閾值之角度以形成主波束序列，主波束反射角度則取該主波束序列首尾值之平均。旁波瓣位準定義為主波束峰值與旁波瓣峰值之差，訊號強度則直接取主波束峰值，並依實際之半功率波束寬查表 3-3 或表 3-4 取得期望增益作為合格門檻。於多波束情境下，上述計算將針對每一目標主波束方向獨立執行。圖 3-8 與圖 3-9 為性能度量之計算結果示例，其中圖 3-8 為一單元大小 16×16 之相位分布所對應之輻射場型，其期望增益應超過 36 dB 且半功率波束寬應為 6° ，而由圖 3-9 可見實際量測結果之各項數值皆落於容忍區間之內，故可藉此判定模型所生成之相位分布是否符合需求。




圖 3-8 計算性能度量示意圖

Reflect Angle: -39.6°
 Beam Width: 8.9°
 SLL: 12.0 dB
 Gain: 43.0 dB

圖 3-9 性能度量數值圖

3.7 即時推論方法

3.5 節所述之驗證方法於 GPU 伺服器端透過陣列因子公式與電磁模擬軟體評估模型所生成相位分布之場型品質。然而，如 2.5 節之問題定義所指出，既有研究多於高運算資源之伺服器端完成驗證，鮮少將模型部署至運算資源受限之邊緣運算平台以驗證其即時推論能力。為呼應本研究所欲解決之第四項核心問題，本節說明訓練完成之模型如何部署至邊緣裝置，並闡述自使用者下達角度指令至 RIS 完成相位更新之完整即時推論流程。3.6.1 節說明模型之部署平台與環境設定，3.6.2 節則介紹整體推論流程及推論時間之量測方法。

3.7.1 模型部署與環境設定

本研究將訓練完成之模型部署於 NVIDIA Jetson AGX Orin 邊緣運算裝置。選用該平台之主要考量在於，6G 通訊場景中之 RIS 控制器多位於基地台或反射面端，其運算資源遠較訓練階段所使用之 GPU 伺服器受限；於此類邊緣平台上驗證模型之推論延遲，方能真實反映系統部署於實際環境時之即時性表現。於軟體環境方面，邊緣裝置採用 Linux 作業系統並以 PyTorch 作為模型執行框架，與訓練階段所使用之框架一致，使訓練所得之權重檔可直接載入而無須額外之模型轉換程序。

就完整之系統架構而言，本研究團隊所規劃之即時相位控制系統係由邊緣運算裝置與硬體控制端協同構成，以 Nvidia Jetson AGX Orin 執行模型之前向推論以產生相位分布，隨後透過序列埠將結果傳送至負責訊號發送之微控制器 (ESP32)，再由該微控制器將控制訊號送至 RIS 硬體以驅動各單元之相位狀態切換；此一設計使深度學習推論與硬體控制之職責明確分離，前者由具備 GPU 之邊緣裝置負責高運算量之相位生成，後者由低功耗微控制器負責即時之訊號傳輸與單元控制。惟須特別說明的是，上述微控制器與 RIS 硬體之連接屬研究團隊整體系統之設計規劃，本論文之探討範圍僅聚焦於推論裝置本身，亦即模型於邊緣運算裝置上之部署與即時推論能力；至於下游之硬體訊號傳輸與 RIS 相位切換等環節，並不在本論文之實測與討論範圍之內，在此僅以系統設計之形式一併敘述，藉以完整呈現本模型於實際部署情境中所扮演之角色與定位。

為確保推論時間量測之準確性與穩定性，本研究於正式推論前對邊緣裝置進行三項環境設定。第一個為關閉所有非必要之背景執行程式，避免其餘程序與模型推論競爭運算資源而造成延遲波動，第二個為將裝置切換至最高效能電源模式，使 CPU 與 GPU 得以於最高時脈下運作，不因功耗管理機制而降頻，第三個為鎖定 GPU 之運作頻率，藉此消除動態電壓頻率調節 (Dynamic Voltage and Frequency Scaling, DVFS) 所引入之時脈變動。邊緣裝置於預設狀態下會依當前負載動態調整時脈以節省功耗，此一機制將導致推論時間呈現顯著之波動，並使

初次推論因時脈尚未提升而明顯偏慢；透過上述設定，可使每次推論皆於一致且最佳之硬體狀態下執行，確保時間量測結果具備可重現性。

3.7.2 推論流程

本研究團隊所設計之整體推論流程如圖 3-10 所示，自使用者下達指令至 RIS 完成相位更新可劃分為五個階段，以下依序說明各階段之運作。

第一階段為使用者發送指令，使用者於邊緣裝置上執行使用者介面程式後，介面首先提供波束模式之選擇，使用者依當前終端使用者之方位需求選擇單波束或多波束功能，若選擇單波束模式，程式要求輸入一組入射角與一組反射角，若選擇多波束模式，則先指定波束數量，再依序輸入一個入射角與對應數量之反射角。此二類角度為使用者於部署後唯一可變更之輸入，其餘規格則已於訓練階段固定而無法於推論時修改。

第二階段為啟用 GPU 進行推論，邊緣裝置將角度條件向量輸入條件式生成器，啟用 GPU 執行單次前向傳播，並經 3.3 節之隨機相位預編碼遮罩與 Gumbel-Sigmoid 量化層處理後，於毫秒等級內輸出符合 1-bit 硬體規格之相位分布；由於本研究以單一模型承載多種角度規格之映射關係，此階段毋須針對不同角度組合重新載入或切換模型。前述兩階段於推論裝置上完成，亦為本論文實際部署與探討之核心。

第三階段起則屬研究團隊整體系統之硬體設計規劃，於第三階段中模型所輸出之二維相位分布將編碼為對應之控制字串，透過序列埠傳送至負責訊號發送之微控制器。第四階段為處理硬體排列並傳送至 RIS，微控制器解析所接收之控制字串，依面鏡之單元排列順序將其映射為各單元之實體控制訊號，再將該排列訊號傳送至 RIS 硬體。第五階段為 RIS 接收排列訊號並更新相位分布，RIS 依所接收之控制訊號逐一切換各單元之相位狀態，完成整面相位分布之更新，使入射電磁波依設計反射至目標方向，達成即時之波束成形。圖 3-11 為研究團隊的硬體流程圖，以實體裝置的角度呈現前述推論流程的對應關係。整套系統由推論裝置、控制裝置與可重構智慧面三個硬體單元依序串接而成。使用者輸入目標角度

後，推論裝置(NVIDIA Jetson AGX Orin) 會執行模型推論並輸出相位分布，再透過 USB 介面將結果傳送至控制裝置，也就是前述負責訊號發送的微控制器(ESP32)。控制裝置接著經由 GPIO 接腳進行 RIS 對應 (RIS Mapping)，將相位分布轉換為各單元的控制訊號後送至可重構智慧面，最終驅動面鏡更新整體的相位分布。相較於圖 3-10 著重在資料處理的邏輯流程，圖 3-11 進一步標示出各裝置之間的實體連接與傳輸介面補充呈現研究團隊系統在硬體層面的整體配置。

透過此一流程之規劃，可完整呈現本模型自接收指令至驅動硬體之系統定位，惟第三至第五階段之硬體訊號傳輸與相位切換並不在本論文之實測範圍之內，本論文之驗證與討論僅聚焦於推論裝置上之即時推論表現。



圖 3-10 整體推論流程圖




圖 3-11 硬體流程圖

為客觀評估模型於邊緣裝置上之即時推論能力，本研究進一步設計一套推論時間量測流程，如圖 3-12 所示，依序包含環境設定、暖機 (Warmup)、推論 (Inference)、GPU 完成時間計算 (Compute GPU Completion Time) 與結果儲存 (Save Result) 五個步驟。環境設定階段即執行 3.6.1 節所述之三項設定，確保裝置處於穩定且最高效能之狀態。

暖機階段於正式量測前預先執行 100 次推論，其目的在於排除程式首次執行時之初始化開銷，例如 CUDA 執行環境之建立、記憶體配置與運算核心之編譯等；此類一次性之啟動步驟若納入量測將導致時間結果失真，故須先行暖機使

裝置進入穩定運作狀態。推論階段隨機抽取各種入射與反射角組合並執行 500 次推論，藉由大量且多樣化之取樣，使量測結果能反映模型於各種角度規格下之平均推論表現。GPU 完成時間計算階段為時間量測之核心，本研究僅計算實際呼叫 GPU 並等待其運算完成所需之時間，並排除指令發送與資料傳輸等周邊開銷，使量測值能純粹反映模型本身之推論延遲。最後於結果儲存階段記錄每次推論之耗時，以供後續統計平均推論時間及各百分位數等指標。此一量測流程於單波束與多波束情境下皆予套用，相關之實測結果與分析將於第四章詳述。



圖 3-12 推論時間量測流程圖



第四章 實驗

承續第三章所建構之條件式生成器與訓練策略，本章透過一系列實驗對模型進行系統性驗證，以檢視其是否確實回應第 2.5 節所歸納之四項核心問題。本章欲確認單一模型能否以入射角與反射角組合作為動態輸入，涵蓋多種角度規格乃至複雜多波束場型之即時生成，並進一步檢視混合訓練機制對高自由度場景收斂品質之助益。除生成品質外，本章亦關注模型部署於資源受限之邊緣運算裝置後是否仍具備毫秒等級之推論速度，以及其所生成之 1-bit 相位分布於貼近真實硬體之電磁模擬環境下是否仍能維持預期之輻射場型品質。

本章共分為兩節，4.1 節說明實驗所使用之軟硬體環境、模擬工具與可調控之客製化參數範圍，作為後續各項實驗之共同基礎。4.2 節則進行五項實驗，其中實驗一與實驗三分別就單波束與多波束情境驗證模型於不同規格下之生成靈活性，並與既有逐規格訓練之方法相互比較，實驗二檢視啟發式神經網路混合訓練對高自由度多波束收斂之助益，實驗四量測模型於邊緣運算裝置上之平均推論時間，以評估其即時性，實驗五則依實際 RIS 硬體之近場設計參數，以電磁模擬比對理論公式解與模擬解之差異，並檢視 1-bit 量化所致鏡像波束之抑制成效。綜合上述實驗，本章將完整呈現本研究方法於設計靈活性、訓練穩定性、即時性與貼近真實硬體驗證四個面向之表現。

4.1 實驗環境說明

本研究的條件式生成器模型是以 Python 完成，並使用 Ansys HFSS 進行電磁模擬，驗證訓練完之相位分布的輻射場型。而下列分別為本研究在實驗的硬體環境與程式執行環境：

- 模型訓練環境：

- 硬體環境

- ◆ CPU: Intel Xeon E5-2698 v4 2.2 GHz (20-Core, 40-Threads)
 - ◆ RAM: 256G ECC Registered RDIMM DDR4 SDRAM

- ◆ GPU: Nvidia Tesla V100-DGXS-32GB
- 軟體環境
 - ◆ 作業系統: Ubuntu 20.04.2 LTS
 - ◆ 程式語言: Python 3.10.12
 - ◆ 深度學習函式庫: Pytorch 2.4.0、Cuda 12.4
- 電磁模擬環境:
 - 硬體環境
 - ◆ CPU: Intel® Core™ i9-14900 2.0 GHz (24-Core, 32-Threads)
 - ◆ RAM: 128G Micron Crucial DDR5-5600 UDIMM
 - 程式環境
 - ◆ 作業系統: Microsoft Windows 11 程式語言: Python 3.10.12
 - ◆ 模擬程式: Ansys Electronics Desktop 2023 R2 (HFSS)
- 邊緣裝置環境:
 - 硬體環境
 - ◆ 設備名稱: Nvidia Jetson AGX Orin
 - ◆ CPU: 12-core Arm Cortex-A78AE v8.2 64-bit CPU 3MB L2 + 6MB L3
 - ◆ GPU: NVIDIA Ampere architecture with 2048 NVIDIA CUDA® cores and 64 tensor cores
 - ◆ RAM: 64GB 256-bit LPDDR5
 - 軟體環境
 - ◆ 作業系統: Ubuntu 20.04.2 LTS
 - ◆ 程式語言: Python 3.10.12
 - ◆ 深度學習函式庫: Pytorch 2.4.0、Cuda 12.4

本節接續說明實驗所使用之客製化參數，這些參數依其設定時機與可否於推論階段變更，可區分為兩類，分別以表 4-1 與表 4-2 呈現。第一類為訓練前於訓練腳本中預先設定之規格參數，此類參數於訓練過程中固化為模型權重之一部分，模型部署後即無法變更，其涵蓋單元尺寸、工作頻率、訊號源與電磁面鏡距離、電磁面鏡與接收器距離、電磁波入射與反射角度之 φ 平面設定，以及主波束寬度與旁波瓣位準等場型品質規範，如表 4-1 所示，這些參數界定了模型所能生成之規格空間。

表 4-1 訓練腳本設定之規格參數範圍

參數名稱	可調控數值範圍
單元尺寸	16×16 、 32×32
工作頻率	4.7GHz、28GHz
訊號源與電磁面鏡距離	0.45m、0.7m、1.2m
電磁面鏡與接收器距離	2.75m、無窮遠
電磁波入射角度 φ 範圍	0° 、 90°
電磁波反射角度 φ 範圍	0° 、 90°
主波束寬度	$< 20^\circ$
旁波瓣位準	$\leq 20\text{dB}$

第二類為使用者於推論階段可動態指定之角度參數，包含電磁波入射角度 θ 與反射角度 θ ，如表 4-2 所示。在多波束情境下，反射角度 θ 為對應波束數量之多個角度。此類角度即構成模型之角度條件向量，為模型部署後使用者唯一能即時變更之輸入。模型接收該角度輸入後，即生成對應之相位分布，並經由陣列天線公式轉換為輻射場型以驗證其效果是否符合需求，若符合則進一步以電磁模擬軟體進行量測。

表 4-2 使用者可輸入角度參數

參數名稱	可調控數值範圍
電磁波入射角度 θ 範圍	(0°:10°:50°)
電磁波單波束反射角度 θ 範圍	(-60°:10°:60°)
電磁波多波束反射角度 θ 範圍	(-60°:1°:60°)

由表 4-1 與表 4-2 之區分可知，本研究採訓練前預設規格與推論階段輸入角度之兩階段設計，使單一模型得以在固定規格下即時響應使用者對波束指向之動態需求，而毋須針對每一角度組合重新訓練或切換模型。

4.2 實驗設計與結果

為驗證本研究所提條件式生成器之效果，本節依第三章之模型架構與訓練策略設計五項實驗，以驗證第三章表 3-1 所歸納並承接自第 2.5 節之四項核心問題。其中實驗一與實驗三分別就單波束與多波束情境驗證設計靈活性，確認單一條件式生成器能否涵蓋多種角度規格並合成多波束場型。實驗二對應高自由度規格與離散量化所致之訓練困難，驗證啟發式神經網路混合訓練機制對損失收斂之改善程度，以說明模型於龐大多波束解空間中突破收斂瓶頸之能力。實驗四對應即時性需求，量測模型部署於邊緣運算裝置後之平均推論時間，並一併呈現其輕量化部署之可行性。實驗五則依實際 RIS 硬體之近場設計參數，比較陣列因子公式解與電磁模擬解之差異以驗證貼近真實硬體之效能，並透過檢視 1-bit 量化鏡像波束之抑制成效，確認二值化量化之解決策略於真實環境下仍然有效。

各實驗所生成之相位分布皆經第 2.1 節公式 (2) 之陣列因子轉換為輻射場型，並依第 3.5 節之性能度量計算方法取得主波束反射角度、半功率波束寬、旁波瓣位準與訊號強度四項指標，再以表 3-2 之容忍區間判定合格與否；訊號強度之合格門檻取自表 3-3 至表 3-5 之理想增益值乘以 0.8。

4.2.1 實驗一 單波束於不同規格下之相位分布生成效果探討

● 實驗目的

本實驗驗證本研究所提條件式生成器於單波束情境下的相位分布生成能力，並與曾俊瑋 [20] 及蔡奇倫 [21] 所提出的方法進行對比。對比的核心並非單純的性能優劣，而是兩種方法在規格泛化能力與單一規格最佳化品質之間所呈現的設計權衡。蔡奇倫的方法針對每一組角度規格獨立訓練一個專屬模型，因此每個模型皆可充分擬合該規格的相位分布，於各項性能指標上可達到極佳的水準。然而此一架構的代價是規格切換的高昂成本，每當需要支援新的入射或反射角組合時，必須重新訓練一個全新模型，無法應對 6G 通訊場景中終端使用者位置持續變動所需的即時規格切換需求。

本研究的條件式生成器則於單一模型內承載大量規格組合，毋須針對個別規格重新訓練。本研究預期於各項性能指標上的合格率略低於蔡奇倫的方法，因為單一模型須同時兼顧大量規格而無法針對個別規格極致最佳化。然而本研究方法在規格切換的彈性與訓練成本上具有顯著優勢，可滿足實際通訊場景對動態波束追蹤的需求。本實驗的目的即是量化此一權衡關係，提供使用者於品質與靈活性之間進行客觀比較的依據。

● 實驗內容

本實驗將分為兩個部分，第一個部分檢視本研究方法於多種規格參數組合下之整體生成能力，涵蓋不同 RIS 單元大小、不同工作頻率、不同訊號源與面鏡距離，以及不同之入射與反射角組合，至於角度的組合依表 4-3 所示，電磁波入射與反射角度 φ 範圍為 0° 與 90° ，電磁波入射角度 θ 範圍為 0° 至 50° 並以 10° 為間隔，電磁波反射角度 θ 範圍為 -60° 至 60° 並以 10° 為間隔。隨後模型以正規化後之角度條件向量作為輸入，輸出對應之 1-bit 相位分布，再經陣列因子公式轉換為輻射場型，並輸入第 3.5 節之驗證性能度量程式計算主波束反射角度、半功率波束寬、旁波瓣位準與訊號強度四項指標，依容忍區間判定是否合格。

第二個部分則於相同規格下與曾俊瑋之非監督式生成方法及蔡奇倫之位元遷移策略進行直接性能對比，為求對比盡量公正，皆採相同之角度規格集合；曾俊瑋與蔡奇倫之方法皆為每一規格訓練專屬模型，本研究則以單一條件式生成器涵蓋全部規格。比較項目除四項性能度量之合格率外，另納入規格切換成本與訓練成本，以完整呈現品質與靈活性之權衡。

表 4-3 單波束輸入角度規格表

輸入參數	數值
電磁波入射角度 φ 範圍	0° 、 90°
電磁波反射角度 φ 範圍	0° 、 90°
電磁波入射角度 θ 範圍	$[0^\circ : 10^\circ : 50^\circ]$
電磁波反射角度 θ 範圍	$[-60^\circ : 10^\circ : 60^\circ]$

● 實驗結果

表 4-4 至表 4-23 分別為不同參數規格下之相位分布生成結果，表格中將會標示客製化電磁面鏡規格參數以及經過 Array Factor 公式性能度量後的結果，達標的數值將不會做任何標示，若該項數值未達標的話，則會以紅字做標示；表 4-23 則會與過往方法進行比較，從每一項指標是否有達標的方式判斷方法的優勢並於實驗觀察中探討其權衡關係。

表 4-4 16 × 16 參數組合其一之生成結果



客製化電磁面鏡規格	
● 單元數量: 16 × 16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): (0°, 0°)	● 半功率波束寬: 6°
● 反射角度(θ, φ): (30°, 90°)	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: 29.3° 半功率波束寬: 7.7° 旁波瓣位準: 11.3 dB 主波束增益: 43.5 dB

表 4-5 16×16 參數組合其二之生成結果



客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): $(10^\circ, 0^\circ)$	● 半功率波束寬: 6°
● 反射角度(θ, φ): $(-40^\circ, 90^\circ)$	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: -39.6° 半功率波束寬: 8.9° 旁波瓣位準: 11.6 dB 主波束增益: 43.4 dB

表 4-6 16×16 參數組合其三之生成結果



客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): $(20^\circ, 0^\circ)$	● 半功率波束寬: 6°
● 反射角度(θ, φ): $(50^\circ, 90^\circ)$	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
 16x16 4.7GHz 1bit Array Factor inc=20° ref= 50°	
相位分布	性能度量 (Array Factor)
 1-bit Phase Distribution (inc=20.0°, ref=50.0°)	反射角度: 51.3° 半功率波束寬: 10.7° 旁波瓣位準: 12.2 dB 主波束增益: 43.8 dB

表 4-7 16 × 16 參數組合其四之生成結果



客製化電磁面鏡規格	
● 單元數量: 16 × 16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): (40°, 0°)	● 半功率波束寬: 6°
● 反射角度(θ, φ): (60°, 90°)	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: 59.8° 半功率波束寬: 13.3° 旁波瓣位準: 12.0 dB 主波束增益: 42.4 dB

表 4-8 16 × 16 參數組合其五之生成結果




客製化電磁面鏡規格	
● 單元數量: 16 × 16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): (50°, 0°)	● 半功率波束寬: 6°
● 反射角度(θ, φ): (-20°, 90°)	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
 16x16 4.7GHz 1bit Array Factor inc=50° ref= -20°	
相位分布	性能度量 (Array Factor)
 1-bit Phase Distribution (inc=50.0°, ref=-20.0°)	反射角度: -19.8° 半功率波束寬: 7.2° 旁波瓣位準: 11.6 dB 主波束增益: 42.7 dB

表 4-9 16 × 16 參數組合其六之生成結果

客製化電磁面鏡規格	
● 單元數量: 16 × 16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): (0°, 0°)	● 半功率波束寬: 6°
● 反射角度(θ, φ): (-40°, 90°)	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 1.2 m	● 電磁面鏡與接收器距離: 2.75 m

輻射場型	
	


相位分布	性能度量 (Array Factor)
	反射角度: -39.7° 半功率波束寬: 8.7° 旁波瓣位準: 13.8 dB 主波束增益: 44.0 dB

表 4-10 16 × 16 參數組合其七之生成結果



客製化電磁面鏡規格	
● 單元數量: 16 × 16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): (20°, 0°)	● 半功率波束寬: 6°
● 反射角度(θ, φ): (10°, 90°)	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 1.2 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: 10.1° 半功率波束寬: 6.8° 旁波瓣位準: 10.8 dB 主波束增益: 43.7 dB

表 4-11 16 × 16 參數組合其八之生成結果



客製化電磁面鏡規格	
● 單元數量: 16 × 16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): (30°, 0°)	● 半功率波束寬: 6°
● 反射角度(θ, φ): (-50°, 90°)	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 1.2 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
 16x16 4.7GHz 1bit Array Factor inc=30° ref= -50°	
相位分布	性能度量 (Array Factor)
 1-bit Phase Distribution (inc=30.0°, ref=-50.0°)	反射角度: -50.2° 半功率波束寬: 10.5° 旁波瓣位準: 9.6 dB 主波束增益: 43.5 dB

表 4-12 16×16 參數組合其九之生成結果



客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): $(40^\circ, 0^\circ)$	● 半功率波束寬: 6°
● 反射角度(θ, φ): $(0^\circ, 90^\circ)$	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 1.2 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: -0.2° 半功率波束寬: 6.8° 旁波瓣位準: 11.9 dB 主波束增益: 43.7 dB

表 4-13 16 × 16 參數組合其十之生成結果



客製化電磁面鏡規格	
● 單元數量: 16 × 16	● 理想增益: 45 dB
● 工作頻率: 4.7 GHz	● 期望增益: 36 dB
● 入射角度(θ, φ): (50°, 0°)	● 半功率波束寬: 6°
● 反射角度(θ, φ): (-10°, 90°)	● 旁波瓣位準: 15 dB
● 訊號源與電磁面鏡距離: 1.2 m	● 電磁面鏡與接收器距離: 2.75 m
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: -9.8° 半功率波束寬: 6.8° 旁波瓣位準: 11.9 dB 主波束增益: 43.9 dB

表 4-14 32×32 參數組合其一之生成結果



客製化電磁面鏡規格	
● 單元數量: 32×32	● 理想增益: 57 dB
● 工作頻率: 28 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): $(0^\circ, 90^\circ)$	● 半功率波束寬: 3°
● 反射角度(θ, φ): $(50^\circ, 90^\circ)$	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.7 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
 32x32 28GHz 1bit Array Factor inc=0° ref=50°	
相位分布	性能度量 (Array Factor)
 1-bit Phase Distribution (inc=0.0°, ref=50.0°)	反射角度: 50.0° 半功率波束寬: 5.1° 旁波瓣位準: 14.2 dB 主波束增益: 54.5 dB

表 4-15 32 × 32 參數組合其二之生成結果



客製化電磁面鏡規格	
● 單元數量: 32 × 32	● 理想增益: 57 dB
● 工作頻率: 28 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): (20°, 90°)	● 半功率波束寬: 3°
● 反射角度(θ, φ): (0°, 90°)	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.7 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: 0.0° 半功率波束寬: 3.3° 旁波瓣位準: 14.2 dB 主波束增益: 55.2 dB

表 4-16 32 × 32 參數組合其三之生成結果



客製化電磁面鏡規格	
● 單元數量: 32 × 32	● 理想增益: 57 dB
● 工作頻率: 28 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): (30°, 90°)	● 半功率波束寬: 3°
● 反射角度(θ, φ): (−60°, 90°)	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.7 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: −59.9° 半功率波束寬: 6.5° 旁波瓣位準: 15.0 dB 主波束增益: 55.3 dB

表 4-17 32 × 32 參數組合其四之生成結果



客製化電磁面鏡規格	
● 單元數量: 32 × 32	● 理想增益: 57 dB
● 工作頻率: 28 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): (40°, 90°)	● 半功率波束寬: 3°
● 反射角度(θ, φ): (-30°, 90°)	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.7 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: -29.9° 半功率波束寬: 3.8° 旁波瓣位準: 15.0 dB 主波束增益: 55.1 dB

表 4-18 32×32 參數組合其五之生成結果



客製化電磁面鏡規格	
● 單元數量: 32×32	● 理想增益: 57 dB
● 工作頻率: 28 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): $(50^\circ, 90^\circ)$	● 半功率波束寬: 3°
● 反射角度(θ, φ): $(-40^\circ, 90^\circ)$	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.7 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
32x32 28GHz 1bit Array Factor inc=50° ref=-40° 	
相位分布	性能度量 (Array Factor)
	反射角度: -39.8° 半功率波束寬: 4.2° 旁波瓣位準: 13.9 dB 主波束增益: 55.0 dB

表 4-19 32×32 參數組合其六之生成結果


客製化電磁面鏡規格	
● 單元數量: 32×32	● 理想增益: 57 dB
● 工作頻率: 4.7 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): $(0^\circ, 90^\circ)$	● 半功率波束寬: 3°
● 反射角度(θ, φ): $(-40^\circ, 0^\circ)$	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: -39.7° 半功率波束寬: 4.4° 旁波瓣位準: 14.0 dB 主波束增益: 54.3 dB

表 4-20 32×32 參數組合其七之生成結果



客製化電磁面鏡規格	
● 單元數量: 32×32	● 理想增益: 57 dB
● 工作頻率: 4.7 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): $(10^\circ, 90^\circ)$	● 半功率波束寬: 3°
● 反射角度(θ, φ): $(20^\circ, 0^\circ)$	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
32x32 4.7GHz 1bit Array Factor inc=10° ref=20° 	
相位分布	性能度量 (Array Factor)
	反射角度: 20.0° 半功率波束寬: 3.5° 旁波瓣位準: 15.1 dB 主波束增益: 55.1 dB

表 4-21 32×32 參數組合其八之生成結果



客製化電磁面鏡規格	
● 單元數量: 32×32	● 理想增益: 57 dB
● 工作頻率: 4.7 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): $(30^\circ, 90^\circ)$	● 半功率波束寬: 3°
● 反射角度(θ, φ): $(0^\circ, 0^\circ)$	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: 0.0° 半功率波束寬: 3.2° 旁波瓣位準: 13.7 dB 主波束增益: 55.4 dB

表 4-22 32×32 參數組合其九之生成結果



客製化電磁面鏡規格	
● 單元數量: 32×32	● 理想增益: 57 dB
● 工作頻率: 4.7 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): ($40^\circ, 90^\circ$)	● 半功率波束寬: 3°
● 反射角度(θ, φ): ($50^\circ, 0^\circ$)	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
32x32 4.7GHz 1bit Array Factor inc=40° ref=50° 	
相位分布	性能度量 (Array Factor)
	反射角度: 50.0° 半功率波束寬: 5.1° 旁波瓣位準: 14.3 dB 主波束增益: 54.7 dB

表 4-23 32×32 參數組合其十之生成結果



客製化電磁面鏡規格	
● 單元數量: 32×32	● 理想增益: 57 dB
● 工作頻率: 4.7 GHz	● 期望增益: 45 dB
● 入射角度(θ, φ): $(50^\circ, 90^\circ)$	● 半功率波束寬: 3°
● 反射角度(θ, φ): $(-40^\circ, 0^\circ)$	● 旁波瓣位準: 20 dB
● 訊號源與電磁面鏡距離: 0.45 m	● 電磁面鏡與接收器距離: 無窮遠
輻射場型	
	
相位分布	性能度量 (Array Factor)
	反射角度: -39.9° 半功率波束寬: 4.5° 旁波瓣位準: 13.8 dB 主波束增益: 54.3 dB

表 4-24 不同方法之單波束相位分布生成結果比較

客製化電磁面鏡規格			
文獻 [20]、文獻 [21]		本研究方法	
● 單元數量: 40×40 ● 入射角度(θ, φ): $(30^\circ, 90^\circ)$ ● 反射角度(θ, φ): $(-30^\circ, 0^\circ)$ ● 理想增益: 60 dB ● 期望增益: 48 dB ● 半功率波束寬: 3° ● 旁波瓣位準: 20 dB		● 單元數量: 32×32 ● 入射角度(θ, φ): $(30^\circ, 90^\circ)$ ● 反射角度(θ, φ): $(-30^\circ, 0^\circ)$ ● 理想增益: 57 dB ● 期望增益: 45 dB ● 半功率波束寬: 3° ● 旁波瓣位準: 15 dB	
性能度量 (Array Factor)	文獻 [20]	文獻 [21]	本研究方法
主波束反射角度	-29.9°	-30.6°	-29.6°
半功率波束寬	3.9°	3.4°	3.9°
旁波瓣位準	10.0 dB	15.0 dB	15.0 dB
主波束增益	49.0 dB	58.0 dB	55.0 dB
是否支援即時切換規格	否	否	是

● 實驗觀察

由表 4-4 至 表 4-23 可見，本研究之條件式生成器展現出橫跨多項客製化參數之泛化能力。在單元尺寸方面涵蓋 16×16 與 32×32 兩種規格，在工作頻率方面涵蓋 4.7 GHz 與 28 GHz，在訊號源與電磁面鏡距離方面則涵蓋 0.45 公尺、0.7 公尺與 1.2 公尺等多種設定，並進一步涵蓋入射 θ 角 0° 至 50° 與反射 θ 角 -60° 至 60° 之大量入射與反射角組合，同時入射 φ 角與反射 φ 角也有 0° 和 90° 等不同組合。於上述各種參數彼此交錯之規格下，模型皆能

依輸入之角度條件向量生成指向正確且品質良好之 1-bit 相位分布，其中主波束增益之表現最為穩定，各規格之主波束增益均高於期望增益值並逼近理想增益值，主波束反射角度於多數規格下亦能落於 $\pm 1^\circ$ 之容忍區間內。此結果說明單一模型不僅能適應角度之動態變化，亦能在不同單元尺寸、工作頻率與收發距離之間自由切換而維持一致之生成品質，驗證 FiLM 機制確能於同一組權重內，依正規化後之角度條件動態切換出對應之子網路響應，達成單一模型涵蓋多種角度規格之設計目標，亦即第 2.5 節所定義之設計靈活性需求。

由表 4-24 之對比可見，文獻 [20] 之主波束增益僅略高於期望增益值，與其理想增益 60 dB 仍有相當差距，且其旁波瓣位準僅 10.0 dB，與所設定之目標旁波瓣位準 20.0 dB 相差甚遠；至於看到文獻 [21] 的部分，可以發現其主波束增益的表現上與理想增益非常接近，且旁波瓣位準比起文獻 [20] 擁有更好的表現；最後探討本研究的方法，雖於主波束增益的表現不如文獻 [21]，不過在旁波瓣位準的部分有顯現出同等的優勢，且其關鍵優勢在於規格切換，新增任意入射與反射角組合時，其他方法須重新訓練一個專屬模型，本研究僅需輸入對應之角度條件向量即可即時生成。

至於本研究於單規格生成品質上略低於逐規格訓練方法之現象，其成因可歸於單一模型須同步承載龐大規格空間所致之權衡。由於模型於訓練時所最佳化者為整體規格空間之平均表現，而非任一特定規格之極致效能，其必須在數量龐大之規格之間分配有限之表徵能力，因而無法如文獻 [21] 之逐規格專屬訓練般針對單一規格深度擬合。此一單規格品質之些微讓步並非源自訓練流程之瑕疵，而是模型為換取跨規格泛化能力與近乎為零之切換成本所付出之必然代價，恰為本研究所欲量化之品質與靈活性權衡之具體體現。

此實驗結果印證本研究目的所述之品質與靈活性權衡，本研究以略低之單規格品質，換取單一角度規格模型架構所無法提供之規格泛化能力與近乎為零之切換成本，恰對應 6G 終端使用者位置持續變動所需之即時切換需求。

4.2.2 實驗二 混合訓練方法於模型的提升能力實驗

● 實驗目的

本實驗旨在驗證第 3.4.3 節所提出之啟發式神經網路混合訓練機制對訓練後期收斂瓶頸之突破能力。多波束情境因離散搜尋空間龐大，僅以當前的方法進行訓練易停滯於局部最佳解，因此本實驗將測試此混合式訓練所生成之相位分布的品質提升能力，並觀察實驗參數如單次抽取數量 (Batch)、單元翻轉數量以及迭代次數於 Loss 曲線的收斂影響，確認混合訓練是否能有效提升多波束之主波束增益與旁波瓣抑制效果。

● 實驗內容

本實驗以四波束情境為主要測試對象，單波束因搜尋空間相對較小，實驗一並未啟用該機制進行訓練。實驗採第 3.4.3 節所述之兩階段訓練，第一階段以多波束損失函數進行基礎訓練，使模型穩定習得角度條件至相位分布之基本映射；第二階段以第一階段之最佳權重為起點啟動混合訓練機制，於每一訓練步驟先由模型前向預測，再於其鄰域內執行 T 步貪婪式 1-bit 翻轉搜尋，並以引導式損失 $\mathcal{L}_{guide}$ 將優於模型自身輸出之離散解回饋至權重更新。

本次實驗將會先針對可調參數進行實驗、如單次抽取數量、單元翻轉數量以及迭代次數，詳細參數設定範圍如表 4-25 所示，測試在不同設定下這些參數對於 Loss 收斂的影響為何，最後將會根據以上參數觀察的結果進行最終模型能力提升測試，最終實驗設定之參數 Batch 大小設定為 1280000、翻轉單元數量為 1 或是 3、迭代次數為 5，參數的設定理由會在實驗觀察中講解，再來將會以多波束原始訓練結束後之模型權重作為提升目標。

表 4-25 混合式訓練方法可調參數範圍

參數名稱	可調控數值範圍
單次抽取數量 (Batch)	25600、51200、256000
翻轉單元數量	1、2、3
迭代次數	5、10、20

● 實驗結果

表 4-26、表 4-27、表 4-28 為混合式訓練方法可調參數的個別測試結果，透過固定測試參數來觀察其對 Loss 曲線的收斂影響為何；至於表 4-29 為多波束原始訓練與起用混合式訓練後之 Loss 曲線結果，而混合式訓練分別為訓練前期與後期採用不同的訓練設定。



表 4-26 Batch 大小測試結果




訓練 Loss 曲線圖	訓練設定
	Batch: 25600 翻轉單元數量: 1 迭代次數: 10 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3641.69
訓練 Loss 曲線圖	訓練設定
	Batch: 51200 翻轉單元數量: 1 迭代次數: 10 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3586.11
訓練 Loss 曲線圖	訓練設定
	Batch: 256000 翻轉單元數量: 1 迭代次數: 10 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3401.65

表 4-27 翻轉單元數量測試結果




訓練 Loss 曲線圖	訓練設定
	Batch: 25600 翻轉單元數量: 1 迭代次數: 10 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3641.69
訓練 Loss 曲線圖	訓練設定
	Batch: 25600 翻轉單元數量: 2 迭代次數: 10 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3647.96
訓練 Loss 曲線圖	訓練設定
	Batch: 25600 翻轉單元數量: 3 迭代次數: 10 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3651.24

表 4-28 迭代次數測試結果







訓練 Loss 曲線圖	訓練設定
	Batch: 25600 翻轉單元數量: 1 迭代次數: 5 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3634.14
訓練 Loss 曲線圖	訓練設定
	Batch: 25600 翻轉單元數量: 1 迭代次數: 10 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3641.69
訓練 Loss 曲線圖	訓練設定
	Batch: 25600 翻轉單元數量: 1 迭代次數: 20 訓練 Epoch 數量: 1000
	訓練結果
	Best Loss: 3649.22

表 4-29 原始訓練與混合訓練方法之訓練結果比較

原始訓練 Loss 曲線圖 <table><caption>原始訓練 Loss 數據 (估計值)</caption><thead><tr><th>Epoch</th><th>Average Loss</th></tr></thead><tbody><tr><td>1.0</td><td>100.0</td></tr><tr><td>2.0</td><td>86.5</td></tr><tr><td>3.0</td><td>86.5</td></tr><tr><td>4.0</td><td>87.5</td></tr><tr><td>5.0</td><td>90.0</td></tr></tbody></table>	Epoch	Average Loss	1.0	100.0	2.0	86.5	3.0	86.5	4.0	87.5	5.0	90.0								
Epoch	Average Loss																			
1.0	100.0																			
2.0	86.5																			
3.0	86.5																			
4.0	87.5																			
5.0	90.0																			
訓練設定 • 訓練 Epoch 數量: 5																				
混合式訓練初期設定之訓練 Loss 曲線圖 <table><caption>混合式訓練初期設定 Loss 數據 (估計值)</caption><thead><tr><th>Epoch</th><th>Avg Loss</th></tr></thead><tbody><tr><td>0</td><td>105.0</td></tr><tr><td>25</td><td>95.0</td></tr><tr><td>50</td><td>90.0</td></tr><tr><td>75</td><td>87.0</td></tr><tr><td>100</td><td>85.0</td></tr><tr><td>125</td><td>83.0</td></tr><tr><td>150</td><td>82.0</td></tr><tr><td>175</td><td>81.0</td></tr><tr><td>185</td><td>81.0</td></tr></tbody></table>	Epoch	Avg Loss	0	105.0	25	95.0	50	90.0	75	87.0	100	85.0	125	83.0	150	82.0	175	81.0	185	81.0
Epoch	Avg Loss																			
0	105.0																			
25	95.0																			
50	90.0																			
75	87.0																			
100	85.0																			
125	83.0																			
150	82.0																			
175	81.0																			
185	81.0																			
訓練設定 • 翻轉單元數量: 3 • 迭代次數: 5 • 訓練 Epoch 數量: 185																				
混合式訓練後期設定之訓練 Loss 曲線圖 <table><caption>混合式訓練後期設定 Loss 數據 (估計值)</caption><thead><tr><th>Epoch</th><th>Avg Loss</th></tr></thead><tbody><tr><td>0</td><td>79.5</td></tr><tr><td>200</td><td>77.5</td></tr><tr><td>400</td><td>76.5</td></tr><tr><td>600</td><td>75.5</td></tr><tr><td>800</td><td>74.8</td></tr><tr><td>1000</td><td>74.5</td></tr></tbody></table>	Epoch	Avg Loss	0	79.5	200	77.5	400	76.5	600	75.5	800	74.8	1000	74.5						
Epoch	Avg Loss																			
0	79.5																			
200	77.5																			
400	76.5																			
600	75.5																			
800	74.8																			
1000	74.5																			
訓練設定 • 翻轉單元數量: 1 • 迭代次數: 5 • 訓練 Epoch 數量: 1000																				

● 實驗觀察

由表 4-26 可以發現，當 Batch 大小設定越大時，Loss 下降的趨勢越明顯，但同時每一次進行迭代的樣本數量變得更多，代表訓練的時間也會跟著變多。在單元翻轉數量之設定上，從表 4-27 可以觀察到，當翻轉單元數量為 1 時，模型能夠有效探索到更低的 Loss 值，此現象說明了較小的擾動有利於在解空間中進行微調，進而能夠有效突破局部最佳解。至於翻轉次數的部分，由表 4-28 可以看到，迭代次數以 5 次為最佳，優化效益便趨近於飽和，代表在兼顧收斂效率與訓練速度的前提下，並沒有將其設高的必要。

再來將進一步探討原始多波束訓練與套用混合式訓練方法後之結果差異，如表 4-29 所示，首先觀察原始多波束訓練之 Loss 曲線可見，模型於訓練前期僅到第 3 個 Epoch 時，Loss 就已停止收斂，這是因為多波束的輸入角度組合過於龐大，所以代表僅依靠模型訓練是無法負荷的，導致整體的訓練效果受到影響。而在套用混合式訓練方法後，透過前期設定翻轉單元數為 3，模型在前期訓練中能夠快速找到更好的解，Loss 曲線亦呈現快速收斂的趨勢。然而一到訓練後期，過大的翻轉數量反而沒辦法有效突破局部最佳解，再來就會把單元數量調整為 1，我們可以發現經此調整後，Loss 曲線轉以穩定的趨勢進行收斂，雖然收斂的速度慢，但卻可以有效的一直突破局部最佳解。

4.2.3 實驗三 多波束於不同規格下之相位分布生成效果探討

● 實驗目的

本實驗旨在評估本研究模型生成複雜多波束輻射場型之能力，同時與經實驗二的方法優化後之模型進行比較。於多使用者通訊場景中，單一 RIS 往往須同時將訊號導向多個方向，故模型須能依角度條件向量同步生成具備多個主波束之相位分布。本實驗將驗證模型於雙波束、三波束與四波束情境下，是否能精準控制各主波束之反射角度與波束寬度，並確認其峰值增益是否符合第 3.5 節所推導之多波束理想增益上限。與此同時，將會額外測試此方法是否能夠生成指定角度之寬波束輻射場型，驗證模型的生成泛化性。

● 實驗內容

本次實驗將電磁面鏡參數固定為單元尺寸 16×16 、工作頻率 4.7 GHz、訊號源與電磁面鏡距離 0.45 公尺、電磁面鏡與接收器距離 2.75 公尺，而多波束之輸入角度規格如表 4-30 所示，其反射角度改以 1° 為間隔，其餘數值與單波束規格相同。就規格空間之規模而言，本實驗之入射角 θ 於 0° 至 50° 間以 10° 為間隔，共 6 種取值，反射角 θ 於 -60° 至 60° 間以 1° 為間隔，共 121 種取值。在每一多波束情境下， K 個反射角須彼此相異且不計順序，故於固定 φ 之條件下，雙波束之可生成規格組合數為 $6 \times C(121, 2)$ ，約為 4.36 萬組，三波束為 $6 \times C(121, 3)$ ，約為 173 萬組，四波束則為 $6 \times C(121, 4)$ ，高達約 5097 萬組，而寬波束係由四波束以固定且相近之間距並排所構成，屬四波束規格之特例。由此可見，本研究單一模型所須涵蓋之多波束規格空間極為龐大，此亦正是第 2.5 節第三項問題所述龐大規格訓練困難之來源，並凸顯實驗二啟發式神經網路混合訓練機制之必要性。依第 3.2.1 節之定義，多波束情境之角度條件向量包含一個入射角分量與 K 個反射角分量，本實驗分別設計雙波束 ($K = 2$)、三波束 ($K = 3$) 與四波束 ($K = 4$) 之角度組合，另外還會額外測試寬波束的生成效果，只要將輸入的四個角度以固定間距隔開，將會得到類似的效果。至於損失函數採第 3.4.2 節建構之多波束損失函數，並依公式 (24) 將主波束目標增益隨波束數量調整為理想的大小。隨後將會比較無經過啟發式神經網路混合訓練機制與有經過該方法之生成效果對比。生成之相位分布同樣經陣列因子公式轉換為輻射場型，並針對每一目標主波束方向獨立計算其反射角度、半功率波束寬、旁波瓣位準與訊號強度，依容忍區間判定合格與否。

表 4-30 多波束輸入角度規格表

輸入參數	數值
電磁波入射角度 φ 範圍	0°
電磁波反射角度 φ 範圍	90°
電磁波入射角度 θ 範圍	$[0^\circ : 10^\circ : 50^\circ]$
電磁波反射角度 θ 範圍	$[-60^\circ : 1^\circ : 60^\circ]$

● 實驗結果

表 4-31 至表 4-34 分別為雙波束、三波束、四波束與寬波束情境下之相位分布生成結果。每一表格皆以四個欄位呈現單一規格之完整資訊，左上欄為模型所預測之相位分布，右上欄為該次生成所對應之客製化電磁面鏡規格，左下欄為相位分布經陣列因子公式轉換後之輻射場型，右下欄則為性能度量之驗證數值。性能度量涵蓋各主波束之反射角度、半功率波束寬、旁波瓣位準與主波束增益四項指標，並依第 3.5 節所訂之容忍區間判定合格與否，凡主波束增益未達期望增益值或半功率波束寬超出容忍範圍者，皆以紅字標示。而各表僅自完整規格集合中選取具代表性之角度組合呈現。

表 4-31 雙波束生成結果



客製化電磁面鏡規格	
● 單元數量: 16×16 ● 入射角度 $\varphi_{inc}: 0^\circ$ ● 反射角度 $\varphi_{ref}: 90^\circ$ ● 入射角度 $\theta_{inc}: 10^\circ$ ● 反射角度($\theta_{ref1}, \theta_{ref2}, \theta_{ref3}, \theta_{ref4}$): ($-35^\circ, -34^\circ, 2^\circ, 3^\circ$)	● 理想增益: 42 dB ● 期望增益: 33 dB ● 半功率波束寬: 6° ● 訊號源與電磁面鏡距離: 0.45 m ● 電磁面鏡與接收器距離: 2.75 m
輻射場型比較	相位分布
	
性能度量 (Array Factor)	
反射角度: ($-34.5^\circ, -34.5^\circ, 2.5^\circ, 2.5^\circ$) 波束寬: ($7.8^\circ, 7.8^\circ, 6.7^\circ, 6.7^\circ$) 旁波瓣位準: 13.2 dB 主波束增益: (36.9, 36.9, 37.5, 37.5) dB	

表 4-32 三波束生成結果



客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 40 dB
● 入射角度 φ_{inc} : 0°	● 期望增益: 32 dB
● 反射角度 φ_{ref} : 90°	● 半功率波束寬: 6°
● 入射角度 θ_{inc} : 10°	● 訊號源與電磁面鏡距離: 0.45 m
● 反射角度($\theta_{ref1}, \theta_{ref2}, \theta_{ref3}, \theta_{ref4}$): ($-43^\circ, -18^\circ, -17^\circ, 29^\circ$)	● 電磁面鏡與接收器距離: 2.75 m
輻射場型比較	相位分布
	
性能度量 (Array Factor)	
反射角度: ($-43.0^\circ, -18.0^\circ, -17.0^\circ, 29.0^\circ$) 波束寬: ($8.9^\circ, 7.8^\circ, 7.8^\circ, 7.4^\circ$) 旁波瓣位準: 11.6 dB 主波束增益: (36.9, 37.3, 37.3, 37.2) dB	

表 4-33 四波束生成結果





客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 39 dB
● 入射角度 φ_{inc} : 0°	● 期望增益: 31 dB
● 反射角度 φ_{ref} : 90°	● 半功率波束寬: 6°
● 入射角度 θ_{inc} : 10°	● 訊號源與電磁面鏡距離: 0.45 m
● 反射角度($\theta_{ref1}, \theta_{ref2}, \theta_{ref3}, \theta_{ref4}$): ($-43^\circ, -17^\circ, 1^\circ, 56^\circ$)	● 電磁面鏡與接收器距離: 2.75 m
輻射場型比較	相位分布
	
性能度量 (Array Factor)	
反射角度: ($-43.0^\circ, -17.0^\circ, 1.0^\circ, 56.0^\circ$) 波束寬: ($9.2^\circ, 6.3^\circ, 6.1^\circ, 11.2^\circ$) 旁波瓣位準: 8.9 dB 主波束增益: (35.9, 37.8, 37.6, 36.8) dB	

表 4-34 寬波束生成結果

客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 39 dB
● 入射角度 φ_{inc} : 0°	● 期望增益: 31 dB
● 反射角度 φ_{ref} : 90°	● 半功率波束寬: 6°
● 入射角度 θ_{inc} : 10°	● 訊號源與電磁面鏡距離: 0.45 m
● 反射角度($\theta_{ref1}, \theta_{ref2}, \theta_{ref3}, \theta_{ref4}$): ($-2^\circ, 0^\circ, 2^\circ, 4^\circ$)	● 電磁面鏡與接收器距離: 2.75 m
輻射場型比較	相位分布
	
性能度量 (Array Factor)	
反射角度: ($-2.0^\circ, 0.0^\circ, 2.0^\circ, 4.0^\circ$) 波束寬: 12.9° 旁波瓣位準: 12.1 dB 主波束增益: 37.8 dB	

● 實驗觀察

由表 4-31 之雙波束結果可見，本研究模型於多數角度組合下皆能同時導向兩個目標方向，各主波束增益普遍高於 33 dB 之期望增益值，顯示能量於兩波束之分配大致符合第 3.5 節所推導之多波束理想增益上限。然而當兩目標反射角過於接近時，例如同時指定相差僅 1° 之 -35° 與 -34° ，模型所生成之兩主波束會合併為單一較寬之波束，使個別角度難以精準分辨，半功率波束寬亦因此略為增大，而於波束密集之規格下，旁波瓣位準偶有低於目標 15 dB 之情形，反映波束彼此干涉所致之能量外溢。

表 4-32 之三波束結果進一步驗證模型可同時合成三個指向不同方向之主波束，並支援一寬兩窄等非對稱組合。於三方向分散良好之規格下，各主波束增益皆達期望增益值且反射角度落於容忍區間內，惟當其中兩波束間距偏小時，仍可觀察到與雙波束相同之合併現象，且最外側波束之增益略低於中央波束，顯示角度分布之均勻性會影響各波束間之能量平衡。

表 4-33 四波束為本方法生成自由度之極限測試。實驗結果顯示，在四個反射角分散且彼此間距足夠之情況下，模型仍能同步生成四個主波束，各波束增益接近四波束理想增益上限 39 dB 所對應之期望增益值 31.2 dB，驗證本研究方法於高自由度場景下之生成能力。當四角度趨於密集時，部分邊緣波束之增益與半功率波束寬則略有衰退，此與雙波束、三波束所觀察到之趨勢一致。

表 4-34 之寬波束結果則展示本方法之延伸應用，透過將四個反射角分量以固定且相近之間距並排輸入，原本各自獨立之窄波束會相互融合為單一寬波束，藉此於不增設專屬寬波束損失函數之前提下，合成半功率波束寬約 12° 之輻射場型，顯示模型具備由多窄波束組合逼近寬波束之泛化能力。

綜合上述四項結果，本研究之條件式生成器可於單一模型內，依角度條件向量同步生成雙波束、三波束、四波束乃至寬波束等多樣化之客製化輻射場型，且多數規格之主波束增益與反射角度皆能達標，充分展現本研究方法所具備之強大泛化能力。至於前述波束合併、能量外溢與最外側波束衰退等未達標情形，其成

因可收斂為兩項物理限制，其一為角度密集所致之波束干涉，當多個反射角彼此過於接近時相鄰波束於遠場相互重疊而合併，使半功率波束寬增大並抬升旁波瓣位準，其二為能量守恆所致之增益上限，多波束總輻射能量須分配於各主波束之間，波束數量越多則各波束所分得之峰值增益越低，故個別波束於能量分配不均時容易低於期望增益值，二者均屬相位陣列之固有繞射與能量特性，而非模型指向能力之不足。整體而言，本方法雖於角度高度密集之需求下仍受此類物理特性之限制，惟其能於單一模型內涵蓋極廣之多波束角度規格並穩定維持生成品質，已充分驗證本研究於複雜場型下之泛化能力。除本節所列之代表性規格外，本方法在整體規格空間之達標率統計另於附錄一呈現。

4.2.4 實驗四 模型於邊緣裝置上之即時推論能力

● 實驗目的

本實驗旨在驗證本研究模型部署於資源受限之邊緣運算平台後，是否仍具備毫秒等級之即時推論能力，以滿足 6G 通訊對極低延遲動態波束切換之需求。過往啟發式演算法與部份非監督式學習方法雖能合成高品質場型，惟單次相位設計之耗時通常落於秒級乃至分鐘級；本研究以單次前向傳播即可生成相位分布，從生成方法上具備即時性，本實驗即透過推論時間量測來驗證此一優勢。

● 實驗內容

本實驗將訓練完成之模型部署至 NVIDIA Jetson AGX Orin 邊緣運算裝置上，於相同之模型權重下，對多組角度規格重複執行推論並統計其平均單次推論時間，至於推論的方法則依 3.6.1 節所述之方法進行測試，設定預熱次數為 100 次，推論次數為 500 次，預測規格採隨機角度。為呈現相對優勢，另於高運算資源之 V100 GPU 伺服器上量測相同模型之推論時間，並與啟發式演算法、曾俊瑋與蔡奇倫生成相位分布所需之時間進行對比。測試涵蓋單波束與四波束兩種情境，單波束之測試規格範圍與表 4-1、表 4-2 所列出之規格範圍相同，而多波束則是以實驗三所設定之規格相同，以評估推論時間隨規格複雜度之變化。

● 實驗結果

表 4-35 至表 4-38 為模型推論時間之量測結果，首先表 4-35 記錄模型於訓練所使用之 V100 GPU 伺服器上之推論時間，表 4-36 與表 4-37 則分別記錄模型於邊緣運算裝置在未進行環境設定與完成環境設定兩種狀態下之推論時間，三者皆同時呈現單波束與多波束兩種情境之結果。每一表格除平均推論時間外，另列出第 50、第 95 與第 99 百分位數及最小值與最大值，以完整反映推論延遲之集中趨勢與離散程度。表 4-38 則為本研究方法與既有相位設計方法於單張相位分布生成時間上之比較，藉以凸顯本研究於即時性上之相對優勢。

表 4-35 訓練設備上之模型推論時間測試

	單波束	多波束
平均推論時間	3.630 ms	3.668 ms
pr50	3.630 ms	3.663 ms
Pr95 / Pr99	3.644 / 3.652 ms	3.719 / 3.731 ms
Min / Max	3.608 / 3.754 ms	3.644 / 3.739 ms

表 4-36 於無設定環境的邊緣裝置上之模型推論時間測試

	單波束	多波束
平均推論時間	15.002 ms	15.954 ms
pr50	15.746 ms	16.047 ms
Pr95 / Pr99	17.064 / 19.384 ms	17.092 / 19.233 ms
Min / Max	10.178 / 23.535 ms	10.705 / 19.587 ms

表 4-37 於有設定環境的邊緣裝置上之模型推論時間測試

	單波束	多波束
平均推論時間	8.458 ms	8.506 ms
pr50	8.390 ms	8.436 ms
Pr95 / Pr99	8.443 / 11.183 ms	8.493 / 11.302 ms
Min / Max	8.327 / 12.397 ms	8.369 / 12.364 ms

表 4-38 單波束相位分布生成時間比較表

方法	單元尺寸	單張相位分布生成時間
最佳化灰狼演算法	40×40	120 min
文獻 [20]	40×40	21 s
文獻 [21]	40×40	380 s
本研究模型	$16 \times 16 / 32 \times 32$	3.630 ms

● 實驗觀察

首先就生成規格數量對推論速度之影響而言，由表 4-35 可見，模型於訓練設備上之單波束與多波束平均推論時間分別為 3.630 毫秒與 3.668 毫秒，兩者極為接近，相同之趨勢亦見於邊緣裝置之量測結果。此一現象說明，由於本研究以單次前向傳播完成相位生成，無論輸出之主波束數量多寡，模型所經歷之運算路徑皆相同，故所生成之規格數量幾乎不影響推論速度。

其次就運算平台之差異而言，模型於 V100 GPU 伺服器上之平均推論時間約為 3.6 毫秒，而部署至完成環境設定之邊緣裝置後，平均推論時間上升至約 8.5 毫秒。此一差距源自邊緣運算裝置之運算資源遠較伺服器受限，惟其推論延遲仍維持於毫秒等級，足以反映模型於實際資源受限環境下仍具備即時生成之能力。

再就環境設定之影響而言，比較表 4-36 與表 4-37 可發現，未進行環境設定之邊緣裝置其平均推論時間約為 15 毫秒，且最小值與最大值之落差甚大，顯示推論延遲存在明顯波動，而依第 3.6.1 節完成三項環境設定後，平均推論時間降至約 8.5 毫秒，且各百分位數之分布明顯收斂。此結果印證關閉背景程式、鎖定最高效能電源模式與固定 GPU 運作頻率等設定，確能消除動態電壓頻率調節所引入之時脈變動，使推論時間趨於穩定且可重現。

最後由表 4-38 之方法比較可見，於文獻 [20] 中所測試之傳統最佳化灰狼演算法生成單張相位分布需耗時約 120 分鐘，而文獻 [20] 與文獻 [21] 的主要方法亦分別需要約 21 秒與 380 秒，而本研究模型僅需約 3.630 毫秒即可完成生成，於生成時間上較既有方法快上數個數量級。此一結果直接呼應第 2.5 節所定義之即時性問題，證實本研究方法確實具備滿足 6G 通訊毫秒等級動態波束切換需求之即時生成能力。值得一提的是，如實驗一所示，本研究方法雖以單一模型承載大量規格而於單規格生成品質上略有犧牲，但卻換得既有逐規格訓練或迭代式方法所無法達成之毫秒級生成速度，於即時性與生成品質之間取得符合實際通訊場景需求之平衡。

最後值得一提的是，本研究方法之即時性係建立於一次性之離線訓練之上。模型於訓練階段須付出可觀之時間成本，單波束模型之訓練約需 100 分鐘，而多波束模型於加入啟發式神經網路混合訓練後，完整訓練時間更長達三至五日。然而此一訓練成本屬一次性之離線投入，模型一旦訓練完成，即可於其所支援之規格範圍內以毫秒等級即時生成任意角度組合之相位分布，無須針對個別規格重複付出生成代價。相較之下，傳統迭代式最佳化方法並無訓練與推論之分離，其每生成一筆新規格之相位分布皆須完整重新執行一次最佳化流程，故每一次生成皆須重複承擔其高昂之運算時間。由此可見，本研究方法雖以較長之訓練時間為代價，卻將此成本攤提於後續無限次之即時推論之中，因而於實際部署時仍能充分發揮其即時生成之優勢。

4.2.5 實驗五 模型生成相位分布之電磁模擬驗證

● 實驗目的

本實驗旨在驗證模型所生成之 1-bit 相位分布於更貼近真實之環境中是否仍能維持預期效果。陣列因子公式未考慮單元間互相耦合等所產生的物理干擾，故本實驗進一步以 Ansys HFSS 電磁模擬，將理論公式解、電磁模擬解進行比較，確認反射角度、波束寬度與訊號強度之一致性，並探討是否符合 3.5 節所提之性能度量規格。

● 實驗內容

本次實驗將採用研究團隊所設計之 RIS 控制板，如 2.1 節所述，因其為雙極化的設計，再者本研究的方法是以單極化相位分布為訓練目標，所以在進行電磁模擬時需將另一通道的空缺以相同數值補上。再來將會固定電磁面鏡參數如表 4-1、表 4-2 所示，其目的為配合硬體設計。然後選取數組代表性規格，涵蓋不同反射角、單波束與多波束，先以陣列因子公式生成輻射場型，再將相同相位分布輸入 HFSS 進行電磁模擬，最後將進行疊圖比較，並分別計算性能度量，依第 3.5 節電磁模擬之容忍區間判定是否合格，並進行兩者差異的探討。

● 實驗結果

表 4-39 至 表 4-43 為本實驗所選取之代表性規格於陣列因子公式解與電磁模擬解之比較結果，涵蓋不同反射角度之單波束與多波束組合。每一規格皆先以陣列因子公式生成理論輻射場型，再將相同之 1-bit 相位分布輸入 Ansys HFSS 進行電磁模擬，並將兩者之輻射場型疊圖呈現，以利直接觀察兩種驗證方式於主波束指向、波束寬度與旁波瓣分布上之吻合程度。表格中並分別列出兩種方式所計算之反射角度、半功率波束寬與訊號強度，因半功率波束寬於電磁模擬中的誤差較大，故在此不做討論，最後依第 3.5 節電磁模擬之容忍區間判定合格與否，凡未達標之項目以紅字標示。

表 4-39 單波束公式解與電磁模擬之比較結果



客製化電磁面鏡規格		
● 單元數量: 16×16	● 理想增益: 45 dB	
● 入射角度(θ, φ): $(10^\circ, 0^\circ)$	● 期望增益: 36 dB	
● 反射角度(θ, φ): $(-40^\circ, 90^\circ)$	● 半功率波束寬: 6°	
● 訊號源與電磁面鏡距離: 0.45 m	● 旁波瓣位準: 15 dB	
● 電磁面鏡與接收器距離: 2.75 m		
輻射場型比較		
		
相位分布	性能度量 (Array Factor)	性能度量 (電磁模擬)
	反射角度: -39.5° 波束寬: 8.8° 旁波瓣位準: 11.6 dB 主波束增益: 43.4 dB	反射角度: -41.6° 波束寬: 14.4° 主波束增益: 43.4 dB

表 4-40 雙波束公式解與電磁模擬之比較結果



客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 42 dB
● 入射角度 φ_{inc} : 0°	● 期望增益: 33 dB
● 反射角度 φ_{ref} : 90°	● 半功率波束寬: 6°
● 入射角度 θ_{inc} : 10°	● 訊號源與電磁面鏡距離: 0.45 m
● 反射角度($\theta_{ref1}, \theta_{ref2}, \theta_{ref3}, \theta_{ref4}$): ($-40^\circ, -39^\circ, 9^\circ, 10^\circ$)	● 電磁面鏡與接收器距離: 2.75 m
輻射場型比較	相位分布
	
性能度量 (Array Factor)	
反射角度: ($-39.5^\circ, -39.5^\circ, 9.5^\circ, 9.5^\circ$) 波束寬: ($8.3^\circ, 8.3^\circ, 7.1^\circ, 7.1^\circ$) 主波束增益: (36.0, 36.0, 35.7, 35.7) dB	
性能度量 (電磁模擬)	
反射角度: ($-41.0^\circ, -41.0^\circ, 7.0^\circ, 7.0^\circ$) 波束寬: ($7.1^\circ, 7.1^\circ, 9.0^\circ, 9.0^\circ$) 主波束增益: (32.9, 32.9, 36.0, 36.0) dB	

表 4-41 三波束公式解與電磁模擬之比較結果



客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 40 dB
● 入射角度 $\varphi_{inc}: 0^\circ$	● 期望增益: 32 dB
● 反射角度 $\varphi_{ref}: 90^\circ$	● 半功率波束寬: 6°
● 入射角度 $\theta_{inc}: 10^\circ$	● 訊號源與電磁面鏡距離: 0.45 m
● 反射角度($\theta_{ref1}, \theta_{ref2}, \theta_{ref3}, \theta_{ref4}$): ($-37^\circ, -36^\circ, 26^\circ, 44^\circ$)	● 電磁面鏡與接收器距離: 2.75 m
輻射場型比較	相位分布
	
性能度量 (Array Factor)	
反射角度: ($-37.5^\circ, -37.5^\circ, 26.0^\circ, 44.0^\circ$) 波束寬: ($8.5^\circ, 8.5^\circ, 7.9^\circ, 9.0^\circ$) 主波束增益: (35.7, 35.7, 34.6, 35.3) dB	
性能度量 (電磁模擬)	
反射角度: ($-35.0^\circ, -35.0^\circ, 25.0^\circ, 43.0^\circ$) 波束寬: ($12.5^\circ, 12.5^\circ, 8.4^\circ, 7.5^\circ$) 主波束增益: (35.7, 35.7, 35.6, 34.2) dB	

表 4-42 四波束公式解與電磁模擬之比較結果





客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 39 dB
● 入射角度 φ_{inc} : 0°	● 期望增益: 31 dB
● 反射角度 φ_{ref} : 90°	● 半功率波束寬: 6°
● 入射角度 θ_{inc} : 10°	● 訊號源與電磁面鏡距離: 0.45 m
● 反射角度($\theta_{ref1}, \theta_{ref2}, \theta_{ref3}, \theta_{ref4}$): ($-57^\circ, -34^\circ, 3^\circ, 49^\circ$)	● 電磁面鏡與接收器距離: 2.75 m
輻射場型比較	相位分布
	
性能度量 (Array Factor)	
反射角度: ($-59.0^\circ, -34.0^\circ, 1.5^\circ, 47.0^\circ$) 波束寬: ($11.5^\circ, 7.4^\circ, 6.1^\circ, 9.7^\circ$) 主波束增益: (35.5, 36.7, 34.6, 34.9) dB	
性能度量 (電磁模擬)	
反射角度: ($-58.0^\circ, -34.0^\circ, 2.0^\circ, 43.0^\circ$) 波束寬: ($5.6^\circ, 6.8^\circ, 11.5^\circ, 6.7^\circ$) 主波束增益: (29.5, 36.4, 36.7, 33.6) dB	

表 4-43 寬波束公式解與電磁模擬之比較結果

客製化電磁面鏡規格	
● 單元數量: 16×16	● 理想增益: 39 dB
● 入射角度 φ_{inc} : 0°	● 期望增益: 31 dB
● 反射角度 φ_{ref} : 90°	● 半功率波束寬: 6°
● 入射角度 θ_{inc} : 10°	● 訊號源與電磁面鏡距離: 0.45 m
● 反射角度($\theta_{ref1}, \theta_{ref2}, \theta_{ref3}, \theta_{ref4}$): ($-7^\circ, -2^\circ, 3^\circ, 8^\circ$)	● 電磁面鏡與接收器距離: 2.75 m
輻射場型比較	相位分布
	
性能度量 (Array Factor)	
反射角度: 0° 波束寬: 18.6° 主波束增益: 34.6 dB	
性能度量 (電磁模擬)	
反射角度: 0° 波束寬: 15.4° 主波束增益: 34.6° dB	

● 實驗觀察

由表 4-41 至表 4-43 之疊圖比較可見，電磁模擬解之主波束指向與訊號強度大致與陣列因子公式解相吻合。於反射角度方面，多數規格之電磁模擬反射角度與公式解之差異皆落於第 3.5 節所訂電磁模擬之 $\pm 2^\circ$ 容忍區間內，顯示模型所生成之 1-bit 相位分布於納入單元間耦合等實際物理效應後，仍能準確地將能量導向所指定之方向。於主波束增益方面，公式解與電磁模擬解之數值高度一致，多數規格之增益皆達期望增益值，驗證模型於貼近真實硬體之環境下仍能維持預期之波束成形效果。需補充說明的是，半功率波束寬於電磁模擬中因單元耦合與邊緣效應而誤差較大，故如實驗結果所述不納入兩者之比較與合格判定，本實驗於性能度量上僅以反射角度與主波束增益作為公式解與模擬解一致性之依據。

進一步觀察可發現，公式解與模擬解之差異主要集中於反射角絕對值較大之波束。以表 4-42 之四波束為例，於反射角接近 -57° 與 -49° 之最外側波束處，電磁模擬之反射角度與主波束增益相較於公式解出現較明顯之偏移與衰減，部分大角度波束之增益甚至略低於期望增益值。此一大角度衰減可自陣列因子公式獲得解釋，當掃描角增大時陣列於該方向之有效投影孔徑隨掃描角之餘弦而縮減，致使主波束峰值增益下降並使半功率波束寬展寬，且 1-bit 量化誤差對場型之影響亦隨掃描角增大而加劇，如 Yang 等人 [26] 所指出，相位量化會造成與掃描角相關之增益損失與旁瓣抬升，兩項效應相互疊加而導致最外側波束之衰減，此屬相位陣列與 1-bit 量化之固有物理限制，而非本研究生成方法本身之缺陷。

另須特別說明的是，於電磁模擬結果中可觀察到，在反射角度約 -20° 至 20° 之區間出現一突起之雜波干擾。經檢視後確認，此一雜波並非源自本研究方法所生成之相位分布，而是研究團隊所提供之電磁面鏡控制板於該角度範圍內之硬體特性所致。也正因如此，本研究於多波束情境之性能度量並不納入旁波瓣位準之判定，以避免將此類硬體所致之旁波瓣突起誤判為模型生成品質之缺陷，該雜波屬於硬體本身之物理限制，並不影響本研究方法於相位生成上之正確性與有效性。

此外，由電磁模擬之輻射場型亦可確認，本研究於量化前所導入之隨機相位預編碼遮罩確實有效抑制了 1-bit 量化所致之鏡像波束，於目標反射方向之對稱方位並未出現顯著之非預期波束，進一步驗證第 3.3.1 節所提軟體式預編碼策略於貼近真實硬體之環境下仍能維持其鏡像抑制成效，亦呼應第 2.5 節第三項問題中針對離散量化所採行之訓練解決策略。

4.3 實驗總結

本章透過五項實驗，分別就第 2.5 節所歸納之四項核心問題對本研究所提之條件式生成器進行系統性驗證。其中設計靈活性由實驗一之單波束生成與實驗三之多波束生成共同檢視，高自由度規格與離散量化所致之訓練困難由實驗二之混合訓練機制加以解決，即時性由實驗四之邊緣裝置推論時間量測加以驗證，配合實際環境並驗證離散量化策略則由實驗五之近場電磁模擬完成，以下分別說明各項問題之驗證成果。


於設計靈活性方面，實驗一與實驗三共同驗證了本研究單一模型涵蓋多規格之生成能力。實驗一顯示模型能於 16×16 與 32×32 兩種單元尺寸、4.7 GHz 與 28 GHz 兩種工作頻率、多種訊號源距離以及涵蓋入射角 0° 至 50° 與反射角 -60° 至 60° 之大量角度組合下，穩定生成指向正確且主波束增益逼近理想增益之單波束相位分布。實驗三則進一步將此能力延伸至雙波束、三波束、四波束乃至寬波束等複雜場型，多數規格之主波束增益、反射角度與半功率波束寬三項指標皆能達標，充分展現本研究方法之強大泛化能力，惟於多反射角過於接近時，相鄰波束會相互合併而使指向產生誤差。

於多規格與離散量化所致之訓練困難方面，實驗二驗證了啟發式神經網路混合訓練機制對損失收斂之改善。原始多波束訓練於極早期即停滯而無法繼續下降，導入混合訓練機制後，模型透過鄰域之貪婪式翻轉搜尋持續取得優於自身輸出之離散解，使損失曲線得以穩定收斂並突破局部最佳解，證實此機制為多波束高品質生成不可或缺之訓練基礎。

於即時性方面，實驗四將模型部署至 NVIDIA Jetson AGX Orin 邊緣運算裝置，量測結果顯示模型於資源受限之邊緣平台上仍能維持毫秒等級之推論速度，且單波束與多波束之推論時間相近，較傳統迭代式方法快上數個數量級，充分滿足 6G 毫秒等級動態波束切換之需求。此一即時性係建立於一次性之離線訓練之上，雖須付出可觀之訓練時間，惟該成本可攤提於後續無限次之即時推論之中。

於配合實際環境方面，實驗五依實際 RIS 硬體之近場設計參數，以 Ansys HFSS 電磁模擬比對公式解與模擬解之差異。結果顯示兩者於反射角度與主波束增益上大致吻合，差異主要集中於大角度掃描之波束，且模型所導入之隨機相位預編碼遮罩於真實環境下仍能有效抑制鏡像波束，至於 -20° 至 20° 區間之雜波則確認屬控制板之硬體特性而非模型問題，此一結果同時驗證了本研究於近場驗證情境與二值化離散量化兩個面向之有效性。

綜合上述，本章五項實驗逐一回應第 2.5 節所定義之四項核心問題，自設計靈活性、訓練收斂、即時性至貼近真實硬體之驗證，完整證實本研究所提之條件式生成器確實具備於單一模型內即時生成多種客製化相位分布之能力，並於品質與靈活性之間取得符合實際 6G 通訊場景需求之平衡。



第五章 結論與未來展望

本研究針對 6G 通訊環境對可重構智慧面所提出之即時、動態與多規格相位生成需求，提出一套名為條件式生成器之深度學習框架，於模型架構、量化整合與訓練機制三個面向進行系統性設計，並透過五項實驗加以驗證。

於設計靈活性方面，本研究以入射角與反射角組合作為動態輸入，並於生成器內部導入特徵線性調變機制，使單一模型得以於同一組權重內承載大量角度規格之相位映射關係。實驗一與實驗三之結果顯示，本研究模型不僅能於不同單元尺寸、工作頻率與收發距離下生成指向正確之單波束相位分布，亦能依角度條件向量同步合成雙波束、三波束、四波束乃至寬波束等複雜輻射場型，充分展現其強大之泛化能力，並以近乎為零之規格切換成本，換取既有逐規格訓練方法所無法提供之動態波束追蹤彈性。

於二值化量化與訓練收斂方面，本研究將 Gumbel-Sigmoid 量化機制整合至單階段端到端之訓練流程，並參考 P3RIS 之硬體設計理念，於量化前疊加固定之隨機相位預編碼遮罩，於軟體層破壞量化誤差之週期性，有效抑制 1-bit 量化所致之鏡像波束。針對多波束高自由度場景易陷入局部最佳解之問題，本研究進一步提出啟發式神經網路混合訓練機制，將神經網路之快速擬合能力與啟發式演算法之鄰域搜尋能力整合於同一訓練流程，實驗二之結果證實此一機制能有效突破訓練後期之收斂瓶頸。

於即時性與貼近真實硬體之驗證方面，實驗四將模型部署至 NVIDIA Jetson AGX Orin 邊緣運算裝置，量測結果顯示模型於資源受限之邊緣平台上仍能維持毫秒等級之推論速度，且生成規格之數量幾乎不影響推論時間，相較於傳統迭代式方法快上數個數量級。實驗五則依實際 RIS 硬體之近場設計參數，以電磁模擬比對陣列因子公式解與模擬解之差異，結果顯示兩者於主波束指向、波束寬度與訊號強度上大致吻合，確認模型所生成之相位分布於納入單元耦合等實際物理效應後仍能維持預期之波束成形效果。

儘管本研究於上述各面向皆展現良好之成果，仍存在若干值得後續探討之方向。首先，受限於離散相位之物理特性，當所指定之多個反射角彼此過於接近時，相鄰波束會於遠場相互合併而無法被獨立分辨，使雙波束與寬波束之實際指向與需求角度之間存在誤差，未來可於損失函數或網路架構上引入波束分辨度之約束以改善此一限制。其次，本研究以單一模型承載大量規格之代價為單規格生成品質略低於逐規格最佳化之方法。此外，本研究方法之即時性係建立於一次性之離線訓練之上，其代價為可觀之離線訓練時間，尤以多波束加入混合訓練後完整訓練長達三至五日為甚，後續可探討加速收斂或降低訓練成本之策略。最後，本論文之實測範圍聚焦於推論裝置上之即時推論能力，至於下游微控制器與 RIS 硬體之訊號傳輸與相位切換等環節，未來可進一步整合至完整之即時相位控制系統，以驗證本方法於端到端實際部署情境下之整體效能。



參考文獻

- [1] A. M. Said, M. Marot, H. Afifi, and H. Moun gla, “Optimal Mobile IRS Deployment for Empowered 6G Networks,” *IEEE Open Journal of the Communications Society*, vol. 5, pp. 540–552, 2024.
- [2] J. E. Arévalo Peña, A. E. Nuñez Lobos, C. A. Azurdia Meza, J. L. A. Quijano, and J. I. Sandoval Arenas, “Experimental Coverage Measurements on a Commercial 5G Network in the 28 GHz mm-Wave Band,” in *2023 IEEE MTT-S Latin America Microwave Conference (LAMC)*, San José, Costa Rica: IEEE, Dec. 2023, pp. 65–67.
- [3] B. D. Van Veen and K. M. Buckley, “Beamforming: a versatile approach to spatial filtering,” *IEEE ASSP Magazine*, vol. 5, no. 2, pp. 4–24, Apr. 1988.
- [4] 林育丞, 應用於無線通訊環境電磁波再分布之電磁面鏡設計, 碩士論文, 國立中正大學, 2019.
- [5] 李易典, 可改變毫米波傳播通道之剛性與撓性電磁面鏡設計, 碩士論文, 國立中正大學, 2020.
- [6] C. Han, Y. Zhang, and Q. Yang, “A Broadband Reflectarray Antenna Using Triple Gapped Rings With Attached Phase-Delay Lines,” *IEEE Transactions on Antennas and Propagation*, vol. 65, no. 5, pp. 2713–2717, May 2017.
- [7] P. Nayeri, F. Yang, and A. Z. Elsherbeni, *Reflectarray Antennas: Theory, Designs, and Applications*, 1st ed. Wiley, 2018.
- [8] Y.-C. Chen and S.-C. Lin, “Design of mmW Broad-Beam Reflecting Surface Using Grey Wolf Optimizer,” *2022 International Symposium on Antennas and Propagation (ISAP)*, pp. 215–216, Oct. 2022.
- [9] S. Meng *et al.*, “An Efficient Multi-Beam Generation Method for Millimeter-Wave Reconfigurable Intelligent Surface: Simulation and Measurement,” *IEEE Transactions on Vehicular Technology*, vol. 72, no. 10, pp. 13752–13757, May 2023.
- [10] X. Teng *et al.*, “Arbitrary Beam Pattern Synthesis and Measurement for mmWave RIS With Discrete Phase Shifts,” *IEEE Transactions on Vehicular Technology*, vol. 74, no. 6, pp. 9973–9978, Jun. 2025.

- [11] T. Shan, X. Pan, M. Li, S. Xu and F. Yang, "Coding Programmable Metasurfaces Based on Deep Learning Techniques," in *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, vol. 10, no. 1, pp. 114-125, March 2020.
- [12] C. Cui, W. T. Li, X. T. Ye, P. Rocca, Y. Q. Hei and X. W. Shi, "An Effective Artificial Neural Network-Based Method for Linear Array Beampattern Synthesis," in *IEEE Transactions on Antennas and Propagation*, vol. 69, no. 10, pp. 6431-6443, Oct. 2021.
- [13] H. -W. Li, Y. -C. Chen, A. Liu, S. -C. Lin and M. -Y. Hsieh, "A Generative Adversarial Network Approach to Reflectarray Pattern Synthesis," *2023 IEEE Wireless Communications and Networking Conference (WCNC)*, Glasgow, United Kingdom, 2023, pp. 1-6.
- [14] 翁士勛, 基於卷積神經網路之自編碼器於可重構智慧面生成之研究, 碩士論文, 國立中正大學, 2022.
- [15] 王騰緯, 基於全連接網路逆向生成可重構智慧面之研究, 碩士論文, 國立中正大學, 2023.
- [16] S. Keşir, M. Y. Yağan, I. Hökelek, A. E. Pusane, and A. Görçin, "Rapid CNN-Assisted Iterative RIS Element Configuration," *2023 International Symposium on Networks, Computers and Communications (ISNCC)*, pp. 1–6, Oct. 2023.
- [17] S. Wang, H. E. Hassani, M. Di Renzo and M. Poulakis, "Multi-Beam Beamforming in RIS-Aided MIMO Subject to Reradiation Mask Constraints—Optimization and Machine Learning Design," in *IEEE Transactions on Communications*, vol. 73, no. 12, pp. 14914-14930, Dec. 2025.
- [18] H. Zhang, S. Sun, H. Yan and J. Mo, "Deep Learning-Based Beamforming Design Using Target Beam Patterns," *2025 IEEE Virtual Conference on Communications (VCC)*, NY, USA, 2025, pp. 1-6.
- [19] J. Zhang, C. Qu, X. Zhang and H. Li, "Real-Time Pattern Synthesis for Large-Scale Phased Arrays Based on Autoencoder Network and Knowledge Distillation," in *IEEE Transactions on Antennas and Propagation*, vol. 73, no. 3, pp. 1471-1481, March 2025.
- [20] 曾俊瑋, 基於非監督式學習生成客製化電磁面鏡相位之研究, 碩士論文, 國立中正大學電機工程研究所, 2024.
- [21] 蔡奇倫, 基於位元遷移策略於電磁面鏡量化相位生成方法, 碩士論文, 國立中正大學電機工程研究所, 2025.

- [22] A. S. Shekhawat, B. G. Kashyap, R. W. Raldiris Torres, F. Shan and G. C. Trichopoulos, "A Millimeter-Wave Single-Bit Reconfigurable Intelligent Surface With High-Resolution Beam-Steering and Suppressed Quantization Lobe," in *IEEE Open Journal of Antennas and Propagation*, vol. 6, no. 1, pp. 311-325, Feb. 2025.
- [23] B. G. Kashyap, P. C. Theofanopoulos, Y. Cui and G. C. Trichopoulos, "Mitigating Quantization Lobes in mmWave Low-Bit Reconfigurable Reflective Surfaces," in *IEEE Open Journal of Antennas and Propagation*, vol. 1, pp. 604-614, 2020.
- [24] G. M. Brocal and G. Peeters, "Conditioned-U-Net: Introducing a Control Mechanism in the U-Net for Multiple Source Separations," *Zenodo*, Nov. 2019.
- [25] M. Salem, M. O. Ahmed, F. Tung, and G. Oliveira, "Gumbel-Softmax Selective Networks," *arXiv.org*, 2022.
- [26] H. Yang *et al.*, "A Study of Phase Quantization Effects for Reconfigurable Reflectarray Antennas," *IEEE Antennas and Wireless Propagation Letters*, vol. 16, pp. 302–305, Jan. 2017.
- [27] P. Nayeri, F. Yang and A. Z. Elsherbeni, "Design and Experiment of a Single-Feed Quad-Beam Reflectarray Antenna," in *IEEE Transactions on Antennas and Propagation*, vol. 60, no. 2, pp. 1166-1171, Feb. 2012.
- [28] Y. -C. Chen, Y. -T. Chen, Y. -J. Lai, S. -C. Lin, S. -F. Chang and A. Liu, "Dynamic DRL Guided RIS Control for Enhancing Multi-User Communication under Unit Malfunctions," *2025 IEEE Annual Congress on Artificial Intelligence of Things (AIoT)*, Osaka, Japan, 2025, pp. 465-472.
- [29] E. Jang, S. Gu, and B. Poole, "Categorical Reparameterization with Gumbel-Softmax," *arXiv:1611.01144 [cs, stat]*, Aug. 2017.
- [30] C. J. Maddison, A. Mnih, and Y. W. Teh, "The Concrete Distribution: A Continuous Relaxation of Discrete Random Variables," *arXiv.org*, 2016.
- [31] W. Tang *et al.*, "Wireless Communications With Reconfigurable Intelligent Surface: Path Loss Modeling and Experimental Measurement," in *IEEE Transactions on Wireless Communications*, vol. 20, no. 1, pp. 421-439, Jan. 2021.

附錄一、其餘多波束不同規格之相位分布生成指標統計

第四章的多波束實驗針對代表性規格，逐一呈現其輻射場型與各項指標，為驗證本方法的效能建立在整個規格空間，而非只在少數規格上表現良好，本附錄對大量多波束規格進行批次推論，以統計方式呈現整體達標率。由於單波束規格僅 78 種且已於實驗一涵蓋，本附錄聚焦於規格組合龐大的多波束情境。評估範圍與實驗三相同，每一入射角隨機抽樣 2000 組反射角組合，合計 12000 組，各指標計算方式與第 3.5.3 節相同。

為了更細緻地呈現效能分布，本附錄將各項指標分成完美達標、達標與未達標三個等級，此分級只用於本附錄的統計呈現，不影響正文的判定標準。反射角度誤差在不大於 2° 時判為完美達標，不大於 3° 時判為達標。訊號強度以表 3-5 推得的四波束理想增益 39 dB 為基準，達到其 0.8 倍時判為完美達標，達到 0.63 倍時判為達標。半功率波束寬以理論值 6° 為目標，並採計數方式判定，先計算每一個波束各自的波束寬，個別偏差不大於 1.5° 為個別完美，不大於 2° 為個別可用，當四個波束都個別完美時整組判為完美達標，至少有兩個波束達到個別可用時判為達標。旁波瓣位準因為主瓣與旁瓣的邊界不易客觀量化，此處不納入統計，改在正文以輻射場型圖搭配人工檢視。

各指標之三級分布如表 A-1 所示。於 12000 組規格中，主波束增益表現最佳，99.72% 完美、可用 0.28%、未達標 0%；反射角度 65.47% 完美、15.92% 可用、未達標 18.61%，達標率約 81%；半功率波束寬僅 1.21% 完美，67.47% 為可用，未達標 31.32% 為三項最高，是主要的未達標來源。

表 A-1 多波束各項指標之三級達標分布

指標	完美達標	達標(可用)	未達標
反射角度	65.47%	15.92%	18.61%
半功率波束寬	1.21%	67.47%	31.32%
主波束增益	99.72%	0.28%	0.00%