

國立清華大學 電機工程學系

實作專題研究成果摘要

Channel estimation and prediction for LEO multi-user hybrid
beamforming

低軌道衛星多用戶混和波束成型的通道估計和通道預測

專題領域： 通訊

組 別：B324

指導教授：翁詠祿

組員姓名：張勻誠、張愛翎

研究期間：112年2月1日至113年1月31日止，共12個月

摘要

每隔10年，通訊就會進步一個世代。從1998年的3G，2008年的4G，到2020年的5G，通訊的標準也在不斷的演進以滿足市場的需求。5G增強的面相包含增強型移動寬頻(eMBB)、超高可靠低延遲通訊(uRLLC)、大規模機器類互聯(mMTC)。這些面相都要比前一個世代還要好10倍以上。因此，下一個世代的通訊，也就是6G，必須採用新的技術和不同的通訊協定來提供比5G各個面向還更好的通訊品質。

目前世界的通訊協定主要是由第三代合作夥伴計劃(3GPP)和國際電信聯盟(ITU)來制定，其中3GPP在Release17已經制定出了5G的非地表網路(NTN)的相關定義和應用情景。NTN包含了所有非地表的網路應用情境，包含無人機(UAV)、高空偽衛星(High Altitude Pseudo Satellite, HAPS)、地球同步衛星(GEO)等，其中一個重要的項目就是低軌衛星(LEO satellite)。

低軌衛星可以提供成本上的優勢，且距地表距離相較於傳統衛星還要更短，並且可以利用更高頻的載波來提供高頻寬的通訊，以及提供全球性的覆蓋，因此低軌衛星是在未來6G中不可或缺的一環。

為了抵銷高載波頻率且長距離所帶來的路徑損失，大規模多輸入多輸出波束成形將是必要的。因此如何設計Massive MIMO Beamforming的通訊系統將是重要的研究課題。

本專題在設定上採用單載波的分頻雙工(FDD)，使用上行載波頻率28Ghz，下行頻率採用18Ghz，並使用Matlab來進行模擬。我們設計出了低複雜度且低負載的通道估計方法，搭配高效的通道預測演算法來對抗快速改變的通道環境。我們的架構非常適用在低軌道衛星的通訊環境。

一、研究目的

隨著低軌衛星業者如 Starlink 或 OneWeb 佈署大量低軌衛星以提供高覆蓋的通訊，如何設計更有效且低複雜度的通訊系統變成是最重要的問題。由於低軌衛星的傳輸延遲(transmission delay)雖然比傳統中高軌衛星的延遲還低，但相較於地表通訊，延遲還是太高。因此，低軌衛星的通訊系統必須考慮傳輸延遲對系統帶來的影響。

傳統通訊系統必須由用戶端(UT)回饋通道資訊(CSI)給基地台(BS)，來獲得從基地台到用戶端的下行通道資訊。因此本專題採用機器學習預測的方式，利用上下行之間的具有的相關性，直接預測下行通道的通道資訊，省去了回傳通道資訊的步驟。另外，為了進一步地減少通道資訊的負載，本專題將使用自行開發的壓縮感知的方式，減少導頻訊號(Pilot Signal)的長度，並且也減少通道估計所需的時間，同時也能支援多用戶的同步通道估計。

專題所使用的機器學習預測模型，是來自實驗室的 Attention 模型。我們將此模型套用在通道預測上，並測試它們的性能。而我們設計的通道估計方式，是參考[8]的方式。不過[8]並不適用在低軌衛星的環境中，因為它的波樣式(Beam pattern)太過發散，無法有效傳遞到衛星上。因此我們改變了它的預估方式，讓波樣式不僅可以集中，也可以達到壓縮感知所需的條件，進而降低運算所需的時間。

二、研究方法

1. 系統架構




Fig. 1 Block Diagram of LEO 衛星收發結構

我們將採用 Fig.1的衛星收發架構，考慮多用戶的低軌衛星，並設計通道估計(Channel Estimation)和通道估計(Channel Prediction)的演算法和架構。

2. 通道架構

了解 LEO 環境下的通道模型，會是完成壓縮感知很重要的一項工作。我們使

用[6]的通道模型，LEO 的衛星和第 k 用戶端之間的上行及下行通道模型可以表示如下：

$$\mathbf{H}_k^{ul}(t, f_c^{ul}) = \exp \{j2\pi[tv_k^{sat} - f_c^{ul}\tau_k^{min}]\} \cdot g_k^{ul}(t, f_c^{ul}) \cdot \mathbf{U}_k \in \mathbb{C}^{N_b \times N_{u_k}} \quad (1-a)$$

$$g_k^{ul}(t, f) = \sum_{p=0}^{P_k^{ul}-1} g_{k,p}^{ul} \exp \{j2\pi[tv_{k,p}^{ut} - f\tau_{k,p}^{ut}]\} \quad (1-b)$$

$$\mathbf{H}_k^{dl}(t, f_c^{dl}) = \exp \{j2\pi[tv_k^{sat} - f_c^{dl}\tau_k^{min}]\} \cdot g_k^{dl}(t, f_c^{dl}) \cdot \mathbf{V}_k \in \mathbb{C}^{N_{u_k} \times N_b} \quad (2-a)$$

$$g_k^{dl}(t, f) = \sum_{p=0}^{P_k^{dl}-1} g_{k,p}^{dl} \cdot \exp \{j2\pi[tv_{k,p}^{ut} - f\tau_{k,p}^{ut}]\} \quad (2-b)$$

其中各個參數表示如下：

Table 1 Channel Parameters 通道參數

Parameter	Meaning
v_k^{sat}	衛星都卜勒頻移
$v_{k,p}^{ut}$	用戶端都卜勒頻移
τ_k^{min}	最小延遲
$\tau_{k,p}^{ut}$	第 p 條路徑延遲和最小延遲之間的差
$g_{k,p}^{ul}, g_{k,p}^{dl}$	第 p 條路徑上的增益
P_k^{dl}	路徑的數量
$\mathbf{U}_k, \mathbf{V}_k$	陣列反應矩陣

3. 通道估計

本專題將採用壓縮感知的演算法進行通道估計，架構圖如下：




Fig. 2 Block Diagram of Channel Estimation 通道估計架構

訊號量測(Signal Measurement)是在傳送訊號之前加一段導頻訊號(Pilot Signal)，利用這段已知的 Pilot Signal，接收端就可以利用得到的訊號來推出通道，由於我們的情境是多用戶的混和波束成形傳輸，因此 Signal Measurement 的式子會如下：

$$\mathbf{y} = \mathbf{W}_b^H \sum_{l=1}^K \mathbf{H}_k \mathbf{w}_{u_k} x_k + \mathbf{n} \quad (3)$$

字典建立(Codebook Construction)是為了我們所使用的壓縮感知演算法-正交匹配追蹤演算法而設計，傳統的字典建立方法[8]是將 Signal Measurement 的等號兩邊做向量化：

$$\text{vec}(y) = \text{vec}(\mathbf{W}_b^H \sum_{l=1}^K \mathbf{H}_k \mathbf{w}_{u_k} x_k + \mathbf{W}_b^H n) \quad (4-a)$$

$$= \text{vec}(\mathbf{W}_b^H \sum_{l=1}^K \mathbf{H}_k \mathbf{w}_{u_k} x_k) + \tilde{n} \quad (4-b)$$

$$= x_k [(\mathbf{w}_{u_1}^T \otimes \mathbf{W}_b^H)(\mathbf{w}_{u_2}^T \otimes \mathbf{W}_b^H) \dots (\mathbf{w}_{u_K}^T \otimes \mathbf{W}_b^H)] \mathbf{h} + \tilde{n} \quad (4-c)$$

$$= x_k [(\mathbf{w}_{u_1}^T \otimes \mathbf{W}_b^H)(\mathbf{w}_{u_2}^T \otimes \mathbf{W}_b^H) \dots (\mathbf{w}_{u_K}^T \otimes \mathbf{W}_b^H)] I_L \otimes \mathbf{F}_u^* \otimes \mathbf{F}_b \mathbf{h}_\omega + \tilde{n} \quad (4-d)$$

但是這樣不僅會占用大量的空間去存放字典，而且演算法所需要花的時間將隨著用戶數的增加而大幅拉長。另外，字典的建立其實需要考慮字典矩陣的互相干性(Mutual Coherence)。傳統的壓縮感知演算法會將(4-d)中的

$x_k [(\mathbf{w}_{u_1}^T \otimes \mathbf{W}_b^H)(\mathbf{w}_{u_2}^T \otimes \mathbf{W}_b^H) \dots (\mathbf{w}_{u_K}^T \otimes \mathbf{W}_b^H)] I_L \otimes \mathbf{F}_u^* \otimes \mathbf{F}_b$ 當作字典 $\mathbf{B}$ ，亦即：

$$\text{vec}(y) = \mathbf{B} \mathbf{h} + \tilde{n} \quad (5-a)$$

$$\mathbf{B} = x_k [(\mathbf{w}_{u_1}^T \otimes \mathbf{W}_b^H)(\mathbf{w}_{u_2}^T \otimes \mathbf{W}_b^H) \dots (\mathbf{w}_{u_K}^T \otimes \mathbf{W}_b^H)] I_L \otimes \mathbf{F}_u^* \otimes \mathbf{F}_b \quad (5-b)$$

並且 $\mathbf{W}_b$ 和 $\mathbf{w}_{u_k}$ 會利用隨機的方法建立 [8]，再搭配多量測 (Multiple Measurement, MM)，以期能減少互相干性數值。這個字典的互相干性數值對於4個用戶的情況來說，約等於0.3312。

這個方法雖然在室內的環境有效，但對於低軌衛星環境來說，將 $\mathbf{W}_b$ 和 $\mathbf{w}_{u_k}$ 利用隨機的方法建立將會使得原本波束成形的效果消失，取而代之的就是需要更大的功率來讓接收端得到一樣的符號錯誤率(SER)。

因此，我們使用的通道估計方法和傳統的壓縮感知方法不同，將原本的字典拆成每個用戶有著獨立的字典：

$$\mathbf{B}_k = x_k (\mathbf{w}_{u_k}^T \otimes \mathbf{W}_b^H) \quad (6)$$

原本的 $\mathbf{W}_b$ 和 $\mathbf{w}_{u_k}$ 會利用隨機的方法建立 [8]，我們則是直接使用 ABF 的方法，不加任何隨機的訊號。訊號需要 K 次的量測，每次的 $\mathbf{w}_{u_k}$ 保持不變，但 $\mathbf{W}_b$ 只保留其中一欄(Column)。這個方法剛好每一欄都會對應到一次量測，而每一次量測所得出來的通道，就是對應用戶的通道。我們將兩者方法的差別做成下表：

Table 2 壓縮感知通道估計的比較

	對照組[8]	本專題
字典大小	$20K^3 N_{u_k} N_b$	$KN_{u_k} N_b$
量測次數	$20K^2$	K
使用情境	室內、短距離	長距離
ABF 預建立	不需要	需要
用戶之間的同步	不需要	不需要

值得注意的是，本專題的架構避開原本複雜的多用戶字典建立，也不需要用戶之間先進行同步，只需要在衛星端改變波束成形的矩陣去做多次的測量。

我們之所以能這麼做，其實是因為對於不同的用戶，有著不同的角度反應。因此我們可以利用長距離波束成形天生的空間濾波性(Spatial Filtering)，將其他用戶的上行訊號干擾降到最低。因此可以將原本的系統(3)重新表示成下式：

$$y_m = \mathbf{W}_{b,m}^H \mathbf{H}_m \mathbf{w}_{u_m} x_m + \mathbf{W}_{b,m}^H \sum_{k \neq m}^K \mathbf{H}_k \mathbf{w}_{u_k} x_k + n = \mathbf{W}_{b,m}^H \mathbf{H}_m \mathbf{w}_{u_m} x_m + \tilde{n} \quad (7)$$

來自其他用戶的訊號將會被視作雜訊，而字典也就可以寫成和(6)一樣，儘管我們的互相干性較高，但由於空間濾波性，我們可以把通道向量還原出來。

而還原過程就需要壓縮感知的演算法。正交匹配追蹤的演算法是利用字典 A 加上量測到的訊號 y ，來還原原始訊號 x ，如 Fig 6 所示。 A 會等於(6)式， y 會等於(7)式，還原出來的 x 為向量化後的通道矩陣。因此我們的正交匹配追蹤演算法 **Algorithm 1** 會利用 A 和 y 以及稀疏度 K 當作輸入， x 作為輸出。

Algorithm 1:

Input: A, y *Output* x

$R = A$ // 殘差

$support = \phi$ // 字典欄項(Column Index)

$Proj = \|A^H R\|$; // 將殘差投影

$support = sort(Proj)$; 排列投影量

$support = support(1:K)$ 找到最大的 K 個投影量當作字典集

$x(support) = A(support)^\dagger y$; // 找出字典集對應的 x 訊號

end

4. 通道預測

本專題使用兩種不同的演算法來預測通道資訊 CSI，分別為 LSTM 和 Self-attention。LSTM 跟 RNN 同樣可用時間相關性的預測，但不同的是，LSTM 修正了 RNN 容易產生梯度爆炸或梯度消失的問題，可以在通道預測中協助獲得時間的相關訊息，並將不重要的歷史訊息捨棄。LSTM 是由一個 memory cell、遺忘門 f_t 、輸入門 i_t 以及輸出門 o_t 所組成。其運作方程式如下所示：

$$i_t = F_{sig}(W_i x_t + U_i g_{t-1} + b_i) \quad (8-a)$$

$$f_t = F_{sig}(W_f x_t + U_f g_{t-1} + b_f) \quad (8-b)$$

$$o_t = F_{sig}(W_o x_t + U_o g_{t-1} + b_o) \quad (8-c)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes F_{tan}(W_c x_t + U_c g_{t-1} + b_c) \quad (8-d)$$

$$g_t = o_t \otimes F_{tan}(c_t) \quad (8-e)$$

$$F_{sig} = \frac{1}{1+e^{-x}}, F_{tan} = \frac{e^{2x}-1}{e^{2x}+1} \quad (8-f)$$

其中 c_t, c_{t-1} 代表當下與前一刻的 memory cell 狀態， W 和 U 分別代表對應該門的 input vector x_t 和前一刻 hidden state g_{t-1} 的權重， b 則代表對應的偏差值。而 F_{sig}, F_{tan} 代表激活函數 sigmoid function 和 hyperbolic tangent function。

Self-attention 是用於找輸入序列間相依關係的演算法，且因可以大量並行運算，所以複雜度會比使用 convolution kernels 低。其運作方程式如下所示：

$$q^i = W^q \times a^i, k^i = W^k \times a^i, v^i = W^v \times a^i \quad (9-a)$$

$$\alpha_{i,j} = k^j \times q^i, \quad (9-b)$$

$$b^i = \sum_j \alpha'_{i,j} \times v^j \quad (9-c)$$

其中 a^i 和 b^i 代表輸入和輸出向量的第 i 個值， W 代表每個對應元素的權重， q ， k ， v 則分別代表 query , key ,和 value 。若將其合併成矩陣形式，則會如下：

$$Q = W^q A, K = W^k A, V = W^v A \quad (10-a)$$

$$\alpha = K^T Q, \alpha' = \text{softmax}(\alpha) \quad (10-b)$$

$$B = A\alpha' \quad (10-c)$$

下圖分別為本專題進行通道預測時使用的兩種演算法架構。




Fig.3 LSTM(左)與 Self Attention(右)演算法架構圖

兩個演算法皆有使用到 convolution layer 和 fully connected layer。convolution layer 透過決定使用的矩陣大小以及 feature filter 的數量，能夠獲得 CSI 之間的空間特徵；而 fully connected layer 除了讀取每筆輸入資料間的關係，也可以確保輸出的資料量與所需相同。所以在通道預測中，convolution layer 和 fully connected layer 用以找出通道中空間位置的相依性特徵，而 self-attention 和 LSTM 則是找輸入資料中彼此的時間相關性特徵。

LSTM 和 self-attention 的演算法使用到的 cell 數量分別為933963和372880，可知 LSTM 使用的數量約為 self-attention 的2.5倍，運算上相對較複雜。

三、研究結果

1. 通道估計結果

我們使用最小平方法作為對照組，比較壓縮感知的優點和缺點。

NMSE 比較:




Fig. 12 Performance in NMSE

可以看到我們使用壓縮感知的效果雖然也不錯，但最小平方法還是會精準很多。

但比較每次量測所需要花的時間。壓縮感知所花的時間是最小平方法花的時間的 $\frac{1}{9}$ ，

因此可以在相同的時間內得到更多的樣本數。

2. 通道預測結果

LSTM 和 Self Attention 的 loss 皆控制在 10^{-2} 的 order，但 LSTM 可以較快收斂到期望的值，而 self-attention 需要多一倍的 training epoch。LSTM 跑一遍神經網路的時間需要0.321674 s，而 self-attention 則需要0.056859 s，可知 self-attention 運算速度比 LSTM 快了大約5倍。




Fig.5 LSTM(左)和 self-attention(右)通道預測結果圖

可由上圖看出，兩個演算法都可以相當不錯的達到通道預測的效果。

Table2. LSTM 和 self-attention 演算法成果比較

	LSTM	Self -attention
cell no.	933963	372880
Training epochs	100	300
Cost time	0.288767	0.050397
Validation RMSE	0.0347	0.0419

從上表可知，LSTM 的演算法複雜度較高，並且每一次運算的時間也較長，但其可以用較少的訓練 epoch 便可達到期望的成果，且其驗證的 RMSE 也相對較小。然而，通道預測是期望用較少的時間達成期望的功效，在兩者的 RMSE 沒有差距很大的情況下，self-attention 僅需 LSTM 約 1/6 的時間，故在通訊領域中，self-attention 的演算法作為通道預測是相對較值得發展的。

四、總結

透過我們自行設計的框架，以及整合自文獻及實驗室所得演算法的努力，我們成功完成了在低軌衛星環境下的通道估計與預測。這套系統不僅能同時對多位使用者的通道進行準確估計，更能預測各通道未來的變化。我們的通道估計方法在速度和精確性上均表現出色，同時通道預測方法也達到了可觀的精度水平。這不僅對低軌衛星系統的傳輸速率和低延遲具有極大助益，同時也具有廣泛的應用前景。

未來的研究方向可以更進一步擴展，例如與實驗室現有的預編碼器進行緊密整合，或者思考不同的衛星群結構，以更貼近實際應用需求。考慮到低軌衛星系統需要以群體形式來擴大覆蓋範圍和提升傳輸容量，這方面的研究將為未來的發展提供更多可能性。

由於低軌衛星技術已不再停留在實驗階段，而是由企業如 OneWeb 和 SpaceX 的 Starlink 等推動實際應用的項目，因此通道估計和預測的需求不僅僅在速度上追求卓越，還需要同時考慮如何降低功耗和成本。在硬體方面的深入研究也將對系統效能提升起到關鍵作用。

最終，我們期望將研發的通道估計和預測方法應用於實際低軌衛星系統，並進行實際通道容量和訊雜比的量測，以驗證我們方法在實際應用中的卓越效能。這不僅有助於推動衛星通信技術的不斷發展，同時也將為未來的衛星通信領域帶來更多創新與突破。

五、心得感想

張勻誠:

這個專題讓我深刻理解了與低軌衛星相關的知識，同時也為我在研究所的無線通訊系統課程中提供了更全面的基礎。在修課的過程中，我驚訝地發現，專題中所學的理论、進行的實驗，甚至寫過的程式碼都出現在課堂內，這讓我重新思考了通訊學科的廣度和深度。低軌衛星在未來通訊中的角色十分關鍵，它能提升通訊系統的韌性、擴大覆蓋範圍、增進傳輸速率，同時降低延遲，這使得相關研

究成為 Beyond 5G 和6G 等新一代通訊技術的重要一環。

這樣的研究不僅讓我們對通訊技術有更深入的認識，也啟發了我們對通訊意義的思考。通訊的核心價值在於提供一個基礎，讓我們能夠完成更多事情。當人類的需求不斷演變，例如前往太空、建立元宇宙等新挑戰浮現時，通訊技術的進步就成為實現這些目標的關鍵。通訊並非僅僅是滿足當前需求的手段，更是為未來需求提供可能性的推動力。

另外，通訊技術的進步不僅僅影響那些已擁有先進科技的地區，也能為那些基本需求尚未得到滿足的人群帶來機會。透過通訊的發展，我們有機會連結世界各地，提供資訊、教育、醫療等服務，這對於全球社會的公平與發展都有著深遠的影響。因此，通訊技術的進步不僅是技術創新，更是為了實現更廣泛人類需求的社會進步之一。

張愛翎:

六、參考資料

- [1] E. J. Candes and M. B. Wakin, "An Introduction To Compressive Sampling," in IEEE Signal Processing Magazine, vol. 25, no. 2, pp. 21-30, March 2008, doi: 10.1109/MSP.2007.914731.
- [2] A. M. Elbir, K. V. Mishra, S. A. Vorobyov and R. W. Heath, "Twenty-Five Years of Advances in Beamforming: From convex and nonconvex optimization to learning techniques," in IEEE Signal Processing Magazine, vol. 40, no. 4, pp. 118-131, June 2023, doi: 10.1109/MSP.2023.3262366.
- [3] <https://www.analog.com/en/technical-articles/power-advantage-of-hybrid-beamforming.html>
- [4] M. Cai, J. N. Laneman and B. Hochwald, "Beamforming codebook compensation for beam squint with channel capacity constraint," 2017 IEEE International Symposium on Information Theory (ISIT), Aachen, Germany, 2017, pp. 76-80, doi: 10.1109/ISIT.2017.8006493.
- [5] J. Lee, G. -T. Gil and Y. H. Lee, "Channel Estimation via Orthogonal Matching Pursuit for Hybrid MIMO Systems in Millimeter Wave Communications," in IEEE Transactions on Communications, vol. 64, no. 6, pp. 2370-2386, June 2016, doi: 10.1109/TCOMM.2016.2557791.
- [6] L. You, K. -X. Li, J. Wang, X. Gao, X. -G. Xia and B. Ottersten, "Massive MIMO Transmission for LEO Satellite Communications," in IEEE Journal on Selected Areas in Communications, vol. 38, no. 8, pp. 1851-1865, Aug. 2020, doi: 10.1109/JSAC.2020.3000803.
- [7] A. Alkhateeb, G. Leus and R. W. Heath, "Compressed sensing based multi-user millimeter wave systems: How many measurements are needed?," 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), South Brisbane, QLD, Australia, 2015, pp. 2909-2913, doi: 10.1109/ICASSP.2015.7178503.

- [8] M. A and A. P. Kannu, "Channel Estimation Strategies for Multi-User mm Wave Systems," in *IEEE Transactions on Communications*, vol. 66, no. 11, pp. 5678-5690, Nov. 2018, doi: 10.1109/TCOMM.2018.2854188.
- [9] Y. Zhang, A. Liu, P. Li and S. Jiang, "Deep Learning (DL)-Based Channel Prediction and Hybrid Beamforming for LEO Satellite Massive MIMO System," in *IEEE Internet of Things Journal*, vol. 9, no. 23, pp. 23705-23715, 1 Dec.1, 2022, doi: 10.1109/JIOT.2022.3190412.
- [10] M. Liu, X. Li, B. Ning, C. Huang, S. Sun and C. Yuen, "Deep Learning-Based Channel Estimation for Double-RIS Aided Massive MIMO System," in *IEEE Wireless Communications Letters*, vol. 12, no. 1, pp. 70-74, Jan. 2023, doi: 10.1109/LWC.2022.3217294.