



分散式 AI 資料中心架構演進

中華電信研究院寬頻網路研究所高級研究員 / 王弘毅
中華電信研究院寬頻網路研究所高級研究員 / 李明峰
中華電信研究院寬頻網路研究所高級研究員 / 周愉捷
中華電信研究院寬頻網路研究所主任級研究員 / 熊金源

關鍵字：分散式 AI 資料中心、全光網路、跨站算力調度、能源效率、綠色資料中心

摘要

隨著人工智慧（Artificial Intelligence，AI）發展與需求快速攀升，單一集中式資料中心（Data Center, DC）在電力、空間、散熱及網路效能上已逐漸顯現結構性瓶頸，近年 GPU 伺服器耗電量顯著提升，逐步逼近甚至超過 10kW 以上，使既有供電與冷卻無法滿足其需求，網路亦因集中式架構而易形成壅塞，加上土地取得困難，使單一集中式資料中心架構難以支撐未來持續成長的算力需求。本文介紹分散式 AI 資料中心作為解決上述問題的可行架構，透過「算力與地理位置解耦」的設計理念，將運算工作遷移至電力成本較低與電力使用效率（Power Usage Effectiveness，PUE）較佳的區域，並利用高速全光網路（All-Photonic Network，APN）

進行跨資料中心串接互連，使跨站 GPU 伺服器與儲存伺服器間仍維持接近本地部署的低延遲運算效率。本文透過 AI 資料中心能耗與成本模型分析，發現分散式架構可善用各資料中心的電價與能源結構差異，有效降低電費支出與碳排放量。此架構不僅突破單一資料中心的能源與物理限制，更能透過跨區調度來提升整體成本效益與永續性，成為兼顧效能與能源效率之綠色資料中心基礎。

一、AI 資料中心發展背景與挑戰

1.1 單一資料中心集中式架構的限制

隨著 AI 模型的規模持續成長，從早期數億參數的模型推進至百億、甚至兆級參數的超大型模型，資料中心的運算密度、網路頻



寬與能源消耗皆呈現指數級上升。然而現行多數企業所採用的仍是傳統「單一集中式」的資料中心架構，其設計原則多基於雲端早期的虛擬化與集中式 IT 資源管理，並未完全符合當前高密度 GPU（Graphics Processing Unit）訓練與大規模資料存取的需求。因此，在面對新世代 AI 工作負載時，傳統架構已逐漸暴露出多項限制 [1-3]。

首先，傳統單一集中式架構導致建置與擴充困難。單一資料中心需在同一園區內承載大量 GPU 伺服器、儲存伺服器及高速交換器，使得電力需求、冷卻散熱能力與機房空間成為主要瓶頸。以高階 GPU 伺服器為例，每台耗電可達 10 kW 以上，若要支撐數百台以上 GPU 伺服器組成的 AI 叢集（AI Cluster），不僅需要大幅追加供電與冷卻設備，亦會面臨施工成本高昂、施工週期長等問題。此模式限制資料中心規模彈性，不利於企業依照需求快速擴大 AI 建設。

其次，單點部署造成能耗與電費成本偏高。傳統單一集中式架構下，所有設備皆部署於固定機房，電力來源無法因應地區差異而最佳化，若所在區域電價偏高、PUE 較差，則所有 AI 運算都會承受相同的高成本。此外，單一資料中心必須容納大量高密度伺服器，使其散熱壓力上升，PUE 也難以下降至綠色資料中心可達成的水準，導致全年能耗與電費支出難以有效降低。

再者，單一資料中心的網路架構容易形成瓶頸。於大規模的 AI 運算情境中，大量 GPU 節點之間需要高頻寬、低延遲的互聯，同時，在運算過程中也可能需要持續讀取儲

存系統，形成高併發資料流。當所有運算與儲存資源集中部署於單一站點時，相關流量往往會集中通過少數關鍵的網路匯聚層或骨幹交換節點，使得交換器面臨流量集中、壅塞等問題，進而導致封包遺失、延遲上升，最終影響 GPU 整體運算效能。此類的網路瓶頸問題，將隨著模型規模擴大與參與的節點數增加而愈發明顯。

最後，單一集中式架構的營運模式缺乏彈性，無法應對再生能源與跨區資源調度需求。當企業希望利用不同地區的低電價時段、綠色再生能源或空閒的硬體資源，傳統單一資料中心架構無法有效支持跨資料中心 GPU 與儲存伺服器的協同部署策略，使整體營運成本與碳排放難以最佳化。

綜上所述，單一集中式資料中心架構在擴充性、能源效率、網路效能與營運彈性方面皆逐漸無法滿足 AI 時代的需求，因此發展具跨站分工能力、支援低延遲光互聯、並能有效利用區域電價與綠能優勢的分散式 AI 資料中心（Distributed AI Data Center）已成為必然趨勢。

1.2 分散式 AI 資料中心的概念與優勢

針對傳統單一集中式資料中心架構在擴充性、能源與網路瓶頸等方面的限制，業界逐漸轉向以跨站協同運算與高速網路串聯為基礎的分散式 AI 資料中心（Distributed AI Data Center）架構。此架構的核心在於不再要求「所有 GPU 伺服器與儲存伺服器必須集中部署於同一資料中心」，而是透過高頻寬、低延遲的跨資料中心互聯，使得多個資料中



心能共享算力與資料存取能力，形成邏輯上統一、物理上分散的 AI 平台 [4]。

首先，分散式架構最大的優勢在於跨地區擴充能力與建置彈性。企業不必再受限於單點機房的電力或機房空間，而能將 GPU 伺服器、儲存伺服器、交換器等設備分散部署於多個資料中心，使 AI 叢集能在不同場域間水平擴充。透過分散式部署，企業能更快配置新的節點，避免因大型機房建置週期過長而限制算力成長。

其次，分散式架構有效提升能源效率與電費最佳化能力。由於 GPU 伺服器與儲存伺服器可以分配到不同能源環境，企業能依據不同地區的 PUE、電價與當地再生能源供給進行最佳化。GPU 伺服器通常耗電量最高，因此若能將 GPU 運算負載轉至 PUE 較低、電價較便宜的資料中心，整體電費與碳排放即可顯著下降 [5]，這也是近年企業積極發展跨站 AI 運算的主要原因之一。

再者，分散式 AI 資料中心具備高度可用性與營運韌性。多個資料中心間的算力互通，使企業具備跨站調度能力，可依照需求、資

源狀態或電力使用策略進行動態算力分配。即使某一地點出現障礙、維護或負載過高，也可由其他資料中心接手，避免單點故障造成成長時間延誤。

分散式 AI 資料中心透過跨站協同運算、能源最佳化與網路架構重塑，使企業得以突破傳統集中式單一資料中心的物理限制，達成更高效、更彈性且更具永續性的環境。

1.3 目前台灣 AI 資料中心建設遭遇的問題

隨著生成式 AI 快速普及，台灣產業對大型 AI 資料中心的需求也急速攀升。然而，台灣在建置高密度 AI 資料中心時，面臨多重基礎設施與營運層面的挑戰，這些限制使得傳統單點式資料中心模式更難滿足 AI 所需的電力、空間與網路環境 [6,7]，進一步凸顯導入分散式 AI 資料中心的必要性，如表 1。

首先，電力供應不足與變電容量限制是台灣最普遍且最具結構性的挑戰。隨著 GPU 伺服器耗電量逐漸提升至 10 kW 以上，若要建置 1,000 ~ 2,000 顆 GPU 的 AI 叢集，單一

表 1 台灣集中式 AI 資料中心之結構性限制與分散式 AI 資料中心解法

設計限制與考量	集中式 AI 資料中心	分散式 AI 資料中心
電力供應與變電容量	因算力需求上升，單一站點電力供給難以滿足需求	透過多個資料中心分散部署，攤分單一站點電力需求
散熱空間與機房設計	因 GPU 伺服器需大量的散熱，既有資料中心多為早期空氣冷卻設計，難以滿足其需求	將 GPU 伺服器部署於具備適合冷卻條件的新型或專用資料中心，降低單點散熱壓力
土地取得與地理條件	因台灣建置大型 AI 資料中心之地點稀缺	可利用不同地區既有機房與土地，降低對單一大型資料中心的依賴
耐震與建設風險	因台灣處地震帶，耐震設計要求提高，集中式建設風險較高	分散部署降低單一資料中心承載風險，提升整體營運韌性



資料中心往往需要額外數十 MW 的電力，而變電站容量、供電線路與備援電力系統卻難以在短時間內升級。此外，許多工業區與科學園區已接近負載上限，新建機房或擴建機房必須等待多年才能取得足夠電力，也因此形成建設瓶頸。

其次，散熱空間受限與高密度機架佈局不易亦是重要問題。AI 資料中心多採用高密度機櫃，部分液冷架構甚至更高，而台灣既有資料中心大多是早期設計的空氣冷卻機房，不僅無法支撐此級別熱負載，也難以容納後續的水冷、浸沒式冷卻等系統。即便進行改建，施工成本與施工期間停機風險均十分可觀，使得傳統資料中心難以快速升級以承載大型 AI 叢集。

第三，地理環境與土地取得困難亦對集中式 AI 機房形成限制。台灣地狹人稠，適合建置大面積資料中心的土地有限，且多數合適地點需鄰近主要光纖骨幹與變電站，使選址本身即具高度稀缺性與成本壓力。此外，台灣位處地震帶，高密度機櫃與精密冷卻管線在耐震設計上的要求亦進一步提高集中式大型 AI 資料中心的建設風險。

綜上所述，台灣在電力、空間、散熱、土地等面向皆面臨單一集中式 AI 資料中心的結構性瓶頸，使得建置超大規模 AI 運算環境的成本與風險提高。在此背景下，透過分散式 AI 資料中心分散電力需求、降低單點冷卻壓力、提升跨區彈性，並利用高速網路串接多資料中心協同運作，成為台灣發展大型 AI 能力的必然趨勢。

二、分散式 AI 資料中心網路架構

2.1 AI 資料中心網路架構之現狀

在單一 AI 資料中心內部，網路架構的設計核心在於支撐大規模 GPU 叢集間的高併發資料交換。目前的標準網路架構設計採用扁平化的脊葉架構（Spine-Leaf Architecture），透過葉交換器與脊交換器全互聯（Full-Mesh）提供高頻寬與低延遲的傳輸能力。在此架構下，網路功能被細分為前端網路與後端網路，如圖 1。前端網路主要負責外部用戶存取、管理流量以及與儲存設備的通訊，通常採用標準高性能乙太網路技術；而後端網路則被稱為運算網路，專門處理 GPU 之間極其頻繁的梯度同步與資料交換任務。




圖 1 單一資料中心雲內網路架構示意圖



為了滿足後端網路對極低延遲與零丟包的苛刻需求，業界廣泛導入遠端直接記憶體存取（Remote Direct Memory Access，RDMA）技術，允許資料直接在兩台伺服器的記憶體間進行交換，完全繞過作業系統核心、CPU（Central Processing Unit）處理程序及繁瑣的封包複製過程。這不僅能大幅降低通訊延遲，更能有效釋放被網路 I/O（Input/Output）佔用的 CPU 運算資源，使其能專注於任務調度。在大型語言模型（Large Language Model，LLM）訓練中，RDMA 是確保 GPU 叢集進行大規模梯度同步時不產生通訊瓶頸的關鍵，能顯著縮短 GPU 等待資料的閒置時間，並支撐算力線性擴展與大規模部署下的穩定高效運作。

針對算力性能的提升，架構擴展主要分為兩大路徑，垂直擴展（Scale-up）側重於單一運算節點內部的硬體互聯，利用高速匯流排如 NVLink 強化 GPU 間的直連性能，可在單一伺服器內提升算力密度；水平擴展（Scale-out）則透過前述之高性能後端網路，將數千至上萬個運算節點叢集化，利用叢集調度平台實現跨伺服器的協同計算，從而建構出支撐萬億級參數模型訓練的超大 AI 資料中心。

2.2 單一 AI 資料中心之物理極限與跨地域擴展

儘管內部的脊葉架構與擴展技術已趨成熟，但單一 AI 資料中心在實際部署中面臨物理與能源供應的瓶頸。隨著 AI 晶片性能的飛躍，單台高端 GPU 伺服器的功耗已攀升至約 10 kW。對於一個具備十萬顆 GPU 的超大型 AI 叢集而言，其核心 IT 設備之總功耗已明確突破 150 MW [8]，若進一步計入基礎設施

維運與變配電損耗，總用電需求已逐漸超越傳統都會區電網的單點供電上限。以東京等大都會區為例，龐大的 AI 基礎設施需求已使當地供電系統處於飽和狀態，導致新建資料中心面臨有算力需求卻無電力配額的窘境。

當單一 AI 資料中心內部的垂直擴展與水平擴展達到環境承載極限時，必須打破單一 AI 資料中心的物理機房界限，將技術重心進一步推向跨地域的橫向協作擴展（Scale-across）。其核心理念在於將運算負荷由能源吃緊的都會核心區，分散至具備電力盈餘與豐富綠色能源的偏遠樞紐。透過發展 Scale-across 架構，能實現算力資源與電網負荷在地理空間維度上的物理脫鉤，利用高性能跨域傳輸網路將分布於不同區域的 GPU 資源池進行邏輯一體化，從而突破單一站點的能源供給上限，達成算力規模的持續增長。

2.3 AI 資料中心分散式架構模式

在跨出單體站點後，分散式 AI 資料中心架構主要可分為「計算與儲存解耦」（Disaggregated Compute and Storage），如圖 2 所示，「分散式 GPU 叢集」（Distributed GPU Cluster）如圖 3 所示，兩大技術方向。




圖 2 計算與儲存解耦架構示意圖




圖 3 分散式 GPU 叢集架構示意圖

在「計算與儲存解耦」架構下，將具備高度安全防護、需維持資料主權完整性的存儲節點保留於本地端，而將能源需求極大的大規模 GPU 訓練叢集遷移至電力餘裕充足且 PUE 表現更優的遠端節點。

而在「分散式 GPU 叢集」架構下，則進一步追求硬體資源的最大化，透過網路將地理分散的 GPU 資源整合成一個邏輯上的超大型運算叢集，滿足超大規模模型訓練所需的高效運算能力。

2.4 AI 資料中心分散式架構的物理限制

無論採用何種分散式模式，皆面臨長距離地理限制引發的通訊障礙。地理距離導致的往返時間（Round-Trip Time, RTT）拉長是損耗算力的首要因素。在大規模模型訓練中，GPU 之間需頻繁進行梯度同步（Gradient Synchronization）與資料交換，對延遲極度敏感。

若延遲時間無法得到補償，GPU 叢集的有效算力利用率將隨距離增加而顯著下滑。其次，長距離傳輸易引發網路壅塞與丟包，

特別是當大量遠端 GPU 叢集同時將資料往同一資料中心送時，網路很容易瞬間壅塞，就像多條車道的車子同時擠進一個出口。一旦網路壅塞嚴重，資料可能就會遺失，系統只好重新再送一次，這樣不但浪費時間，還可能讓整個訓練流程大幅延誤，甚至被迫中斷。

2.5 透過 APN 連接分散式 AI 資料中心

針對上述長距離限制，IOWN 全球論壇（IOWN Global Forum）提出了基於全光網路（All-Photonic Network, APN）的技術方案，如圖 4 所示。APN 技術透過消除傳統網路中頻繁的光電轉換過程，改採 L0/L1 層的全光交換，提供接近物理極限的傳輸性能（延遲時間約 5 μ s/km）。

根據 IOWN 全球論壇針對遠端 GPU 使用案例所訂定的關鍵效能指標，跨站點之 AI 訓練時間增幅應嚴格控制在 10% 以內 [9]，才能視為具備商業部署的可行性。在模擬將資料儲存端與 GPU 運算叢集分離的測試情境下，透過 APN 結合長距無損 RDMA 技術，




圖 4 APN 之跨地域算力資源調度



展現了極佳的傳輸效率：當距離在 40 公里時，訓練時間幾乎與本地相同（僅 1.002 倍 [9]）；即便延伸至 100 公里的長距離，整體的 AI 模型訓練時間實測值僅為本地訓練的 1.079 倍 [9]，成功達成規範要求的 10% 門檻。此數據驗證了 APN 能確保網路讀取資料時間優於 GPU 運算時間，使遠端算力叢集能維持如同本地連接般的高效能表現，為應對都會區電力飽和問題提供了關鍵的技術支撐。

三、分散式 AI 資料中心耗電分析

3.1 AI 資料中心電力消耗模型與估算方法

在全球 AI 需求急遽攀升的背景下，資料中心的能源消耗已成為企業營運成本與永續治理中的核心議題。傳統單一資料中心雖具備集中管理的優勢，但其高密度算力集中於同一地點，往往導致冷卻負載增加、電力成本居高不下，並使得整體碳排放持續攀升。另一方面，隨著綠電比例提升與跨資料中心高速光網路技術的成熟，分散式資料中心架構逐漸成為新興選項。透過將儲存伺服器與 GPU 伺服器部署於不同資料中心，企業得以靈活利用各地區的能源結構差異，特別是引入低 PUE 的綠色資料中心後，能源使用效率與碳排表現可大幅改善。因此，探討單一與分散式資料中心在實際 AI 訓練情境下的耗電量差異有助於評估不同部署架構在能源效率與營運成本層面的影響，並作為後續資料中心架構設計與資源配置之參考依據。

根據 IOWN Global Forum 的研究 [9]，可建立 AI 資料中心在不同部署情境下之電力消耗估算方式。AI 資料中心的總消耗電量

主要由三個部分組成：網路設備耗電量、儲存伺服器耗電量、GPU 伺服器耗電量，其中 GPU 伺服器的耗電占比最高，對資料中心能耗與能源效率影響最為關鍵。

在估算 AI 資料中心能耗時，網路設備的運行功率皆以額定功率的 70% 作為實際運作功率，以反映資料中心長時間、穩定運行的負載行為。儲存伺服器則以服務運作期間的功率表現納入計算，涵蓋本地儲存或遠端儲存等情境。而 GPU 伺服器，則將其耗電量拆分為三種狀態： GPU_0 （伺服器基礎耗電量）、 GPU_{ON} （GPU 運算時耗電量）及 GPU_{OFF} （GPU 等待 I/O 時的閒置耗電量）。其中 GPU_{ON} 是整體 AI 訓練中的最大且關鍵耗電量來源，而 GPU_{OFF} 的增減則有效反映資料存取效率與網路效能對整體訓練的能耗影響。

依據 AI 訓練部署情境的不同，資料中心能耗估算可分為兩種情境進行分析：

1. Local Training：所有設備部署於同一資料中心

當 GPU 伺服器、儲存伺服器與網路設備皆位於同一資料中心時，此架構具有最短的資料存取路徑與最小的網路延遲，其資料中心消耗電量公式如下：

$$\begin{aligned} \text{Total Power Consumption} &= (\text{SW Power Consumption}) \times 70\% \\ &+ (\text{NFS Power Consumption}) \\ &+ \{(\text{GPU}_0 \text{ Power Consumption}) \\ &+ [(\text{GPU}_{ON} \text{ Power Consumption}) \\ &+ (\text{GPU}_{OFF} \text{ Power Consumption})] \\ &\times (\text{Number of GPUs})\} \end{aligned}$$



2. Remote Training：GPU 伺服器與儲存伺服器跨資料中心部署

當 GPU 伺服器部署於遠端資料中心，而儲存伺服器仍位於原資料中心，兩端透過全光網路連接，則需將 APN 設備耗電納入估算，此架構確保跨資料中心的傳輸具備低延遲、高吞吐能力，有利於縮短 GPU_{OFF} 閒置時間、改善 GPU 使用率，讓 AI 訓練在跨資料中心部署時仍能維持接近本地的效能與能耗表現。其資料中心消耗電量公式如下：

Total Power Consumption

$$\begin{aligned}
 &= (\text{APN Power Consumption} \\
 &+ \text{SW Power Consumption}) \times 70\% \\
 &+ (\text{NFS Power Consumption}) \\
 &+ \{(\text{GPU}_0 \text{ Power Consumption}) \\
 &+ [(\text{GPU}_{\text{ON}} \text{ Power Consumption}) \\
 &+ (\text{GPU}_{\text{OFF}} \text{ Power Consumption})] \\
 &\times (\text{Number of GPUs})\}
 \end{aligned}$$

3.2 集中式與分散式 AI 資料中心之能耗、電費與碳排比較分析

本節參考 IOWN 報告之量測資料與前述耗電量估算公式，比較單一資料中心（同一站點）與分散式資料中心（跨站，距離 100 公里，APN 互連）在相同的 AI 訓練負載下

的部署模式的能耗、電費與碳排放量差異，分別的情境如下：

1. 單一資料中心架構（基準）

在單一資料中心中，一台 GPU 伺服器含 8 張 GPU、一台交換器與一台儲存伺服器皆部署於同一站點，資料讀取與 GPU 運算皆在本地資料中心端完成，具備最短的資料存取路徑與最低的延遲，為能耗比較的基準情境，如圖 5 所示。

2. 分散式資料中心架構

在分散式資料中心中，一台 GPU 伺服器含 8 張 GPU 與一台交換器部署於綠色資料中心，而一台儲存伺服器與一台交換器位於既有的資料中心，兩者透過 APN 串接。距離設定為 100 公里，並採用 APN 設備與交換器構成的開放式 APN WAN 連接。此架構等於跨站協同運算模式，其中，GPU 運算在綠色資料中心進行，而資料從既有的資料中心的儲存伺服器中讀取，APN 確保跨站資料交換仍具低延遲與高吞吐，如圖 6 所示。

基於前述兩者資料中心的架構，以相同的 AI 訓練負載並套用前一節所建立的資料




圖 5 集中式資料中心架構




圖 6 分散式資料中心架構

中心耗電量模型，針對不同部署模式下進行預估能耗計算。首先依照各類設備的功率需求計算其設備能耗，再分別乘上各資料中心的 PUE 以獲得資料中心整體能耗，最後，再依據所屬資料中心的電價進行換算，即可得到不同架構下的 AI 訓練電費比較結果。其中資料中心的 PUE 與電力價格參考國外資料中心的數字如表 2，計算結果如表 3 所示。

表 2 資料中心 PUE 與電力價格

	標準資料中心	綠色資料中心
PUE	1.98	1.56
電力價格 (\$/kWh)	0.2	0.1

表 3 集中式與分散式架構之功耗、電價與碳排放比較

	單一資料中心架構	分散式資料中心架構
標準資料中心功耗 (kWh)	0.951	0.294
綠色資料中心功耗 (kWh)	X	0.668
基於 PUE 的總功耗 (kWh)	0.951	0.962
總電費 (\$)	0.19	0.126
碳排放量 (公斤)	0.451	0.139

由表 3 可觀察，在單一資料中心架構中，所有設備的運轉能耗經 PUE 換算後，其總耗電量為 0.951 kWh。若依國外標準資料中心電價 0.20 元 /kWh 計算，訓練一次僅需約 0.19 元。進一步以台灣電力排碳係數 0.474 kg/kWh 換算，則此架構於相同訓練負載下的總碳排放約為 0.451 公斤。

相較之下，在分散式資料中心架構中，儲存伺服器部署於標準資料中心，但 GPU 伺服器則運行於綠色資料中心，因此其設備能耗需分別套用不同 PUE 進行換算。受惠於 APN 的低延遲特性，跨站資料讀取對 GPU 訓練時間的影響極小，使得整體訓練耗能依然維持在與單一資料中心近似的水準，約為 0.962 kWh。若依國外標準資料中心與綠色資料中心電價計算，則訓練一次需約為 0.126 元。若以同樣的台灣排碳係數 0.474 kg/kWh 估算，其碳排放量約為 0.139 公斤，較單一資料中心架構大幅降低。

然而，實務上綠色資料中心的電價並非必然低於傳統資料中心。如圖 7 所示，分散式 AI 資料中心的整體電力成本可視為綠色資料中心電價的線性函數，隨再生能源電價上升，其總電費亦隨之提高。當此情境下的綠色資料中心電價低於約 0.196 元 /kWh 時，分散式架構在整體電力成本上仍具備相對於單一集中式資




圖 7 不同資料中心架構電力成本比較

料中心的經濟優勢；一旦綠電價格高於此臨界值，其成本優勢將逐漸縮減，甚至可能轉為劣勢。此結果顯示，分散式 AI 資料中心的經濟效益並非來自架構本身直接降低能耗，而是高度仰賴不同地區之電價結構與能源組合差異。

分散式部署的核心優勢並非來自能耗的直接下降，而在於其可跨區域調度算力，靈活利用不同電力結構與電價機制所帶來的長期成本與碳排放量的優化空間。在具備低電價或高比例再生能源的地區，GPU 伺服器可部署於以綠電為主的資料中心，其碳排放量顯著優於傳統火力發電占比較高的資料中心，如圖 8 所示，在不同用電規模下，集中式資料中心之碳排放量隨功耗線性成長，且因受限於單一電力系統，其每單位用電所對應之碳排放強度維持在較高水準；相對而言，分散式綠色資料中心架構透過將主要運算負載配置於以再生能源為主的節點，使整體碳排放曲線斜率顯著較低。此差異隨訓練功耗規模放大而愈明顯，顯示在大規模使用 AI 情境下，分散式架構能有效降低總體碳排放量的成長。因此，分散式 AI 資




圖 8 不同資料中心架構碳排放量比較

料中心的關鍵價值，在於將算力視為可被調度的資源，依電價、能源來源與碳排放量來進行跨區域配置，而非僅以單一據點的能效改善作為導入的主要理由。

更重要的是，分散式架構具備跨站點算力協同能力，可在不影響訓練效率的前提下，將 GPU 工作負載動態移轉至「電價較低」或「使用率較低」的資料中心。例如在離峰時段，部分地區可能具備更低電力成本，系統便可自動將運算工作切換至該節點，進一步壓低費用。這種「時間 × 地點」的雙軸最佳化，是傳統單一資料中心難以實現的運算策略。

此外，分散式架構搭配高速全光網路，能確保 GPU-GPU 或 GPU-Storage 之間的不同步延遲不會因跨站部署而顯著增加，並使得整體訓練時間維持在可接受範圍內。在當前 AI 訓練耗電成本快速攀升的背景下，電費在整體總體擁有成本（Total Cost of Ownership, TCO）中占比持續提升，分散式部署方案的經濟效益因而更加凸顯。



整體而言，分散式資料中心不僅是一種網路與算力的架構選擇，更是面對能源價格波動與永續發展需求時的策略性布局。透過電價差、離峰調度以及跨站點算力協同等機制，AI 訓練可在不犧牲效能的前提下大幅降低成本，展現其在能源效率與經濟效益上的明顯優勢。若能進一步搭配高再生能源占比的資料中心節點，未來有機會在節能與減碳兩方面同時取得更具競爭力的成果。

四、結論

隨著生成式 AI 推動模型規模與訓練需求高速成長，算力已逐漸成為跨地域整合與調度的關鍵基礎資源。分散式 AI 資料中心的核心價值，在於實現「算力與地理位置的解耦」，使 GPU 運算資源得以依據電力條件、能源結構與基礎設施效率進行彈性部署與整體最佳化。

在此架構下，網路效能成為能否實際落地的關鍵因素。高速的全光網路技術方案，透過 L0/L1 層全光交換機制，降低傳統網路中頻繁光電轉換所造成的延遲與能耗，使跨地域傳輸得以接近物理極限，同時提升頻寬利用效率與傳輸穩定性。實測結果顯示，即使 GPU 節點與資料儲存分離、距離延伸至數十甚至上百公里，整體訓練效能仍可維持在可接受甚至近似本地的水準。此結果顯示，在高效能光網路的支撐下，使原本受距離限制的分散式架構從概念驗證走向實際可部署的解決方案。

此外，分散式架構亦帶來顯著的能源與永續優勢。透過跨區域算力調度，依據 PUE 與再生能源供應比例動態配置運算任務，可

優先使用低碳排、高效率節點，有效降低電力成本與碳排放量。透過結合離岸風電與大型光電場來部署算力節點，更可實現算力與綠能就近整合，減輕電網負載。整體而言，結合 APN 技術的分散式 AI 資料中心，不僅能緩解都會區電力壓力，更為台灣在面對大算力需求與淨零轉型之間，提供一條兼顧效能、成本與永續的可行路徑。

參考文獻

1. NVIDIA DGX H100 產品規格. <https://nvdam.widen.net/s/kpwzdwrbv/ai-for-enterprise-dgx-h100-datasheet-nvidia-a4-2146027-r3-web>
2. Why Traditional Data Center Designs Struggle to Keep Up with AI Demands — and What's Next. <https://edgecore.com/why-traditional-data-center-designs-struggle-to-keep-up-with-ai-demands-and-whats-next/>
3. Current Cooling Limitations Slowing AI Data Center Growth. <https://airsysnorthamerica.com/current-cooling-limitations-slowing-ai-data-center-growth/>
4. How to Connect Distributed Data Centers Into Large AI Factories with Scale-Across Networking. <https://developer.nvidia.com/blog/how-to-connect-distributed-data-centers-into-large-ai-factories-with-scale-across-networking/>
5. IOWN APN による遠隔データセンター間における処理配置最適化の実証実験に成功～再生可能エネルギー積極利用によるカーボンニュートラルへの貢献～. <https://www.ntt-west.co.jp/news/2506/250611a.html>
6. 台電推 AI 資料中心選址近電廠，新管理規則擬明年出爐. <https://technews.tw/2025/12/17/taipower-ai-data-center-new-rules/>
7. 數據中心選址的關鍵因素（三）：台、歐、美土地取得與基礎建設. <https://cmarketnotes.com/data-center-site-selection-land/>
8. 伊隆馬斯克的大型人工智慧資料中心正式啟用－xAI 獲準使用 150 兆瓦電力. <https://www.tomshardware.com/tech-industry/artificial-intelligence/elon-musk-massive-ai-data-center-gets-unlocked-xai-gets-approved-for-150mw-of-power-enabling-all-100-000-gpus-to-run-concurrently>
9. Green Computing with Remote GPU for AI Training with Image Data. <https://iowngf.org/content-type/proof-of-concepts/>