

應用於資源受限邊緣裝置之輕量級自適應 RAFT 共識機制：基於 TABULAR Q-LEARNING 之優化研究

組別：A-4

成員：周雨澄

指導教授：謝孫源

一、專題簡介


背景問題：

- 傳統機制瓶頸：Raft 固定的逾時機制在惡劣網路中易引發頻繁誤判 (Misjudgement)，導致無效選舉並大幅降低系統可用性。
- 邊緣硬體限制：DRL 或 LinUCB 等現有動態優化策略運算開銷過大，無法部署於缺乏浮點運算單元 (FPU) 的受限邊緣節點 (如 缺乏硬體浮點運算單元 FPU 的 8-bit/16-bit MCU)。

解決方案與目的：

- 輕量級 AI 導入：引入 Tabular Q-Learning 演算法，以極低運算開銷實現參數動態自適應，完美契合邊緣節點之硬體限制。
- 雙重驗證：對比傳統 Random 與 TCP-like 策略，證明本機制在複雜網路中兼具提升系統可用性與突破硬體瓶頸之卓越表現。

二、系統架構及設計



SITL 架構 (Software-in-the-Loop)


真實 IoT 網路災難模擬

- 採用 Pareto 排隊模型 模擬邊緣網路常見的瞬間流量暴衝與極端長尾延遲 (Tail Latency)。
- 模擬器可即時注入 Jitter、Packet Loss

Q-Learning 動態適應機制

- State：綜合評估最近 10 次封包的 平均延遲 (Latency) 與 波動程度 (Jitter)
- Action：動態選擇 Timeout 區間
- Reward：Total Reward = Base Reward - Latency Penalty - Timeout Length Penalty

三、成果展示



為確保實驗客觀與可重現性，五種網路干擾劇本 (各 60s) 皆通過 5 組亂數種子的交叉驗證。由分佈圖可見，Q-Learning 模型在多數場景皆穩定收斂於左上角 (Ideal Zone)，其系統可用性與防誤判能力全面優於對照組。

四、結論及未來展望

- 效能突破：Q-Learning 成功適應動態延遲，於 4/5 極端場景中擊敗傳統基準方法。
- 邊界發現：面對高頻波動網路 (Sn5)，Q-Table 學習速度不及環境突變，易生震盪。
- 未來發展：將引入 Forgetting Factor 改善狀態遺忘機制，並拓展至 Docker 容器化測試。

參考資料：

Q. Wang, "BALLAST: Bandit-Assisted Learning for Latency-Aware Stable Timeouts in Raft," *arXiv preprint arXiv:2512.21165*, 2025.

D. Ongaro and J. Ousterhout, "In search of an understandable consensus algorithm (extended version)," in *2014 USENIX Annual Technical Conference (USENIX ATC 14)*, Philadelphia, PA, 2014, pp. 305–319