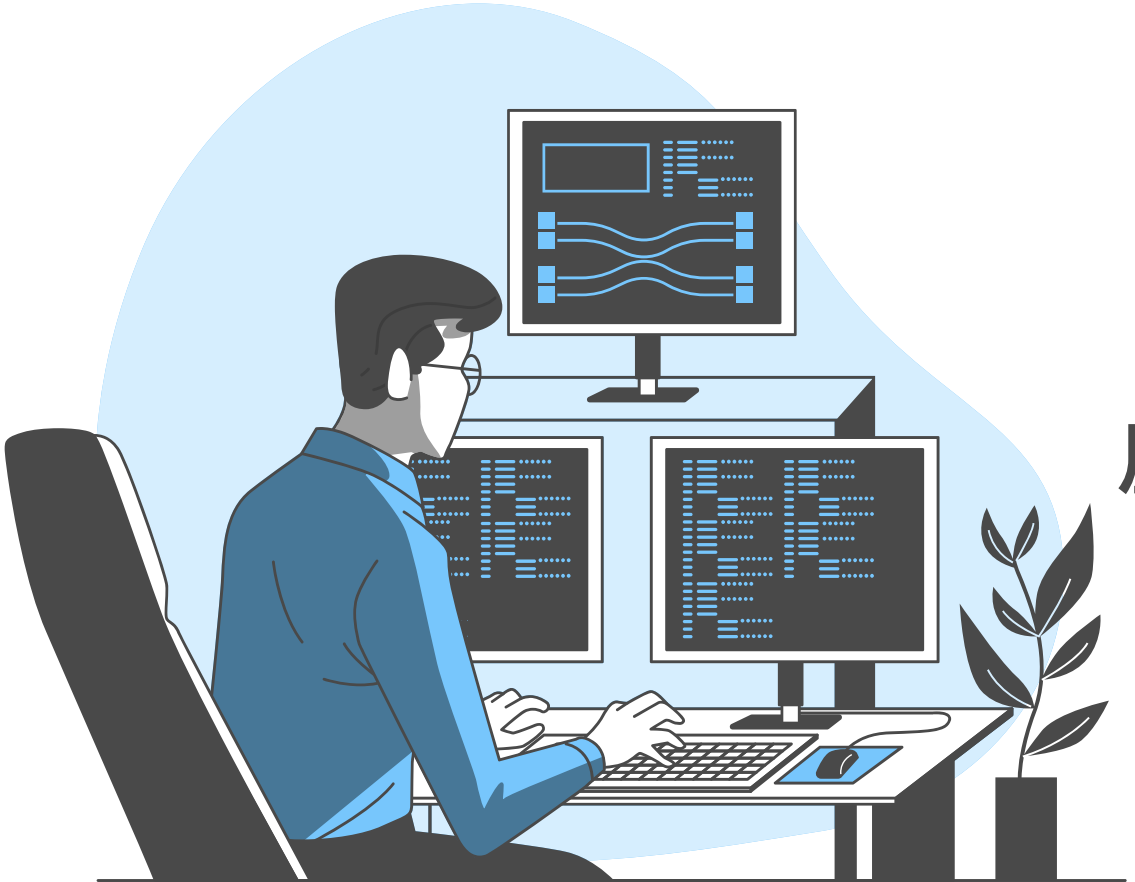

以 Proxmox VE 建置私有雲虛擬主機服務

NTHU CS - LSALAB
（周志遠教授）

APNIC 52 Fellows
牟展佑 www.mou.tw
contact@mou.tw

William Mou

NTHU SCC
New Taipei
Community
Photographer

I am passionate about computer architecture, operating systems and networking. I show these passions in HPC filed and won the championship in ASC20-21 Student Supercomputing Challenge. I'm glad to join here and meet you all!

COSCUP

HITCON

SITCON

Super Computer Competition (HPC)

PVE HOME

Proxmox VE Overlay Networking

WasmEdgeRuntime

Web Assembiy

SiFive

SiFive Intern

目錄

需求及挑戰

學校實驗室有建立伺服器叢集給研究生使用的需求：

- 伺服器叢集、實驗室 A、實驗室 B 位於不同大樓
- 伺服器需要高自由度，供研究生實驗新的軟硬體

在 Naive 的網路及伺服器架構下，使用者有以下困難：

1. 無法透過 SSH 連接內部網路設備
   - A 埠轉發至外部網路（但有可能遭受攻擊）
   - A 設定虛擬私人網路（需要頻繁切換）
2. 伺服器上臨時架設的網頁難以連接
   - A 請管理員設定埠轉發（較為繁瑣）
   - A 使用 `ssh -R` 進行反向隧道連接

1. 硬體機器資源有限互相爭搶
   - A 使用試算表手動排程（繁瑣）
   - A 未滿載使用容易造成資源浪費
2. 軟體環境互相干擾
   - A 使用虛擬環境（學習成本高）
   - A 硬碟多系統開機（中斷成本高）

解決方案

在 Naive 的網路及伺服器架構下，使用者有以下困難：

1. 無法透過 SSH 連接內部網路設備
   - ➢ 埠轉發至外部網路（但有可能遭受攻擊）
   - ➢ 設定虛擬私人網路（需要頻繁切換）
2. 伺服器上臨時架設的網頁或服務難以連接
   - ➢ 請管理員設定埠轉發（較為繁瑣）
   - ➢ 使用 `ssh -R` 進行反向隧道連接

1. 硬體機器資源有限互相爭搶
   - ➢ 使用試算表手動排程（繁瑣）
   - ➢ 未滿載使用容易造成資源浪費
2. 軟體環境互相干擾
   - ➢ 使用虛擬環境（學習成本高）
   - ➢ 硬碟多系統開機（中斷成本高）

L3 Overlay Network

- BGP over WireGuard / L2TP over IPSec
- Build with Mikrotik RouterOS
- Need to manage private AS, IPAM, and more

Proxmox VE Cluster

- PVE Accounts Permission
- Virtual Machine: QEMU / KVM
- Virt-IO / VFIO / PCIe Passthrough
- Virtual Bridge / VLAN

壹、

Overlay Network
概念與優點

覆蓋網路(Overlay Network)

覆蓋網路(Overlay Network)是一種在現有網路基礎上建立的虛擬網路架構。覆蓋網路中的節點是通過現有的底層網路(如網際網路)相互連接的，並且這些節點之間的連接形成了另一個邏輯上的網路結構。

覆蓋網路是在一個物理網路上建立的虛擬網路。

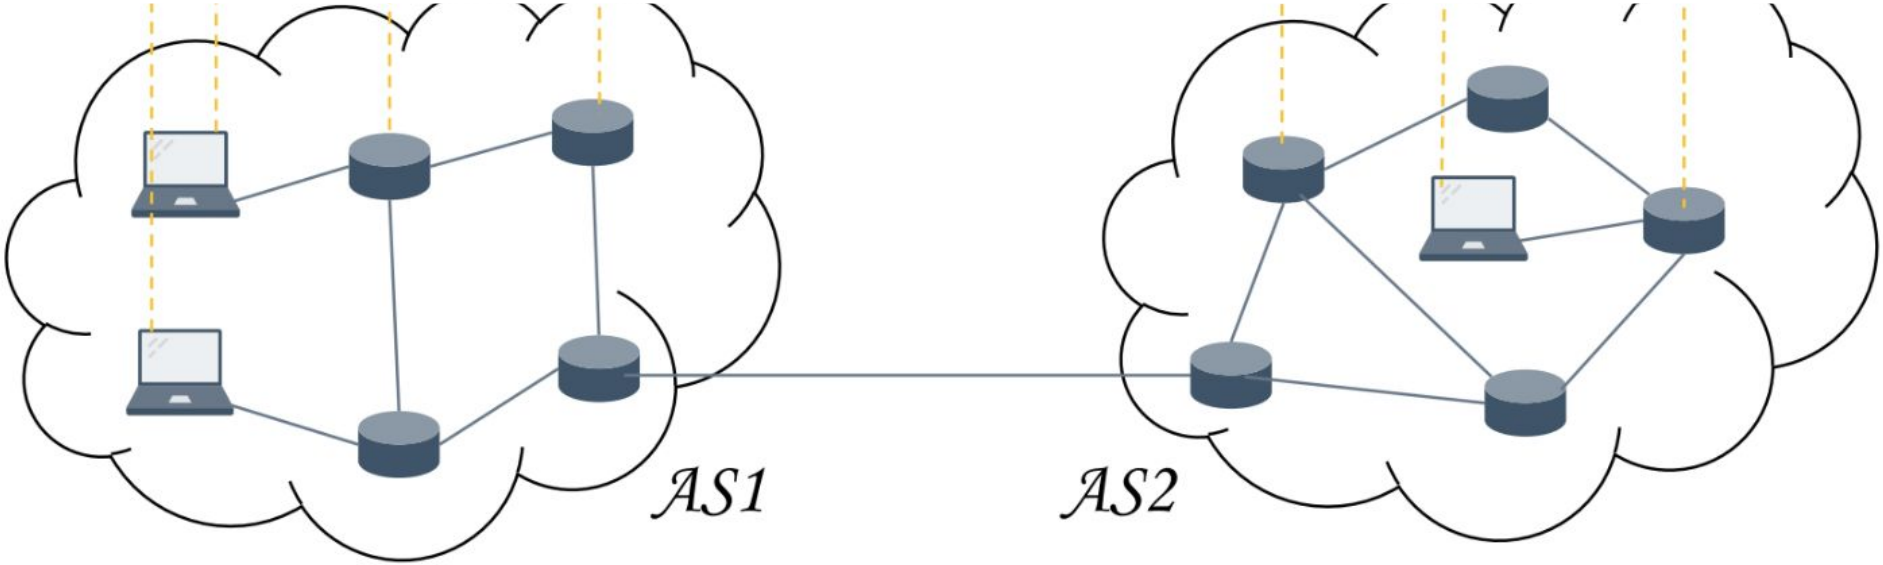

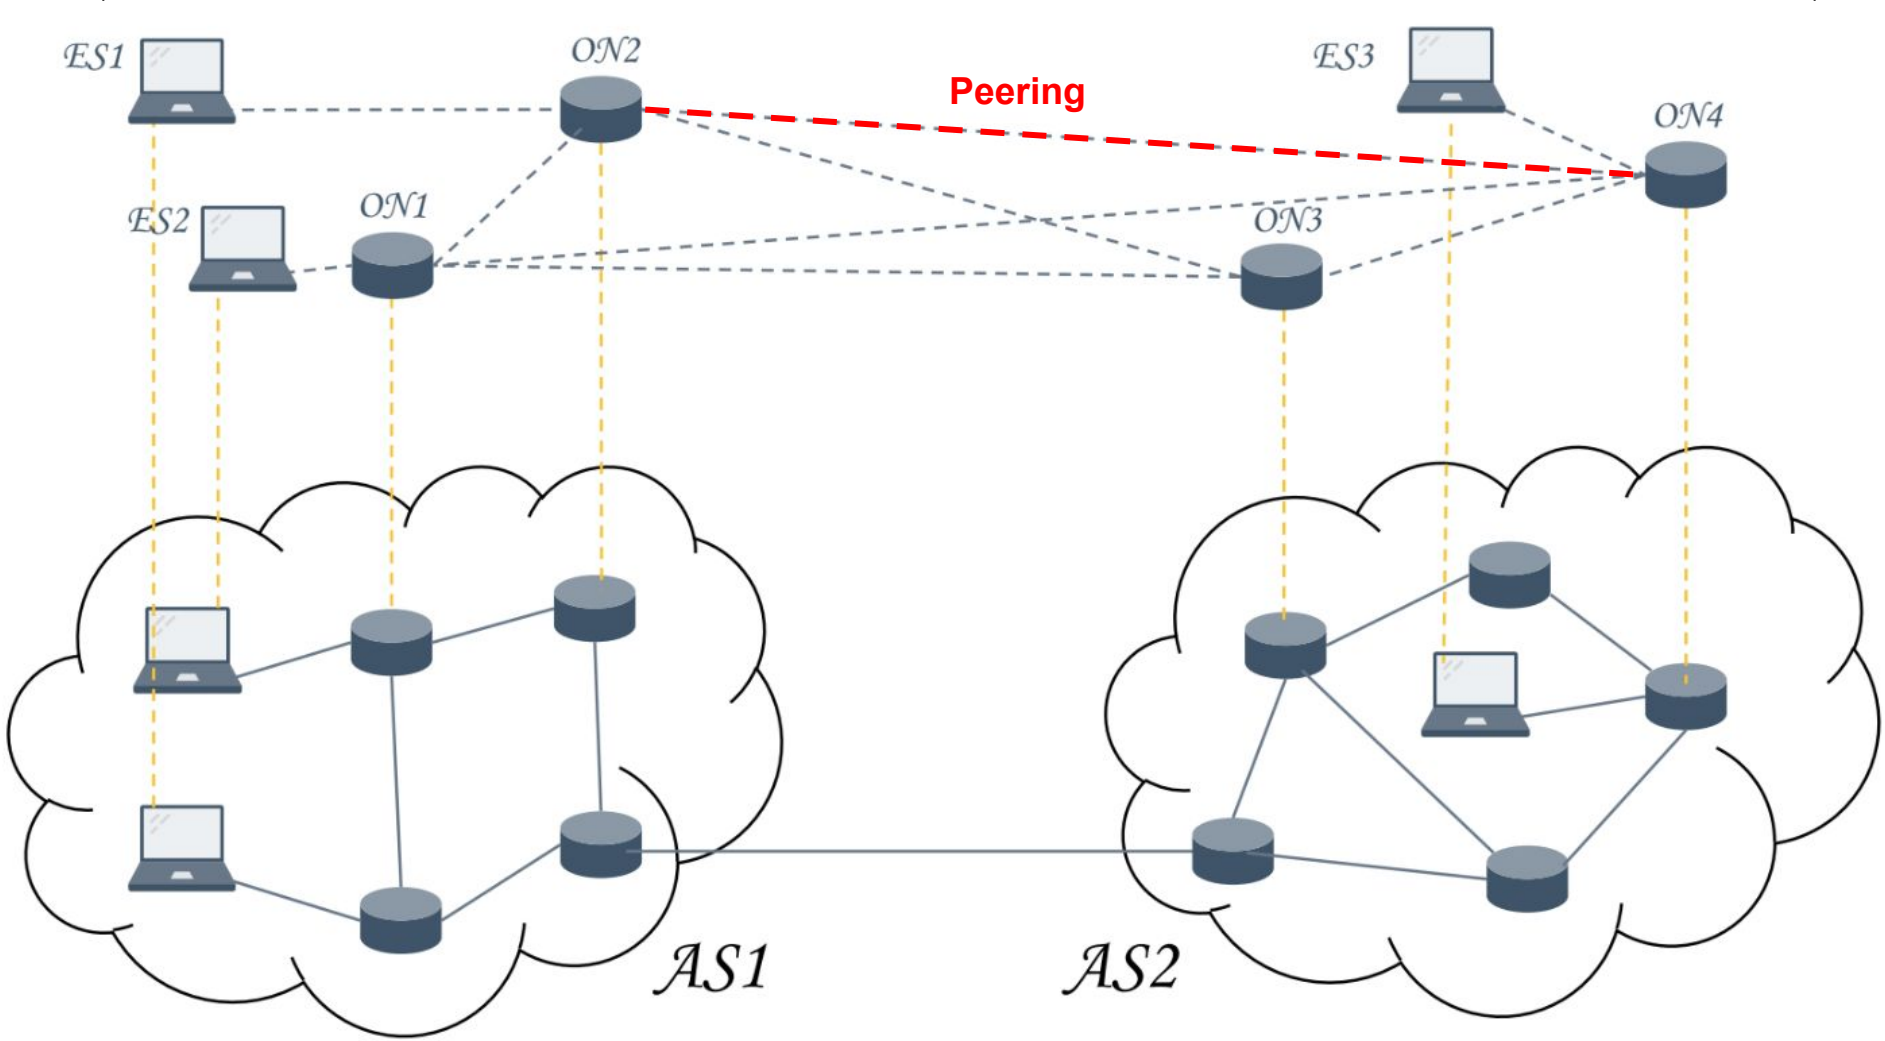
ES1
ON2
Peering
ES3
ON4
ES2
ON1
ON3
AS1
AS2

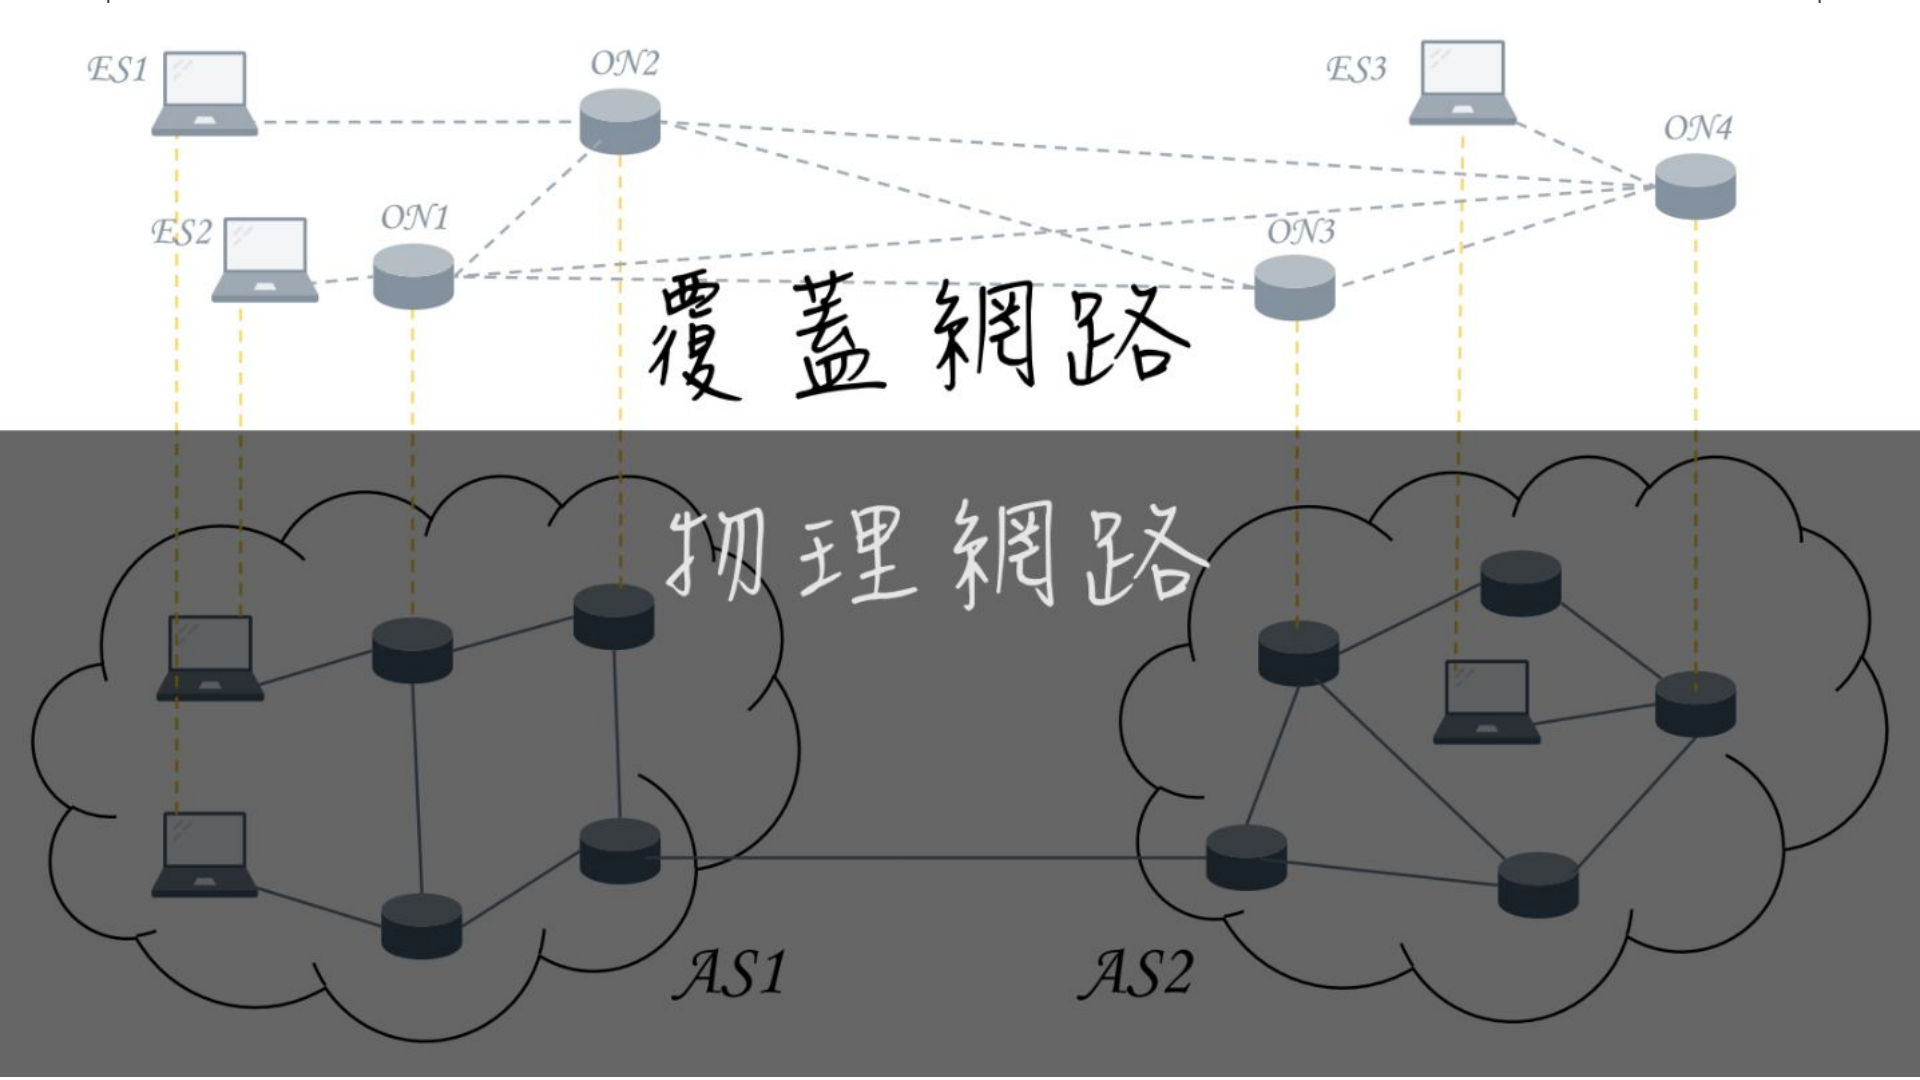
ES1
ON2
ES3
ON4
ES2
ON1
ON3
覆蓋網路
物理網路
AS1
AS2

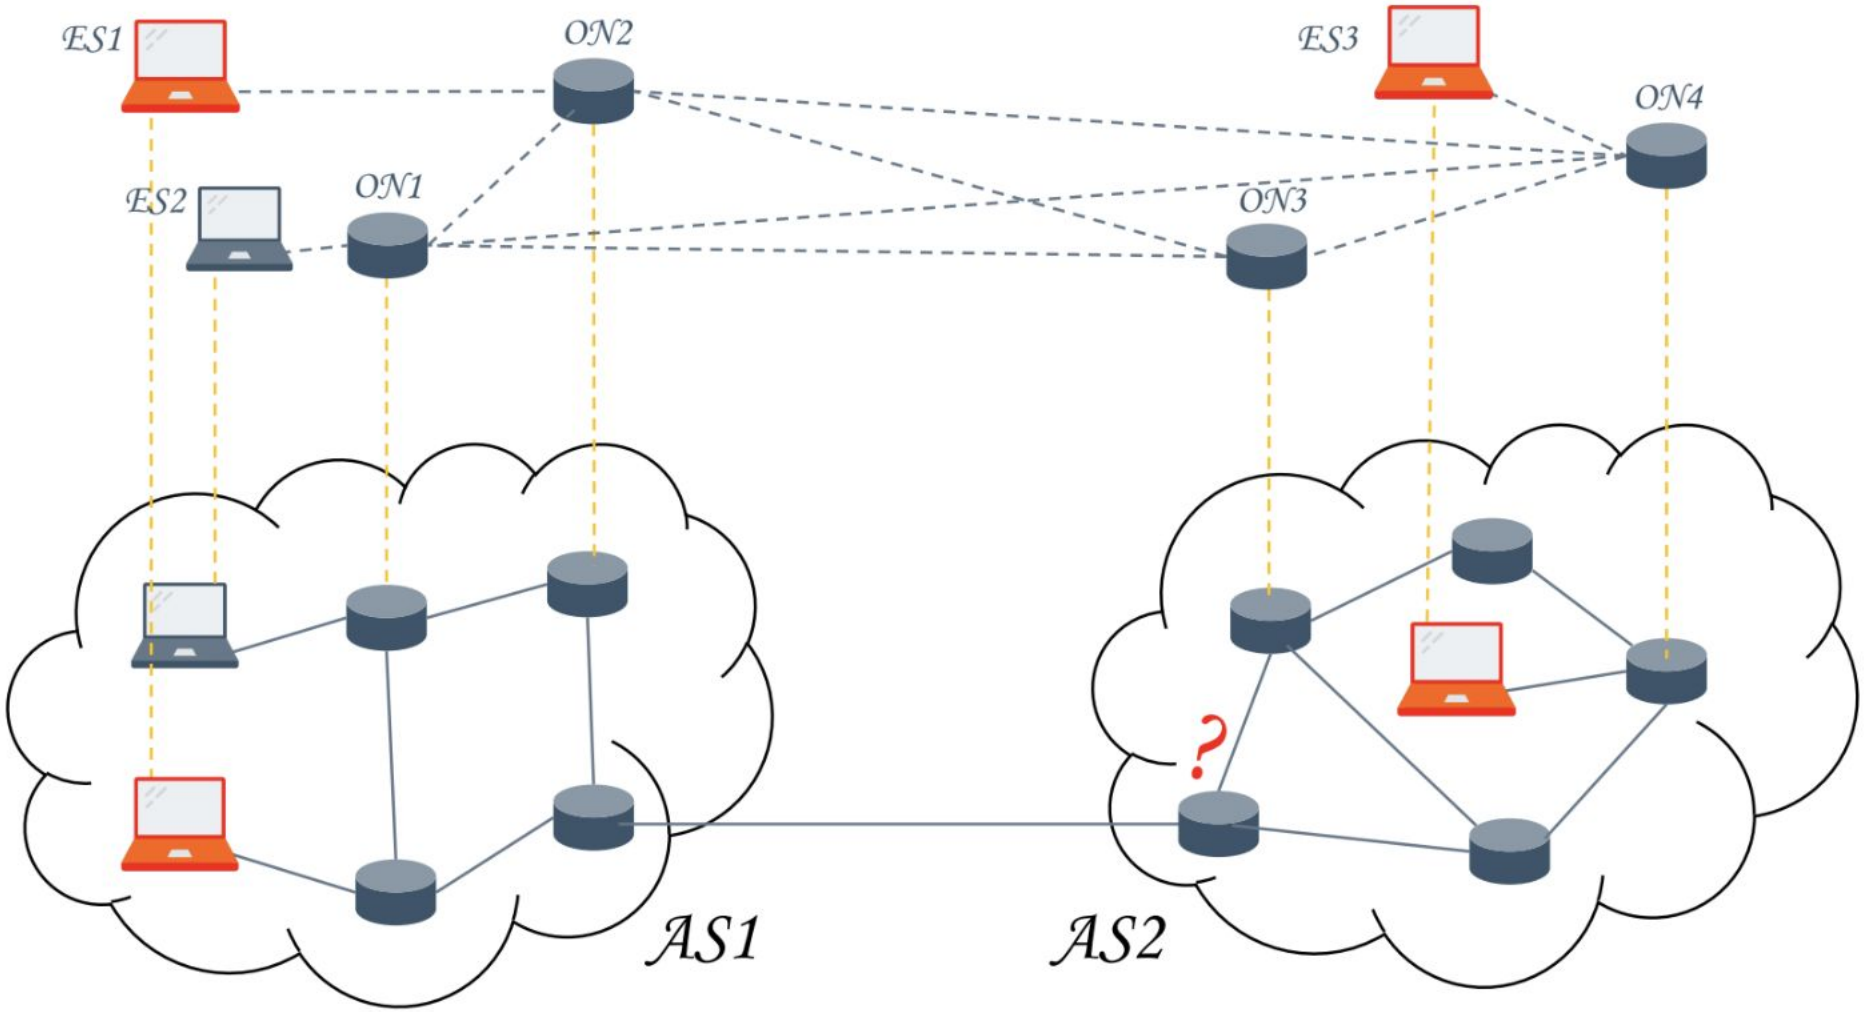
ES1
ON2
ES3
ON4
ES2
ON1
ON3
?
AS1
AS2

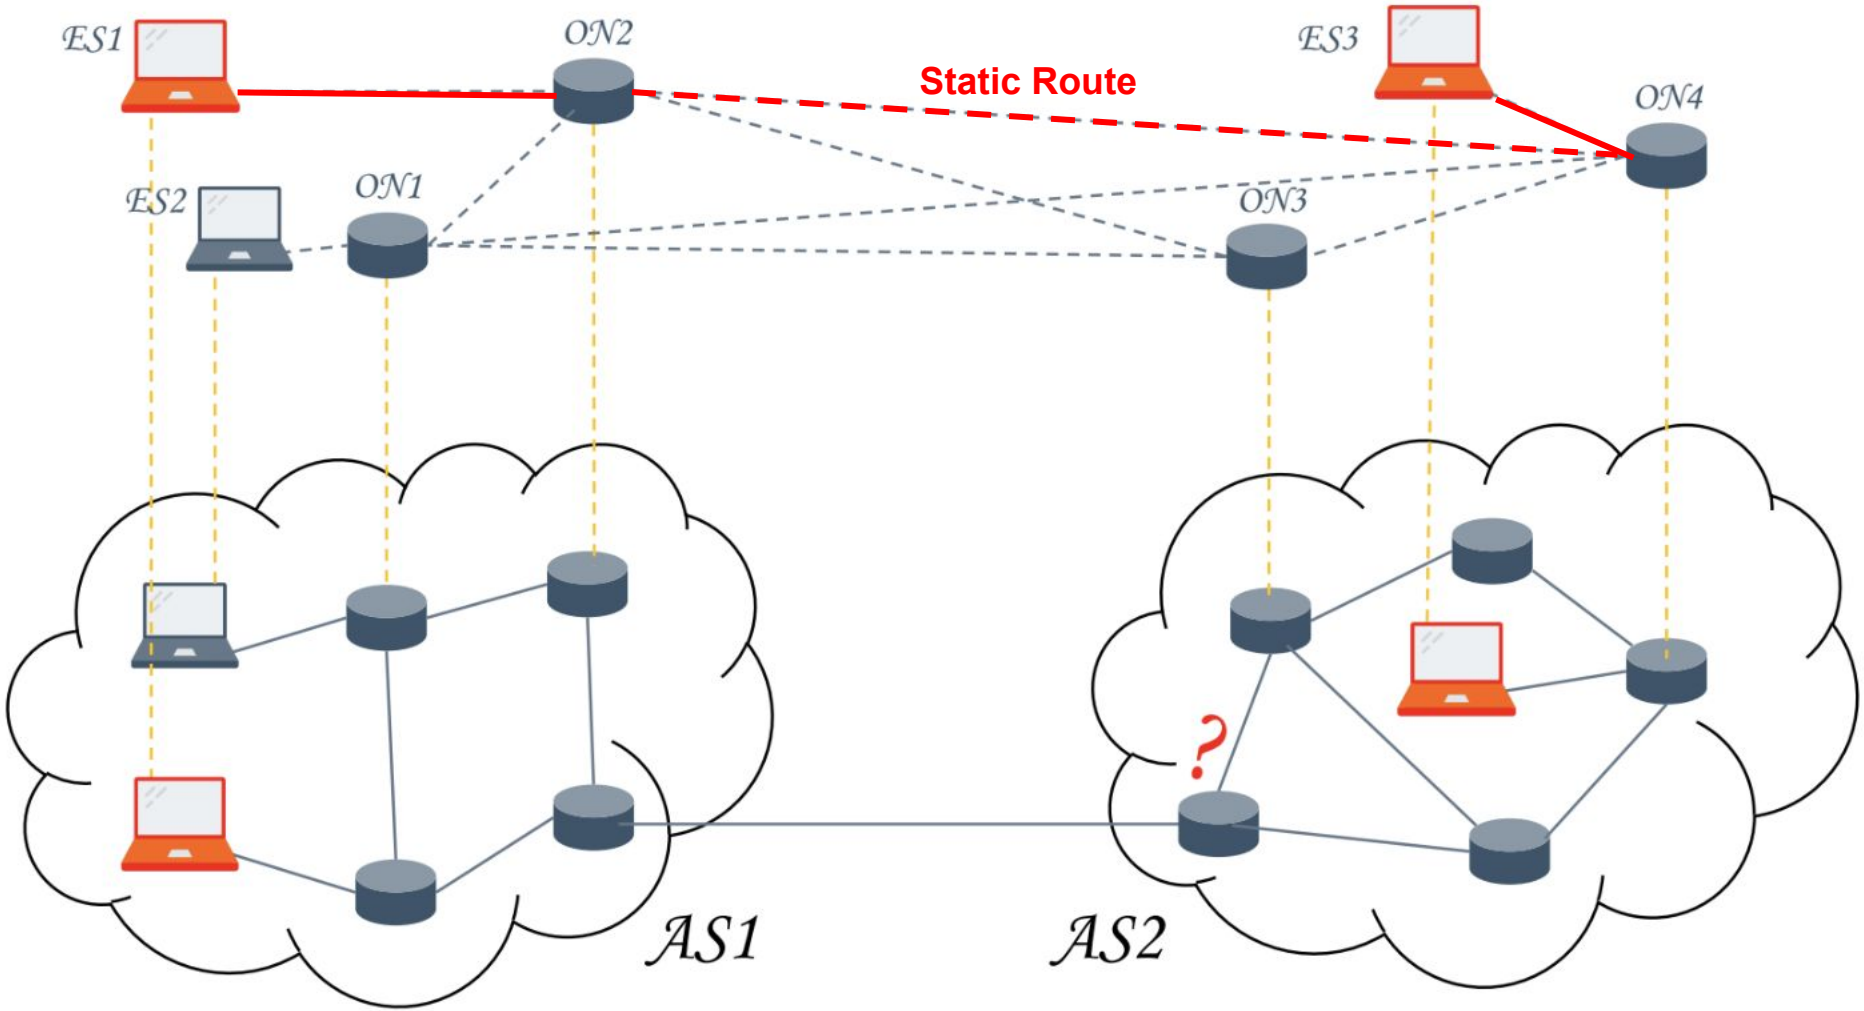
ES1
ON2
Static Route
ES3
ON4
ES2
ON1
ON3
?
AS1
AS2

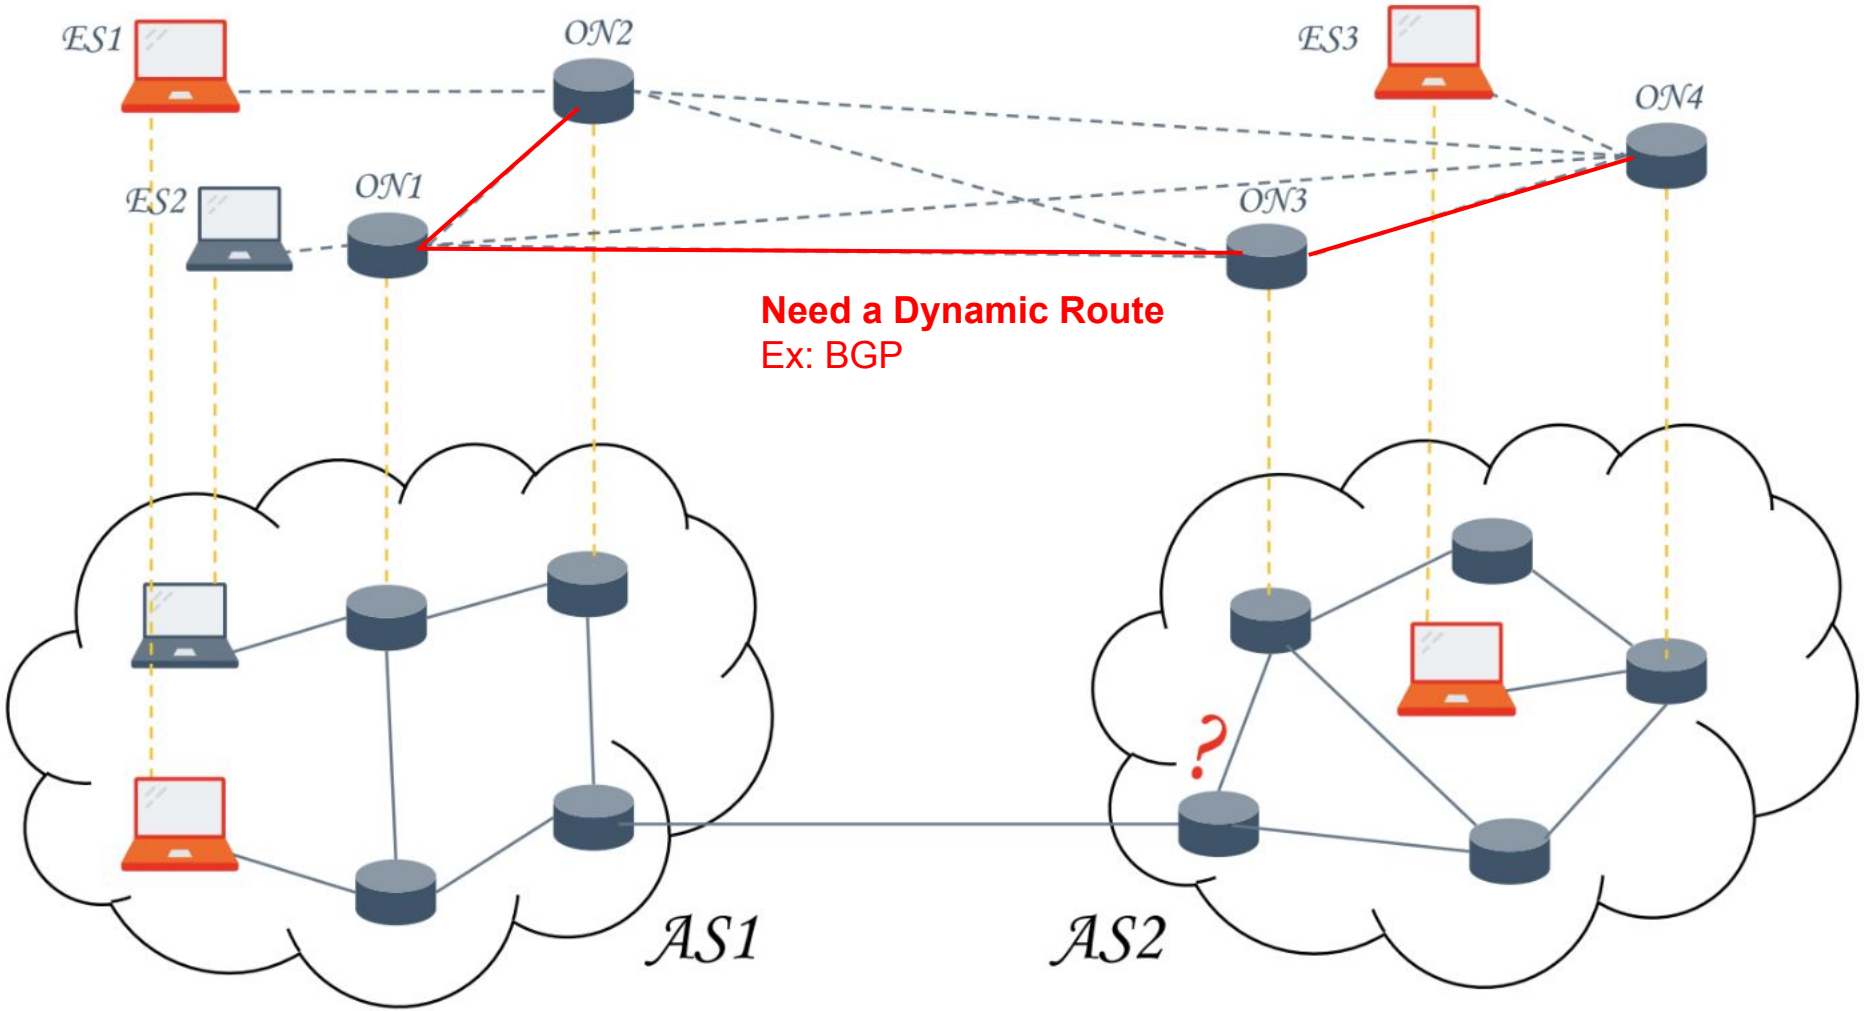
ES1
ON2
ES3
ON4
ES2
ON1
ON3
Need a Dynamic Route
Ex: BGP
?
AS1
AS2

覆蓋網路的優勢

1. 靈活性：如果要新增新的 Site（路由器及伺服器），可以直接和任一 Site peering 即可上線
2. 易於管理：管理員接入 overlay network 後，可以用符合業務邏輯的方式管理網路
3. 安全性：通過 VPN 連入後，可以訪問網路內的伺服器，避免暴露 port 等危險操作
4. 冗餘和效率：overlay 流量可以更輕鬆地根據流量飽和度或網路中斷情況改變路徑

使用者體驗

對於 User 而言：

- 身處任意 Site 的 Subnet 下 *或*
- 連上 VPN 接入 Overlay Network

1. 無法透過 SSH 連接內部網路設備
   - ~~埠轉發至外部網路(但有可能遭受攻擊)~~
   - ~~設定虛擬私人網路(需要頻繁切換)~~
   - **在實驗室內直接連接，實驗室外一個 VPN 連接全網**
2. 伺服器上臨時架設的網頁或服務難以連接
   - ~~請管理員設定埠轉發(較為繁瑣)~~
   - ~~使用 ssh -R 進行反向隧道連接~~
   - **直接透過 Private IP 連接**

貳、

在 RouterOS 建構 Overlay Network

Add a WG interface on 2 Routers

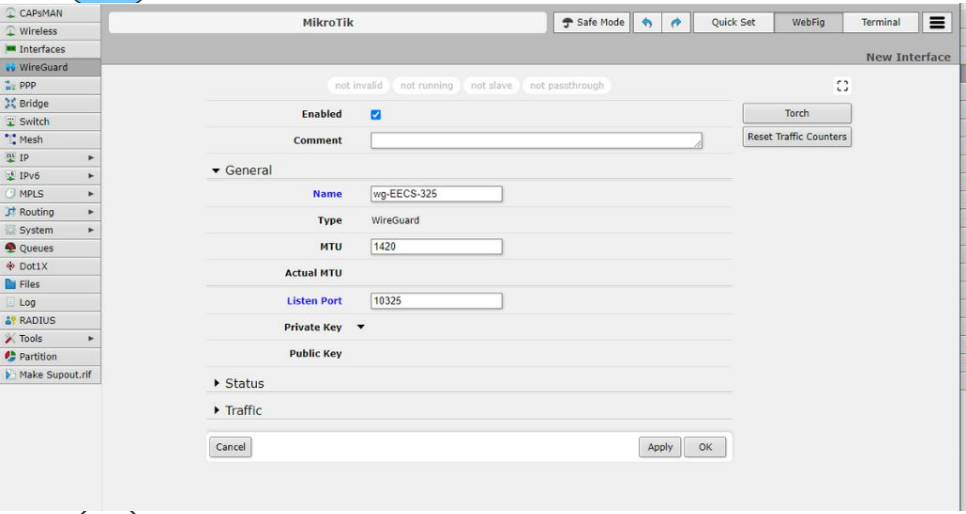

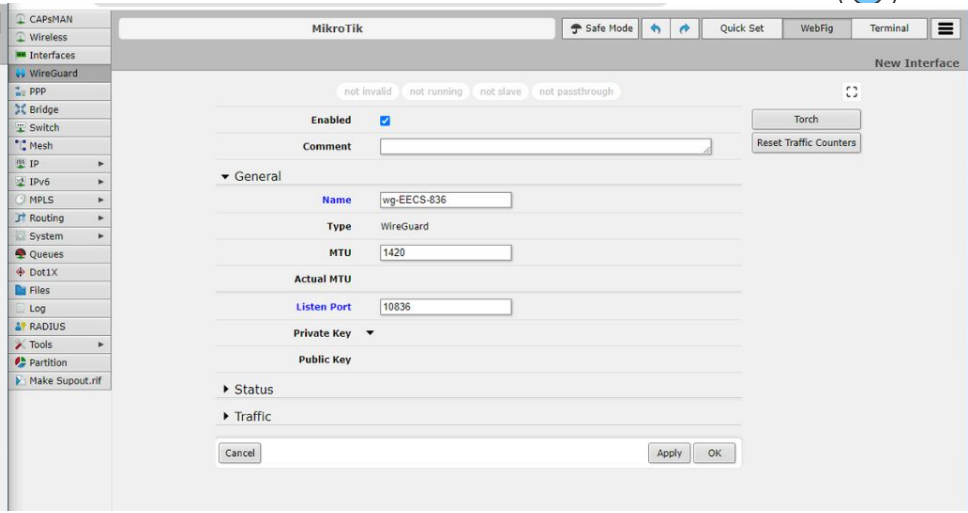

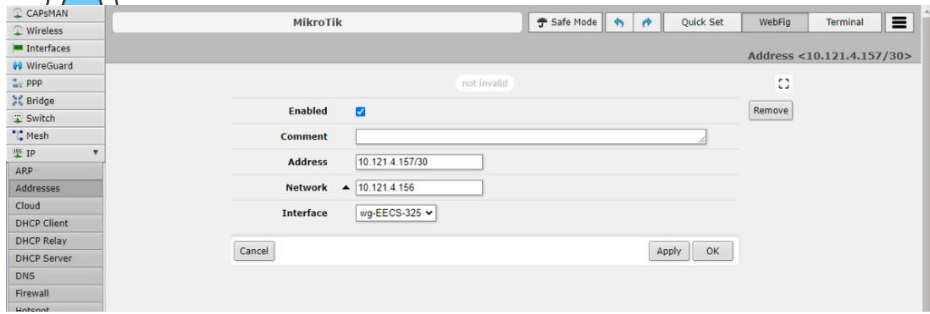

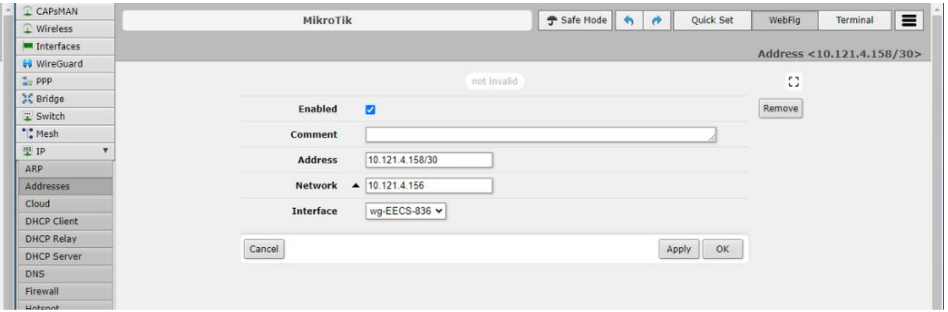

Add a WG interface on 2 Routers

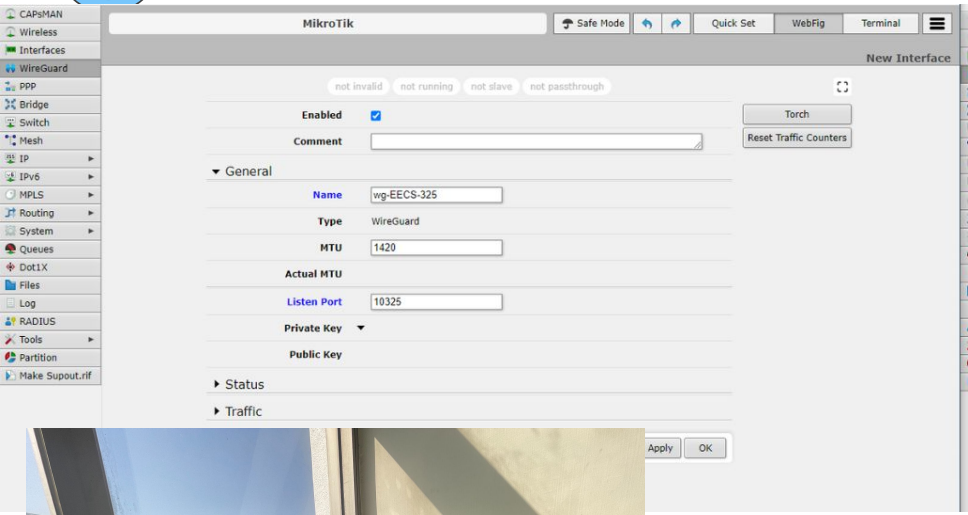

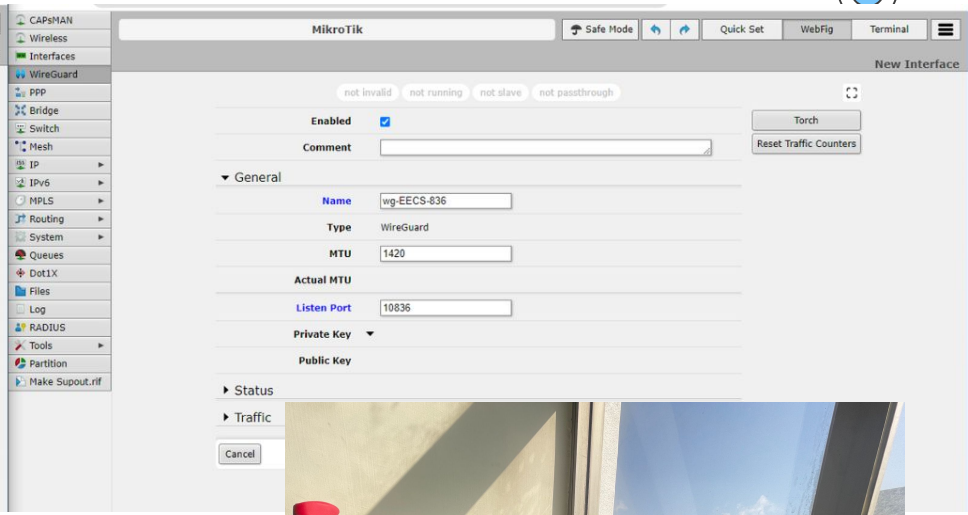

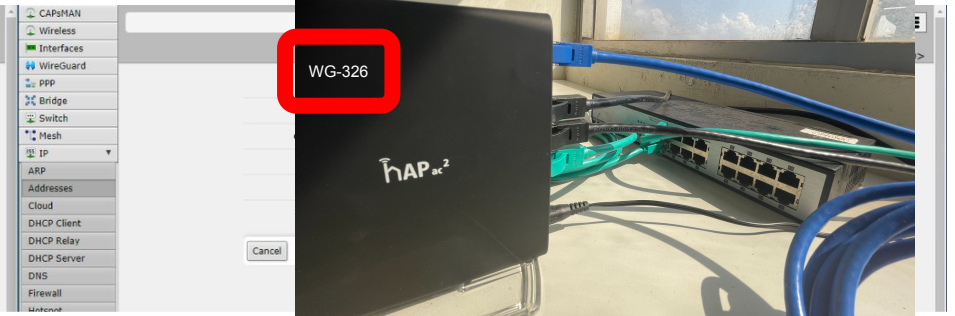

Add a WG tunnel between 2 Routers

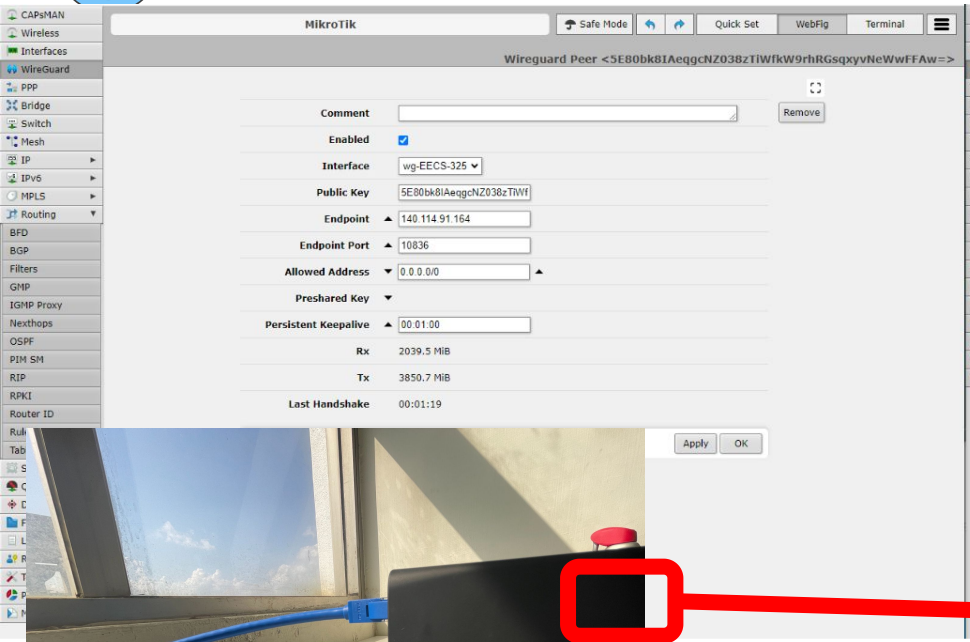

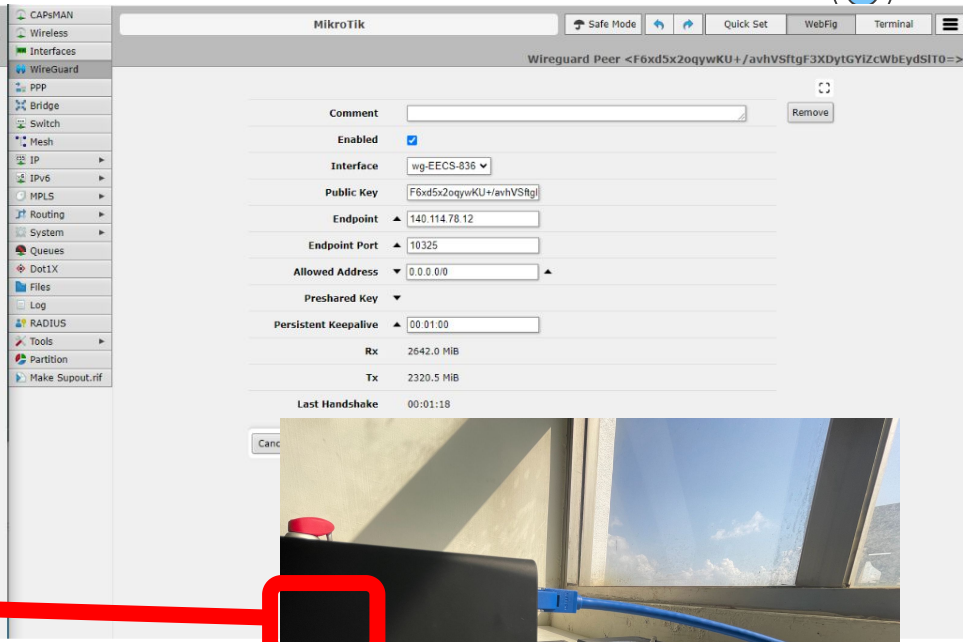

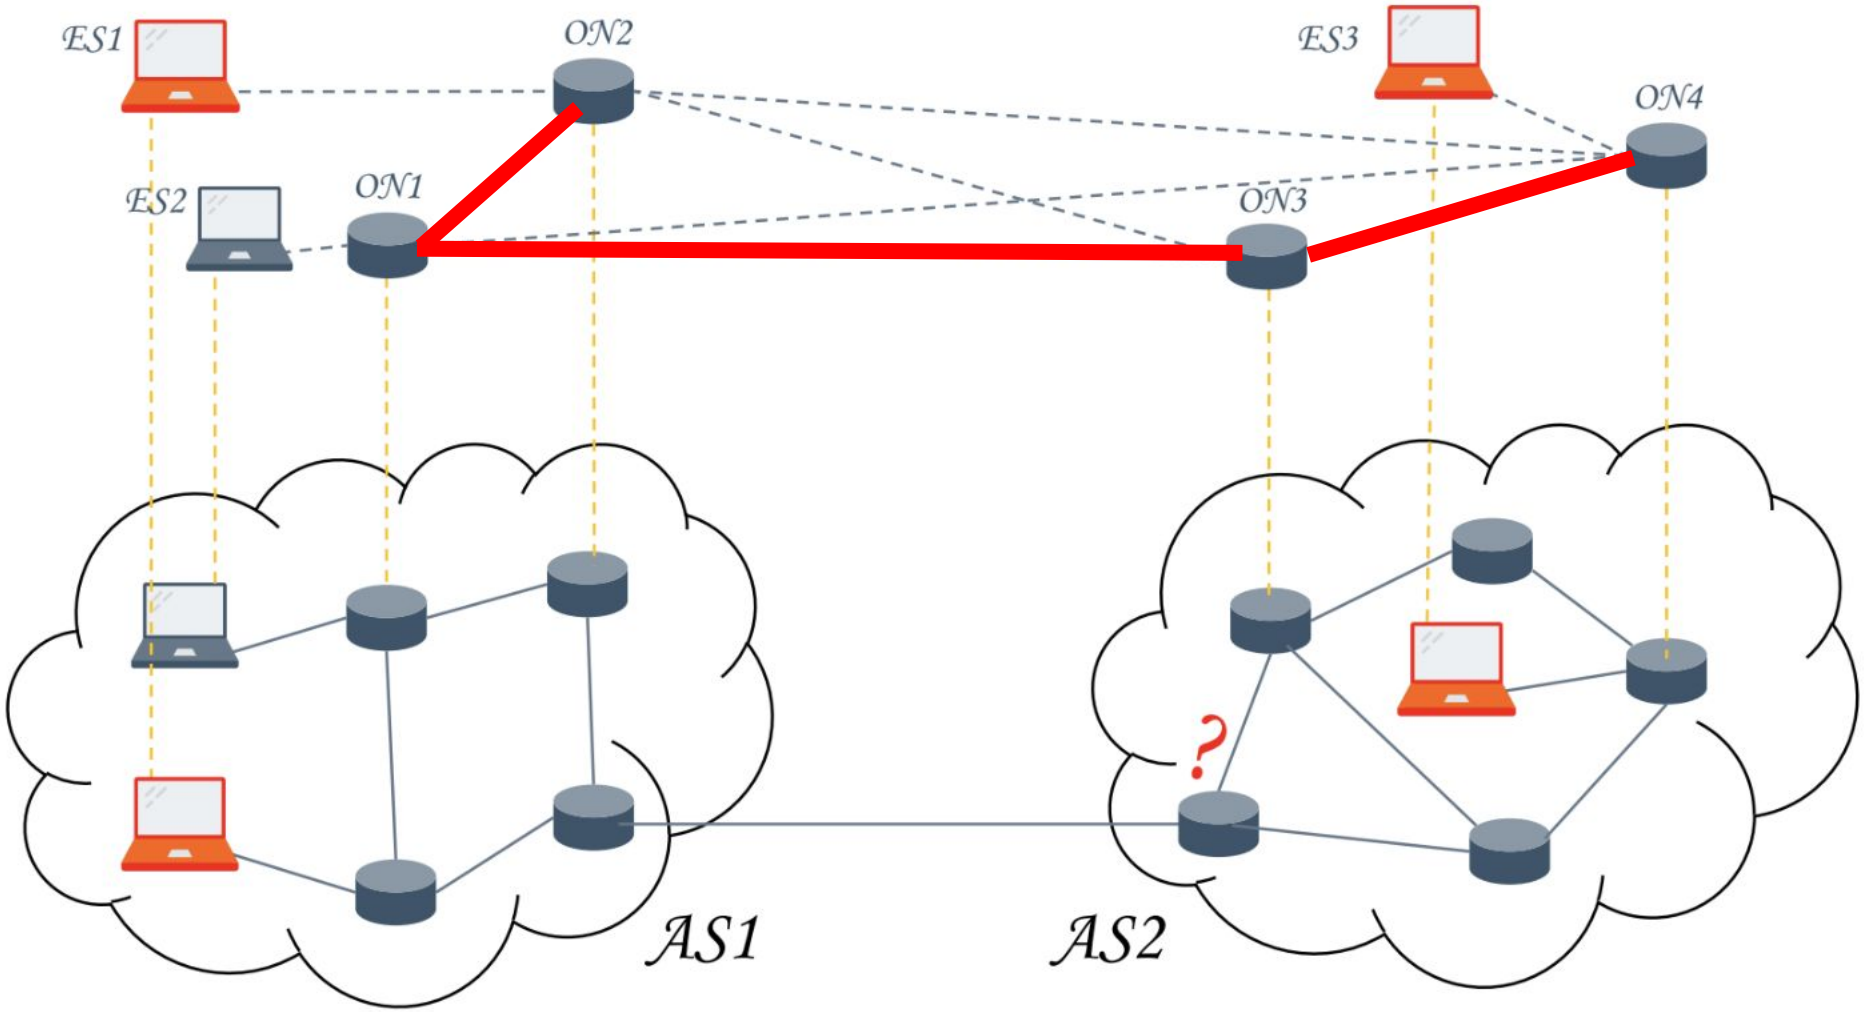
ES1
ON2
ES3
ON4
ES2
ON1
ON3
?
AS1
AS2

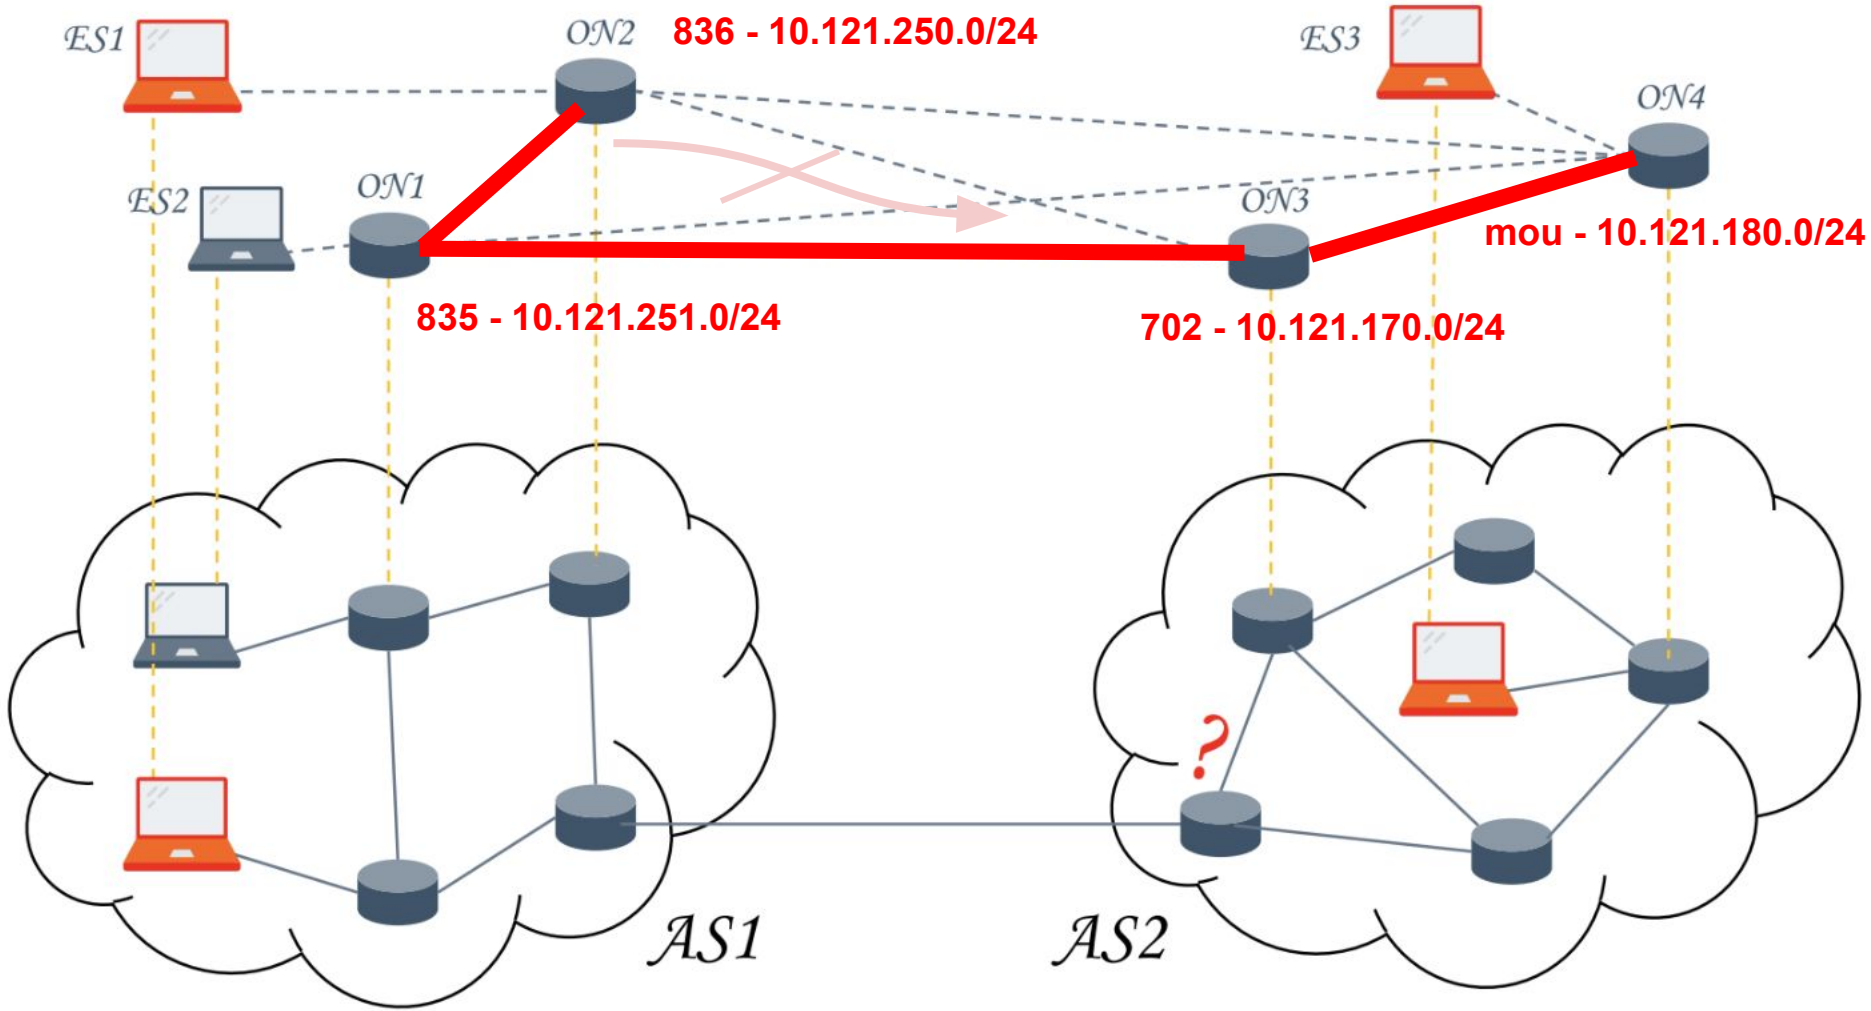
ES1
ON2
836 - 10.121.250.0/24
ES3
ON4
ES2
ON1
ON3
mou - 10.121.180.0/24
835 - 10.121.251.0/24
702 - 10.121.170.0/24
?
AS1
AS2

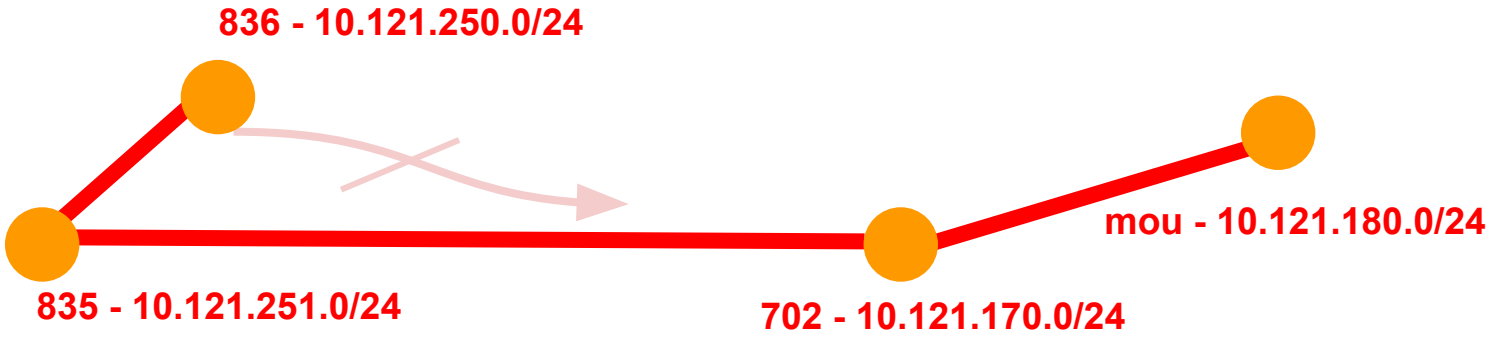

Pool	-	DAC		10.121.250.0/24	%bridge	
Routes	-	DAb		10.121.251.0/24	10.121.4.165	20
SMB	-	Db		10.121.251.0/24	10.121.4.158	20

路由協議
BGP, OSPF

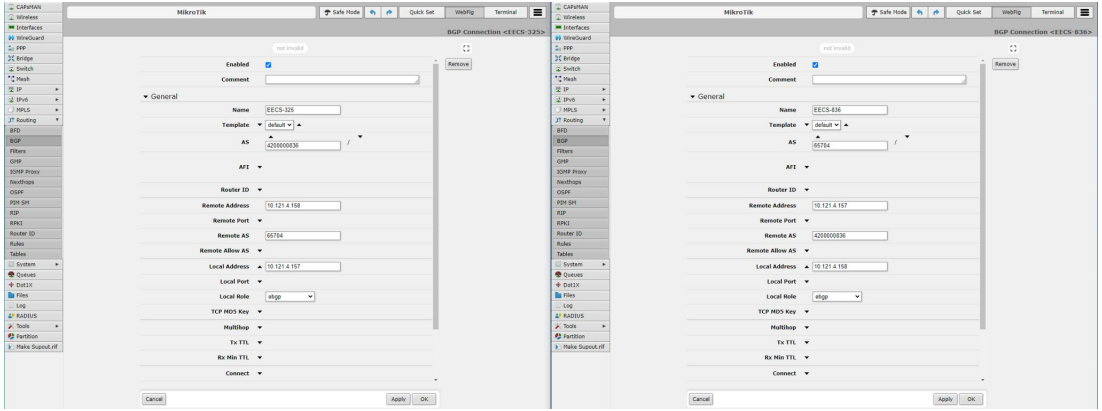

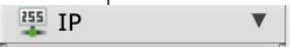

- ARP
- Addresses
- Cloud
- DHCP Client
- DHCP Relay
- DHCP Server
- DNS
- Firewall
- Hotspot
- IPsec
- Kid Control
- Neighbors
- Packing
- Pool
- Routes
- SMB
- SNMP
- SSH
- Services

-	Db		10.121.4.156/30	10.121.4.165	20
-	Db		10.121.4.160/30	10.121.4.158	20
-	DAb		10.121.4.160/30	10.121.4.165	20
-	DAC		10.121.4.164/30	%wg-835	
-	Db		10.121.4.164/30	10.121.4.165	20
-	Db		10.121.4.170/32	10.121.4.158	20
-	DAb		10.121.4.170/32	10.121.4.165	20
-	Db		10.121.4.174/32	10.121.4.158	20
-	DAb		10.121.4.174/32	10.121.4.165	20
-	DAb		10.121.4.192/30	10.121.4.165	20
-	Db		10.121.4.192/30	10.121.4.158	20
-	DAb		10.121.170.0/24	10.121.4.165	20
-	Db		10.121.170.0/24	10.121.4.158	20
-	DAb		10.121.171.0/28	10.121.4.165	20
-	Db		10.121.171.0/28	10.121.4.158	20
-	DAb		10.121.171.16/28	10.121.4.165	20
-	Db		10.121.171.16/28	10.121.4.158	20
-	Db		10.121.171.191/32	10.121.4.158	20
-	DAb		10.121.171.191/32	10.121.4.165	20

LSALAB
Intranet

跨越物理距離的大內網

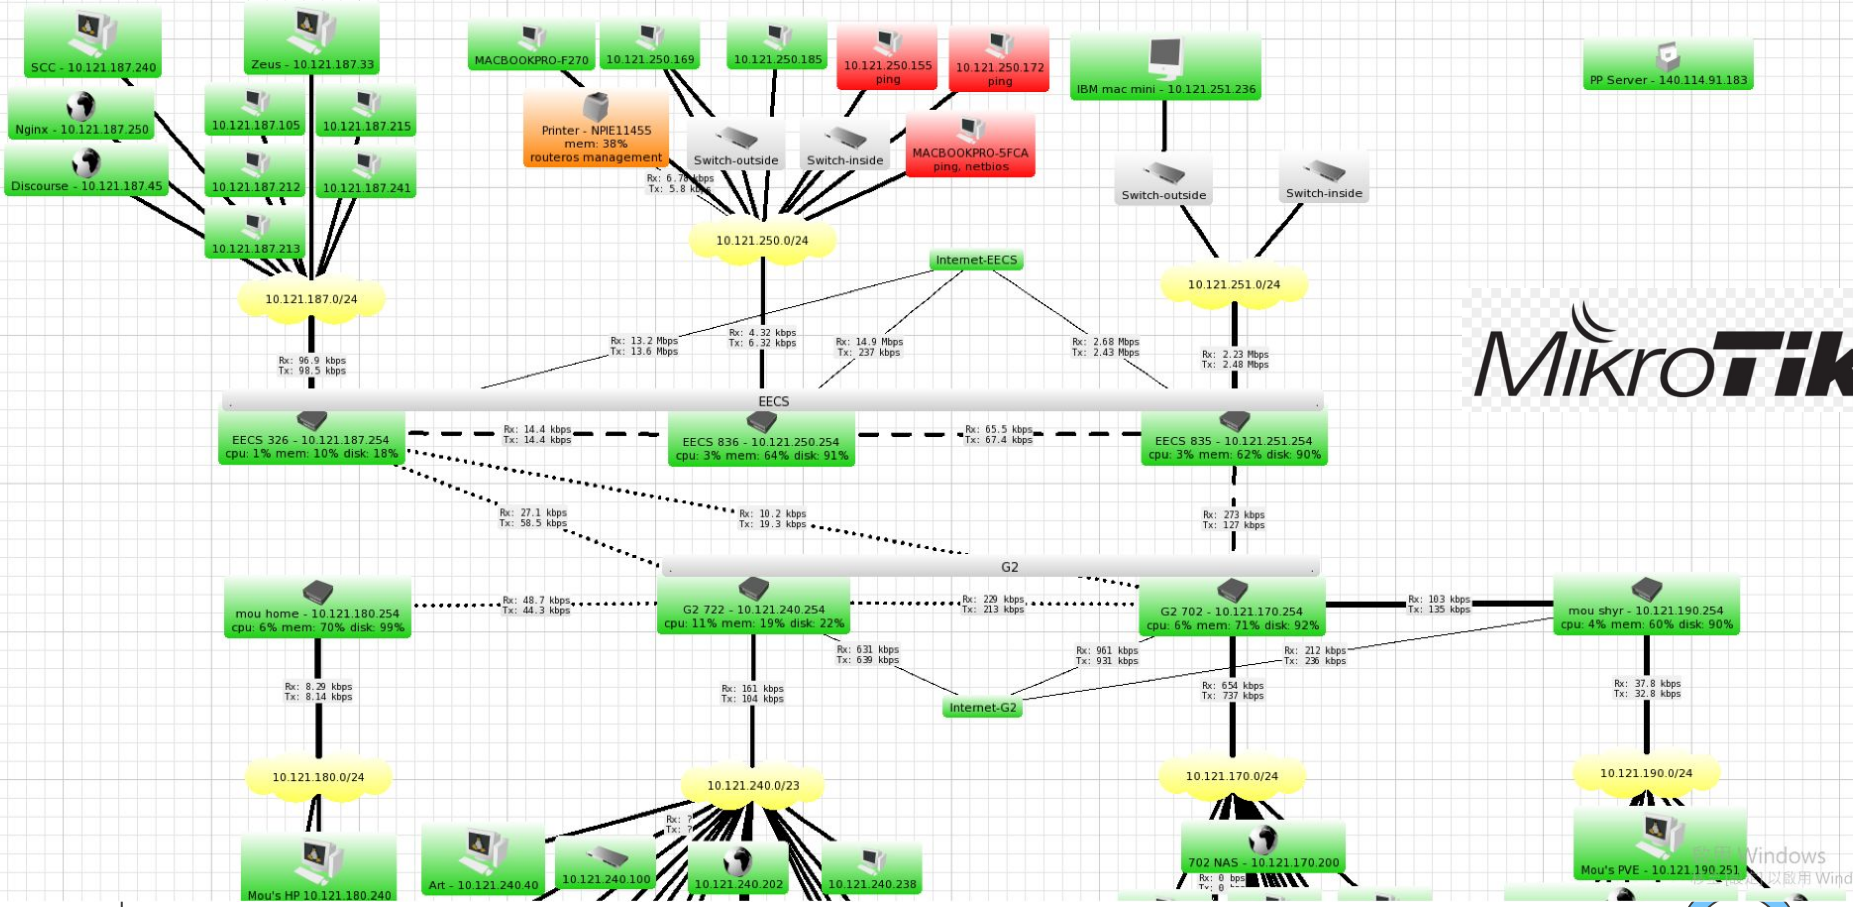
SCC - 10.121.187.240
Zeus - 10.121.187.33
Nginx - 10.121.187.250
10.121.187.105
10.121.187.215
Discourse - 10.121.187.45
10.121.187.212
10.121.187.241
10.121.187.213
10.121.187.0/24
Rx: 96.9 kbps
Tx: 98.5 kbps
MACBOOKPRO-F270
10.121.250.169
10.121.250.185
10.121.250.155
ping
10.121.250.172
ping
Printer - NPIE11455
mem: 38%
routeros management
Rx: 6.78 kbps
Tx: 5.8 kbps
Switch-outside
Switch-inside
MACBOOKPRO-5FCA
ping, netbios
10.121.250.0/24
Internet-EECS
Rx: 13.2 Mbps
Tx: 13.6 Mbps
Rx: 4.32 kbps
Tx: 6.32 kbps
Rx: 14.9 Mbps
Tx: 237 kbps
Rx: 2.68 Mbps
Tx: 2.43 Mbps
IBM mac mini - 10.121.251.236
Switch-outside
Switch-inside
10.121.251.0/24
Rx: 2.23 Mbps
Tx: 2.48 Mbps
PP Server - 140.114.91.183
EECS
EECS 326 - 10.121.187.254
cpu: 1% mem: 10% disk: 18%
Rx: 14.4 kbps
Tx: 14.4 kbps
EECS 836 - 10.121.250.254
cpu: 3% mem: 64% disk: 91%
Rx: 65.5 kbps
Tx: 67.4 kbps
EECS 835 - 10.121.251.254
cpu: 3% mem: 62% disk: 90%
Rx: 27.1 kbps
Tx: 58.5 kbps
Rx: 10.2 kbps
Tx: 19.3 kbps
Rx: 273 kbps
Tx: 127 kbps
G2
mou home - 10.121.180.254
cpu: 6% mem: 70% disk: 99%
Rx: 48.7 kbps
Tx: 44.3 kbps
G2 722 - 10.121.240.254
cpu: 11% mem: 19% disk: 22%
Rx: 229 kbps
Tx: 213 kbps
G2 702 - 10.121.170.254
cpu: 6% mem: 71% disk: 92%
Rx: 103 kbps
Tx: 135 kbps
mou shyr - 10.121.190.254
cpu: 4% mem: 60% disk: 90%
Rx: 631 kbps
Tx: 639 kbps
Rx: 961 kbps
Tx: 931 kbps
Rx: 212 kbps
Tx: 236 kbps
Internet-G2
Rx: 8.29 kbps
Tx: 8.14 kbps
Rx: 161 kbps
Tx: 104 kbps
Rx: 654 kbps
Tx: 737 kbps
Rx: 37.8 kbps
Tx: 32.8 kbps
10.121.180.0/24
10.121.240.0/23
10.121.170.0/24
10.121.190.0/24
Mou's HP 10.121.180.240
Art - 10.121.240.40
10.121.240.100
10.121.240.202
10.121.240.238
702 NAS - 10.121.170.200
Mou's PVE - 10.121.190.251

優點-管理者視角

- **加強對外安全性:**
  - 加密通信:WireGuard 提供端到端加密，確保跨網絡的數據傳輸安全。
  - 最小化攻擊面:private network 隔離了外部威脅。
- **靈活的網絡連接:**
  - 動態路由:使用BGP，網絡路由可以自動調整，以應對節點變化或網絡拓撲變化。
  - 異地連接:地理位置不同的子網也可以輕鬆連接，適合分佈式團隊或辦公室。
- **簡化網絡管理:**
  - 去中心化設計:WireGuard 為去中心化VPN解決方案，簡化了傳統VPN 的設置和維護。
  - 易於配置和維護:WireGuard 設計簡潔，易於配置，而BGP 支持自動化網絡管理

優點-使用者視角

- **遠程工作與協作**
- **1. 安全訪問公司內部資源**
  - w/o：員工需要頻繁更換VPN 連接來訪問不同site 的資源，不便且容易出錯。
  - w/：員工透過單一VPN 連接就能安全地訪問Intranet 的所有內部資源，操作簡單且高效。
- **2. 共享文件和網頁程式**
  - w/o：共享文件或連接伺服器時需透過複雜的port forwarding 配置，增加維護成本。
  - w/：員工一旦連接到VPN，即可直接使用內網 IP 和原生 port 訪問共享資源，簡化流程。
- **3. 分散式設備管理**
  - w/o：不同地點的裝置互連需要透過複雜的網絡配置和NAT，增加管理難度。
  - w/：不同地點的裝置可以直接在私有網絡中互聯，簡化管理和數據收集。
- **4. 安全性和隱私**
  - w/o：IoT 裝置的安全性和隱私保護較難保證，尤其是在公共網絡中。
  - w/：提供了一個加密且隔離的網絡環境，增強IoT 裝置的安全性和數據隱私。

缺點

- **IT 學習成本及開銷：**
  - IT 需要管理兩個不同的網路層。
  - 這些層必須統一管理，因為overlay 期望的拓撲需要underlay 支援。
- **故障排除：**
  - 與前項相同，需要對兩層debug。
- **網路內部潛在的安全疑慮：**
  - 錯誤的配置造成的負面影響可能會因為overlay 放大。
  - 缺少最小權限概念，不如零信任系統強調安全性。

參、

Proxmox VE 介紹

Proxmox VE 截圖

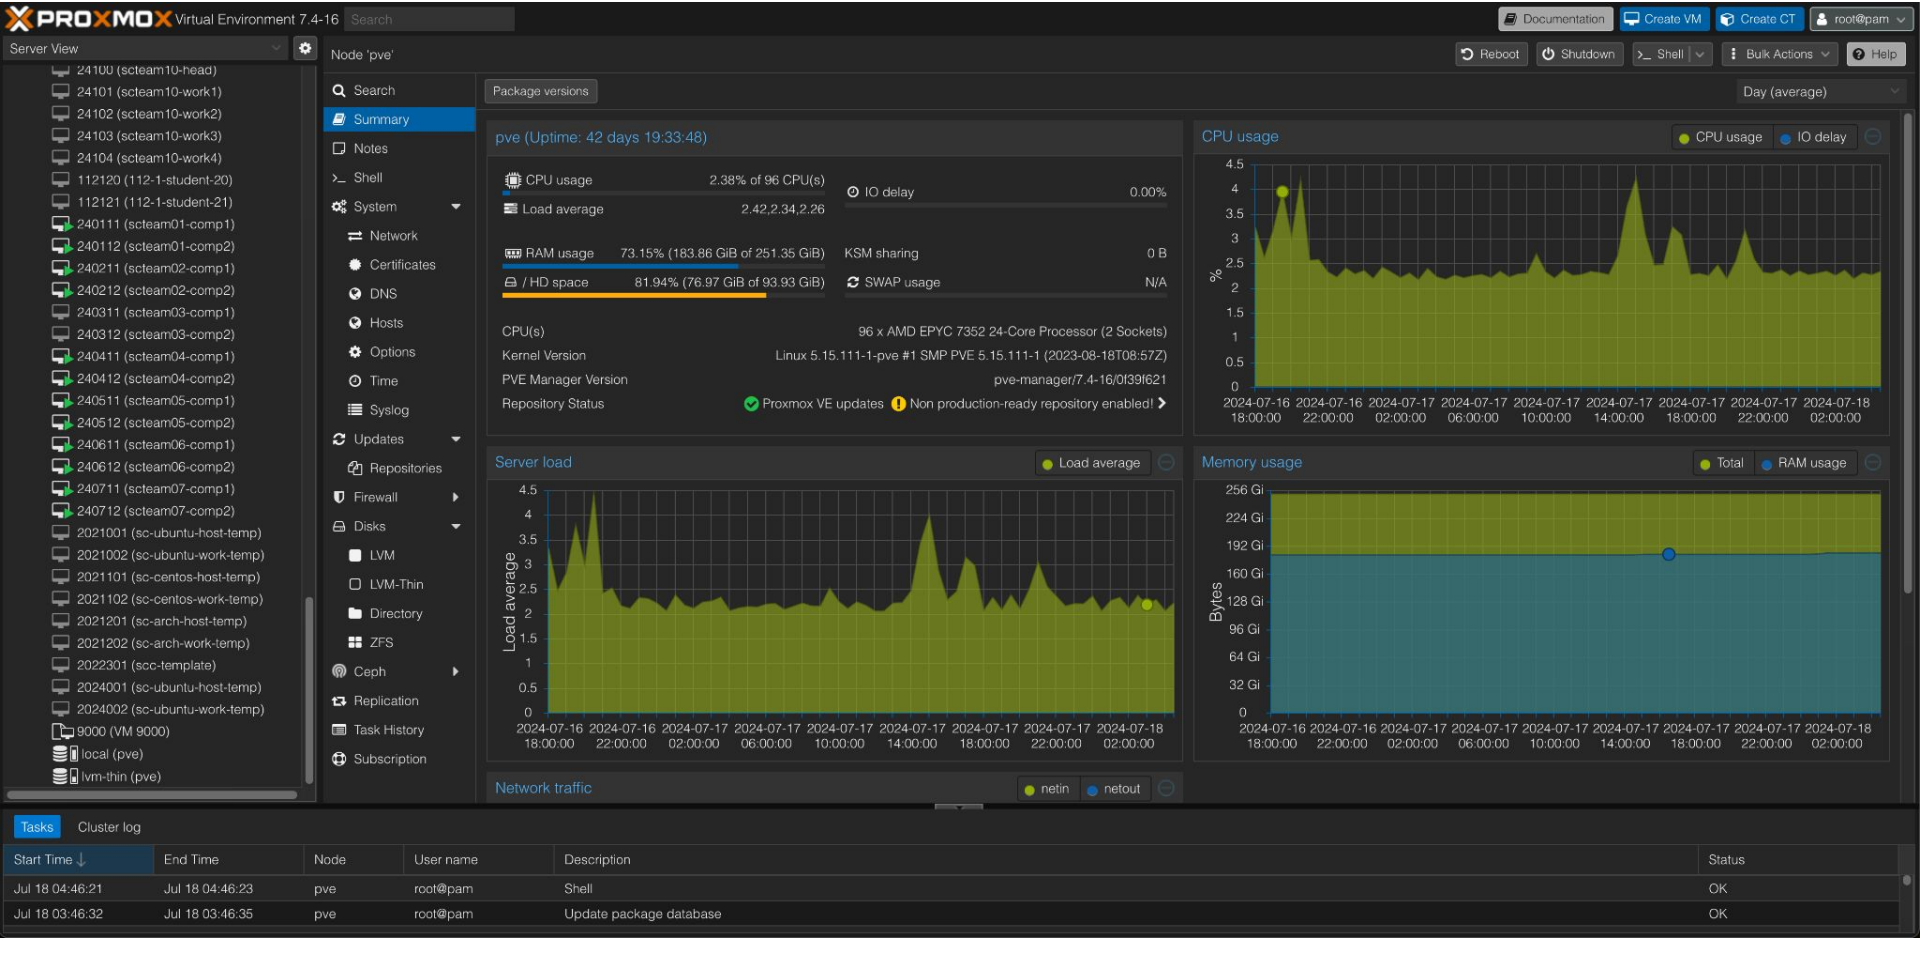

Proxmox VE 介紹

Proxmox VE 是一個開源的虛擬化平台，支援 **虛擬機**和**容器**，讓用戶可以在單一的平台上輕鬆管理虛擬化環境。

Proxmox VE 提供友善的 Web 界面，讓用戶能夠輕鬆管理虛擬機、存儲、網絡和使用者帳 戶等功能。該平台結合了虛擬機和容器技術，並支援多種虛擬化技術，如 KVM、LXC 等。Proxmox VE 提供豐富的功能和強大的性能，適合企業和個人用戶建立和管理虛擬化環境。

- 全 Web 化管理介面
- KVM 虛擬機與 LXC 容器 Cloud init 功能
- ZFS、Ceph、GlusterFS 等多種檔案系統
- NFS、iSCSI、RBD 等多種連接協定
- 去中心化的叢集機制
- 內建完整備份與還原功能
- 提供虛擬機與容器線上遷移功能
- 支援跨節點虛擬機與容器複寫功能
- 提供高可用性容錯機制
- 繁體中文操作介面

傳統伺服器 v.s. Proxmox VE

傳統伺服器的痛點：

1. 低資源利用率：傳統伺服器通常只運行單一作業系統和應用程式，資源利用率不高。
2. 硬體依賴：使用傳統伺服器時，若要提高性能或可用性，通常需要花費大量成本來升級硬體。
3. 難以管理：管理多個獨立伺服器需要更多的人力和時間，並且可能導致管理上的混亂。
4. 災難恢復困難：傳統伺服器在災難時可能會導致資料丟失和停機時間更長。

Proxmox VE 優勢：

1. 虛擬化技術：可以讓您在單一物理伺服器上運行多個虛擬機器，提高伺服器資源的利用率。
2. 管理與監控：提供直觀的 Web 介面，讓您輕鬆地管理和監控所有虛擬機器。
3. 高可用性：支援儲存和虛擬機器的冗餘，可以確保系統的高可用性。
4. 彈性擴展：可以輕鬆地修改伺服器資源，而無需進行更動硬體。
5. 成本較低：軟體本身免費使用，入門門檻低，易於部署中小規模 Cluster。

在一個 OS 上虛擬化另一個 OS

問題：

當你想要在一個主機操作系統 (Host OS) 上虛擬化另一個操作系統時，會出現以下問題：

- OS 認為自己負責管理所有硬體，這可能導致與其他虛擬化的 OS 發生衝突。

解決方案：

為了避免操作系統之間的衝突，必須妥善切分他們的資源：

- CPU：包括寄存器的管理
- Memory：MMU 的切換
- IO Device：確保各自的設備不互相干擾
- Interrupt：妥善處理中斷請求
- Timer

虛擬化技術介紹

	全虛擬化： 利用二進位翻譯	硬體輔助虛擬化 ：VT-x / VT-d 輔助	半虛擬化： 作業系統協助
實現技術	Binary Translation 和直接執行	遇到特權指令轉到 root 執行	Hypercall
Guest 兼容性	無修改 Guest 兼容性高	無修改 Guest 兼容性高	需修改 Guest 僅適用開源 OS
性能	差	僅切換模式的開銷	接近於物理機
應用廠商	VMware (Workstsation) Virtual PC QEMU	VMware ESXi Microsoft Hyper-V Xen 3.0 KVM	Xen

KVM- QEMU 架構

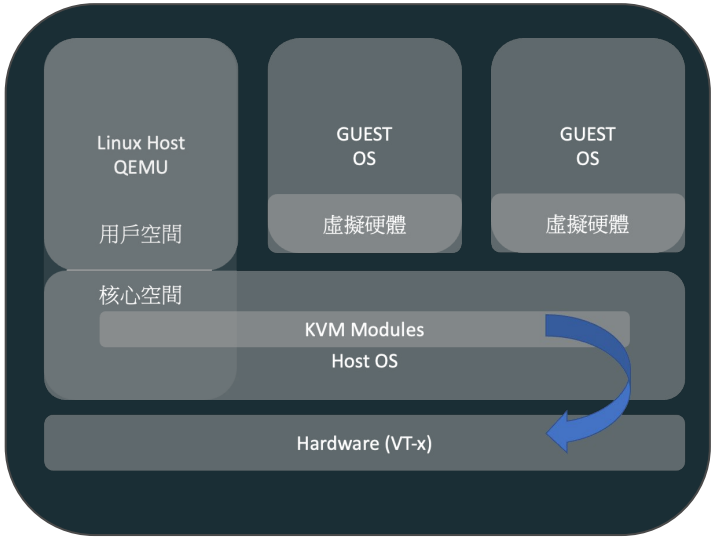

KVM（Kernel-based Virtual Machine）是一個基於 Linux Kernel 的虛擬化解決方案，結合了 Linux Kernel 的模組化和 QEMU 的虛擬化功能。KVM 允許將 Linux Kernel 轉換為一個類似於 Hypervisor 的角色，使得主機系統可以運行多個虛擬機器。

QEMU 是一個開源的虛擬機器監視器和仿真器，它可以模擬多種硬體環境，包括處理器、記憶體和設備。KVM 通過與 QEMU 結合，實現了高性能的虛擬化解決方案，同時提供了完整的虛擬化功能，如動態記憶體管理、網路訪問控制等。

KVM-QEMU 架構的組合優勢在於其高效率和穩定性，使得用戶可以輕鬆建立和管理虛擬機器，同時實現資源的最佳化利用。

PVE Device I/O 虛擬化

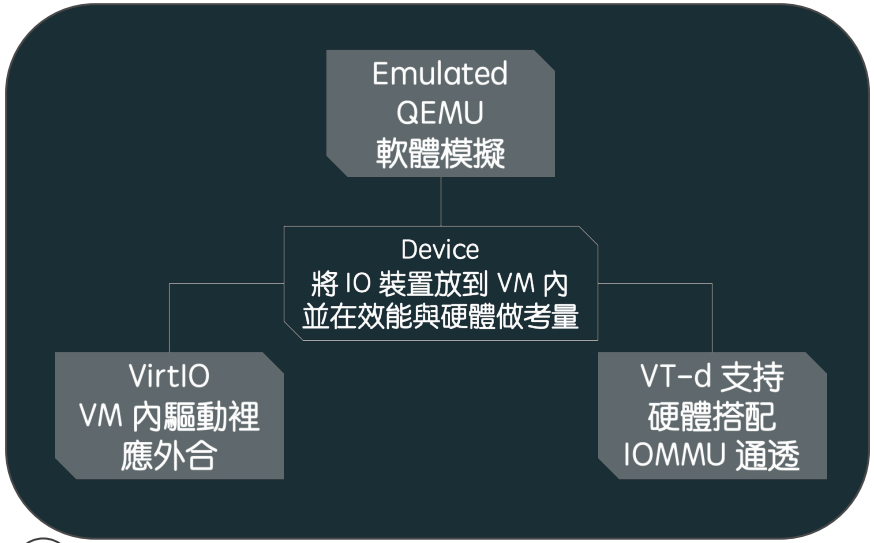

1. Emulated QEMU（軟體模擬）
透過 QEMU 模擬硬體裝置來提供虛擬機使用
軟體模擬會影響性能

2. VirtIO（VM 內驅動裡應外合）
使用 VirtIO 驅動程序來提升虛擬機 內 I/O 效能
需要在虛擬機內安裝對應的 VirtIO 驅動程序

3. VT-d 支持（硬體搭配 IOMMU 通透）
利用 VT-d 技術將實體硬體直接分配給虛擬機
需要硬體支持 IOMMU 技術

肆、
私有雲主機
服務案例

案例介紹 1

狀況：

若學生想進行 AI 研究，學生 A 及 B 各需要 2 張運算卡，但僅有一台伺服器。

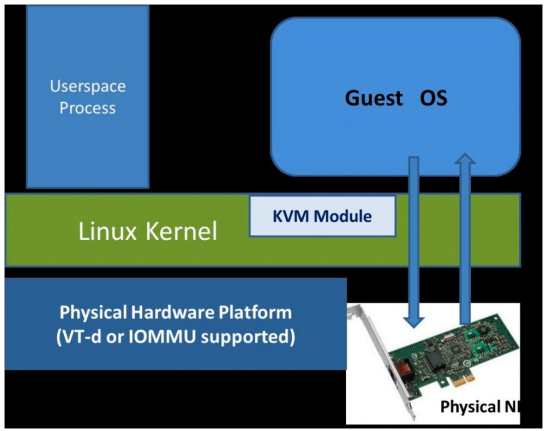

解決方案

在 Proxmox VE 環境下，可建立 2 台虛擬機，並分別將 2 張計算卡使用 PCIe Passthrough 的方式傳入虛擬機中，兩個學生便擁有獨立的環境進行實驗。

案例介紹 2

狀況：

使用者需要測試新的硬體的軟體兼容性或性能，如網路卡。

解決方案

在 Proxmox VE 環境下，可用建立多台虛擬機，並分別將網卡passthrough 進去 VM，可以在僅有一台實體機的情況下測試網卡運作。

案例介紹 3

狀況：

使用者需要大量伺服器模擬大型系統，例如需要多組4 nodes cluster。

解決方案

在 Proxmox VE 環境下，可用腳本建立多台虛擬機，使用cloud-init 等方式法快速部署多台虛擬機，並使用VLAN 等功能切分L2 網路，供使用者測試。

Cluster Topology

- There are two node each group.
- Head node is the login node. It's responsible for hold userdata (`/home`), NIS server and forward IP.

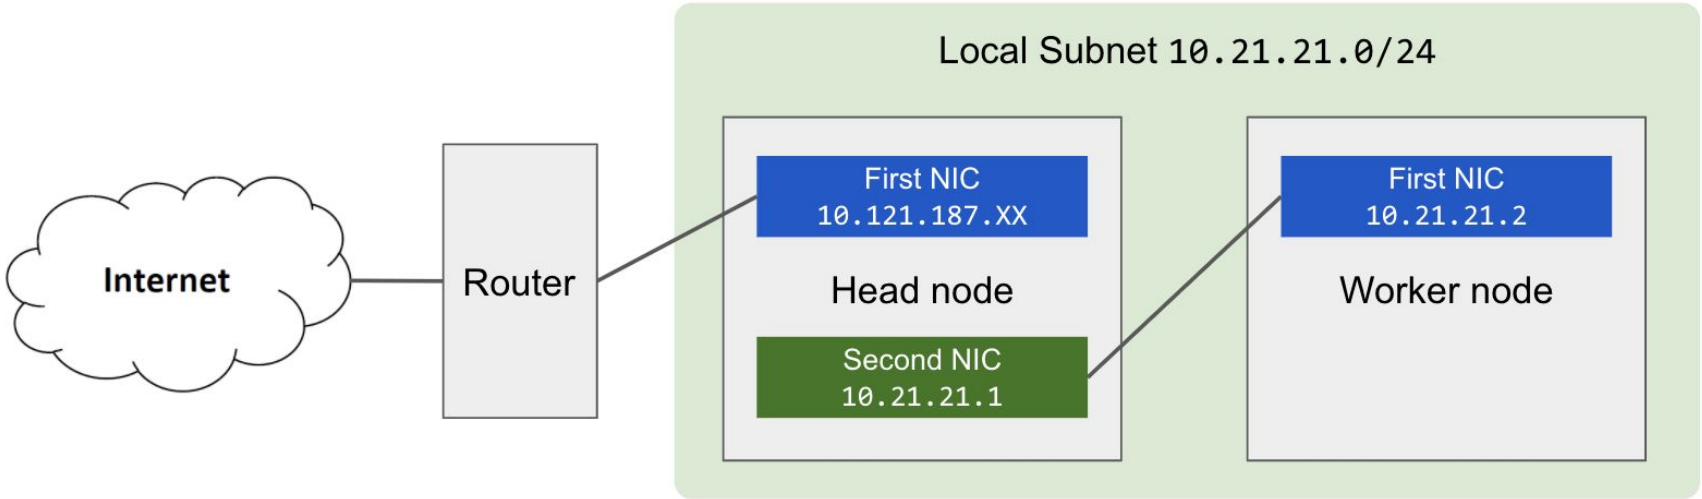

Batch scripts

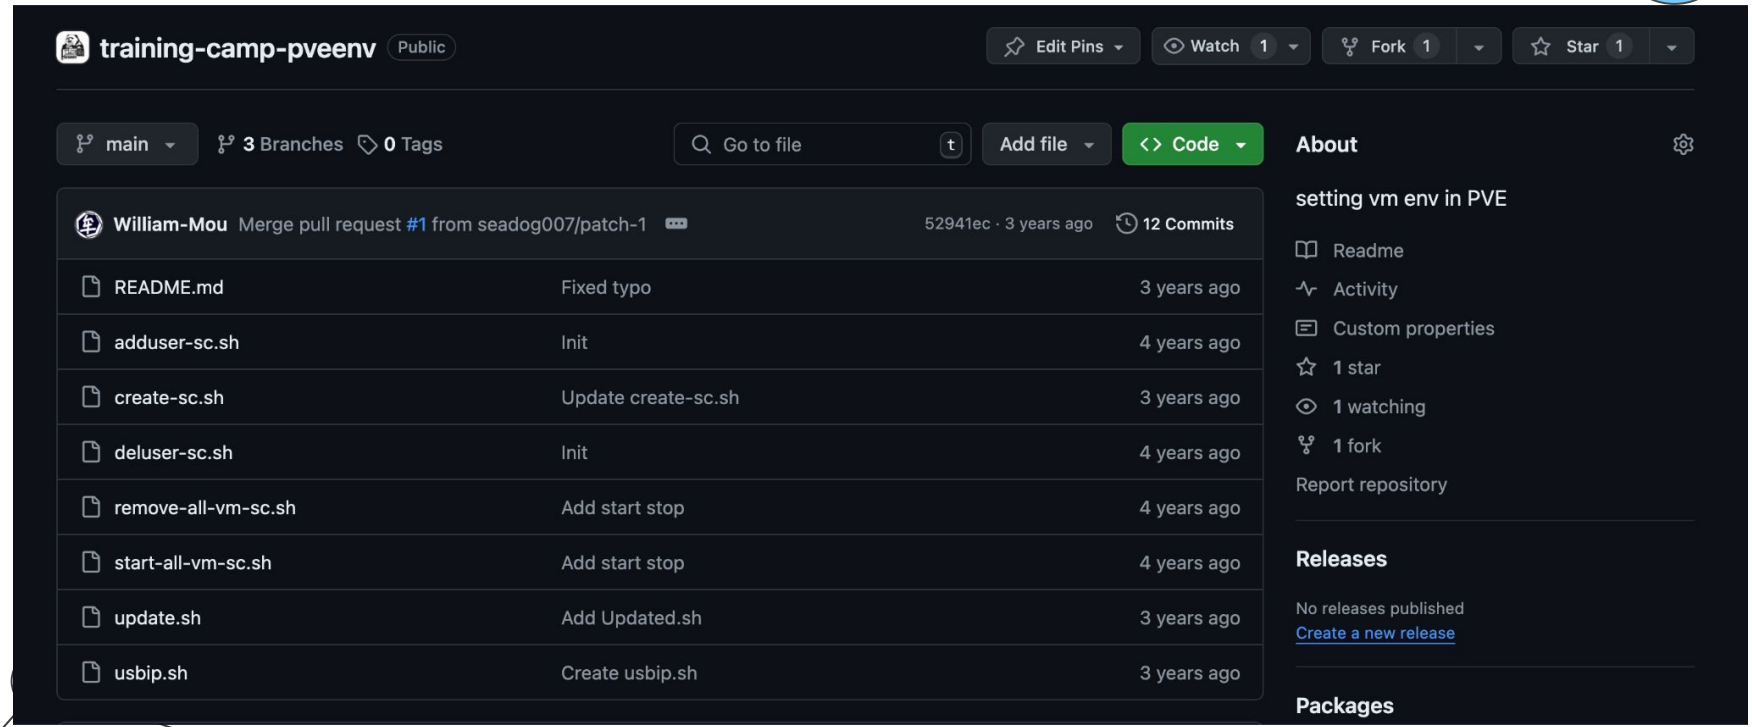

案例介紹 4

狀況：

使用者在實驗室需要連入某VM 進行網頁開發。

解決方案

在 Proxmox VE 搭配 Overlay Network 環境下，即便 Proxmox VE 的 VM 屬於 X subnet，User 所在實驗室配發的是B Subnet，也能透過 BGP 的路由輕鬆連線到 Proxmox VE 虛擬機進行開發。

解決方案

在 Naive 的網路及伺服器架構下，使用者有以下困難：

1. 無法透過 SSH 連接內部網路設備
   - ➢ 埠轉發至外部網路（但有可能遭受攻擊）
   - ➢ 設定虛擬私人網路（需要頻繁切換）
2. 伺服器上臨時架設的網頁或服務難以連接
   - ➢ 請管理員設定埠轉發（較為繁瑣）
   - ➢ 使用 `ssh -R` 進行反向隧道連接

1. 硬體機器資源有限互相爭搶
   - ➢ 使用試算表手動排程（繁瑣）
   - ➢ 未滿載使用容易造成資源浪費
2. 軟體環境互相干擾
   - ➢ 使用虛擬環境（學習成本高）
   - ➢ 硬碟多系統開機（中斷成本高）

L3 Overlay Network

- BGP over WireGuard
- Build with Mikrotik RouterOS
- Need to manage private AS, IPAM, and more

Proxmox VE Cluster

- PVE Accounts Permission
- Virtual Machine: QEMU / KVM
- Virt-IO / VFIO / PCIe Passthrough
- Virtual Bridge / VLAN

Future Work

在現有系統中新增以下服務

1. Netbox
2. VXLAN
3. SSO + LDAP
4. Self host service

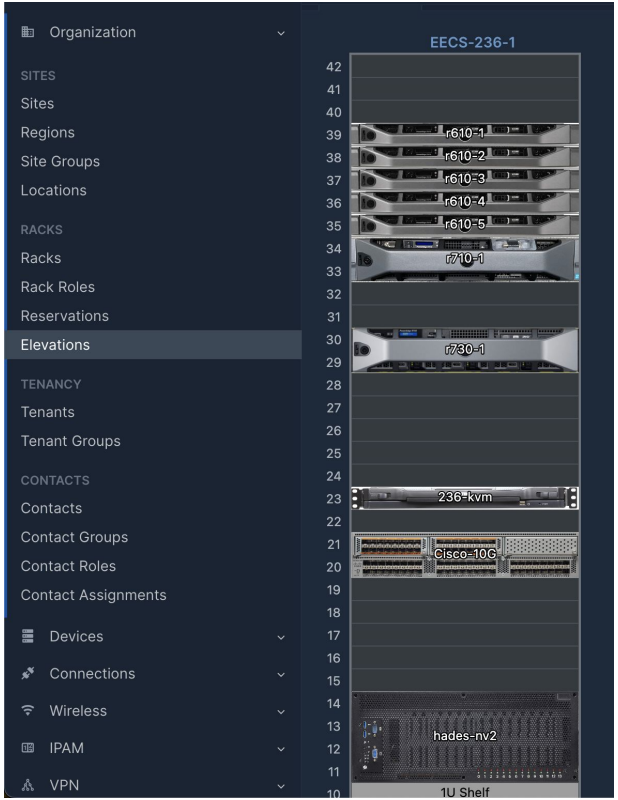

Education

- DN42

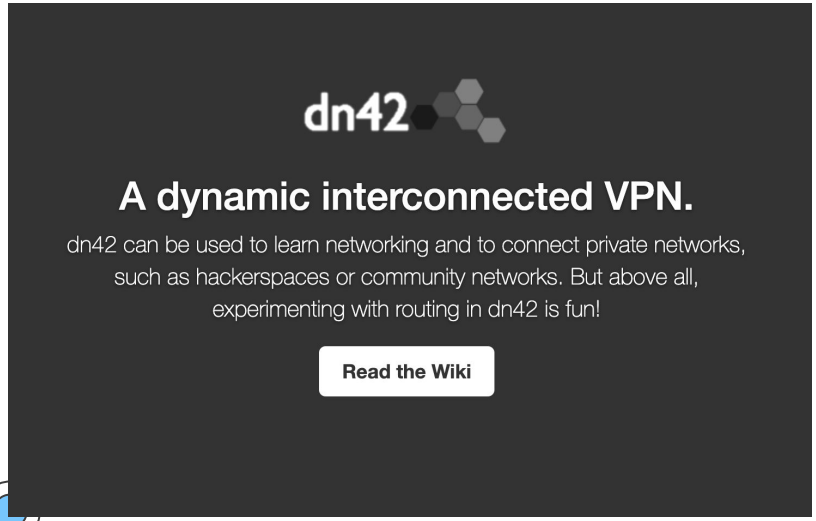

https://dn42.us/

- STUIX

https://stuix.io/

Resource & 感謝

- Overlay-network Link co-work 張意鴻
- PVE 虛擬化——給我一個邁出 Windows 的理由！ Link
- 在家機器學習？用虛擬化技術實現個人 AI 環境配置 Link

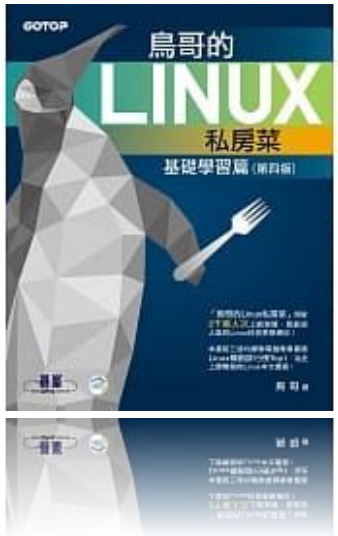

Thanks!

Do you have any questions?

contact@mou.tw
+886 920 992 660
www.mou.tw