ISOVALENT

Cilium : Le meilleur de Linux pour vos réseaux Kubernetes

Paul Chaignon | @pchaigno

Sr. Staff Software Engineer, Isovalent

cilium

Created by ISOVALENT

eBPF-based:

- Networking
- Security
- Observability
- Service Mesh & Ingress

Foundation

CLOUD NATIVE COMPUTING FOUNDATION

Technology

eBPF envoy

Microsoft chooses Cilium for Azure networking

AWS picks Cilium for Networking & Security on EKS Anywhere

Google chooses Cilium for Google Kubernetes Engine (GKE) networking

Building High-Performance Cloud Native Pod Networks

Scaleway uses Cilium as the default CNI for Kubernetes Kapsule

Managed Kubernetes: 1.5 Years of Cilium Usage at DigitalOcean

What Makes a Good Multi-tenant Kubernetes Solution

Kubernetes Network Policies in Action with Cilium

Bell uses Cilium and eBPF for telco networking

TSI uses Cilium for it's Open Sovereign Cloud product

Scaling a Multi-Tenant Kubernetes Clusters in a Telco

F5 uses Cilium VXLAN tunnel integration with BIG-IP

Radio France uses Cilium in their self hosted clusters on AWS

Deezer uses Cilium as their CNI for all on-prem Kubernetes clusters for its performance and security

Rabobank uses Cilium to implement zero trust networking in their API platform

Bloomberg leverages Cilium to construct data sandboxes

Who Am I?

Paul Chaignon
Software Engineer @ Isovalent
Equipe datapath/eBPF pour Cilium

eBPF

ISOVALENT

cilium

Tetragon

- Company behind Cilium
- Remote-first startup
- Just acquired by Cisco!

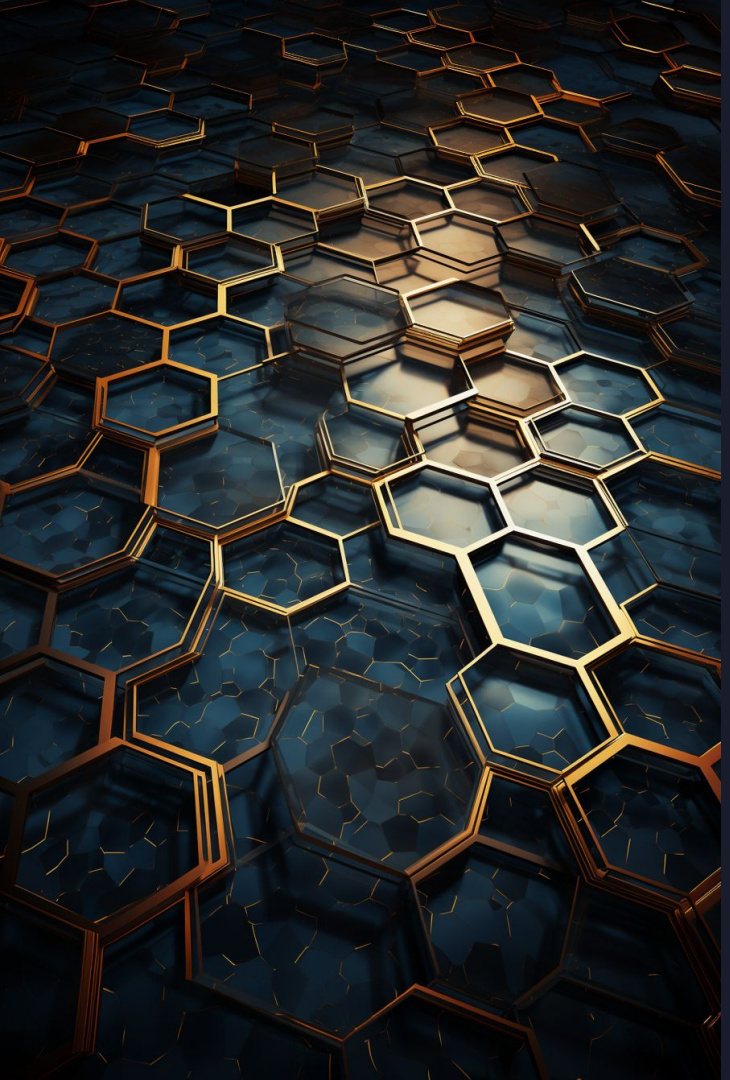

Cilium

- Programmer le noyau : eBPF
- Connecter les conteneurs
- Répartir la charge entre pods
- Segmenter son réseau
- Connecter l'existant
- Conclusion

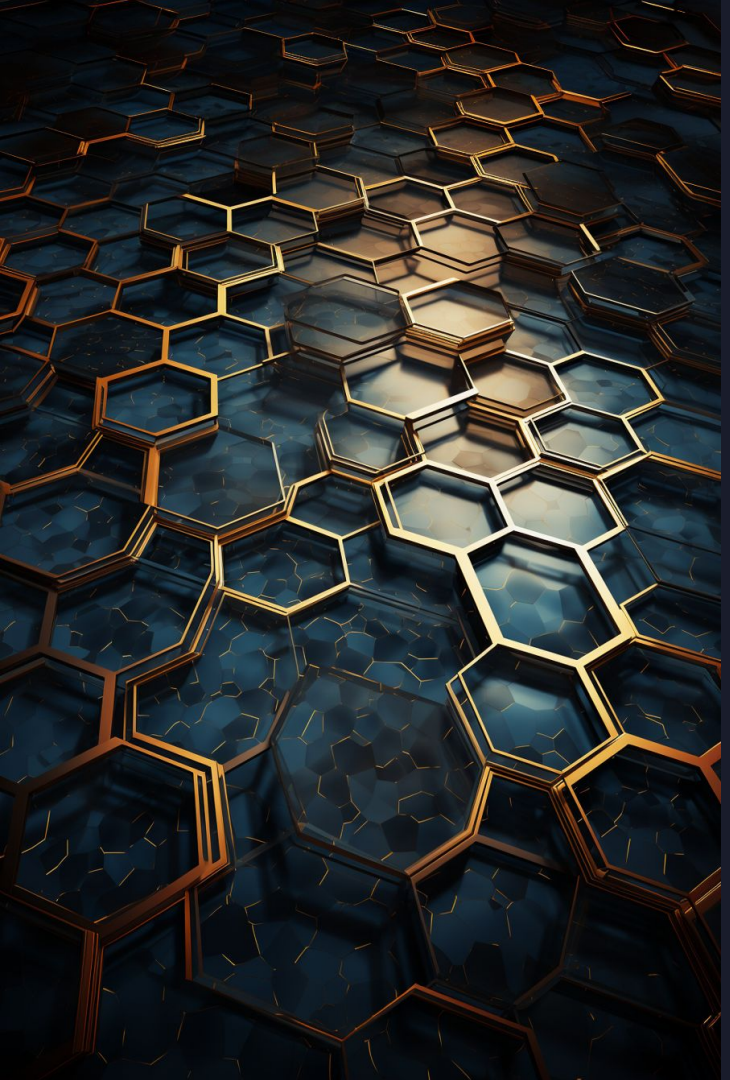

Cilium

- **Programmer le noyau : eBPF**
- Connecter les conteneurs
- Répartir la charge entre pods
- Segmenter son réseau
- Connecter l'existant
- Conclusion

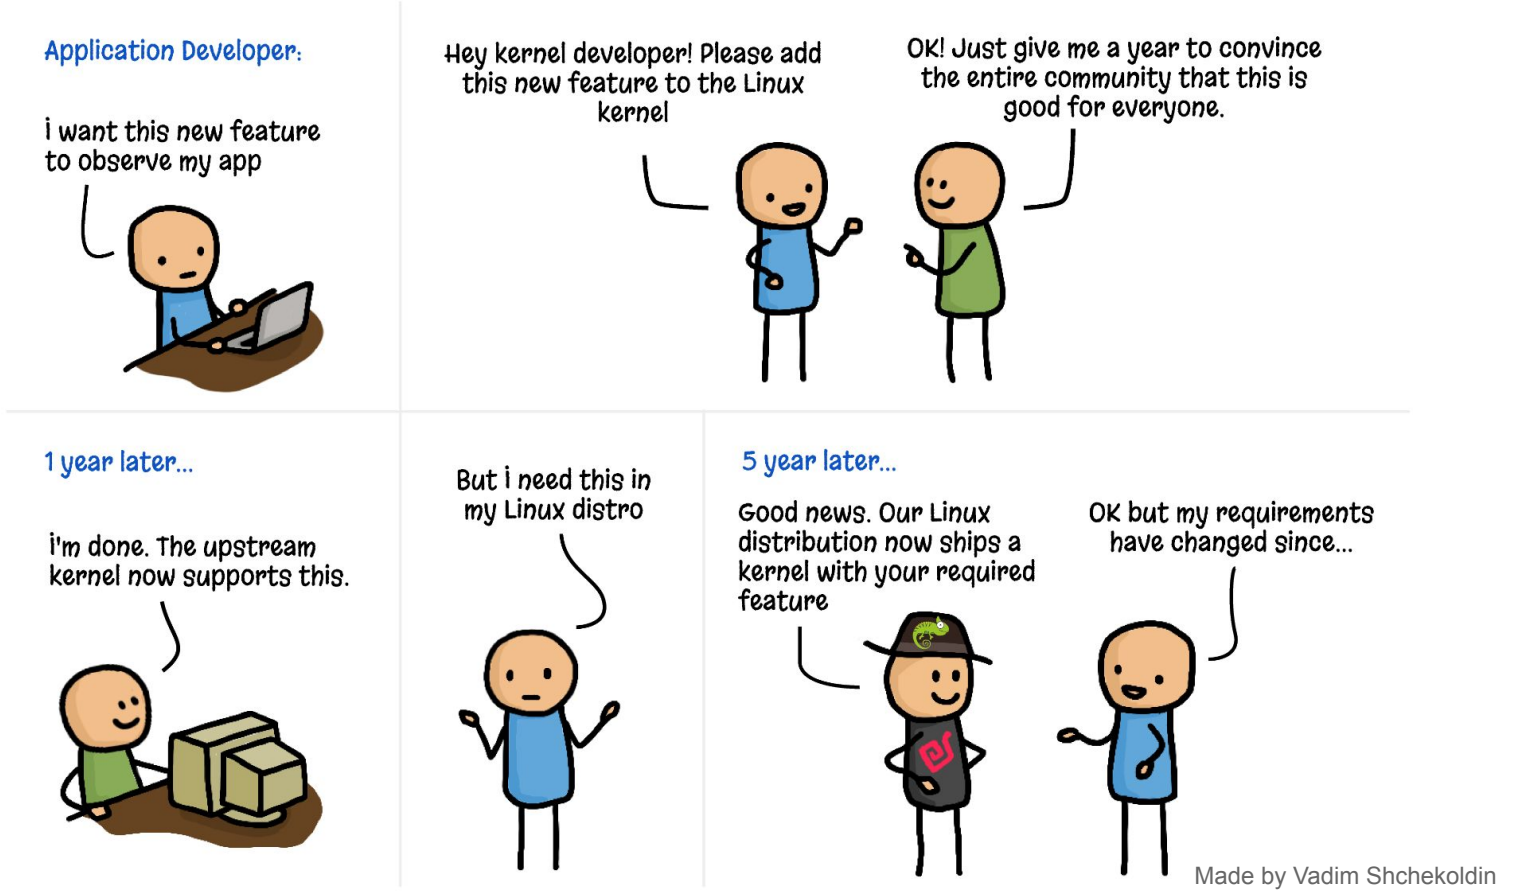
Application Developer:
i want this new feature to observe my app
Hey kernel developer! Please add this new feature to the Linux kernel
OK! Just give me a year to convince the entire community that this is good for everyone.
1 year later...
i'm done. The upstream kernel now supports this.
But i need this in my Linux distro
5 year later...
Good news. Our Linux distribution now ships a kernel with your required feature
OK but my requirements have changed since...
Made by Vadim Shchekoldin

Made by Vadim Shchekoldin

ISOVALENT

Programmer le noyau

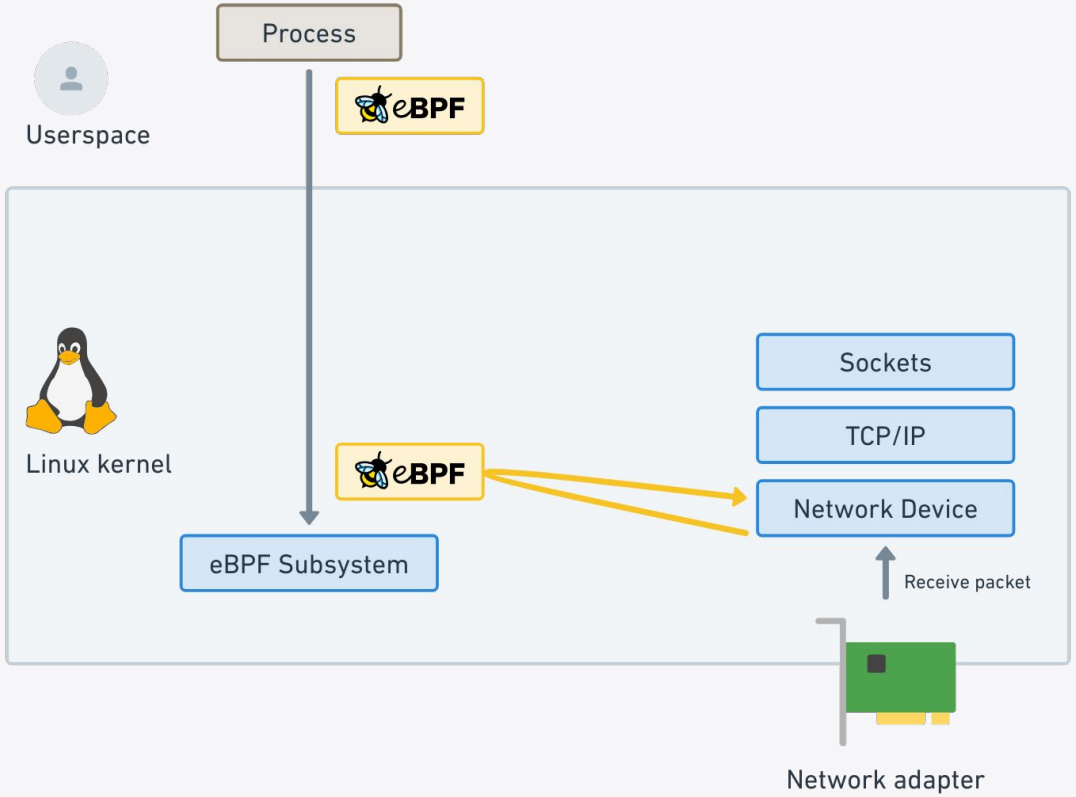

- Programme chargé dans le noyau, vérifié statiquement
- Attaché à des évènements
  - Réception de paquets
  - Appel de fonctions kernel
  - …
- Exécuté pour chaque évènement

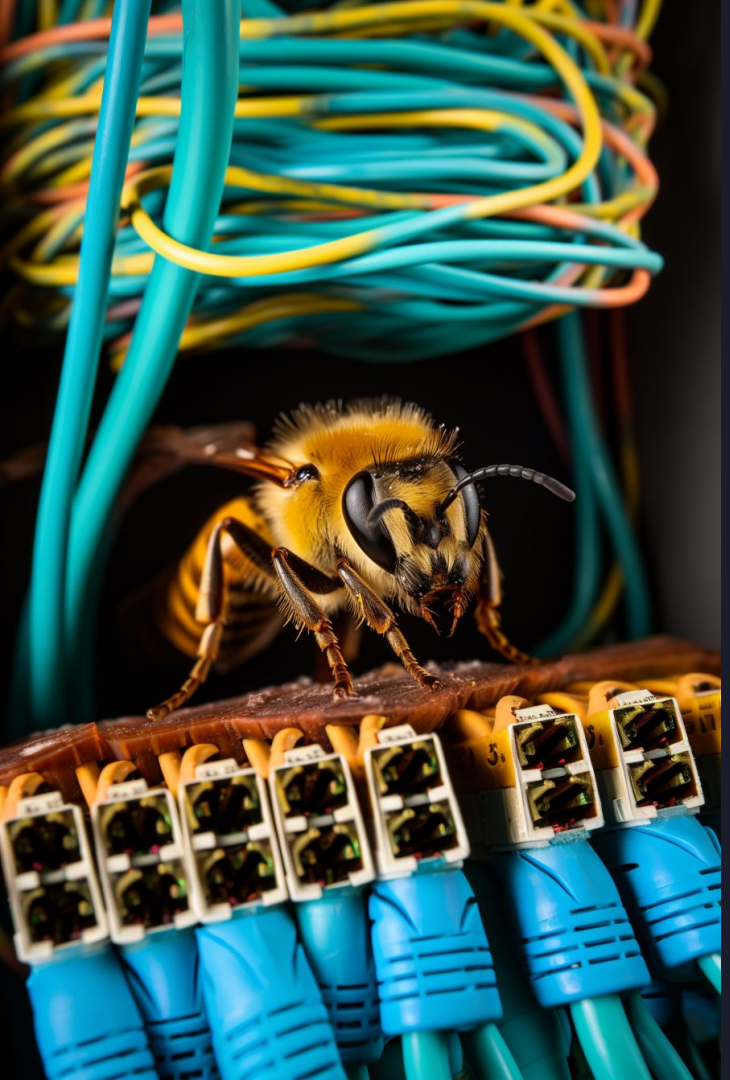

Cilium

- Programmer le noyau : eBPF
- **Connecter les conteneurs**
- Répartir la charge entre pods
- Segmenter son réseau
- Connecter l'existant
- Conclusion

ISOVALENT

Connecter les conteneurs

Modèle Kubernetes :

- Les conteneurs d'un Pod partagent le même namespace réseau
- Chaque Pod a son adresse IP
- Tous les pods du cluster peuvent communiquer entre eux (sans NAT!)

Avec Cilium :

- Pod connecté au namespace hôte via des interfaces veth
- Pod connectés entre eux via un overlay (ex. VXLAN) ou directement si le réseau le permet (avec announcements BGP)

ISOVALENT

Connecter les conteneurs... avec eBPF

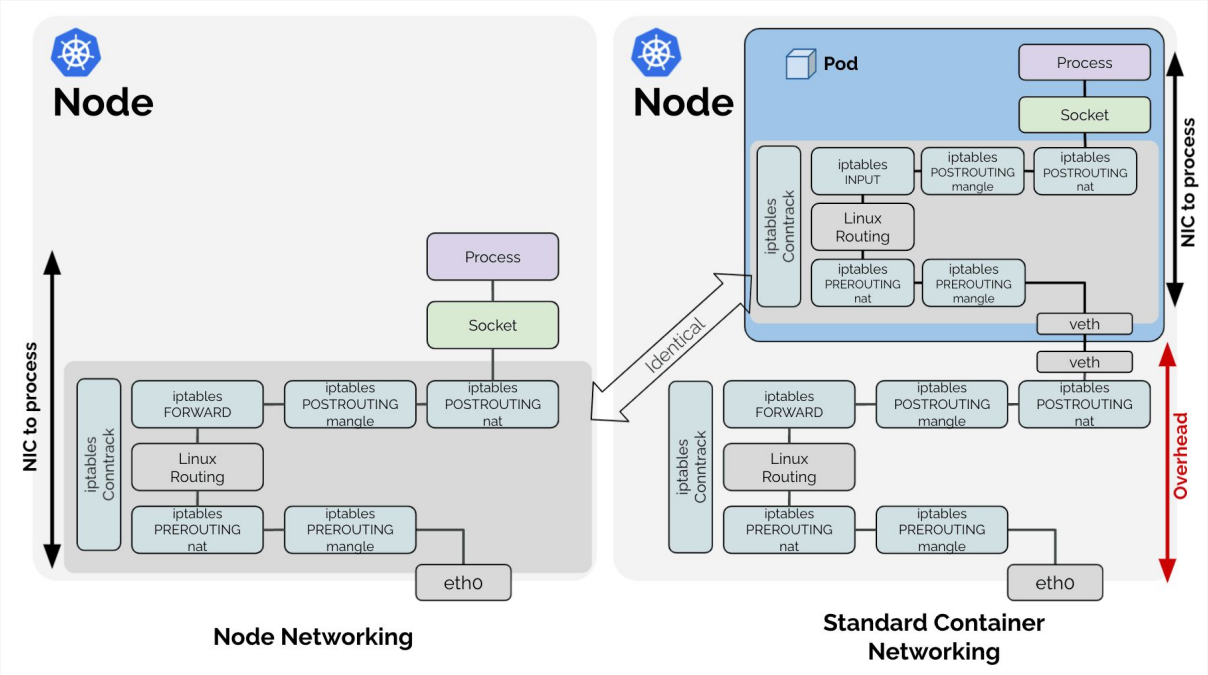

- Stack réseau Linux est assez générale mais lourde
- Stack traversée 2+ fois dans le cas de conteneurs

ISOVALENT

Connecter les conteneurs... avec eBPF

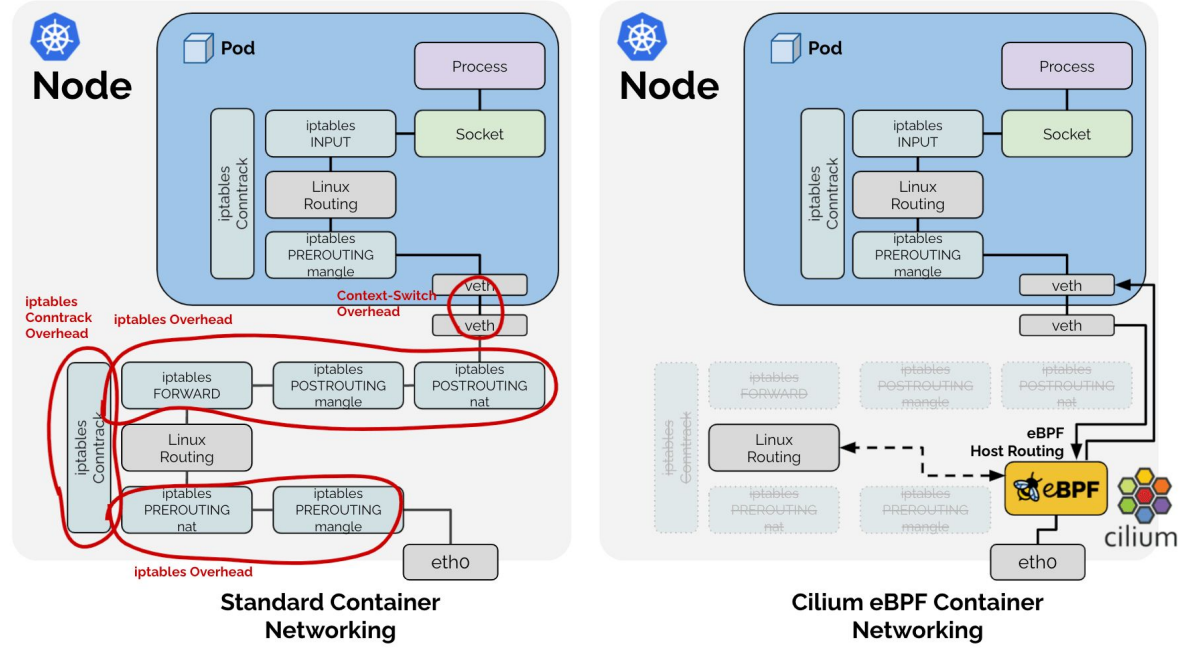

Avec eBPF :

- Spécialisation de la stack réseau
- Bypass tout ce qui n'est pas requis
- Beaucoup à bypasser pour les réseaux de conteneurs

cilium.io/blog/2021/05/11/cni-benchmark

ISOVALENT

Connecter les conteneurs... avec eBPF

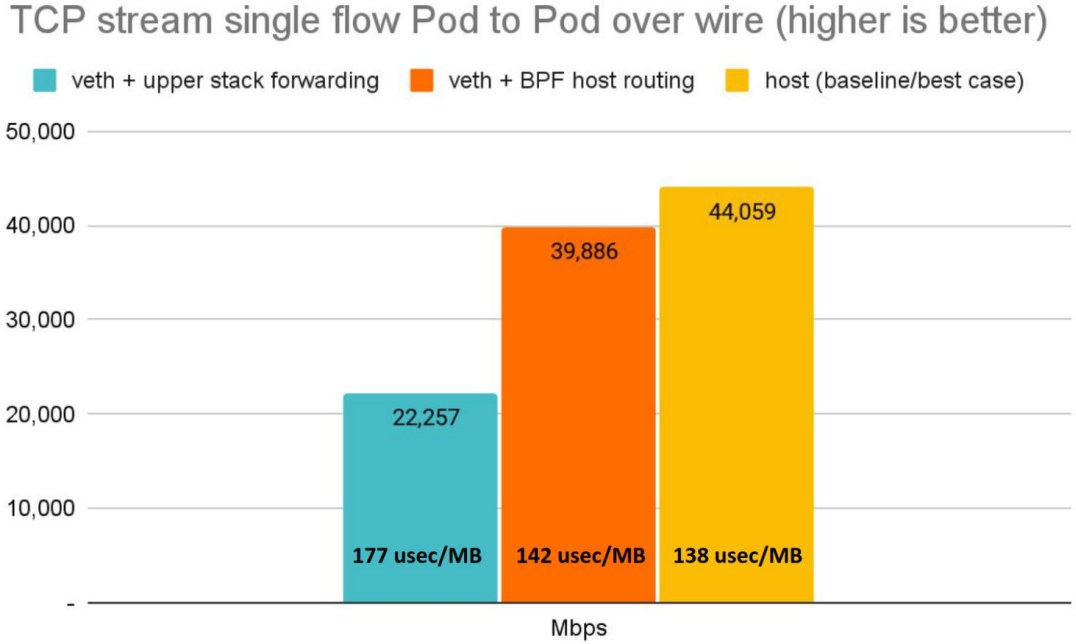

Back to back: AMD Ryzen 9 3950X @ 3.5 GHz, 128G RAM @ 3.2 GHz, PCIe 4.0, ConnectX-6 Dx, mlx5 driver, striding mode, LRO off, 1.5k MTU
Receiver: taskset -a -c <core> tcp_mmap -s (non-zerocopy mode), Sender: taskset -a -c <core> tcp_mmap -H <dst host>

Cilium

- Programmer le noyau : eBPF
- Connecter les conteneurs
- **Répartir la charge entre pods**
- Segmenter son réseau
- Connecter l'existant
- Conclusion

Répartir la charge entre pods

Modèle Kubernetes :

- Les fonctions de load balancing sont inclues
- Tous les noeuds sont des load-balancers

Avec Cilium :

- Support des standards (ClusterIP, NodePort, etc.)
- Possibilité de déployer un load-balancer “standalone”
- Announcements BGP des VIP

ISOVALENT

Répartir la charge entre pods... avec eBPF

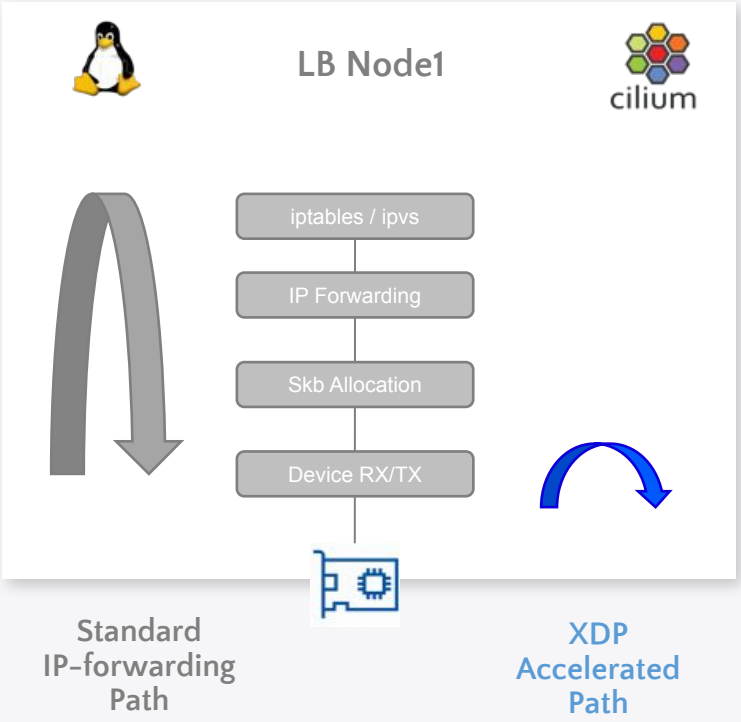

Redirection du load-balancer au plus tôt

- *North-south* : Au niveau du driver (XDP) pour les paquets entrants le cluster
- *East-west* : Au niveau du socket pour le load-balancing entre pods

ISOVALENT

Répartir la charge entre pods

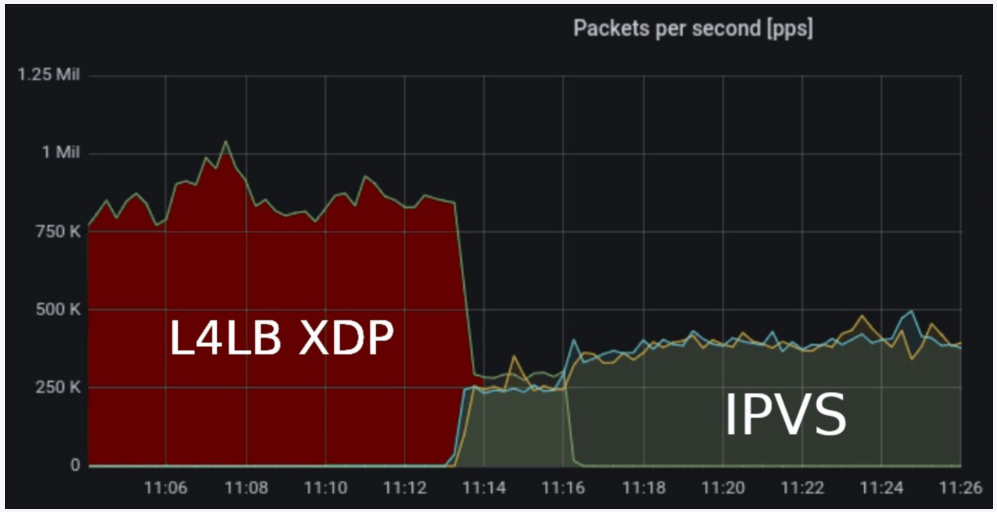

cilium.io/blog/2022/04/12/cilium-standalone-L4LB-XDP

ISOVALENT

Répartir la charge entre pods

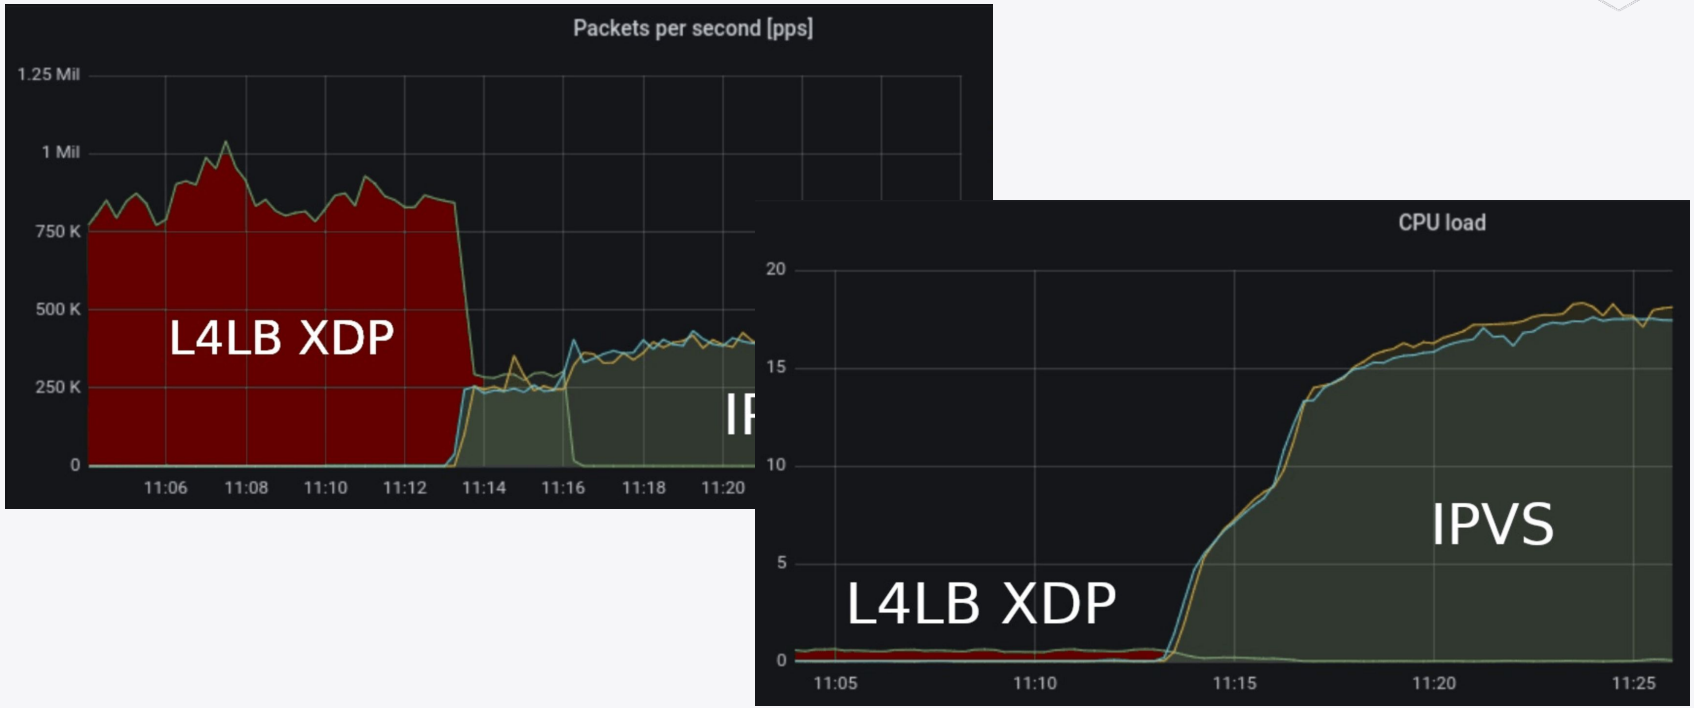

Cilium

- Programmer le noyau : eBPF
- Connecter les conteneurs
- Répartir la charge entre pods
- **Segmenter son réseau**
- Connecter l'existant
- Conclusion

ISOVALENT

Segmenter son réseau

Modèle réseau Kubernetes :

- Isolation réseau des pods par application de politiques de sécurité L3 et L4

Avec Cilium :

- Support du standard NetworkPolicy
- + Support de politiques L7, FQDN-based, ICMP, etc.

ISOVALENT

Segmenter son réseau... avec eBPF

eBPF based

Iptables based

- Liste :
  - Lookup en O(n)
  - Update en O(n)

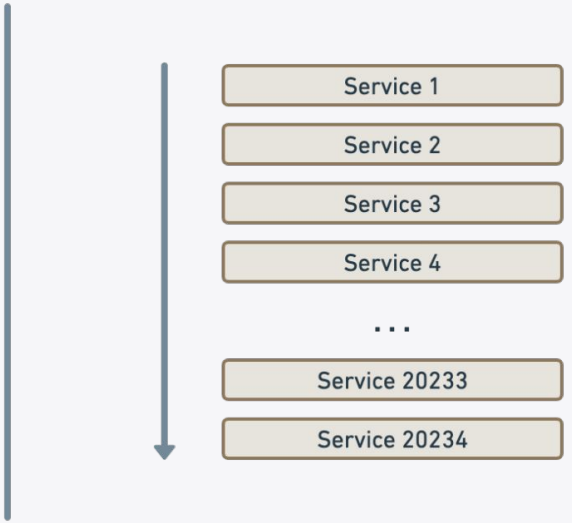

ISOVALENT

Segmenter son réseau... avec eBPF

eBPF based

- Packet classifier :
  - Lookup en O(logn)
  - Update en O(1)

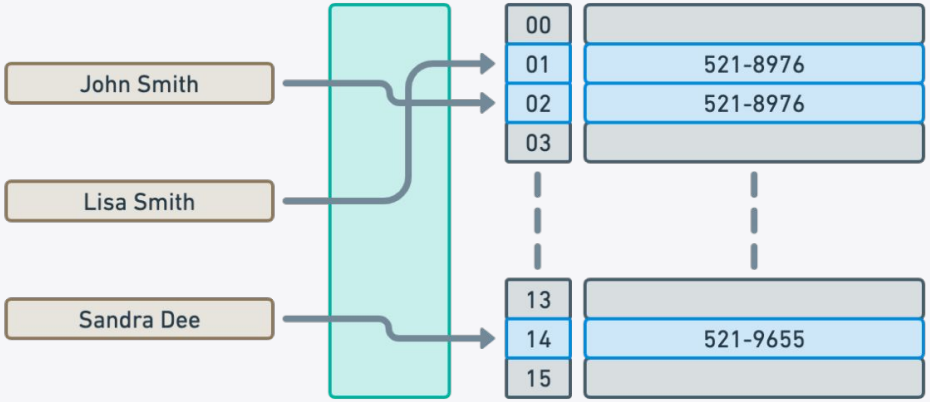

Iptables based

- Liste :
  - Lookup en O(n)
  - Update en O(n)

Cilium

- Programmer le noyau : eBPF
- Connecter les conteneurs
- Répartir la charge entre pods
- Segmenter son réseau
- **Connecter l’existant**
- Conclusion

ISOVALENT

Cilium Egress Gateway

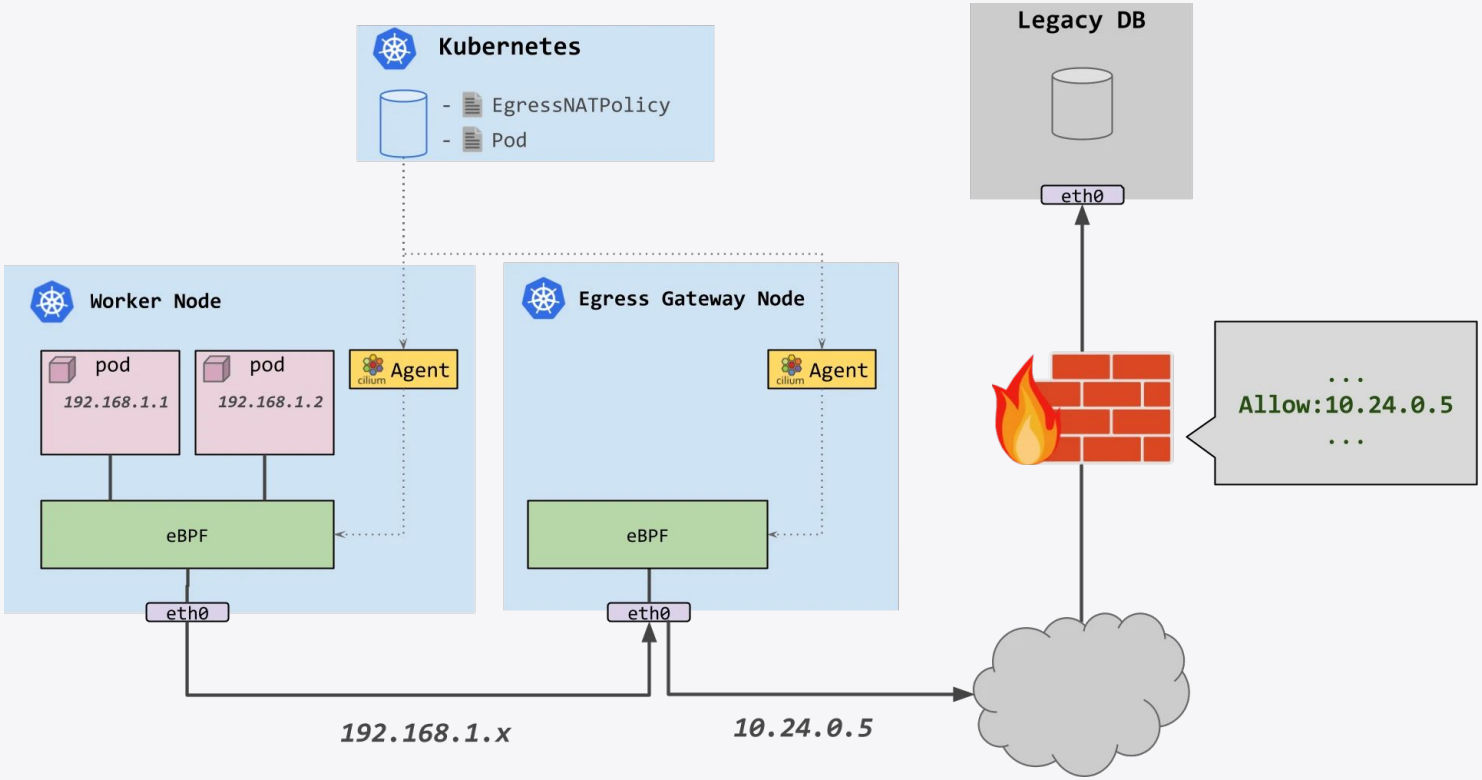

ISOVALENT

Cilium SRv6 L3VPN

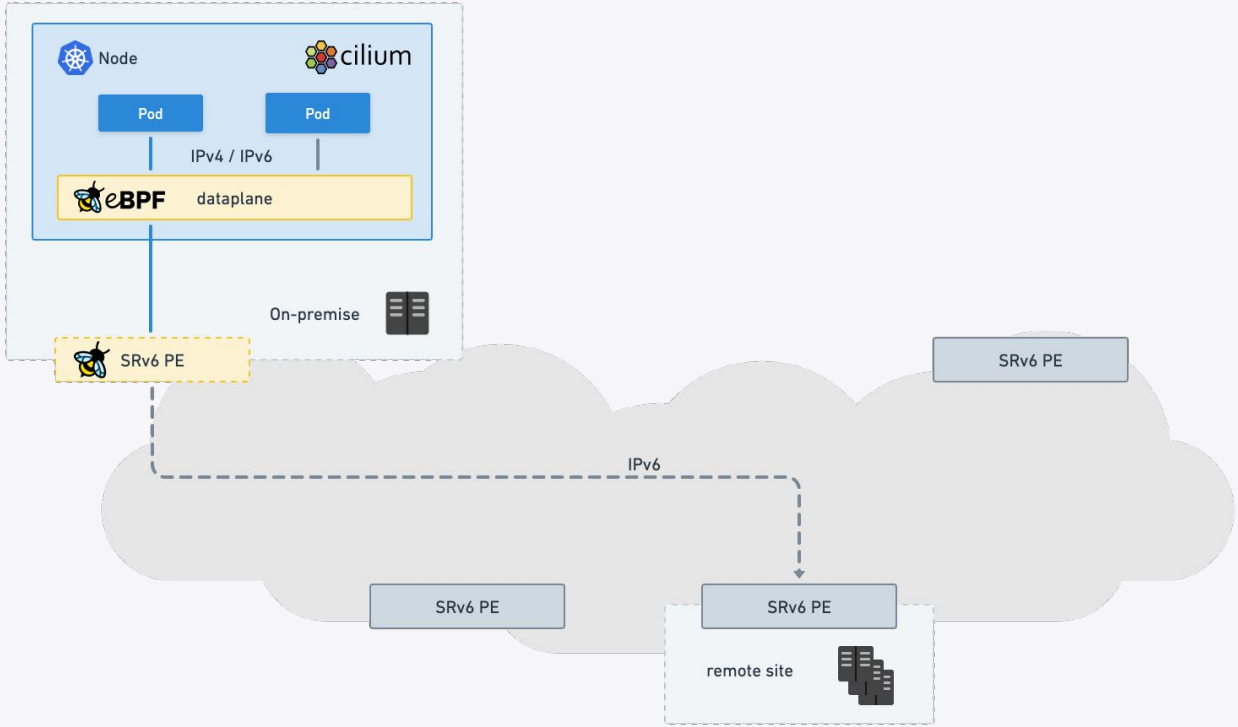

- H.Encaps, H.Encaps.Red, End.DT4
- SID allocator
- BGP integration

ISOVALENT

Cilium Mesh

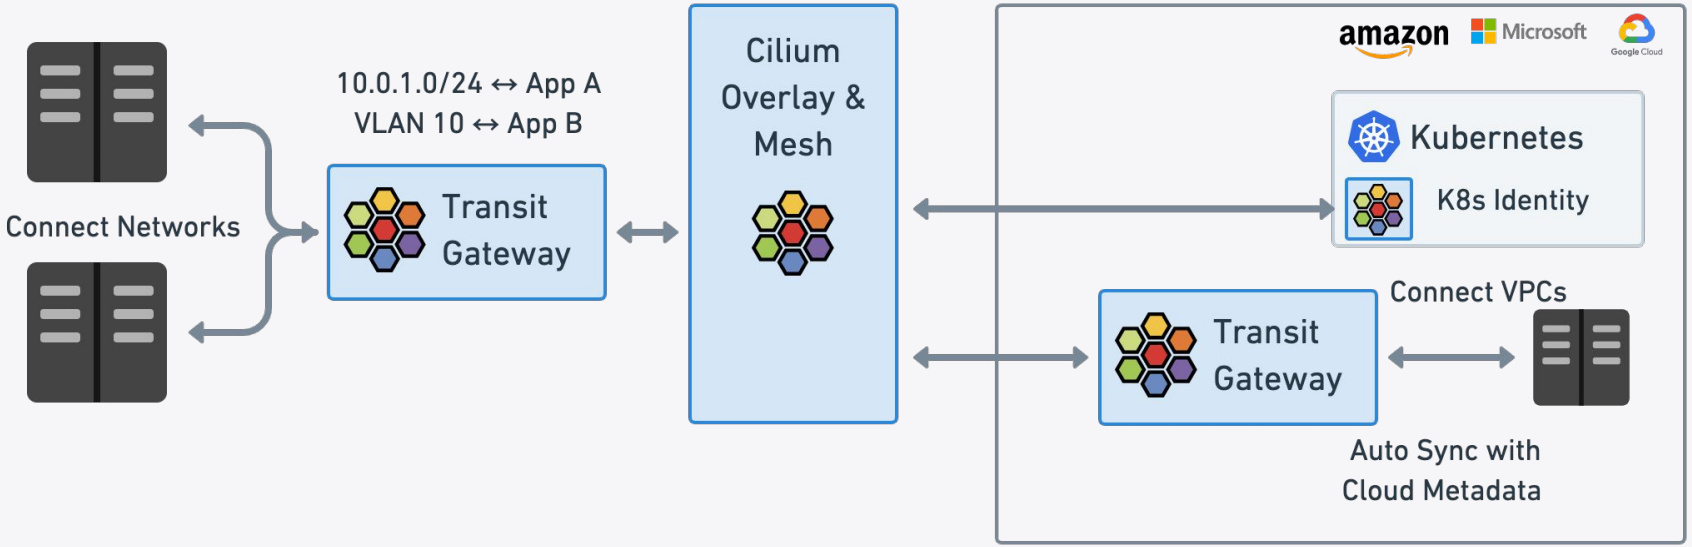

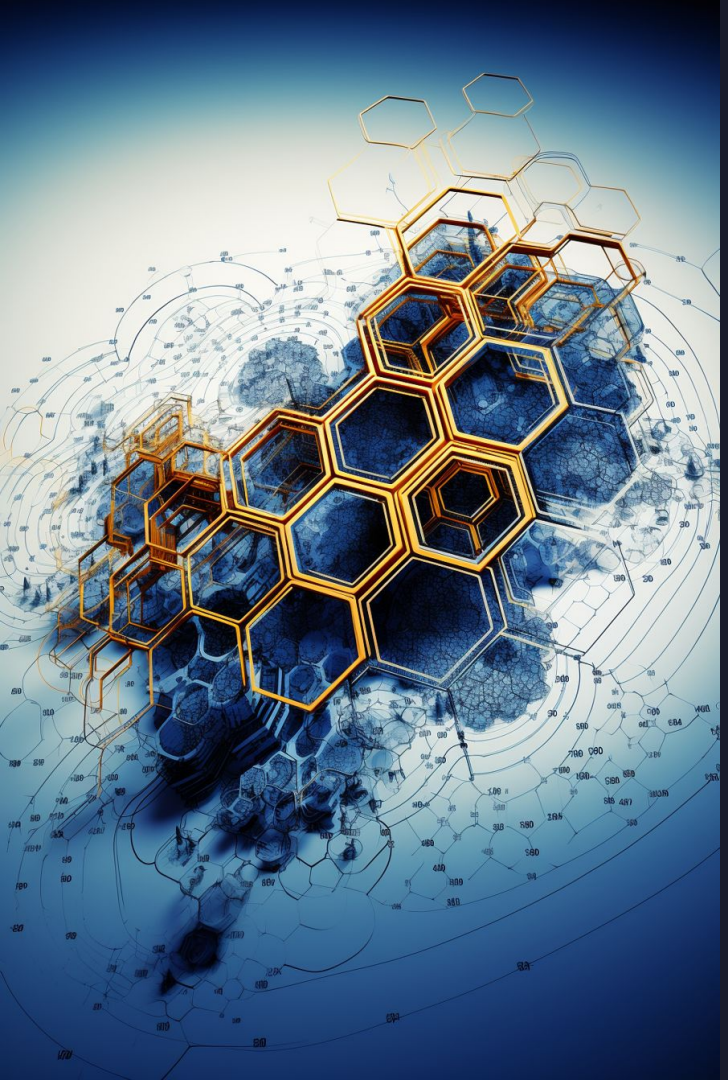

Cilium

- Programmer le noyau : eBPF
- Connecter les conteneurs
- Répartir la charge entre pods
- Segmenter son réseau
- Connecter l'existant
- **Conclusion**

ISOVALENT

Conclusion

- Cilium, le plugin réseau pour Kubernetes
- S’appuie sur les dernières innovations du noyau (pas que BPF!)
  - Principalement des gains en efficacité
- Fonctionnalités pour connecter l’existant au “cloud-native”

ISOVALENT

Merci !

Merci à Raymond de Jong, Raphaël Pinson et Vadim Shchekoldin pour beaucoup des slides et images !