ISOVALENT

Introduction à eBPF : Moderniser Linux pour le cloud

Paul Chaignon | @pchaigno

Senior Staff Engineer, Isovalent at Cisco

ISOVALENT

Avez-vous déjà utilisé eBPF ?

eBPF est peu visible mais omniprésent

- Load balancing & DDoS protection on major websites
- App data stats sur Android
- Réseaux Kubernetes
- systemd

NETFLIX FACEBOOK

Google Microsoft

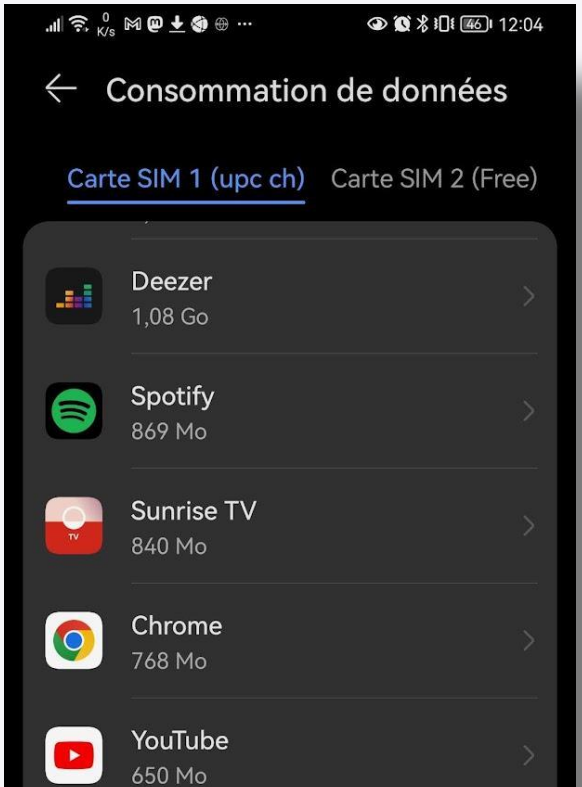

ISOVALENT

Avez-vous déjà utilisé eBPF ?

Dans un contexte DevOps :

- Profiling : OpenTelemetry
- Réseau : Cilium
- Observabilité : bpftrace, pwru
- Sécurité système : Falco, Tetragon, Tracee

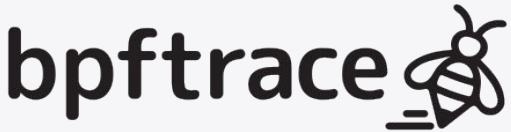

Who Am I?

Paul Chaignon
Senior Staff Engineer @ Isovalent
Equipe datapath sur Cilium
BPF developer since ~2016

eBPF

ISOVALENT

cilium

- Company behind Cilium
- Now part of Cisco
- Remote-first startup/company
- Founding member of eBPF Foundation

Comprendre eBPF

- Kernel space et userspace
- Programmer le kernel : eBPF
- Comment eBPF fonctionne
- Cas d’usages
- Misconceptions
- Conclusion

Comprendre eBPF

- Kernel space et userspace
- Programmer le kernel : eBPF
- Comment eBPF fonctionne
- Cas d’usages
- Misconceptions
- Conclusion

ISOVALENT

Kernel Space

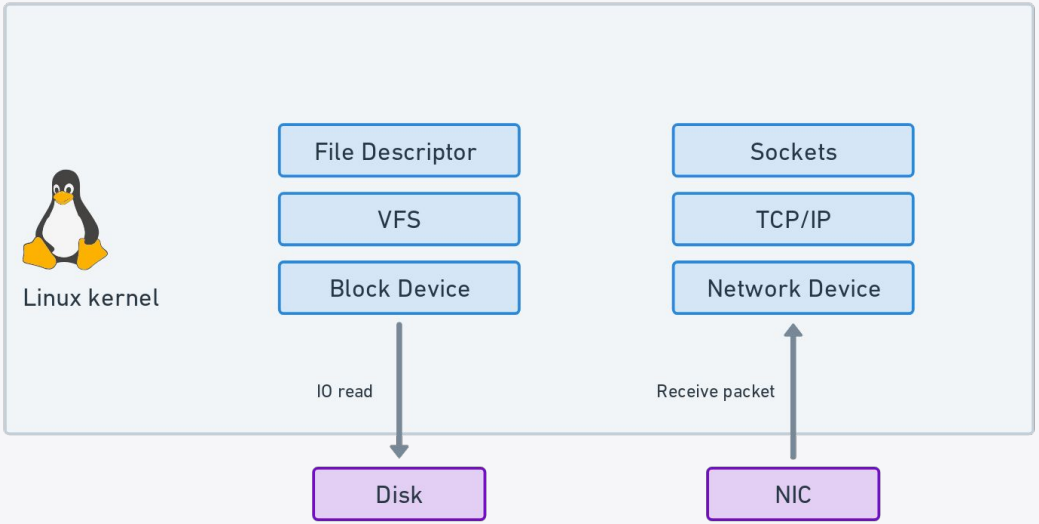

Kernel

- Très privilégié
- Gère l'accès aux ressources physiques
  - Ex. mémoire, disque, réseau
- Expose ces ressources sous formes d'abstraction
  - Ex. files, sockets, processes
- Composant critique

ISOVALENT

Kernel Space et Userspace

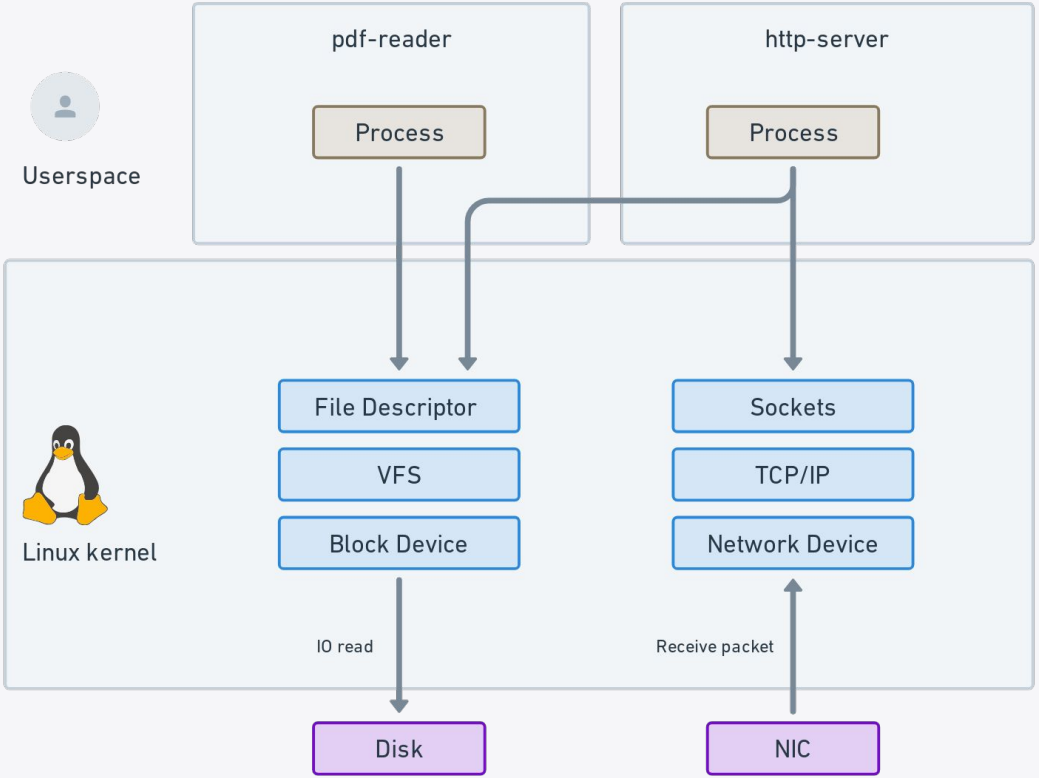

Userspace

- Domaine des processus applicatifs
- Tout accès aux ressources doit passer par le kernel

ISOVALENT

System Calls

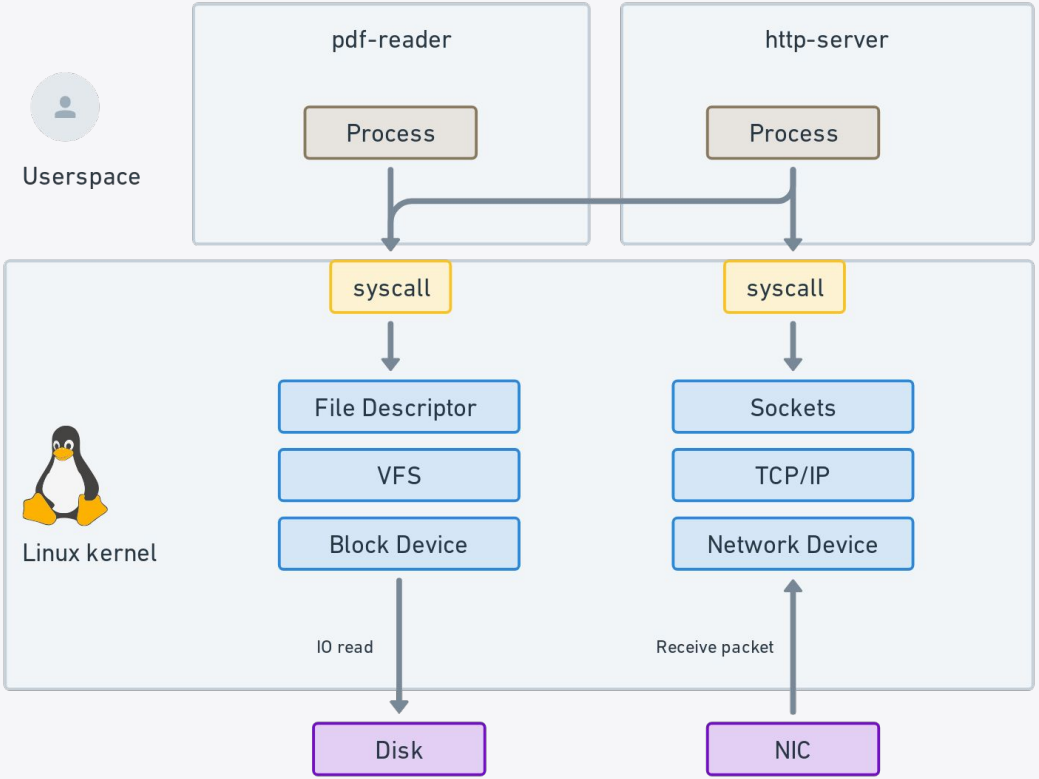

Syscalls

- Principale interface entre kernel et userspace
- Demande au kernel d'effectuer une tâche

ISOVALENT

System Calls

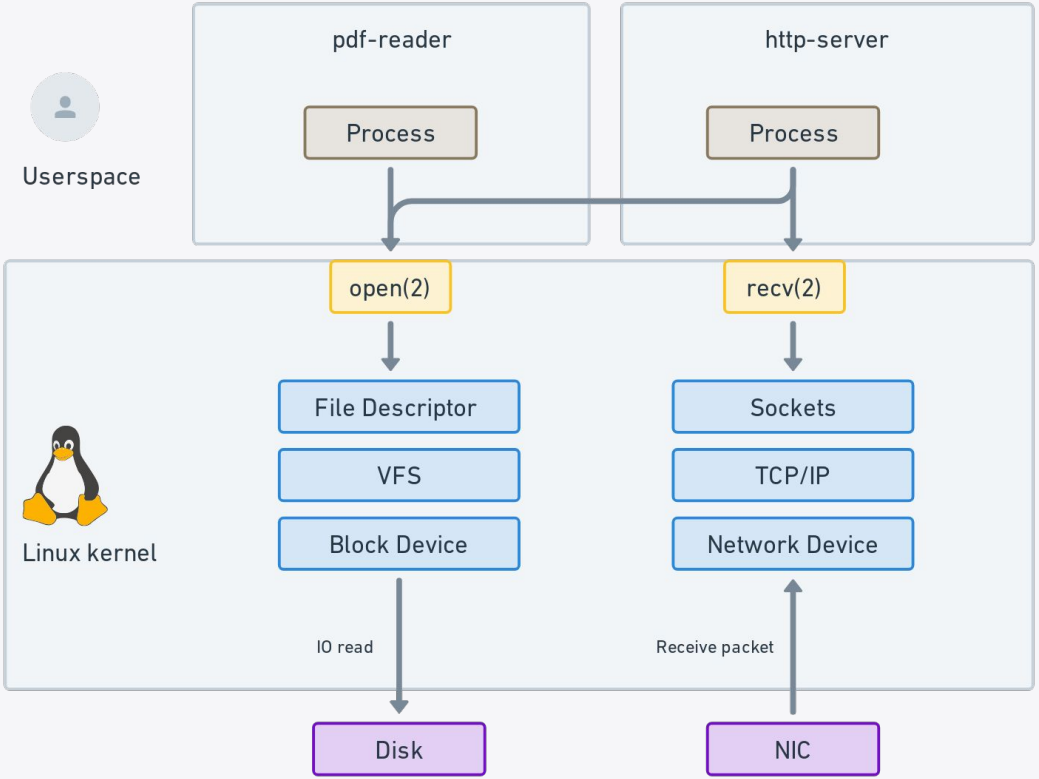

Syscalls

- Principale interface entre kernel et userspace
- Demande au kernel d'effectuer une tâche
  - Ouvrir un fichier
  - Lire ce qui a été reçu sur un socket réseau
  - …

ISOVALENT

System Calls

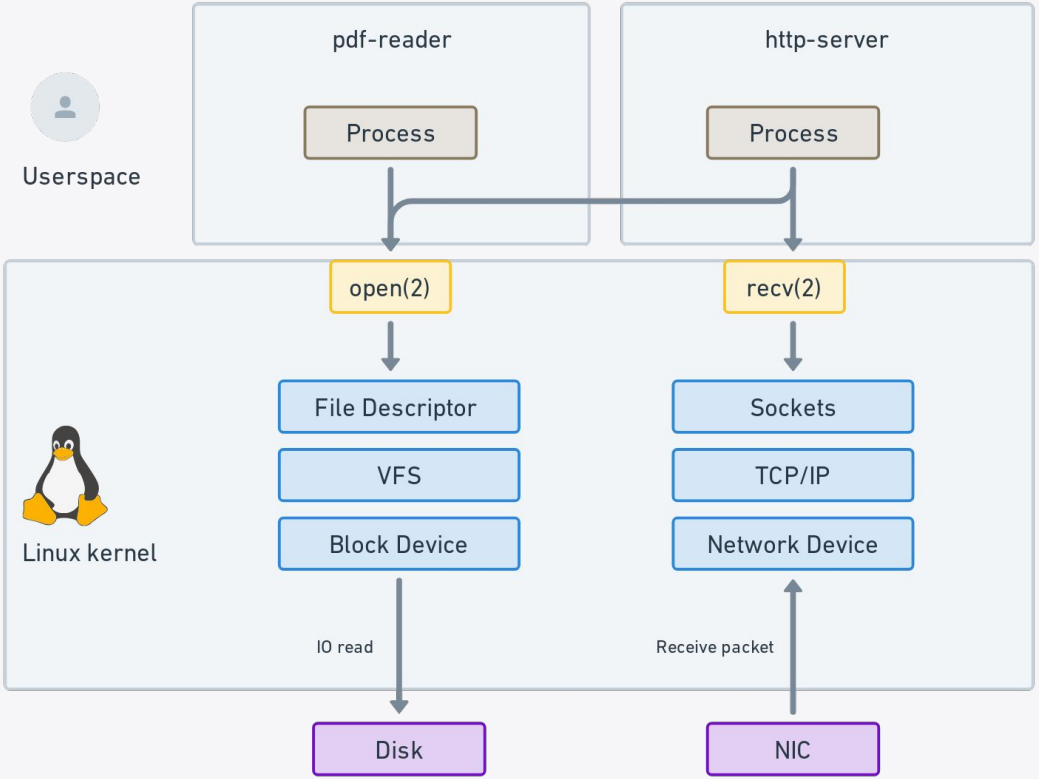

Syscalls

- Principale interface entre kernel et userspace
- Demande au kernel d'effectuer une tâche
  - Ouvrir un fichier
  - Lire ce qui a été reçu sur un socket réseau
  - …
- Très fréquent et assez coûteux

ISOVALENT

Kernel Space et Userspace

Kernel

- Composant critique, très privilégié
- Incontournable

Syscalls

- API du kernel pour les applications
- Peu expressifs
- Assez coûteux

Comprendre eBPF

- Kernel space et userspace
- **Programmer le kernel : eBPF**
- Comment eBPF fonctionne
- Cas d’usages
- Misconceptions
- Conclusion

Kernel et userspace

- Les applications peuvent vouloir de nouvelles fonctionnalités kernel
  - Nouveau protocole réseau
  - Nouvel algorithme de load balancing
  - Redirection du trafic vers un conteneur sidecar
  - …

- Généralement 2 options:
  - Demander au kernel de tout envoyer à l'application
    - Ex. tout le trafic Ethernet pour implémenter un nouveau protocole
    - Très coûteux
  - Implémenter dans le kernel…

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.

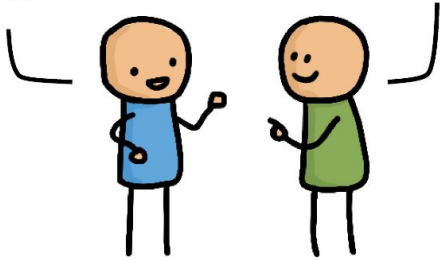

1 year later...

i'm done. The upstream kernel now supports this.

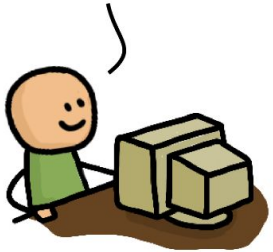

But i need this in my Linux distro

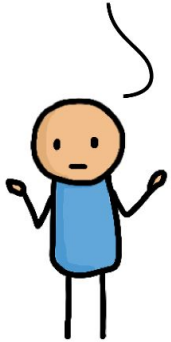

5 year later...

Good news. Our Linux distribution now ships a kernel with your required feature

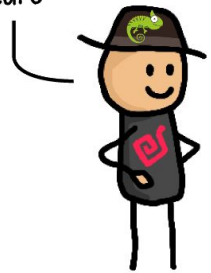

OK but my requirements have changed since...

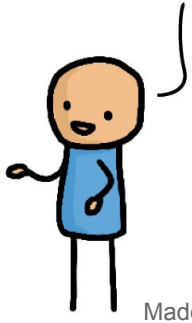

Made by Vadim Shchekoldin


Application Developer:
i want this new feature to observe my app
eBPF Developer:
OK! The kernel can't do this so let me quickly solve this with eBPF.
A couple of days later...
Here is a release of our eBPF project that has this feature now. BTW, you don't have to reboot your machine.
Made by Vadim Shchekoldin

Comprendre eBPF

- Kernel space et userspace
- Programmer le kernel : eBPF
- **Comment eBPF fonctionne**
- Cas d’usages
- Misconceptions
- Conclusion

ISOVALENT

Programmer le kernel

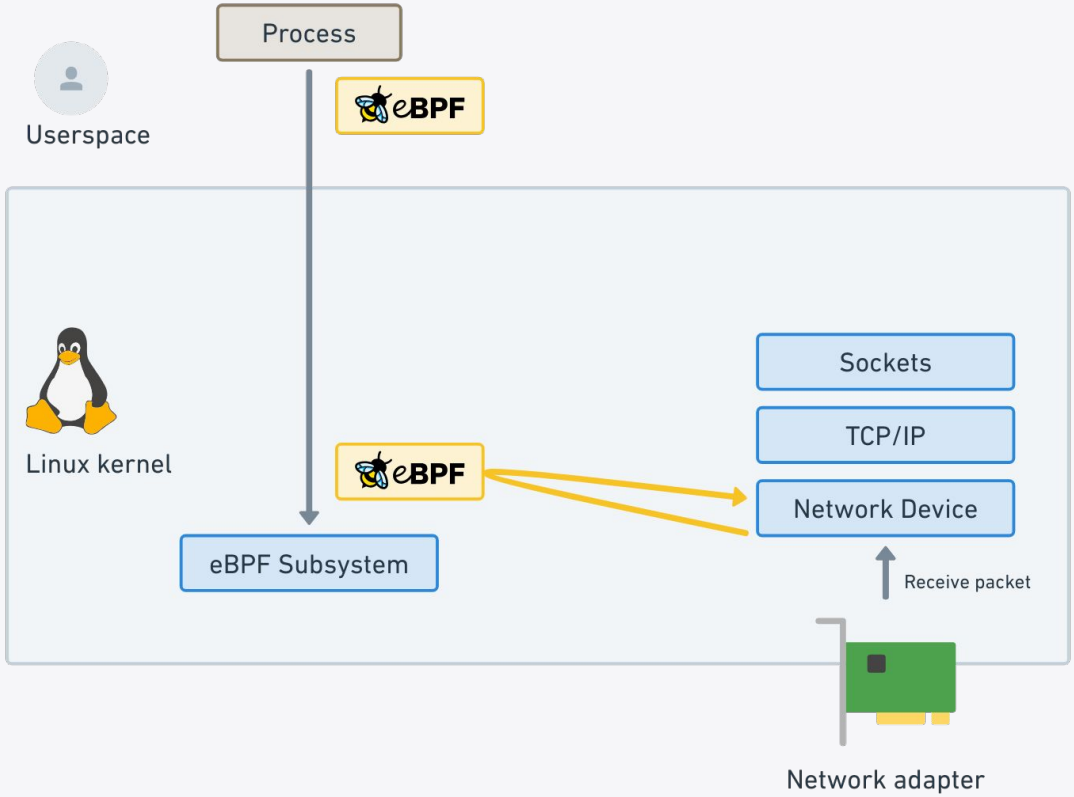

- Programme chargé dans le kernel
- Attaché à des évènements
  - Réception de paquets
  - Appel de fonctions kernel
  - …
- Exécuté pour chaque évènement

ISOVALENT

Programme eBPF

```c
SEC("xdp_sample")
int xdp_sample_prog(struct xdp_md *ctx)
{
        void *data_end = (void *)(long)ctx->data_end;
        void *data = (void *)(long)ctx->data;
        u16 sample_size;
        u64 flags;

        if (data < data_end)
                return XDP_DROP;

        metadata.pkt_len = (u16)(data_end - data);
        metadata.time = bpf_ktime_get_ns();
        sample_size = min(metadata.pkt_len, SAMPLE_SIZE);
        flags = BPF_F_CURRENT_CPU | (u64)sample_size << 32;

        bpf_perf_event_output(ctx, &my_map, flags,
                              &metadata, sizeof(metadata));

        return XDP_PASS;
}
```

```
 0: r6 = r1
 1: r7 = *(u16 *)(r6 +176)
 2: w8 = 0
 3: if r7 != 0x8 goto pc+14
 4: r1 = r6
 5: w2 = 12
 6: r3 = r10
 7: r3 += -4
 8: w4 = 4
 9: call ktime_get_ns#7684912
10: r1 = map[id:218]
12: r2 = r10
13: r2 += -8
14: *(u32 *)(r2 +0) = 32
15: call perf_event_output#120736
...
36: exit
```

ISOVALENT

Programme eBPF

```
SEC("xdp_sample")
int xdp_sample_prog(struct xdp_md *ctx)
{
        void *data_end = (void *)(long)ctx->data_end;
        void *data = (void *)(long)ctx->data;
        u16 sample_size;
        u64 flags;

        if (data < data_end)
                return XDP_DROP;

        metadata.pkt_len = (u16)(data_end - data);
        metadata.time = bpf_ktime_get_ns();
        sample_size = min(metadata.pkt_len, SAMPLE_SIZE);
        flags = BPF_F_CURRENT_CPU | (u64)sample_size << 32;

        bpf_perf_event_output(ctx, &my_map, flags,
                              &metadata, sizeof(metadata));

        return XDP_PASS;
}
```

Context :

- Seul argument
- Dépend du point d'attache
- Donne les données liées à l'évènement reçu

ISOVALENT

Programmer le kernel

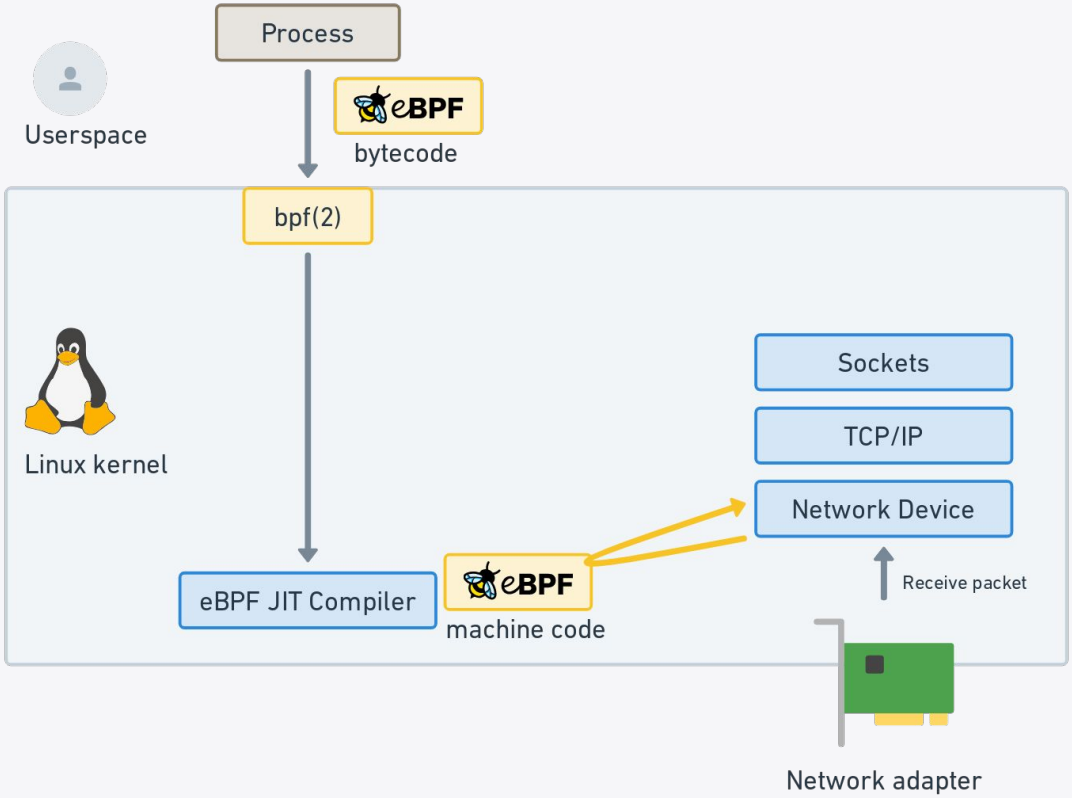

- Chargement via un syscall
  - Même syscall pour beaucoup d'opérations eBPF
- Programme JIT-compilé de bytecode à machine code classique
  - Meilleures perfs qu'un interpréteur

Le Verifier eBPF

- “Le kernel est un composant critique et privilégié”
- Un bug dans le programme pourrait crasher tout le système

- Analyse statique pour rejeter les programmes “unsafe”
  - Ex. Out-of-bounds memory access, unbounded loops, malformed jumps

- Halting problem => 100% précision impossible
- Dans le cas d’eBPF:
  - Subset vérifiable du langage C
  - Des faux positifs mais pas de faux négatifs

ISOVALENT

Le Verifier eBPF

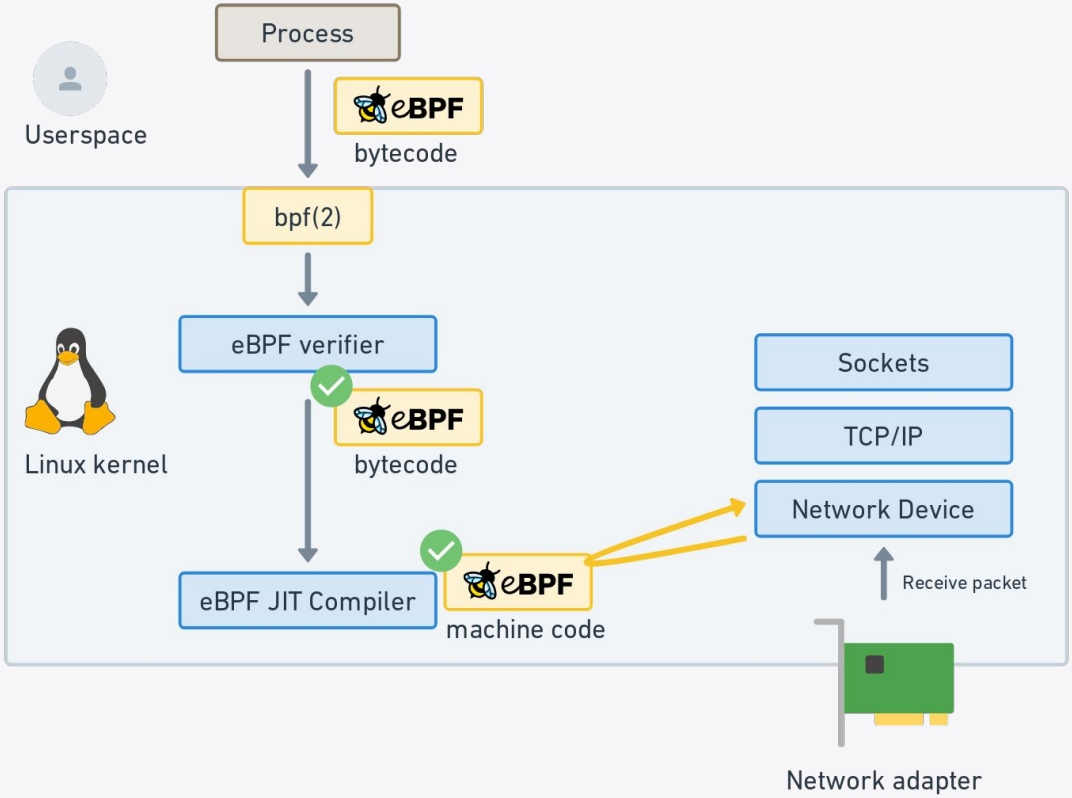

ISOVALENT

eBPF Helpers

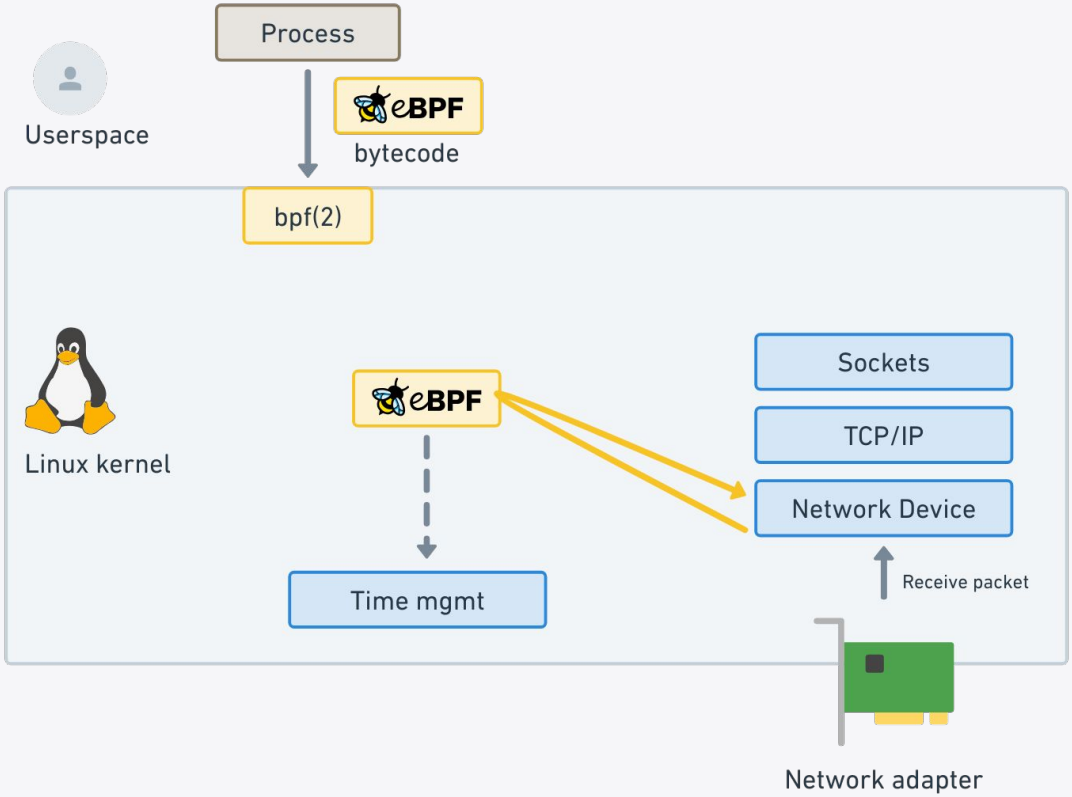

1. Accès d'eBPF aux autres ressources kernel
   - Ex. Mémoire, time, processus, config réseau

2. Moyen d'implémenter ce qu'il est compliqué de faire en eBPF
   - String functions, calcul de checksum, etc.

ISOVALENT

eBPF Helpers

```
SEC("xdp_sample")
int xdp_sample_prog(struct xdp_md *ctx)
{
        void *data_end = (void *)(long)ctx->data_end;
        void *data = (void *)(long)ctx->data;
        u16 sample_size;
        u64 flags;

        if (data < data_end)
                return XDP_DROP;

        metadata.pkt_len = (u16)(data_end - data);
        metadata.time = bpf_ktime_get_ns();
        sample_size = min(metadata.pkt_len, SAMPLE_SIZE);
        flags = BPF_F_CURRENT_CPU | (u64)sample_size << 32;

        bpf_perf_event_output(ctx, &my_map, flags,
                              &metadata, sizeof(metadata));

        return XDP_PASS;
}
```

man7.org/linux/man-pages/man7/bpf-helpers.7.html

eBPF Maps

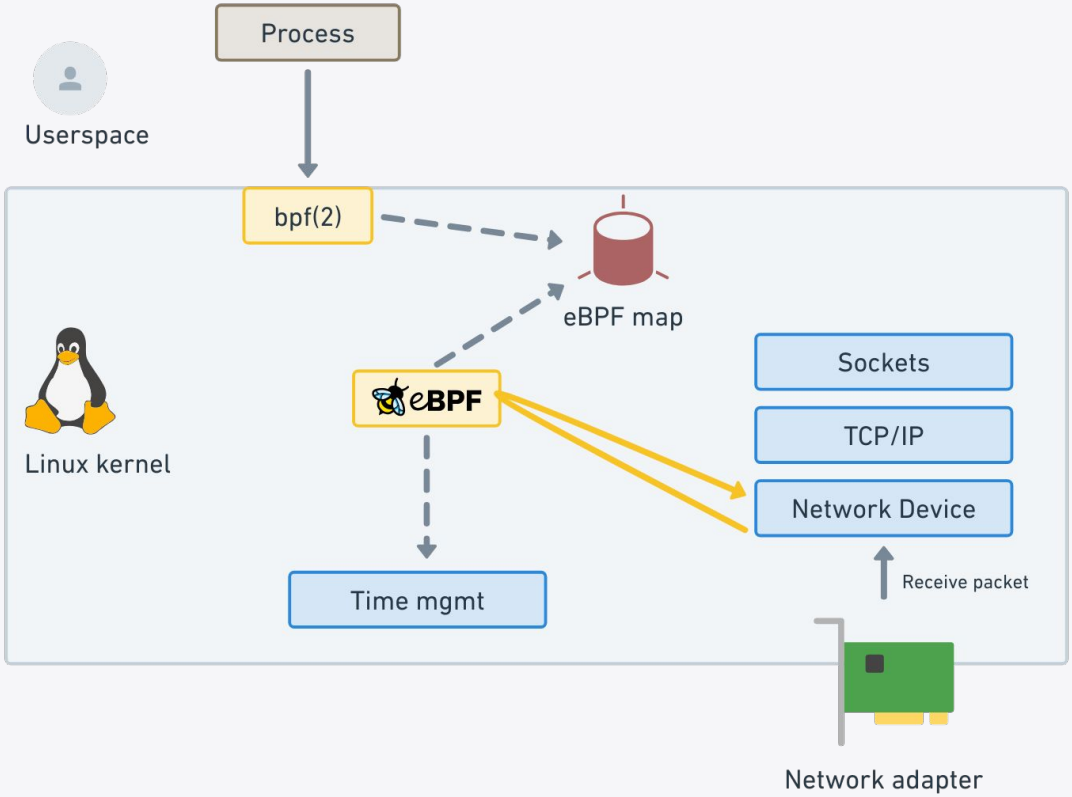

- Key-value stores of many types
- Pour:
  - Stocker des données entre deux évènements
  - Communiquer avec userspace
- Accès aux maps via les helpers
  - Avec bounds checks

eBPF Maps

```
SEC("xdp_sample")
int xdp_sample_prog(struct xdp_md *ctx)
{
        void *data_end = (void *)(long)ctx->data_end;
        void *data = (void *)(long)ctx->data;
        u16 sample_size;
        u64 flags;

        if (data < data_end)
                return XDP_DROP;

        metadata.pkt_len = (u16)(data_end - data);
        metadata.time = bpf_ktime_get_ns();
        sample_size = min(metadata.pkt_len, SAMPLE_SIZE);
        flags = BPF_F_CURRENT_CPU | (u64)sample_size << 32;

        bpf_perf_event_output(ctx, &my_map, flags,
                              &metadata, sizeof(metadata));

        return XDP_PASS;
}
```

eBPF Map Types

- Array
- Hash table
- Ring buffer
- Prefix trie
- Least-recently used hash table
- Map of maps
- FIFO and LIFO queues
- Bloom filter
- …

- Beaucoup de maps supportées
  - Au fur et à mesure des besoins
- Assez haut niveau, simple d’usage
- Évite de devoir les implémenter en C

ISOVALENT

“eBPF est un acronyme”

“extended Berkeley Packet Filter”

- Sans lien avec Berkeley
- S’applique à bien plus que des paquets réseaux
- Peut faire bien plus que filtrer

Un peu comme SFR, spam, taser…

ISOVALENT

Comment eBPF Fonctionne : Résumé

- Code C simplifié
- Exécuté sur des évènements
- Analyse statique protéger le kernel
- Kernel APIs pour :
  - Accéder au reste du kernel
  - Stocker des données

Comprendre eBPF

- Kernel space et userspace
- Programmer le kernel : eBPF
- Comment eBPF fonctionne
- **Cas d’usages**
- Misconceptions
- Conclusion

ISOVALENT

eBPF pour le Monitoring

- Premier cas d’application connu
  - En grande part grâce à Brendan Gregg, un expert en analyse de performance

- Principalement:
  - Outils d’observation du système
  - Outils de profiling axés analyse de performance

ISOVALENT

Application and system profiling

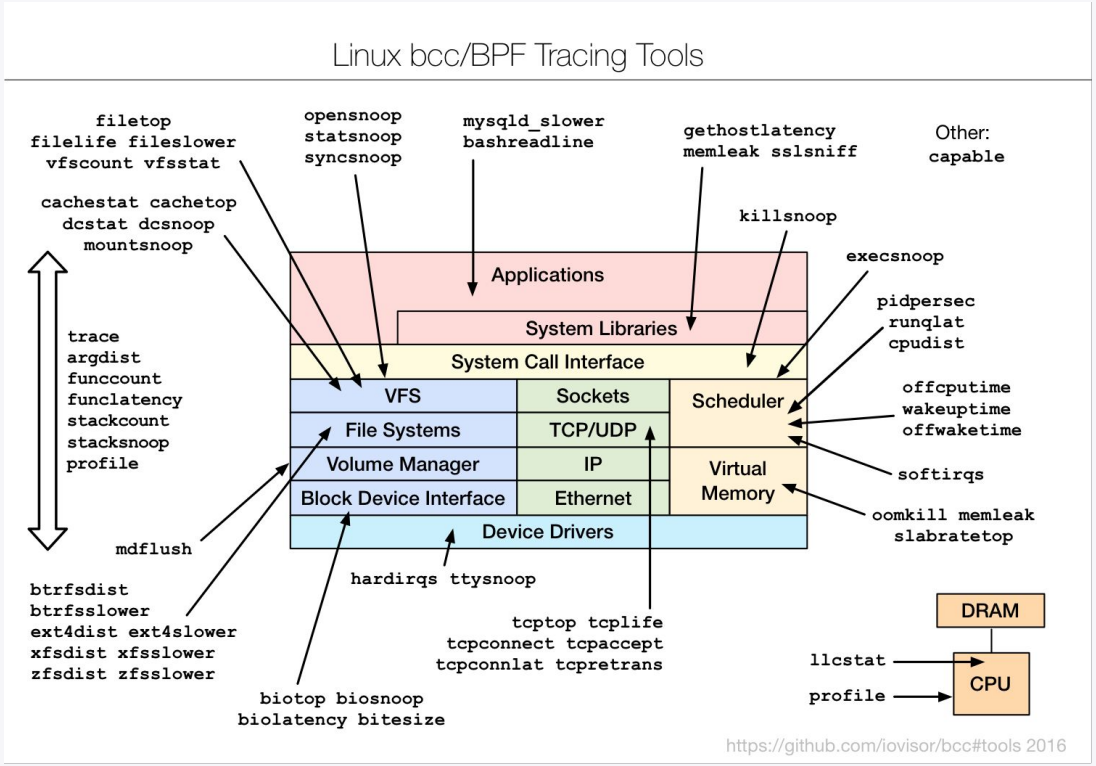

- Read-only
- Très nombreux hook points
- Agrégation dans le kernel
  - Médiane, quantiles
  - Histogram
  - Stacktraces
  - …

ISOVALENT

Application and system profiling

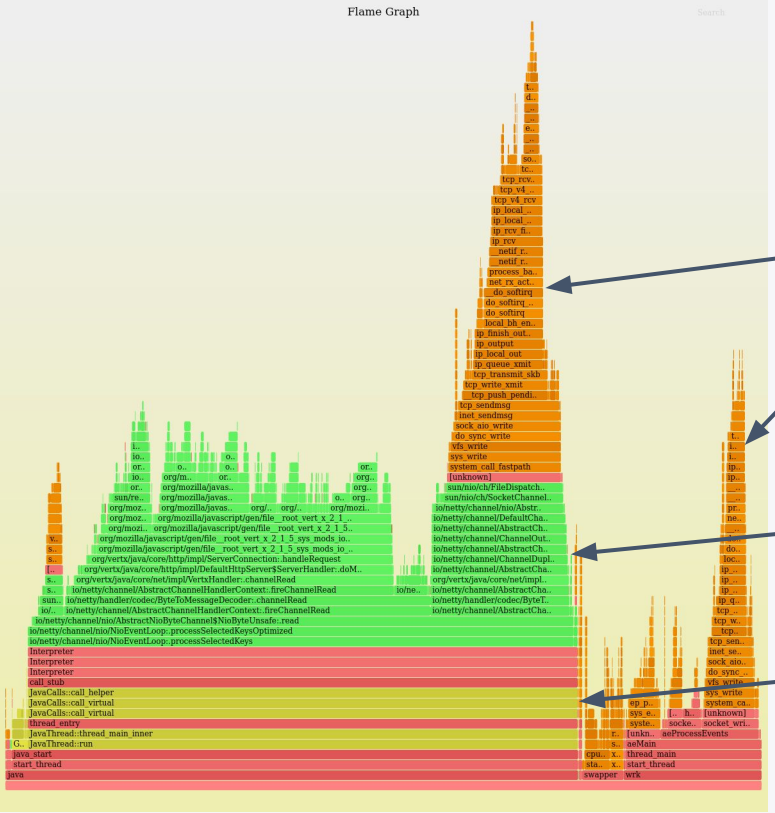

- Existait déjà
- Mais beaucoup plus efficace avec eBPF
- Enables continuous profiling

prodfiler.com/blog/introducing-prodfiler

eBPF pour le Réseau

- Motivation initiale pour eBPF

- Cas d’usage assez variés :
  - Load balancing
  - Sécurité
  - Réseaux de conteneurs
  - Nouveaux protocoles
  - …

ISOVALENT

Container Networking

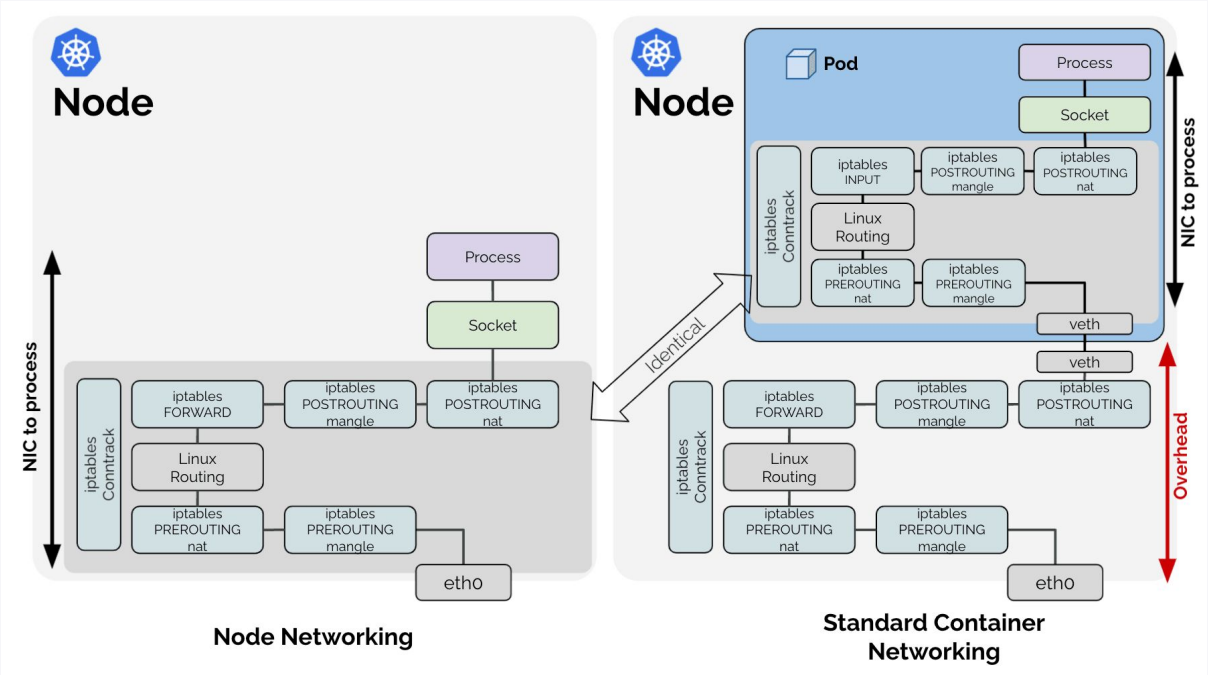

- Stack réseau Linux est assez générale mais lourde
- Stack traversée 2+ fois dans le cas de conteneurs

ISOVALENT

Container Networking

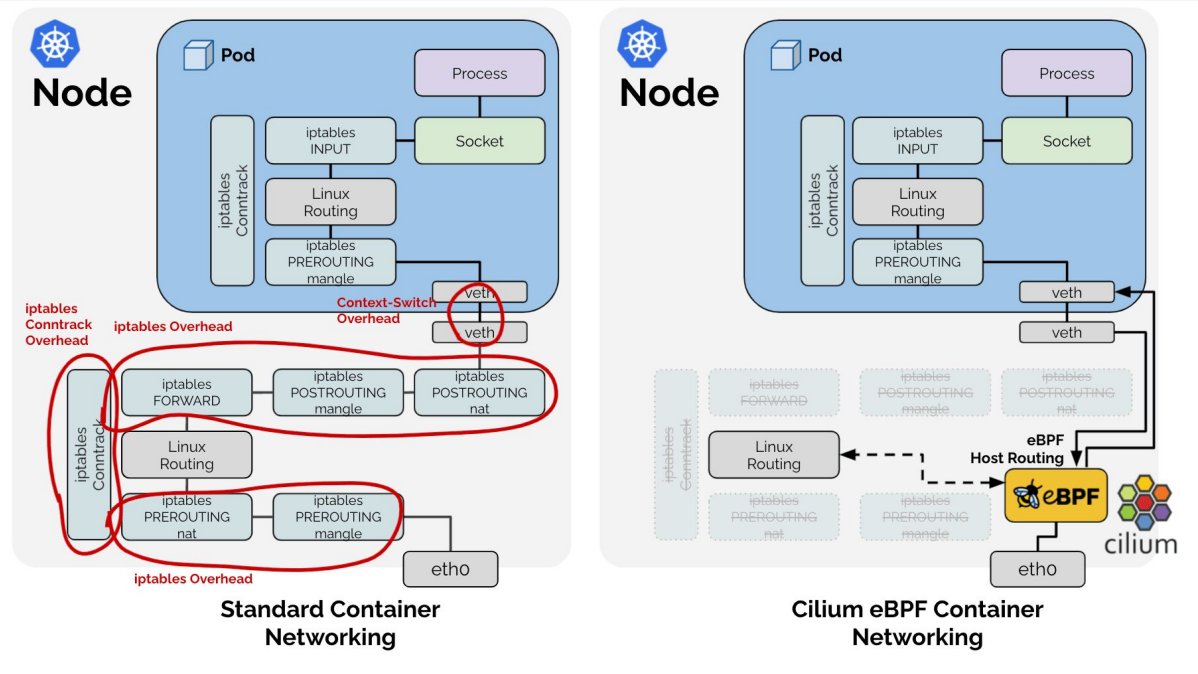

Avec eBPF :

- 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

“Utiliser eBPF améliore les performances”

Non, mais

- Le simple fait d’utiliser eBPF n’améliore pas les performances
- Mais beaucoup de gains de perf possible :
  - Spécialisation du kernel
  - Bypass d’opération inutiles
  - Utilisation d’algorithmes plus adaptés
  - …

pchaigno.github.io/ebpf/2020/09/29/bpf-isnt-about-speed.html

ISOVALENT

Sécurité Système

- Monitoring and enforcement completely with eBPF
- “Kubernetes-aware”
- Low overhead

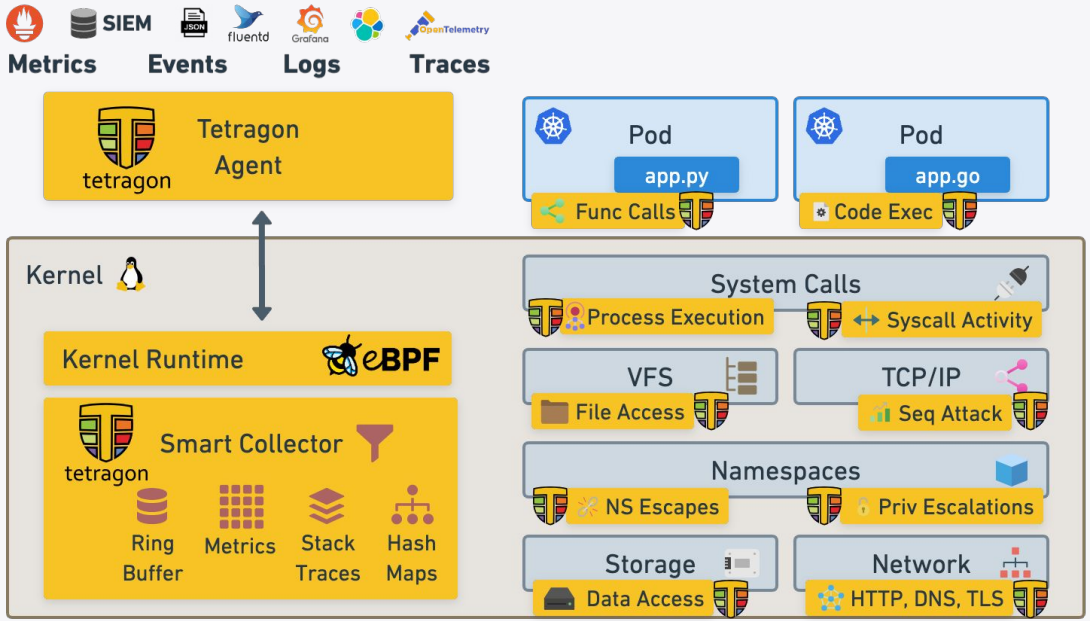

Let’s Deep Dive into a Kubernetes Pod

Tetragon

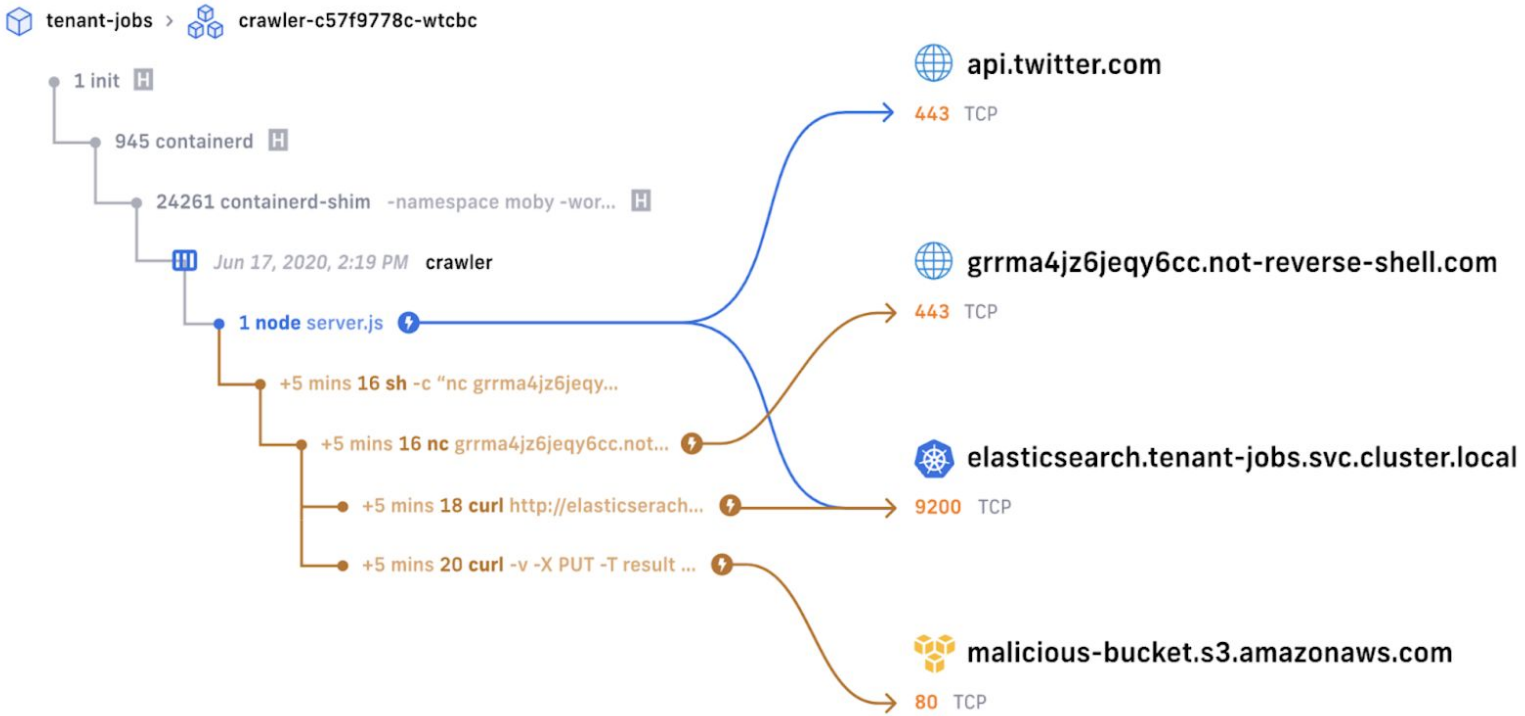

Let’s Deep Dive into a Kubernetes Pod

Tetragon

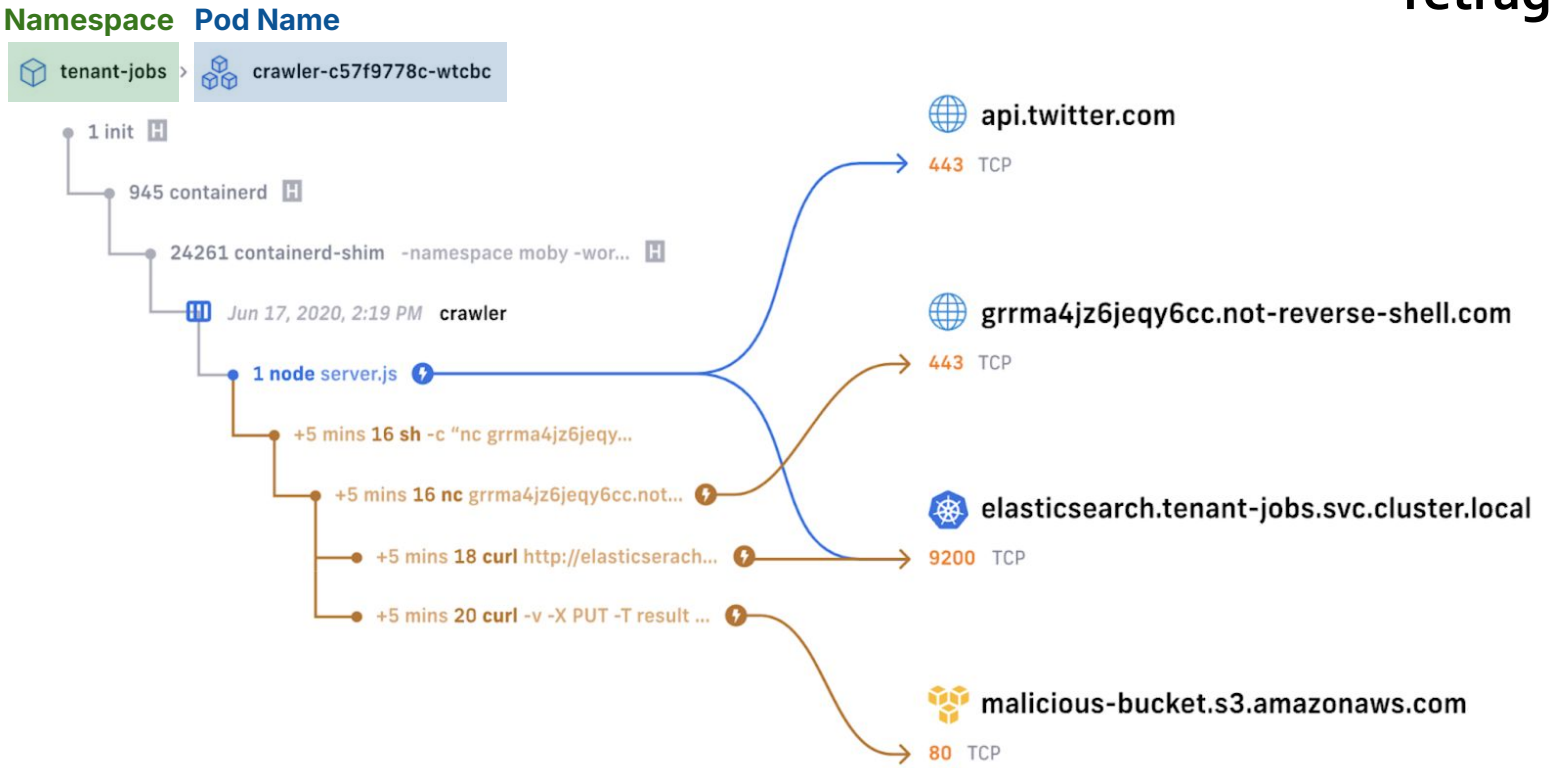

Let’s Deep Dive into a Kubernetes Pod

Tetragon

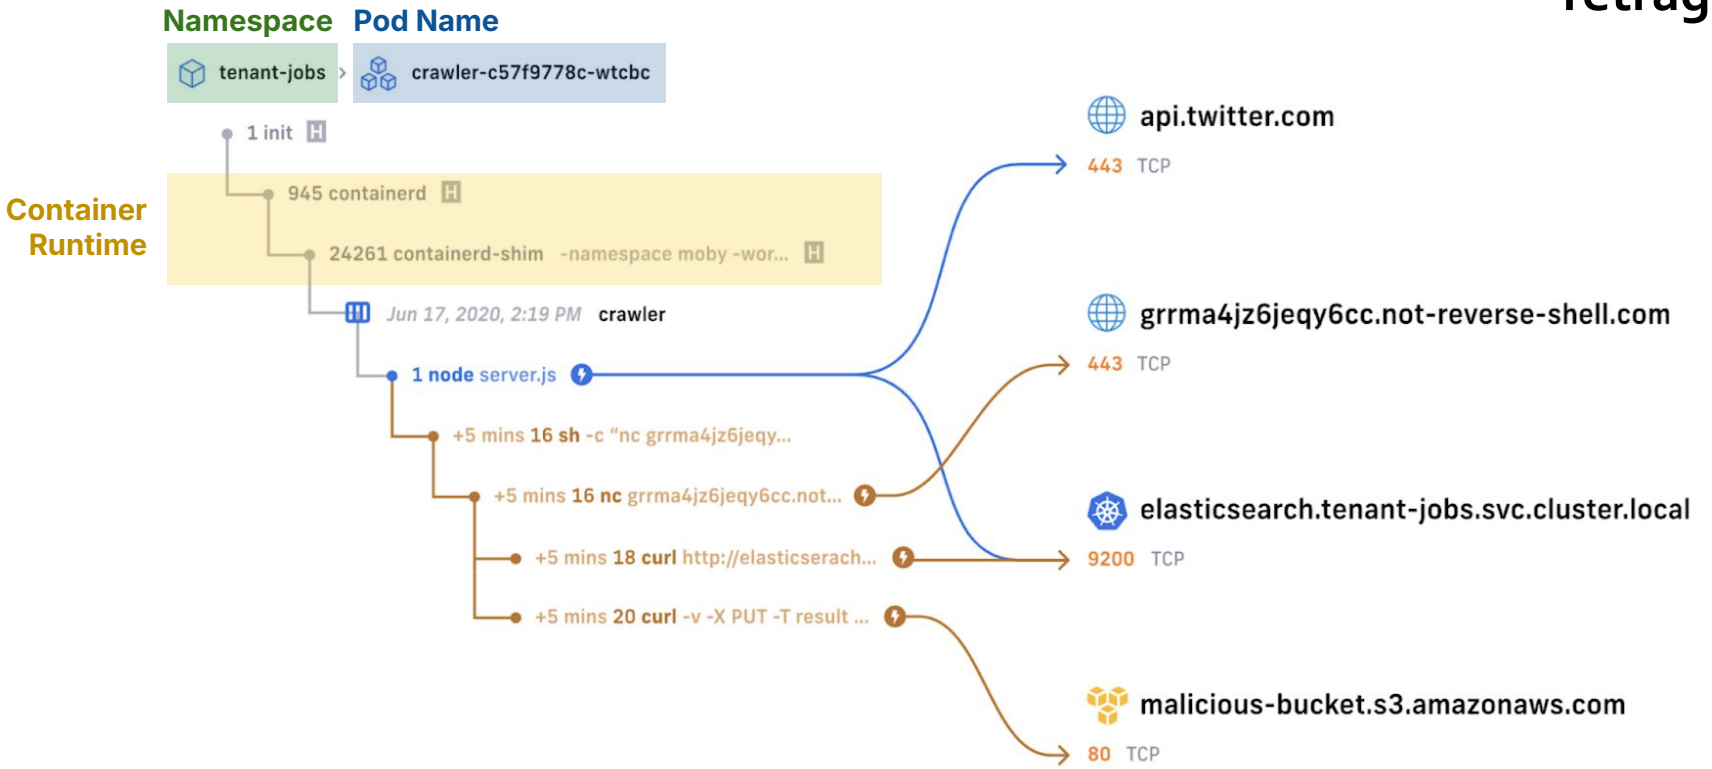

Let’s Deep Dive into a Kubernetes Pod

Tetragon

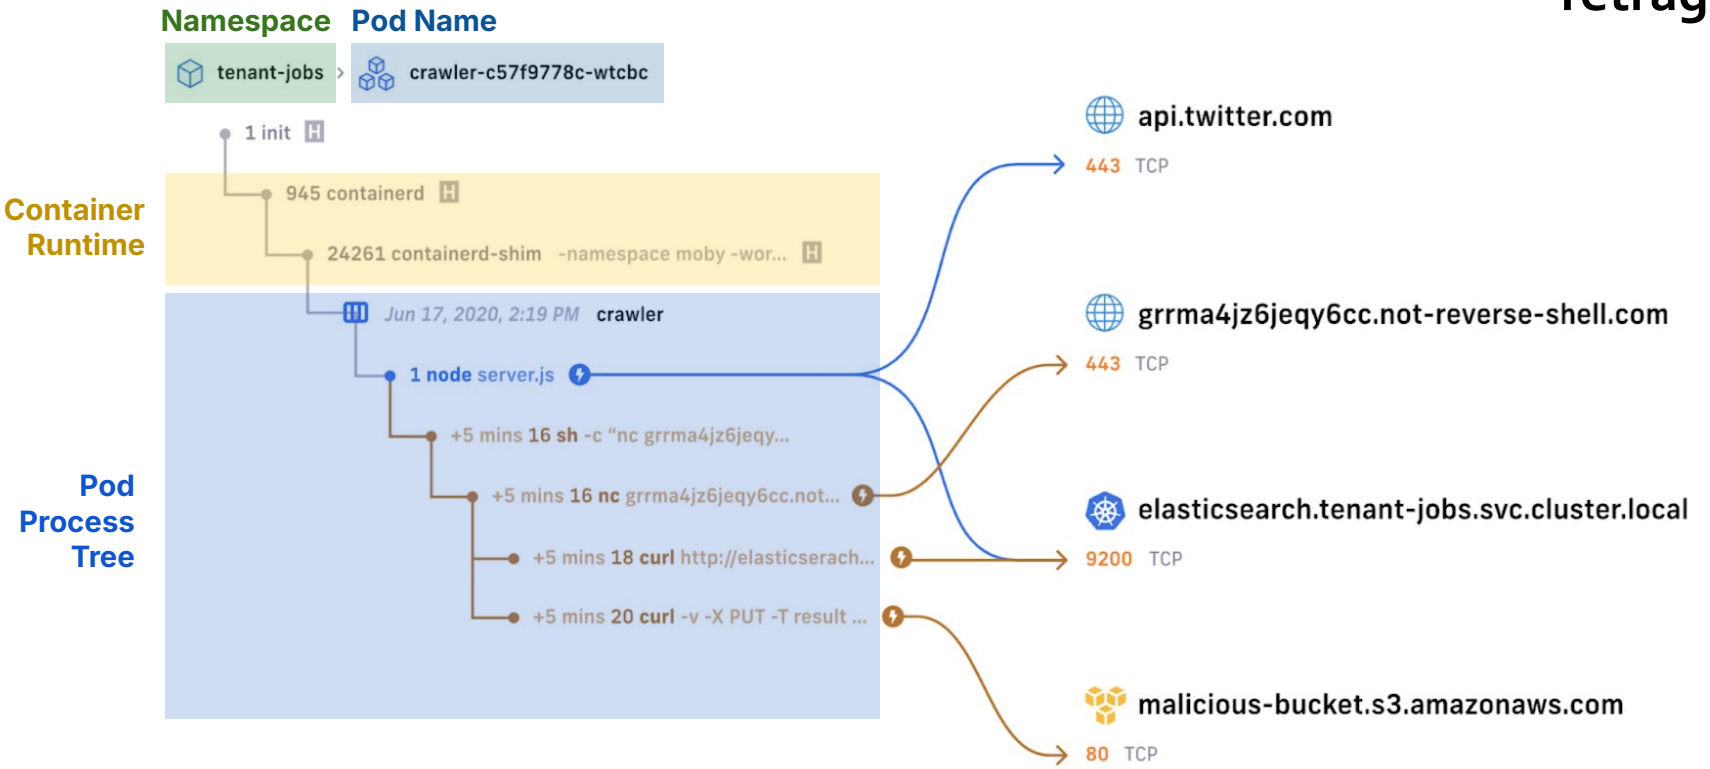

Let’s Deep Dive into a Kubernetes Pod

Tetragon

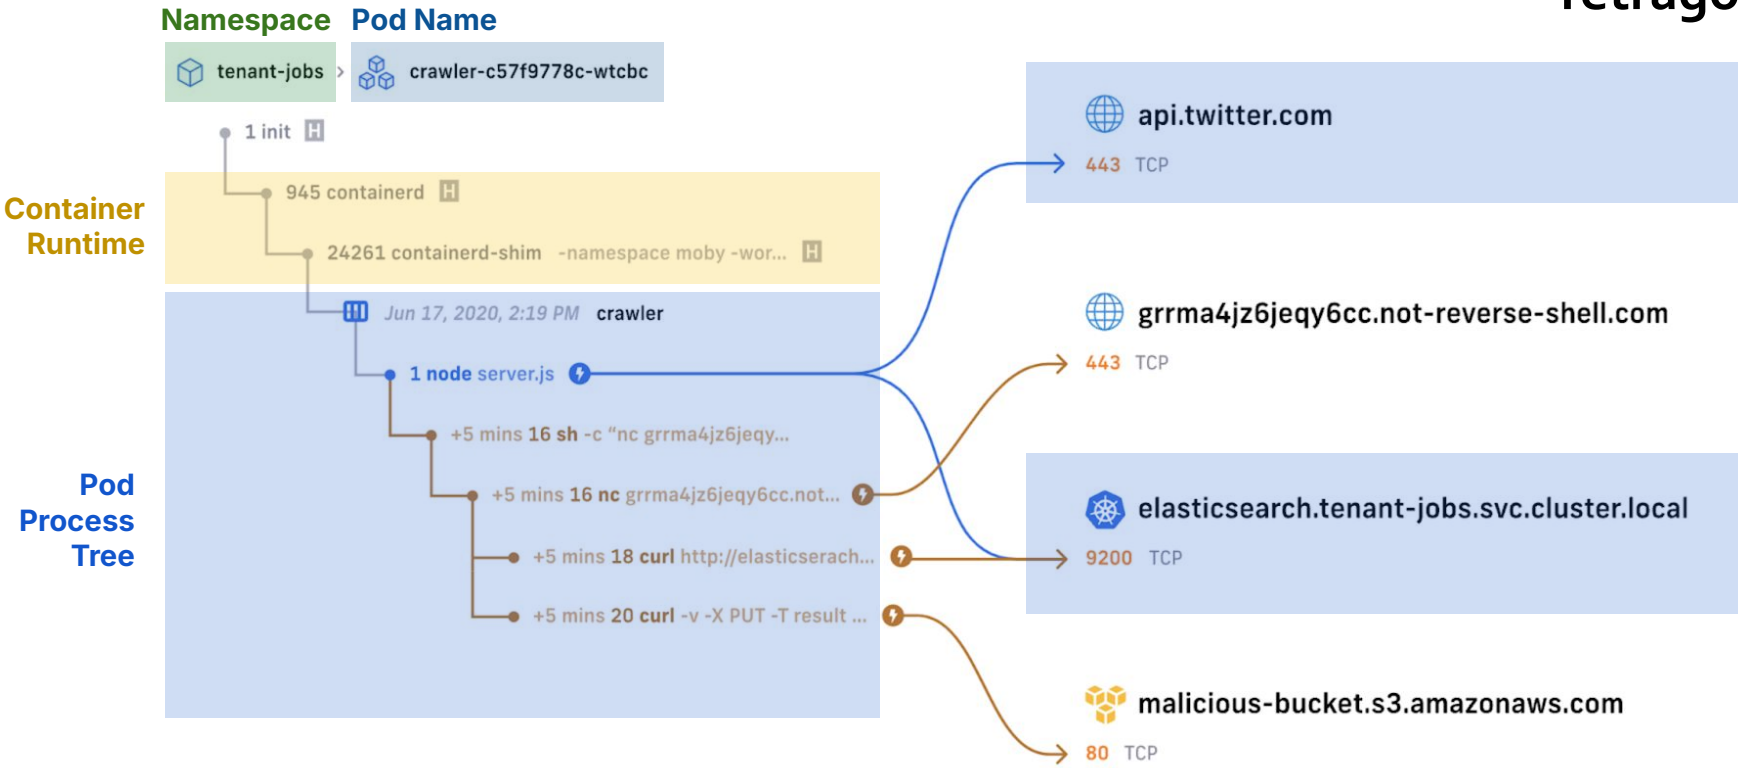

Let’s Deep Dive into a Kubernetes Pod

Tetragon

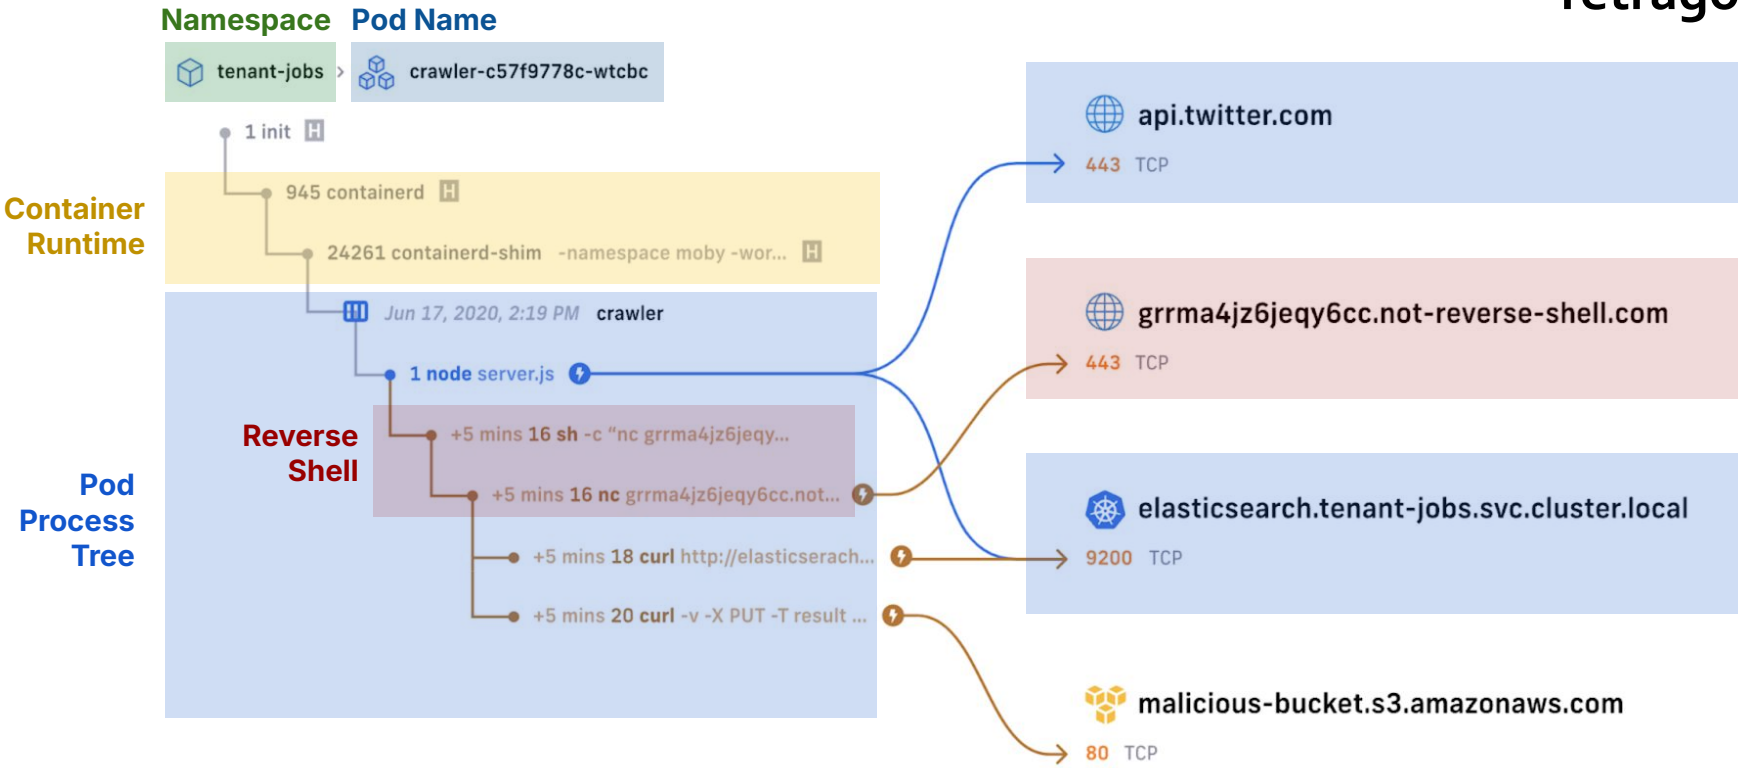

Let’s Deep Dive into a Kubernetes Pod

Tetragon

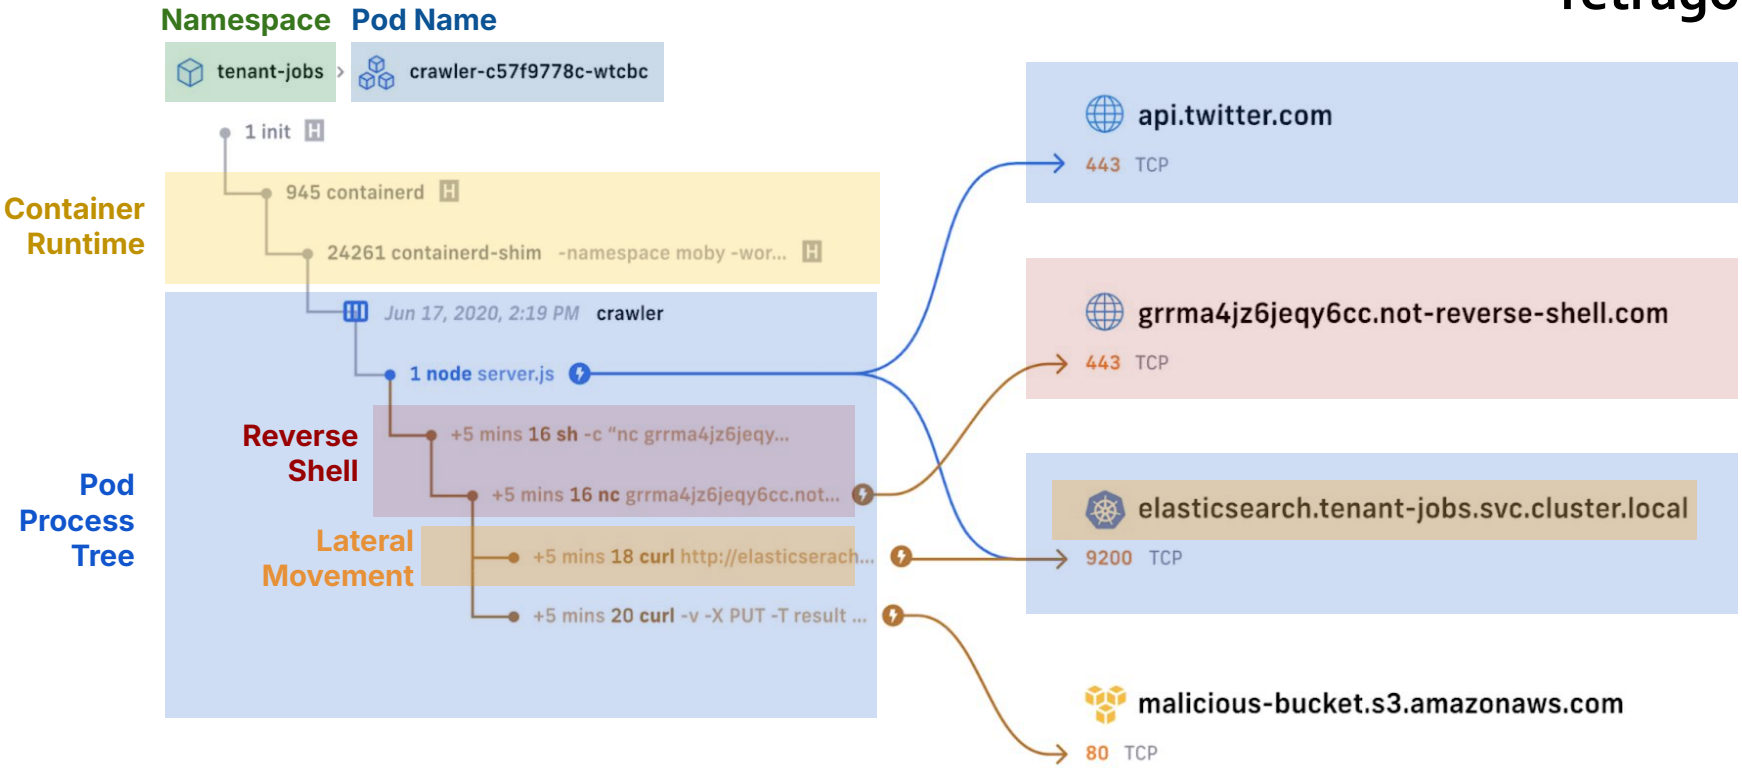

Let’s Deep Dive into a Kubernetes Pod

Tetragon

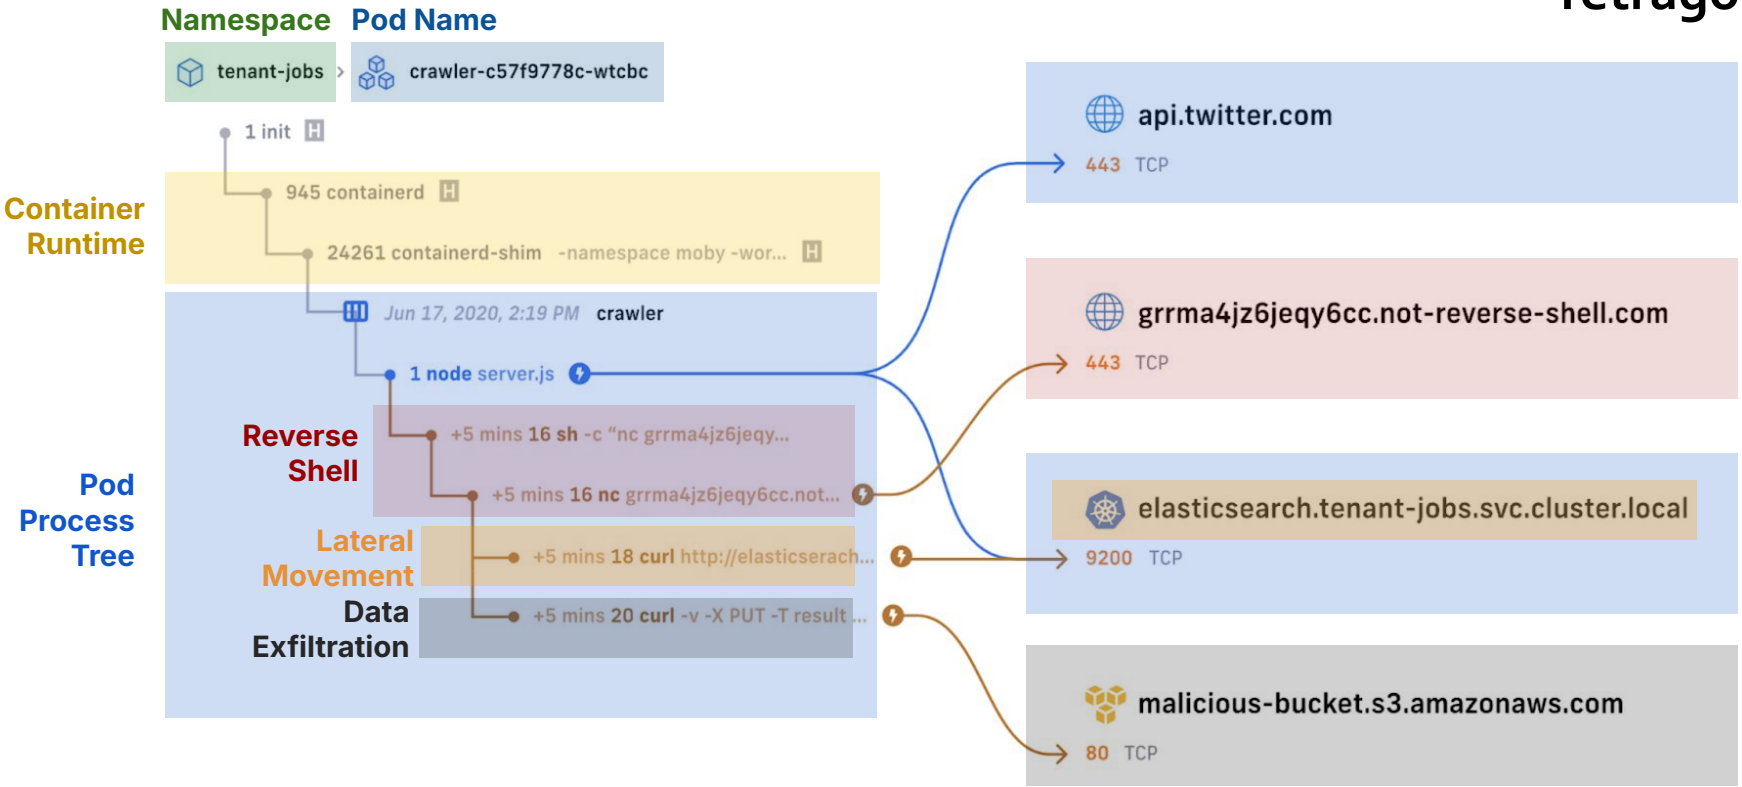

ISOVALENT

Cas d'Usages

- Monitoring, réseau et sécurité système
- Mais aussi : profiling, scheduling CPU, drivers HID, TCP congestion control, live patching de vuln., etc.
- Principales motivations :
  - Optimisations en spécialisant le kernel
  - Supporter de nouveaux standards plus rapidement
  - Patch kernel temporaire

Comprendre eBPF

- Kernel space et userspace
- Programmer le kernel : eBPF
- Comment eBPF fonctionne
- Cas d’usages
- **Misconceptions**
- Conclusion

ISOVALENT

“eBPF est dangereux”

Pas vraiment

- Code exécuté dans un contexte très privilégié, celui du kernel
- Bug dans le verifier => accès à toute la mémoire

Mais

- Par défaut, privilèges admin requis pour charger un programme _(ツ)_/

ISOVALENT

“eBPF ne peut pas crasher le kernel”

Faux

- Le programme lui-même ne peut pas crasher le kernel
- … mais comment vous l’utiliser peut
  - Ex. s’attacher à toutes les fonctions kernel

- Aussi facile de bloquer ex. tout le réseau ou tous les syscalls

- Plus difficile to crasher le kernel par erreur mais possible

ISOVALENT

“On ne peut pas tout programmer avec eBPF”

Si, mais

- eBPF est Turing-complet
  - Prouvé à bpfconf 2023

- En pratique :
  - Le verifier impose des contraintes assez fortes
  - Beaucoup de programmes sont compliqués à implémenter
    - Ex. chiffrement, parsing complet HTTP

- Ca s’améliore à chaque version Linux !
  - Ex. Travaux en cours sur offload Envoy vers eBPF

isovalent.com/blog/post/ebpf-yes-its-turing-complete/

ISOVALENT

Misconceptions

- Beaucoup à nuancer autour du verifier et des usages
  - Verifier assez spécifique à eBPF
  - Usages encore en évolution

Comprendre eBPF

- Kernel space et userspace
- Programmer le kernel : eBPF
- Comment eBPF fonctionne
- Cas d'usages
- Misconceptions
- **Conclusion**

ISOVALENT

Conclusion

- Programmes assez classiques chargés dans le kernel
- Exécutés en réaction à divers évènements
- Permet de définir de nouvelles actions du kernel
- Déjà très utilisé dans le monde Linux

ISOVALENT

Conclusion

- Slides sur pchaigno.github.io

- Ne me suivez pas sur LinkedIn, BlueSky, Mastodon à moins de vouloir du BPF, que du BPF et encore plus de BPF 😇

- On recrute !
  - Ingénieurs logiciels (Go, eBPF, NSX)
  - Community manager

ISOVALENT

Merci !

Merci à Raphaël Pinson et Vadim Shchekoldin
pour beaucoup des slides et images !

eBPF loves Cloud Native

- Contrairement aux VM, les conteneurs partagent un même kernel
- Opportunité de réinventer l’existant

ISOVALENT

“Il faut écrire les programmes eBPF en C”

Non

- Compilateur depuis Rust aussi disponible
- Probablement d’autres à venir
  - Any LLVM frontend?

konghq.com/blog/engineering/writing-an-ebpf-xdp-load-balancer-in-rust