



ISOVALENT

# Comprendre eBPF, ses applications et ses limites

Paul Chaignon | @pchaigno

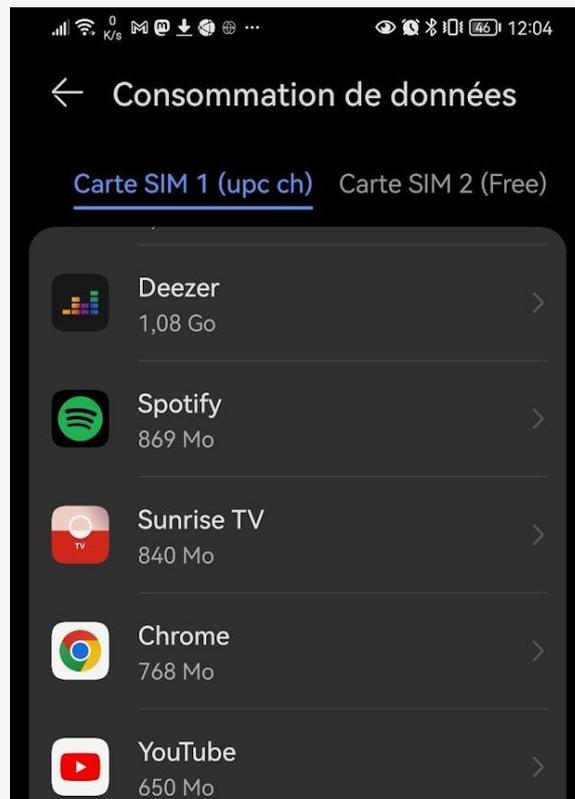
Staff Software Engineer, Isovalent



# 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



## Who Am I?



**Paul Chaignon**

Staff Software Engineer @ Isovalent

Equipe datapath sur Cilium

BPF developer since ~2016



# ISOVALENT



cilium



Tetragon

- Company behind Cilium
- Remote-first startup
- Founding member of eBPF Foundation

# Disclaimers

- Amphi maudit
- Centré sur Linux
  - eBPF existe aussi sous Windows





# Comprendre eBPF

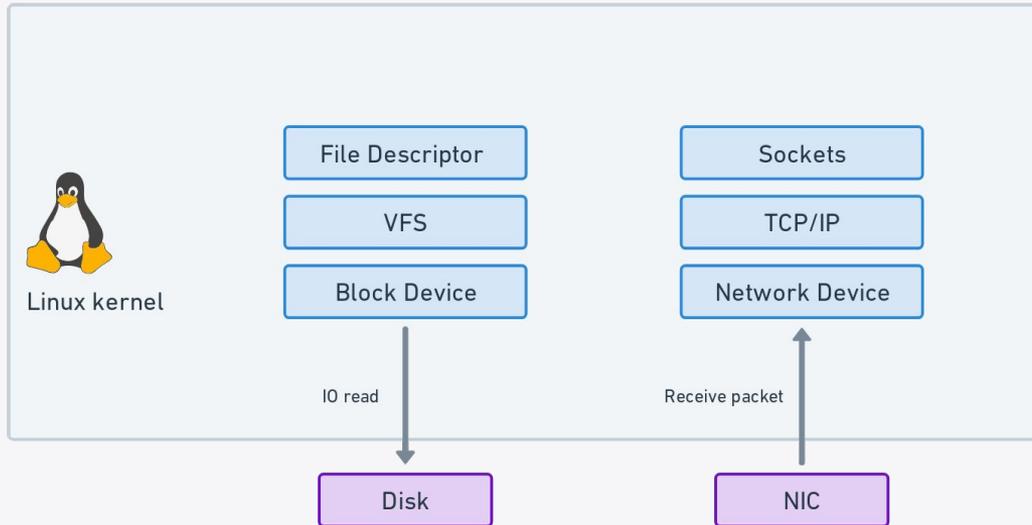
- ◆ Kernel space et userspace
- ◆ Programmer le kernel : eBPF
- ◆ Comment eBPF fonctionne
- ◆ Cas d'usages
- ◆ Misconceptions
- ◆ Conclusion



# Comprendre eBPF

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

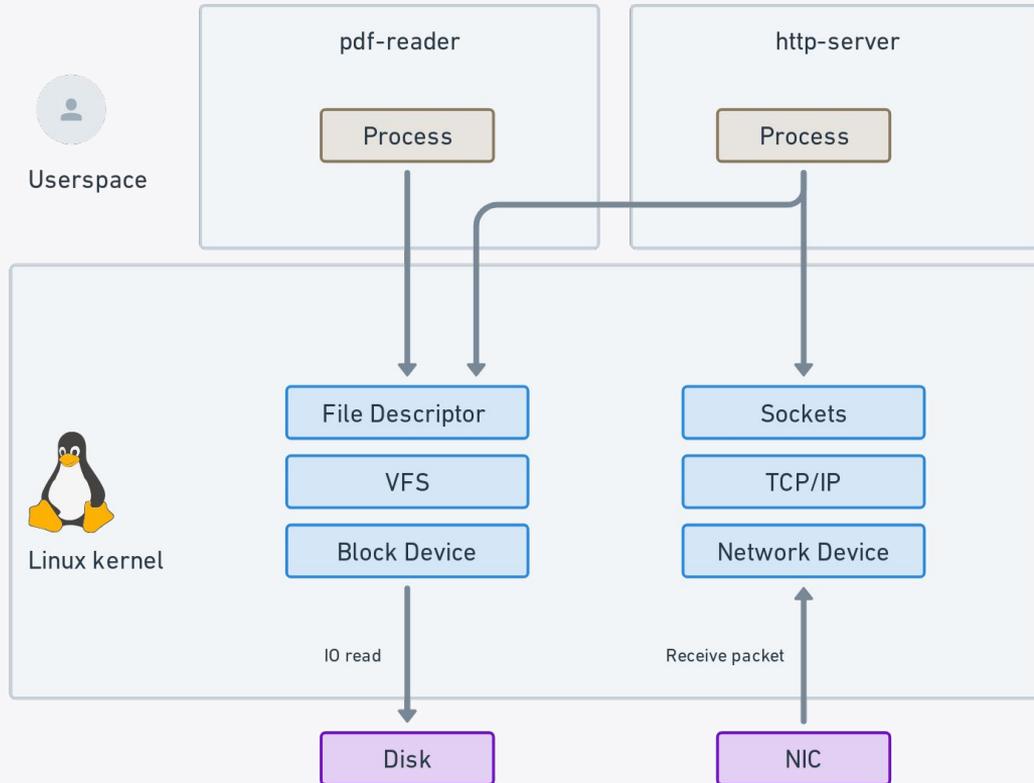
# Kernel Space



## 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

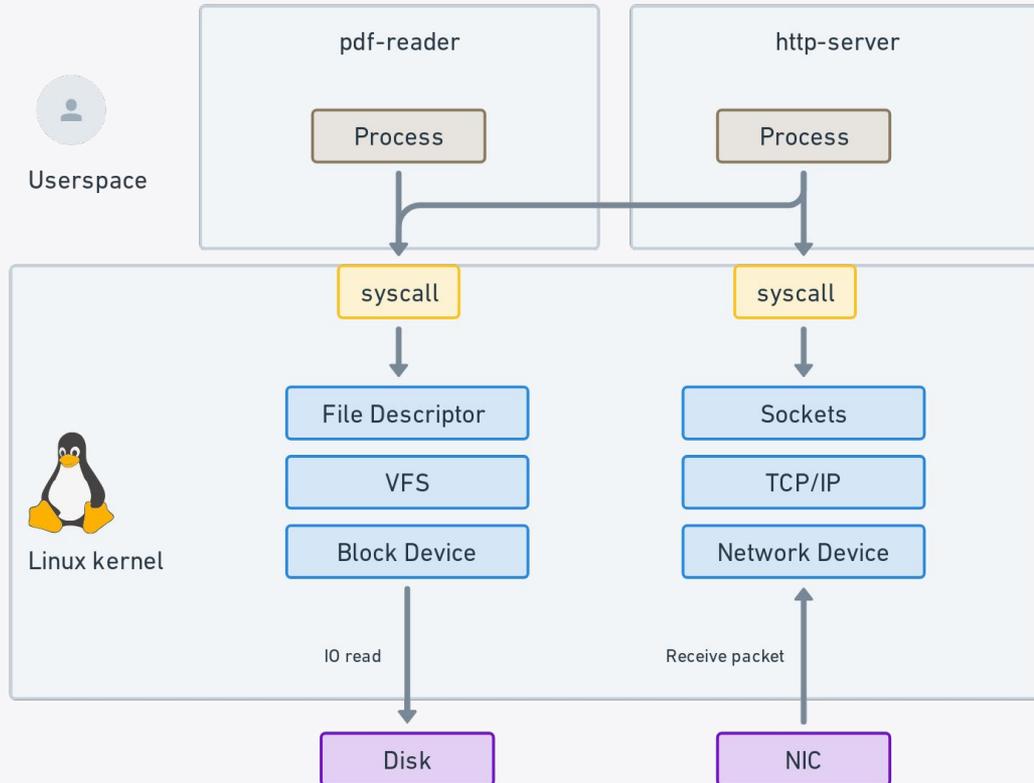
# Kernel Space et Userspace



## Userspace

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

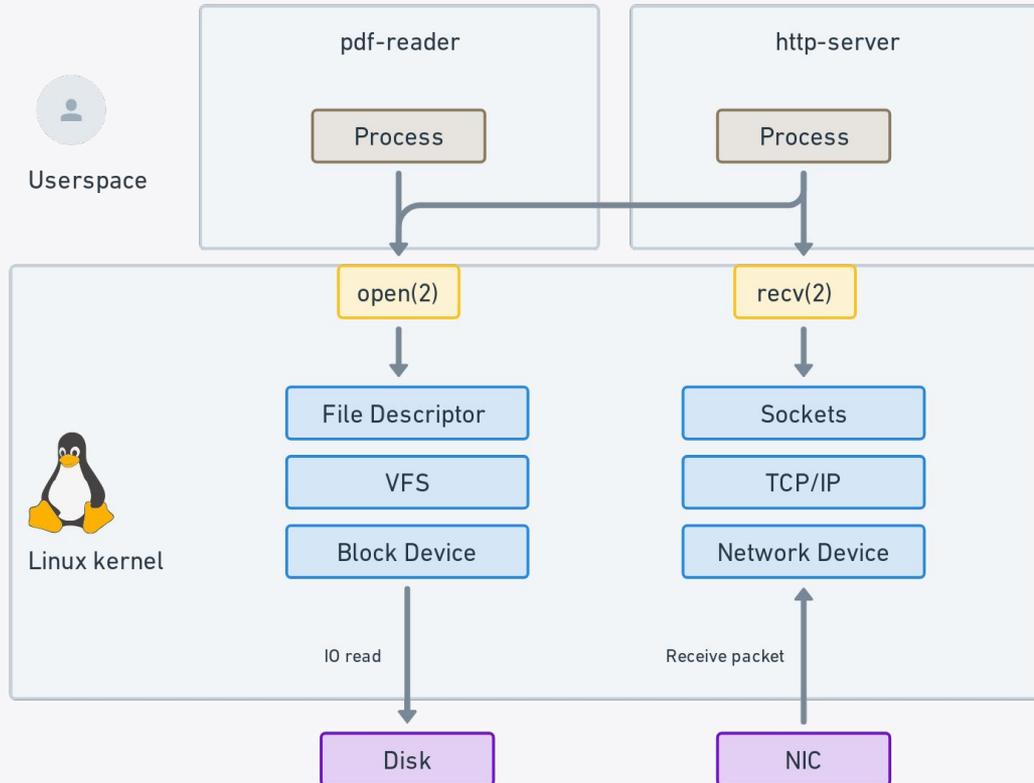
# System Calls



## Syscalls

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

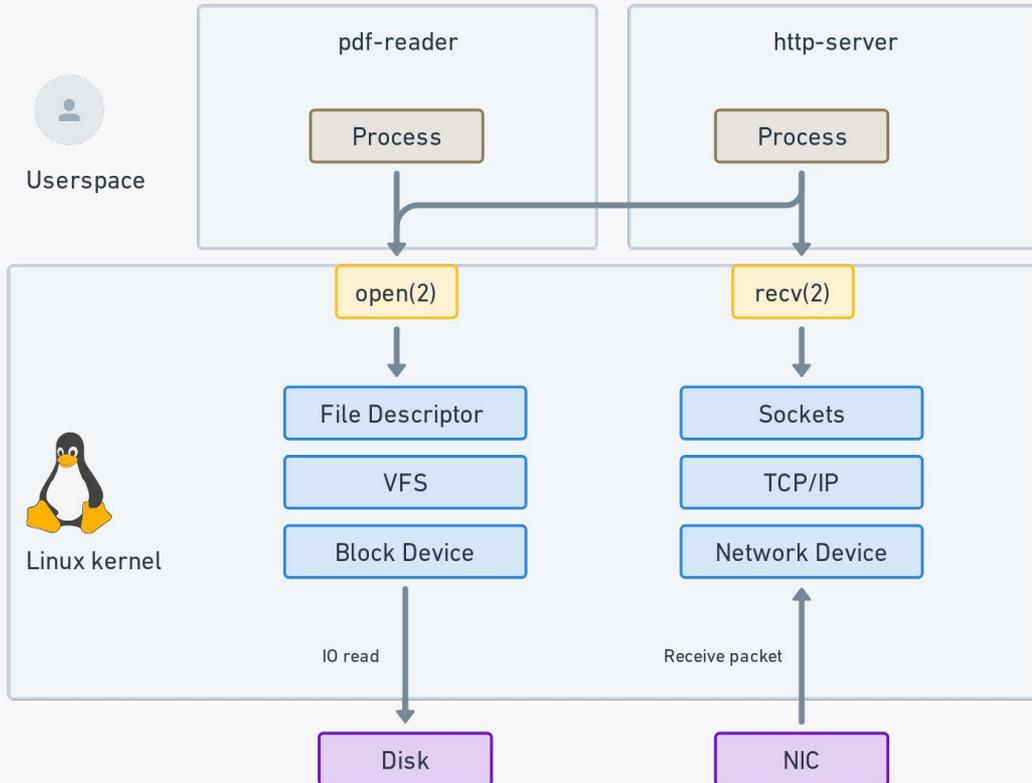
# System Calls



## 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
  - ...

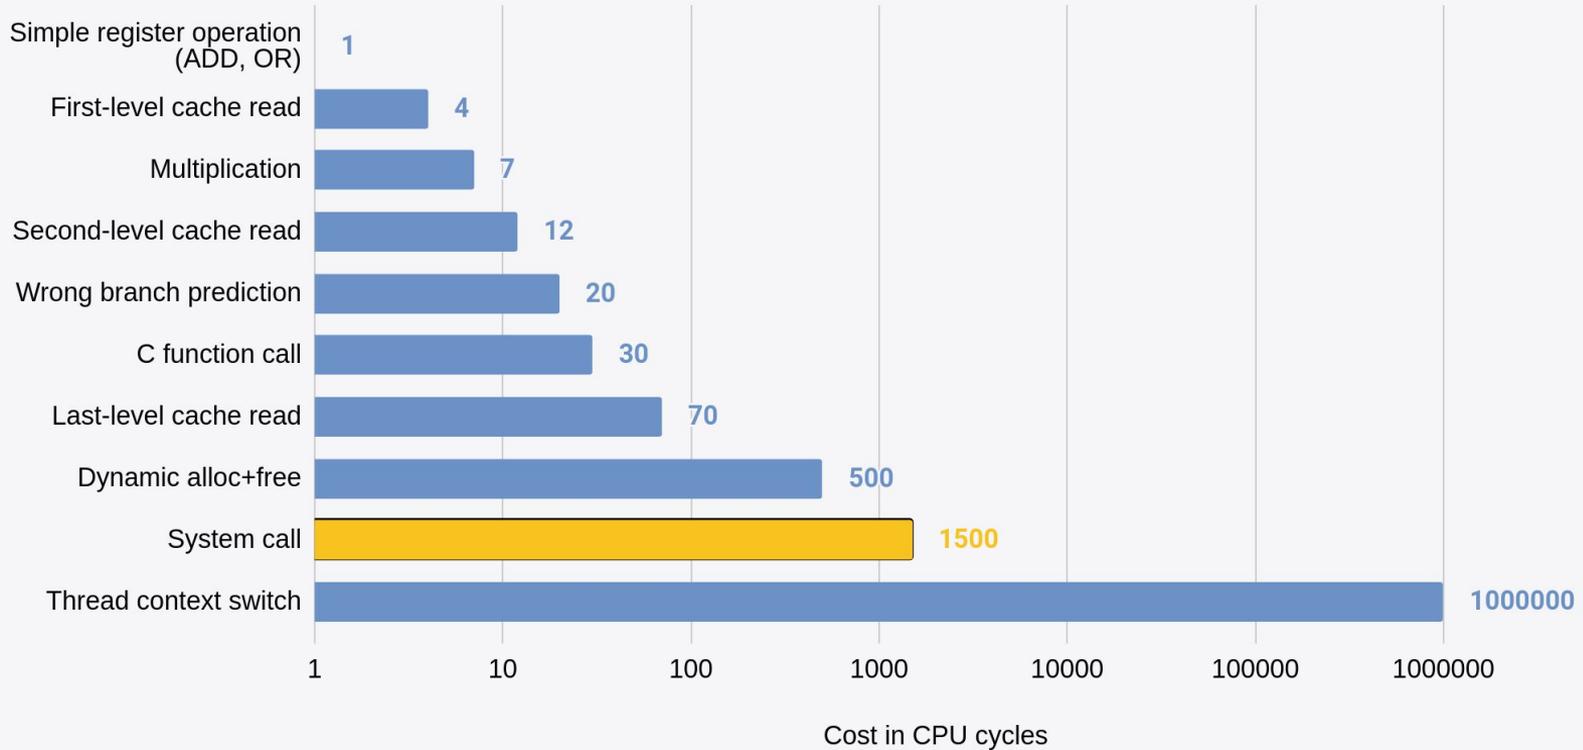
# System Calls



## 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

# Cost of System Calls



# 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
  - Collecte de données pour déboguer
  - ...
- Généralement 2 options:
  - Demander au kernel de tout recevoir pour traiter dans l'application
    - Ex. recevoir tout le trafic IP pour implémenter un nouveau protocole
    - Très coûteux
  - Implémenter dans le kernel...



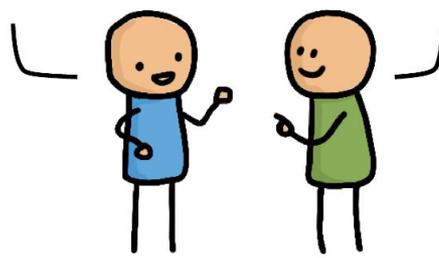
Application Developer:

I want this new feature to observe my app



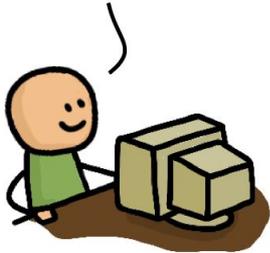
Hey kernel developer! Please add this new feature to the Linux kernel

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.



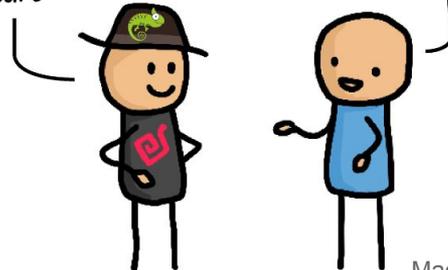
But I need this in my Linux distro



5 year later...

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

OK but my requirements have changed since...



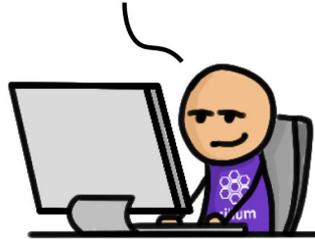
Application Developer:

i want this new feature  
to observe my app



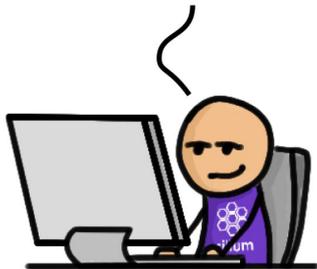
eBPF Developer:

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.

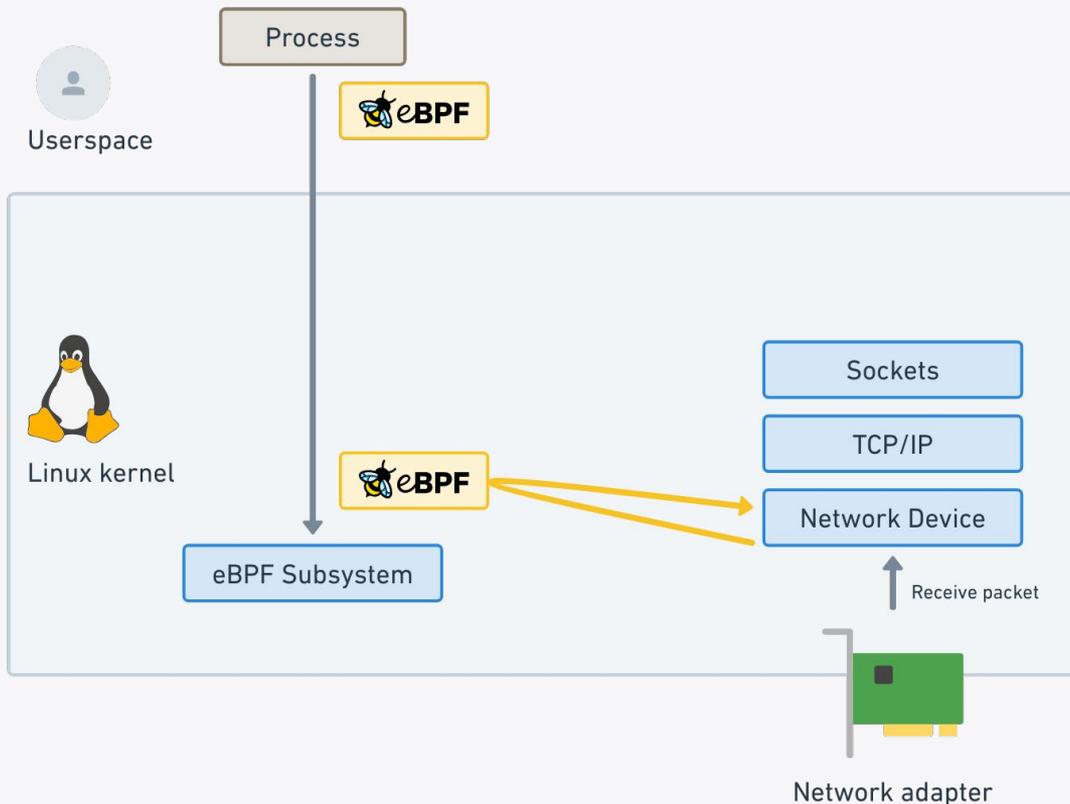




# Comprendre eBPF

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

# Programmer le kernel



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

# 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;
}
```



```
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
```

# 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;

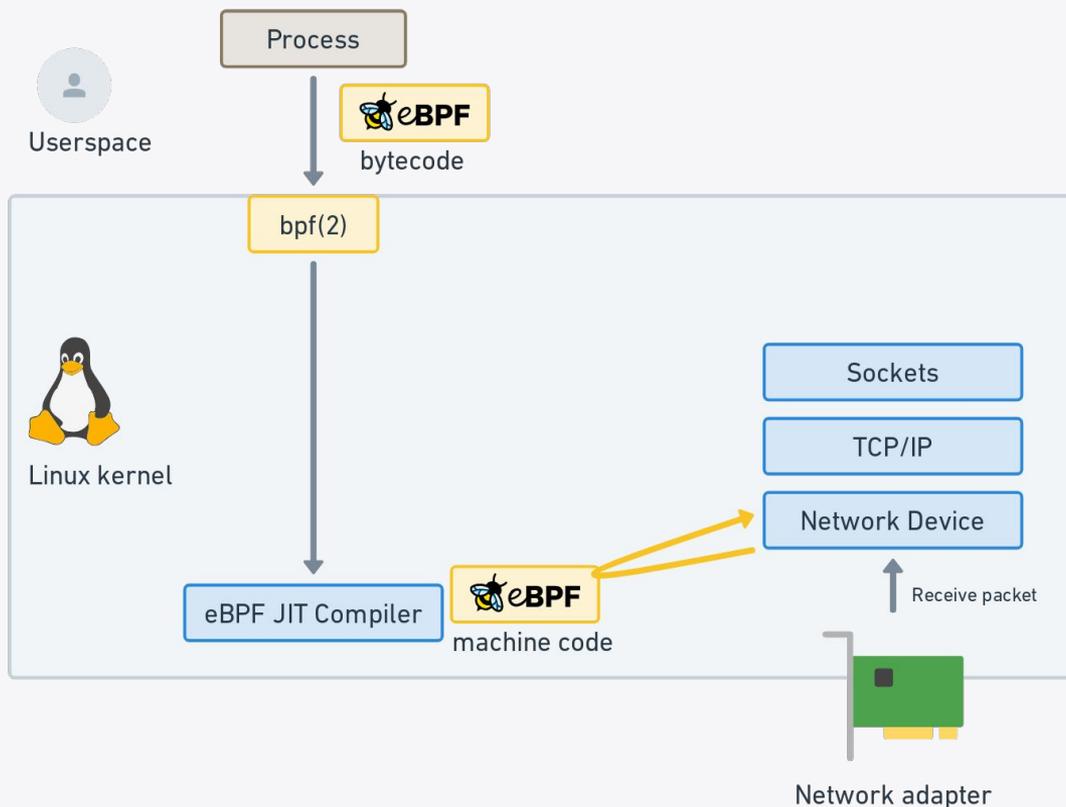
    bpf_perf_event_output(ctx, &my_map, flags,
        &metadata, sizeof(metadata));

    return XDP_PASS;
}
```

## Context :

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

# Programmer le kernel

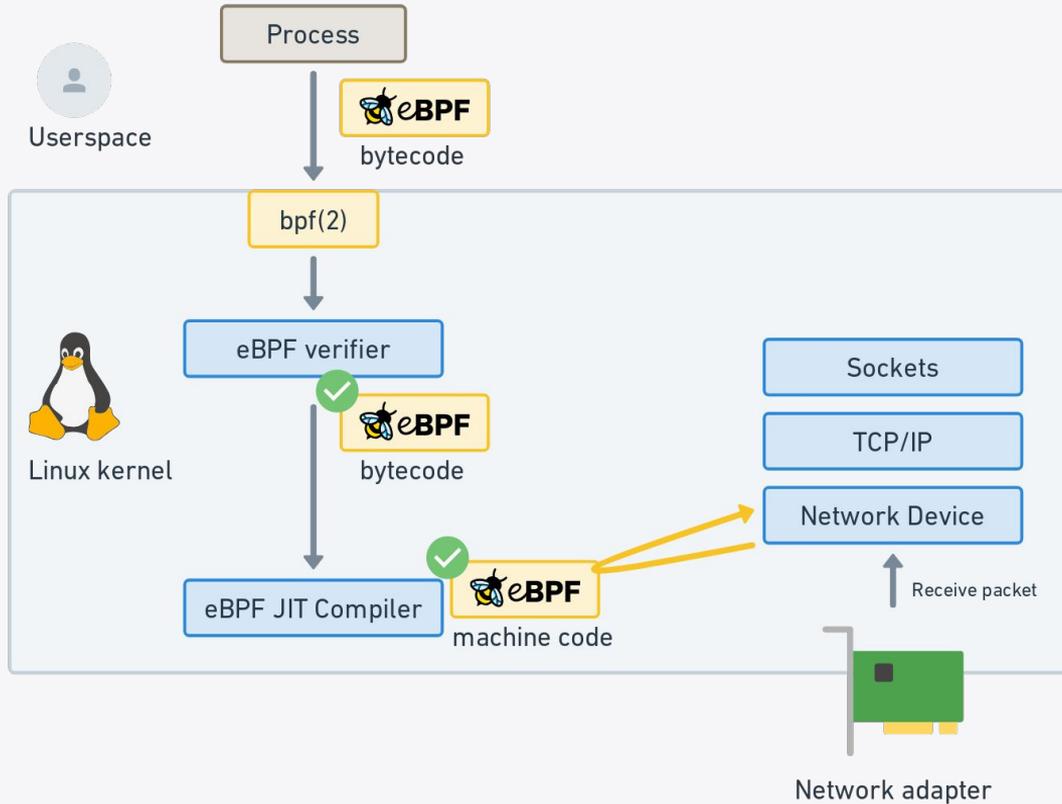


- Chargement via un syscall
  - Même syscall pour beaucoup d'opérations eBPF
- Programme JIT-compilé de bytecode à machine code classique
  - Meilleures perfs qu'un interpréteur

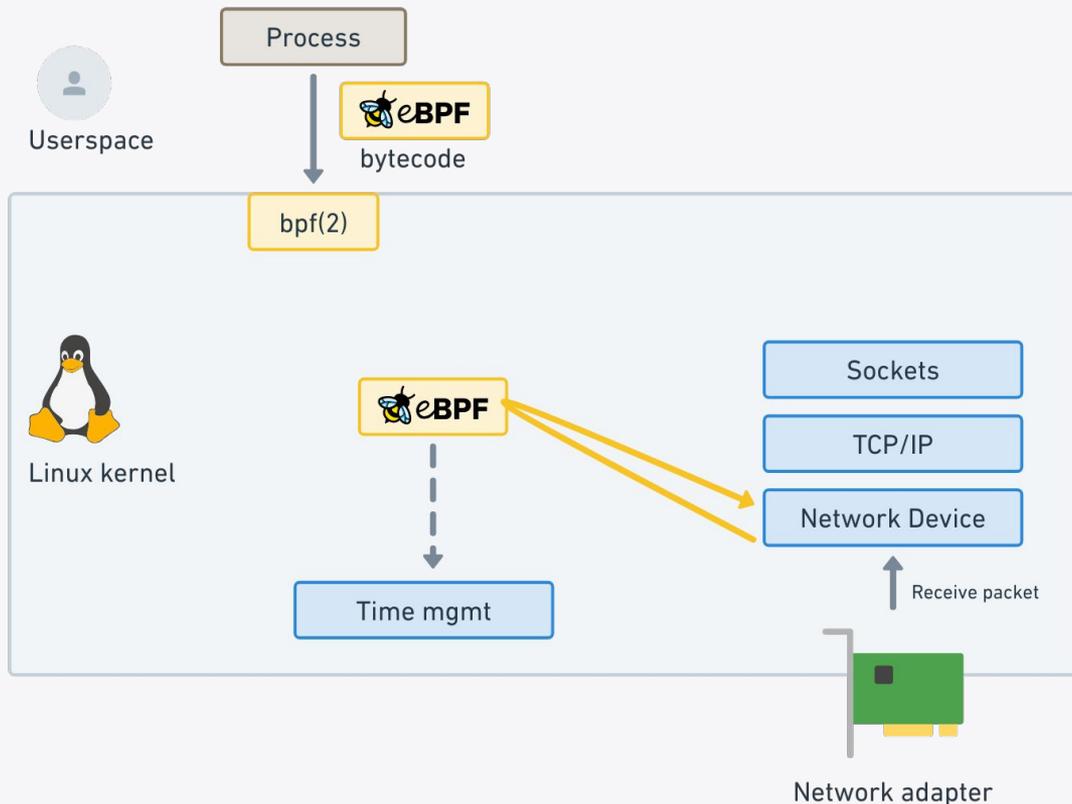
# Le Verifier eBPF

- “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

# Le Verifier eBPF



# 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.

# 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;

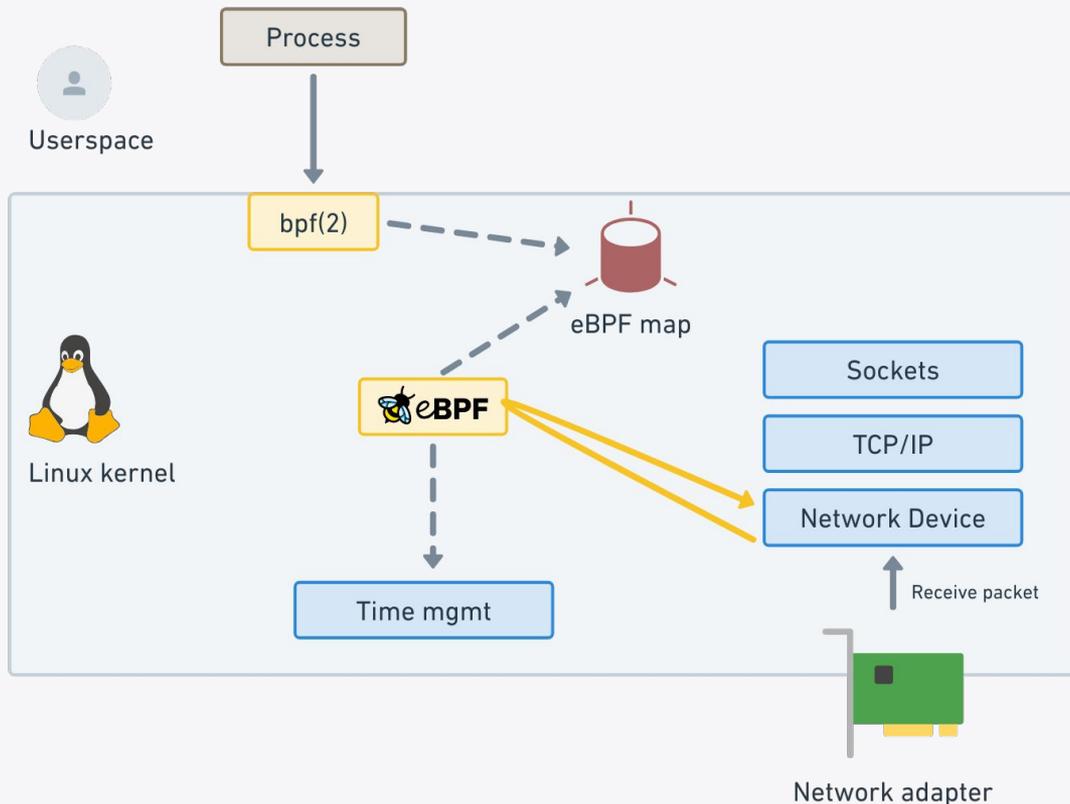
    if (data < data_end)
        return XDP_DROP;

    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;
}
```

# 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

# “eBPF est un acronyme”

Oui, mais

“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...

# 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

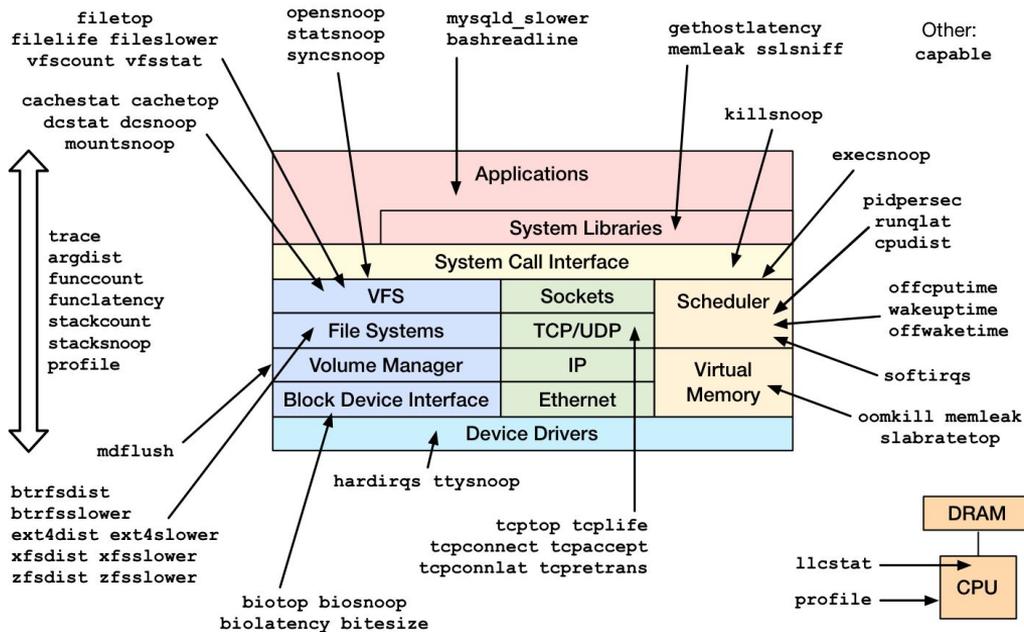
- ◆ Kernel space et userspace
- ◆ Programmer le kernel : eBPF
- ◆ Comment eBPF fonctionne
- ◆ **Cas d'usages**
- ◆ Misconceptions
- ◆ Conclusion

# eBPF pour le Monitoring

- Cas d'application le plus connu
  - En grande part grâce à Brendan Gregg, un expert en analyse de performance
- Principalement:
  - Outils d'observation du système
  - Outils de profiling axé analyse de performance

# Application and system profiling

Linux bcc/BPF Tracing Tools



<https://github.com/iovisor/bcc#tools> 2016

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



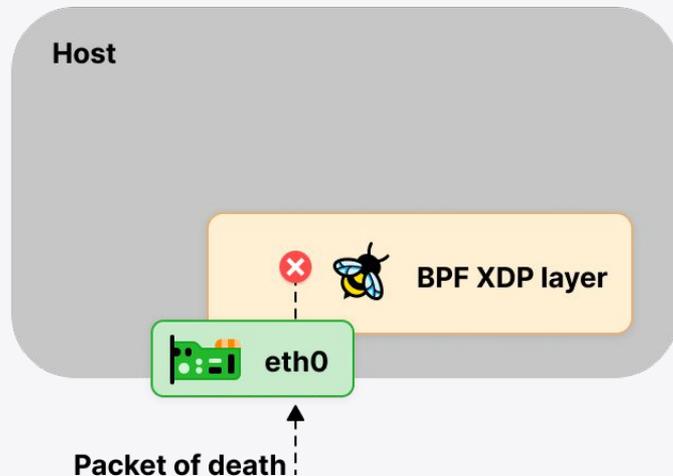
# eBPF pour le Réseau

- Motivation initiale pour eBPF
- Cas d'usage assez variés :
  - Load balancing
  - Sécurité
  - Réseaux de conteneurs
  - Nouveaux protocoles
  - ...

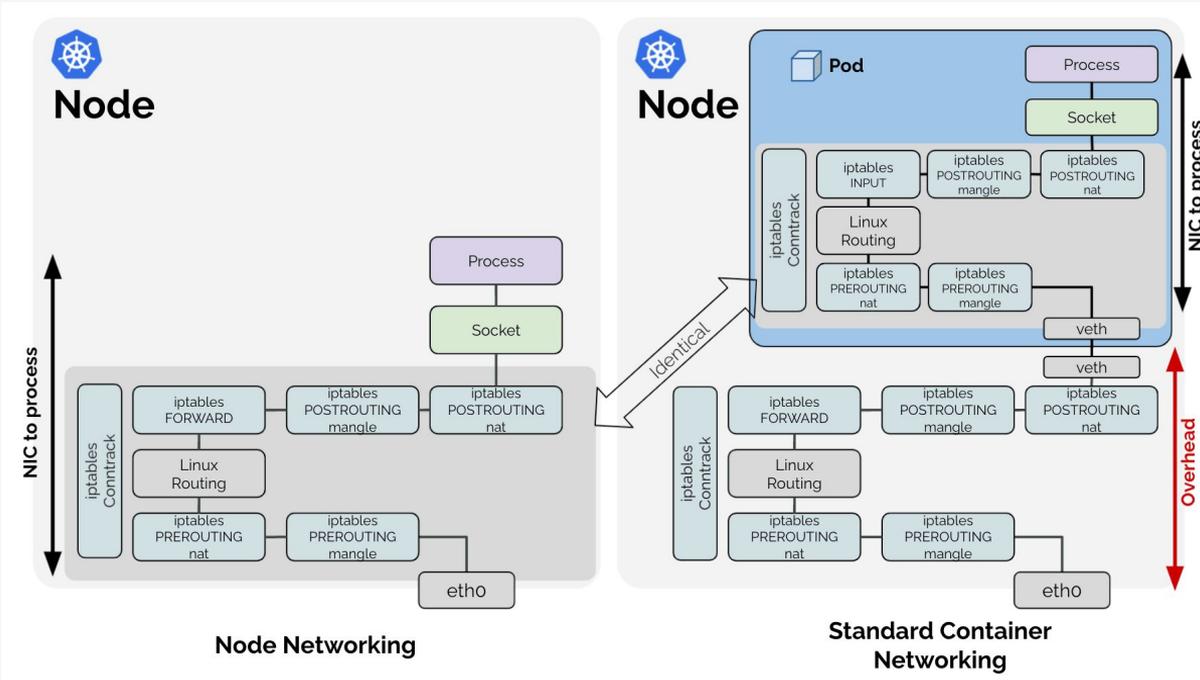


# Denial of Service Mitigation

- Application réseau phare d'eBPF
- Minimiser le temps CPU perdu pour les paquets malveillants
- Analyser et dropper les paquets au plus tôt
- Code eBPF exécuté dans le driver, juste après la copie en mémoire
- Utilisé par Cloudflare & Facebook

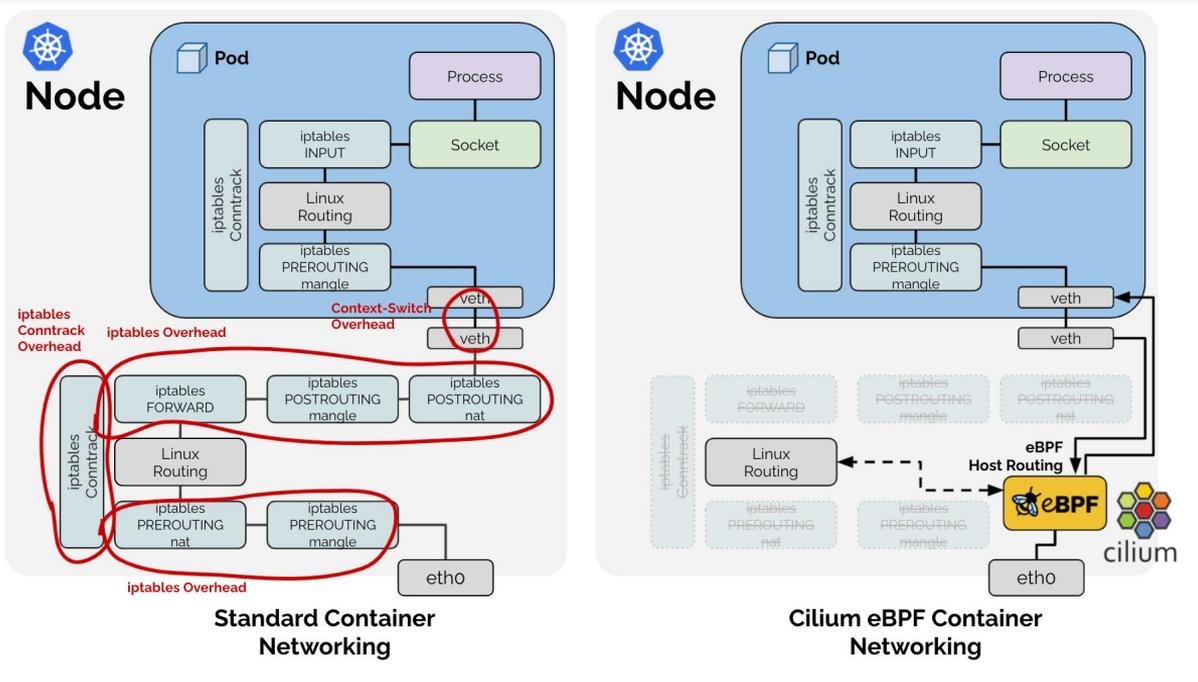


# Container Networking



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

# 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

# “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
  - ...



# Cas d'Usages

- Réseau & monitoring
- Mais aussi : sécurité, scheduling CPU, drivers HID, TCP congestion control, live patching de vuln., etc.
- Principales motivations :
  - Agrégation dans le kernel
  - Algorithme customisé
  - Patch kernel temporaire
  - Bypass des traitements inutiles



# Comprendre eBPF

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

# “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)_/`
- `cat /proc/sys/kernel/unprivileged_bpf_disabled`
  - 1 ou 2 => privilèges requis



# “eBPF ne peut pas crasher le kernel”

- 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

Non



# “On ne peut pas tout programmer avec eBPF”

- eBPF est Turing-complet
  - Prouvé à bpfconf 2023
- En pratique :
  - Le verifier impose des contraintes assez fortes
  - Beaucoup d’algorithmes avancés sont compliqués à implémenter
    - Ex. chiffrement, parcours de graphes
- Ca s’améliore à chaque version Linux !

Si, mais



# “Ça ne s’applique qu’aux GAFA”

Non

- Beaucoup d’utilisateurs via des projets eBPF
  - Falco, Cilium, Tracee, bcc, etc.
- En France :
  - URSSAF
  - Radio France
  - Wifirst
  - Datadog
  - OVH?
  - ...



# 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

# 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

ISOVALENT

# Merci !

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





# “Il faut écrire les programmes eBPF en C”

Non

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

