Fonctionnement d’un LB as a service

EXOSCALE

Un Cloud Provider Européen

1.	FRANKFURT	DE-FRA-1
2.	MUNICH	DE-MUC-1
3.	VIENNA	AT-VIE-1
4.	GENEVA	CH-GVA-2
5.	ZURICH	CH-DK-2
6.	SOFIA	BG-SOF-1

Mathieu Corbin, Ingénieur **@Exoscale**

Développeur

- Clojure
- Golang
- Emacs
- ...

Sysadmin

- Automatisation
- CI/CD
- Monitoring
- Systèmes distribués
- ...

@_mcorbin

mcorbin.fr

Le besoin

Un Load Balancer as a service

Le besoin

- Layer 4
  - TCP/UDP
- Préserver l’IP source
- S’intègre avec nos instance pools (groupes de machines)
  - Scale up/down => mise à jour du load balancer
- Tolérance aux pannes
- Bonnes performances

Le produit

- Un load balancer, une IP, plusieurs services

- Chaque service cible un groupe de machine et peut être paramétré de façon indépendante

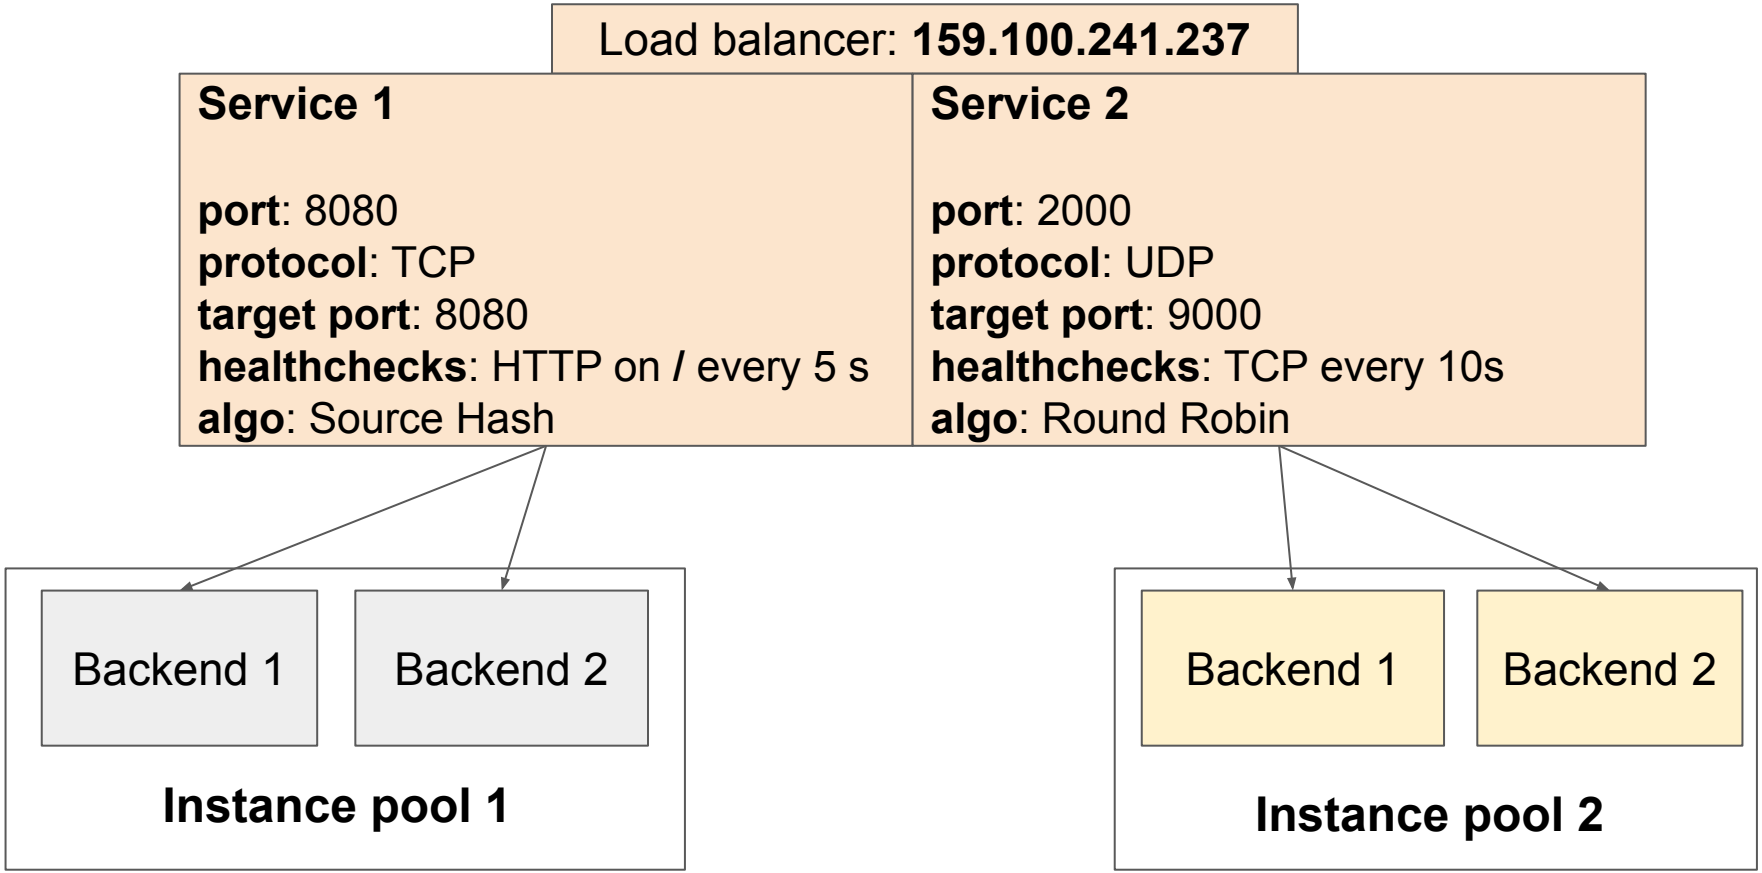
Load balancer: **159.100.241.237**
Service 1
port: 8080
protocol: TCP
target port: 8080
healthchecks: HTTP on **/** every 5 s
algo: Source Hash
Service 2
port: 2000
protocol: UDP
target port: 9000
healthchecks: TCP every 10s
algo: Round Robin
Backend 1
Backend 2
Instance pool 1
Backend 1
Backend 2
Instance pool 2

Fonctionnement réseau

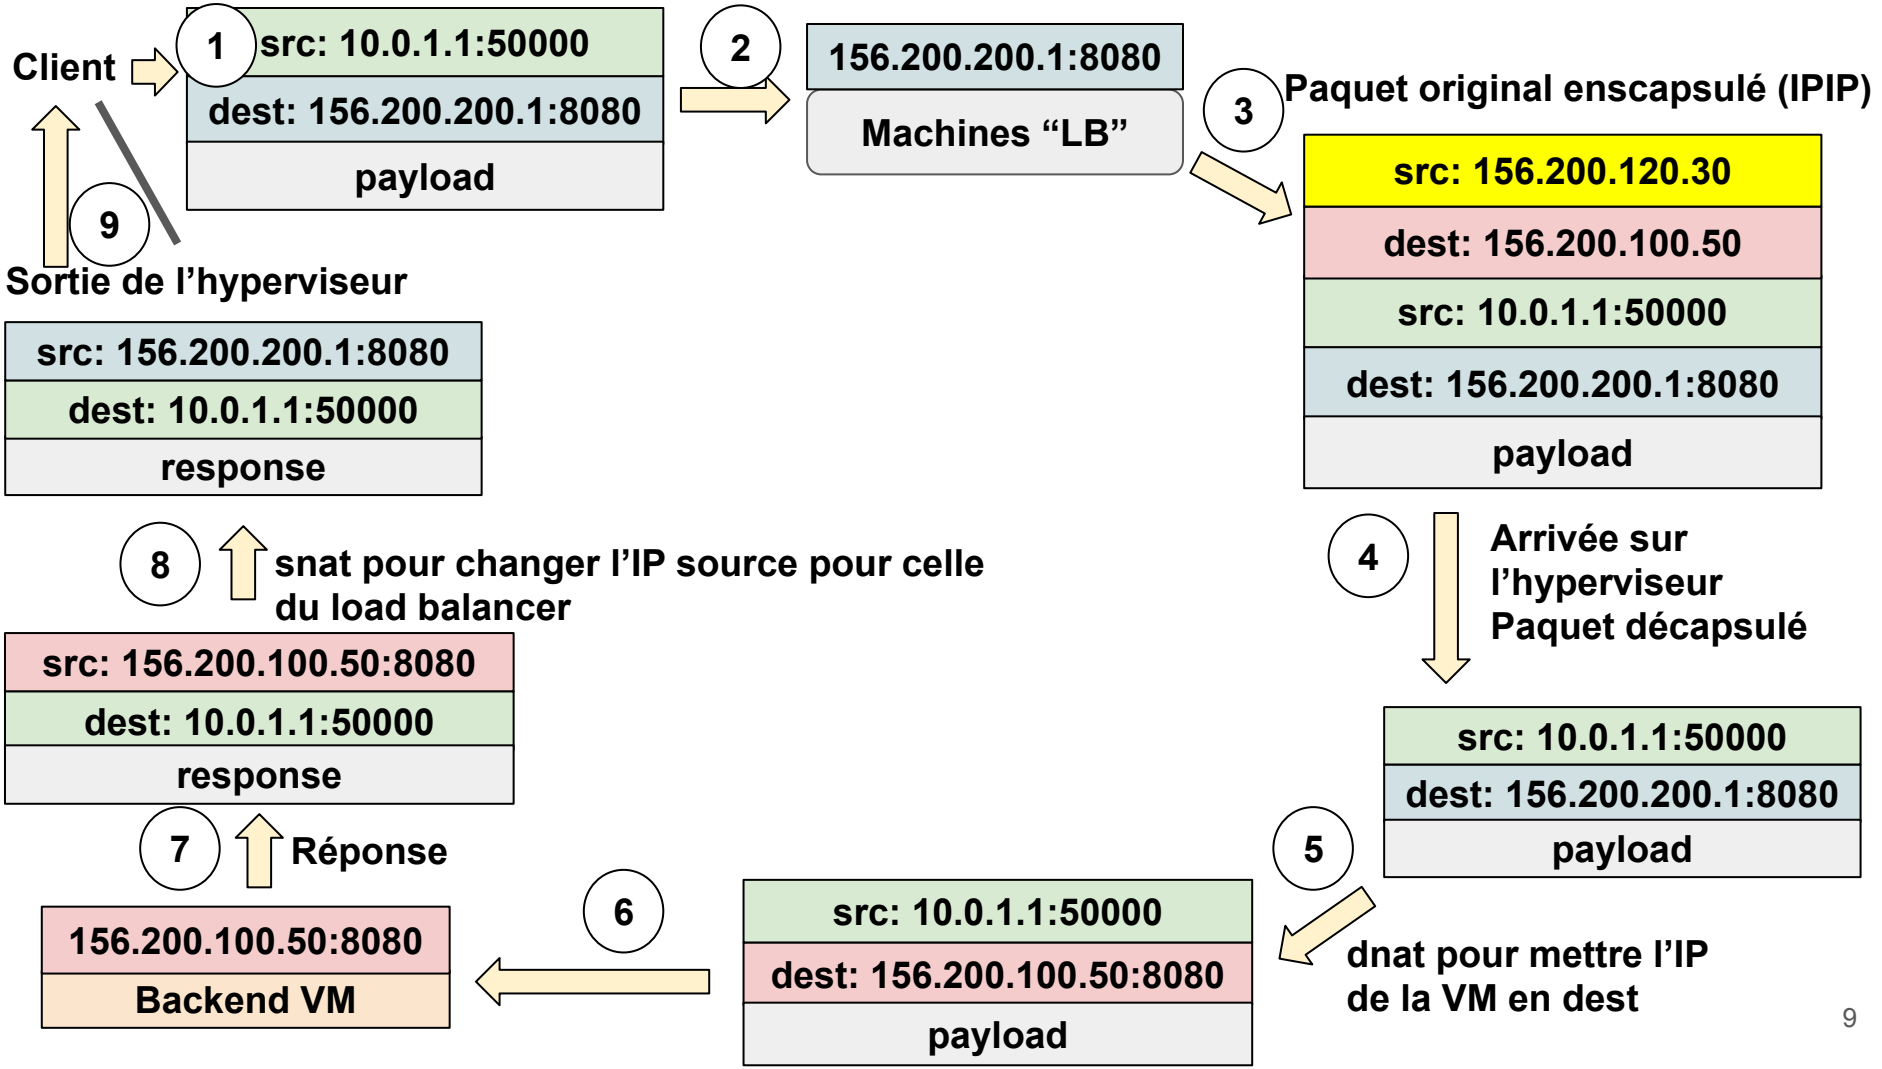
Client
1
src: 10.0.1.1:50000
dest: 156.200.200.1:8080
payload
2
156.200.200.1:8080
Machines “LB”
3
Paquet original enscapsulé (IPIP)
src: 156.200.120.30
dest: 156.200.100.50
src: 10.0.1.1:50000
dest: 156.200.200.1:8080
payload
4
Arrivée sur l’hyperviseur
Paquet décapsulé
src: 10.0.1.1:50000
dest: 156.200.200.1:8080
payload
5
dnat pour mettre l’IP de la VM en dest
src: 10.0.1.1:50000
dest: 156.200.100.50:8080
payload
6
156.200.100.50:8080
Backend VM
7
Réponse
src: 156.200.100.50:8080
dest: 10.0.1.1:50000
response
8
snat pour changer l’IP source pour celle du load balancer
src: 156.200.200.1:8080
dest: 10.0.1.1:50000
response
9
Sortie de l’hyperviseur

En détail...

Première étape: les machines LB

Machines LB: IPVS

- IPVS est utilisé pour le load balancing
  - Intégré au kernel Linux
  - Très bonnes performances
  - Flexible, de nombreuses options (dont IPIP)
  - Simple d’utilisation
  - Configuré dans un namespace réseau dédié

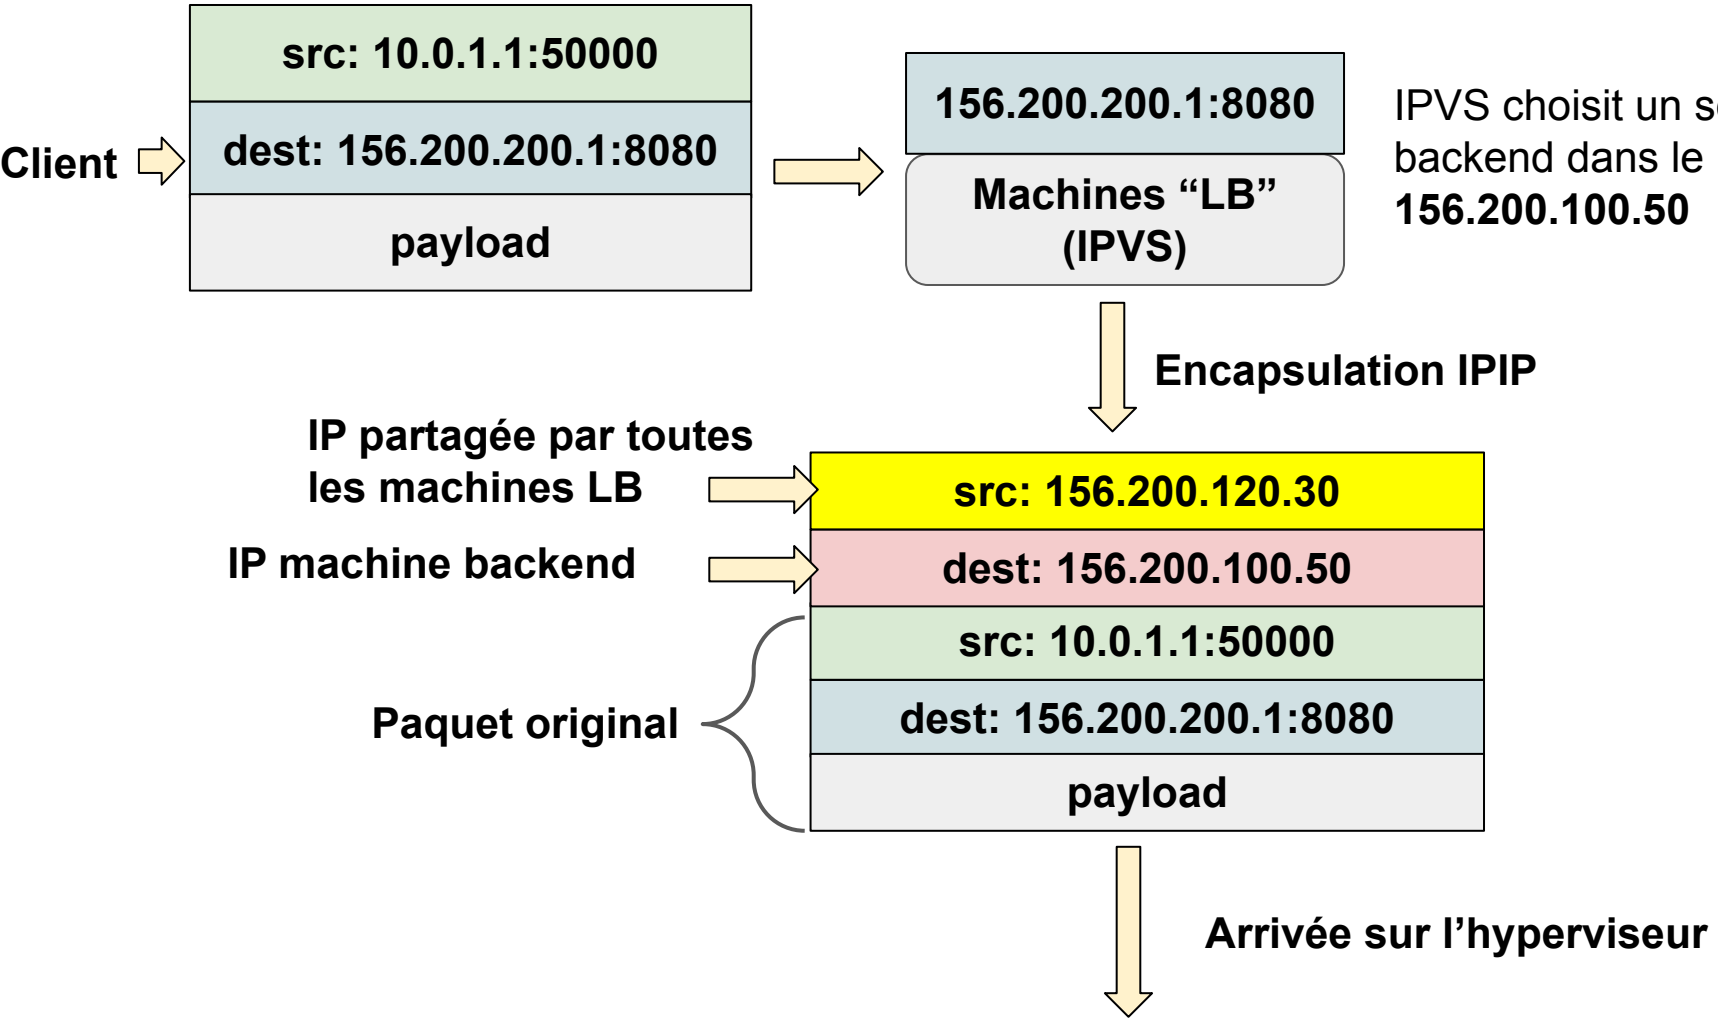
src: 10.0.1.1:50000
dest: 156.200.200.1:8080
payload
Client
156.200.200.1:8080
Machines “LB” (IPVS)
IPVS choisit un serveur backend dans le pool, ici 156.200.100.50
Encapsulation IPIP
IP partagée par toutes les machines LB
IP machine backend
src: 156.200.120.30
dest: 156.200.100.50
src: 10.0.1.1:50000
dest: 156.200.200.1:8080
payload
Paquet original
Arrivée sur l’hyperviseur

L’hyperviseur

- La machine virtuelle cible tourne dessus

- Un module kernel écrit en interne est activé
  - Utilisation de netfilter
  - Deux règles iptables à ajouter pour chaque machine virtuelle dans un service de load balancer

Hyperviseur: décapsulation

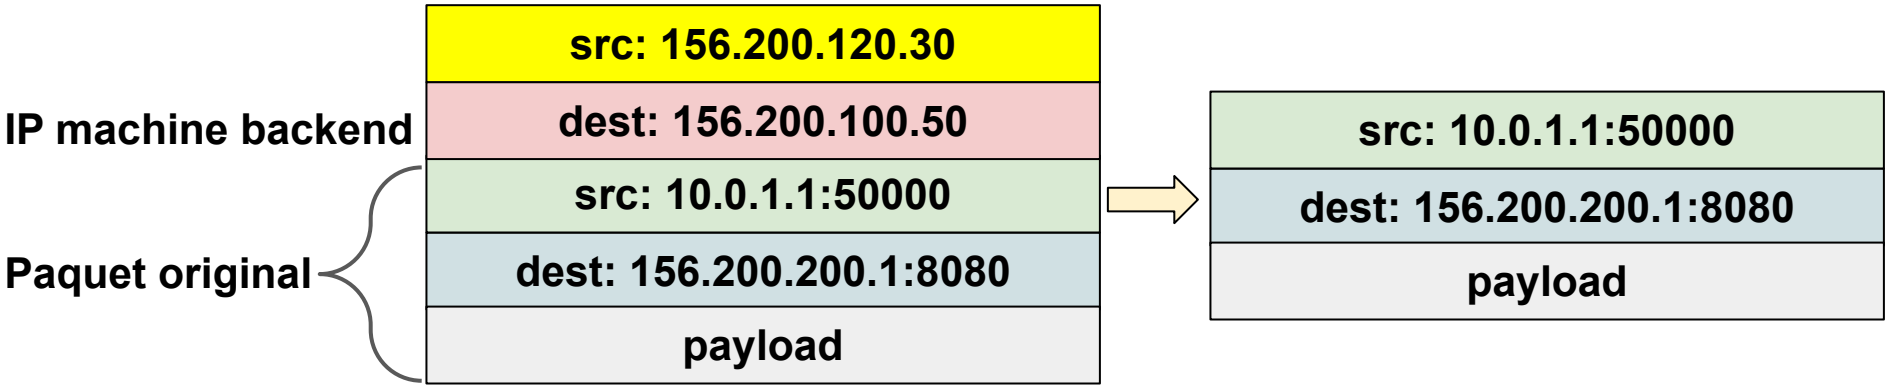

Hyperviseur: nat

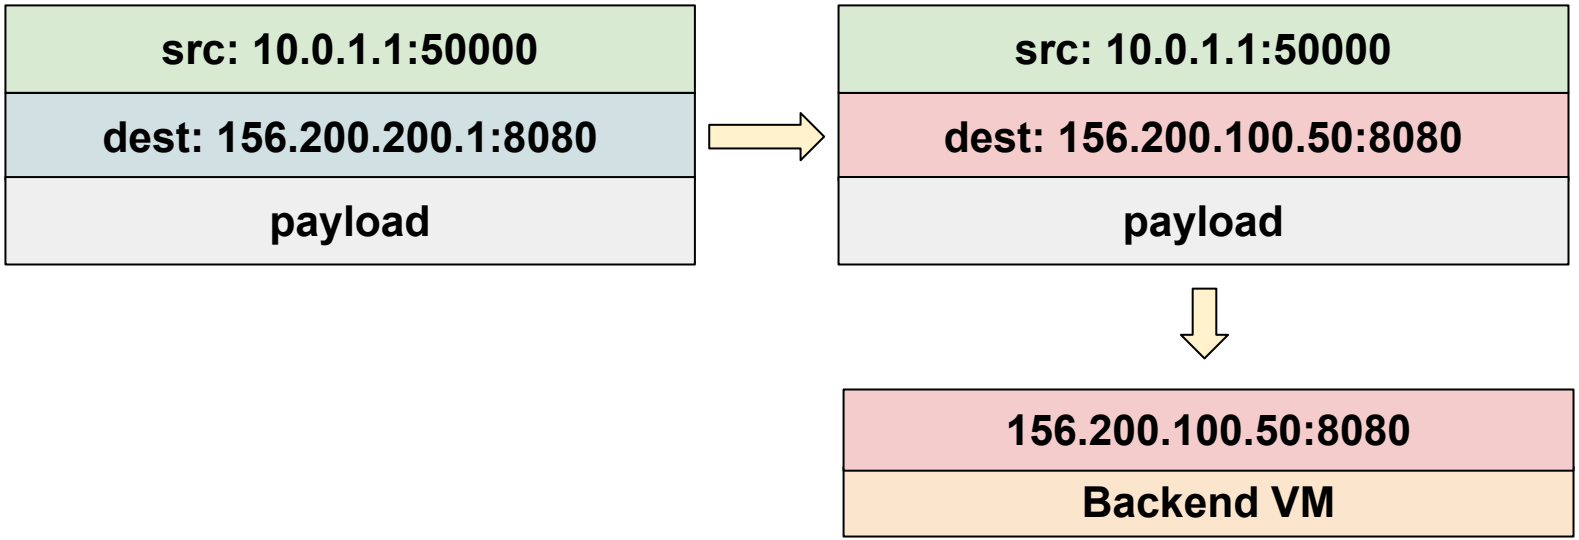

La machine virtuelle a reçue le paquet. Pour elle, le load balancer n’existe pas
L’IP source a été conservée

Hyperviseur: nat

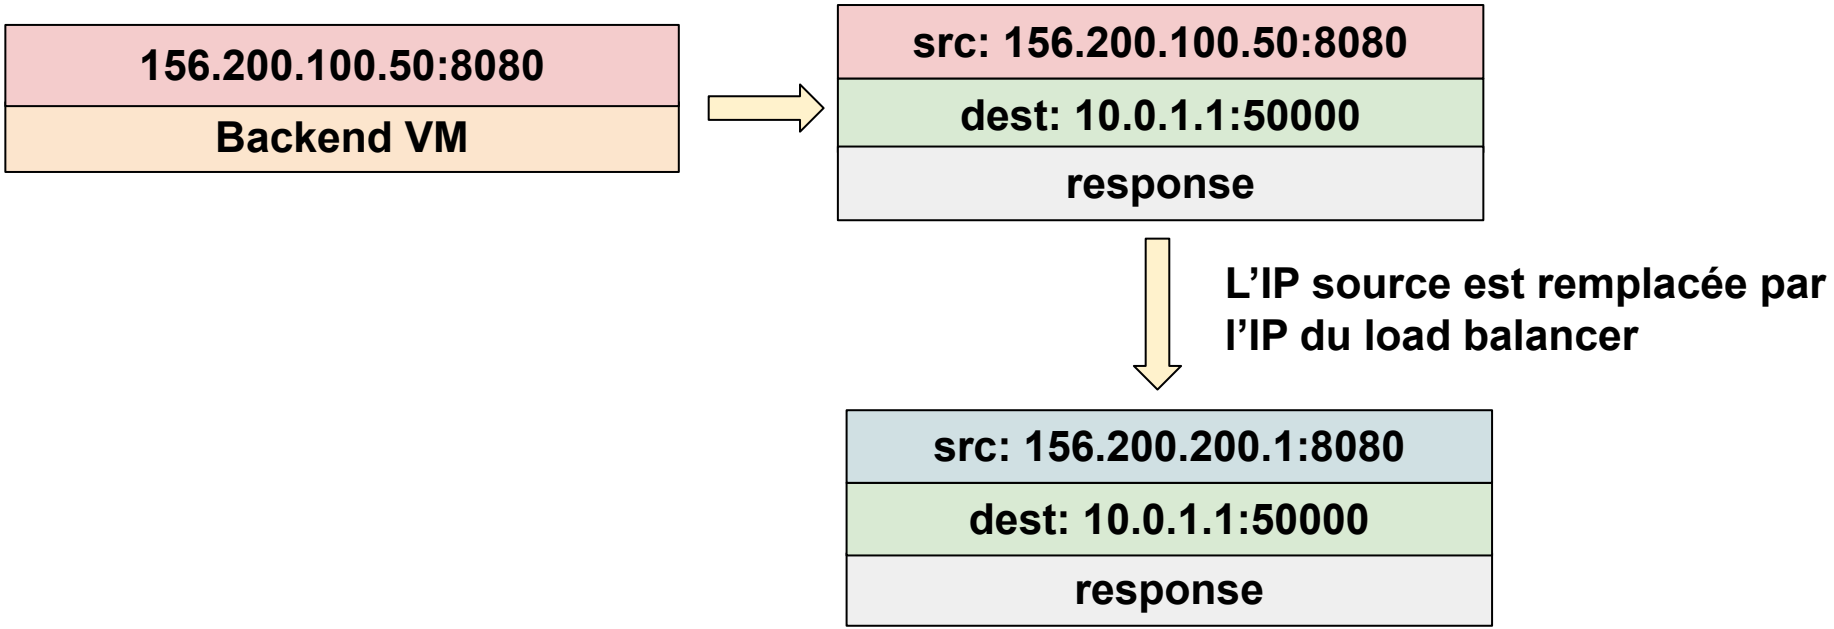

En résumé: ce que voit le client

Envoie

src: 10.0.1.1:50000
dest: 156.200.200.1:8080
payload

reçoit

src: 156.200.200.1:8080
dest: 10.0.1.1:50000
response

En résumé: ce que voit la VM

Reçoit

src: 10.0.1.1:50000
dest: 156.200.100.50:8080
payload

Envoie

src: 156.200.100.50:8080
dest: 10.0.1.1:50000
response

Direct Server Return

Le traffic sortant de la machine virtuel ne repasse jamais par le load balancer

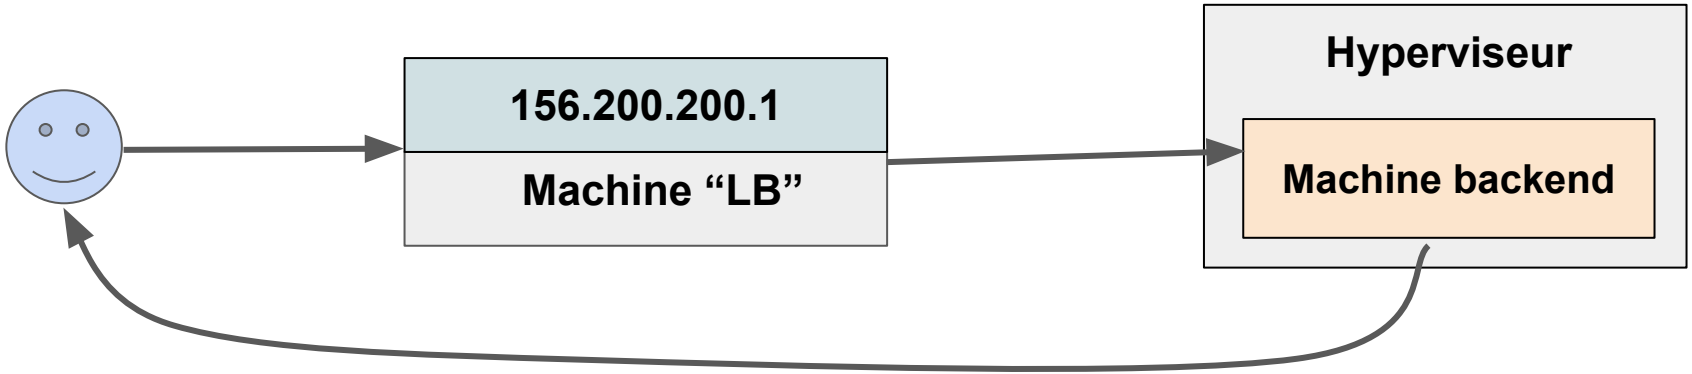

Vue d’ensemble

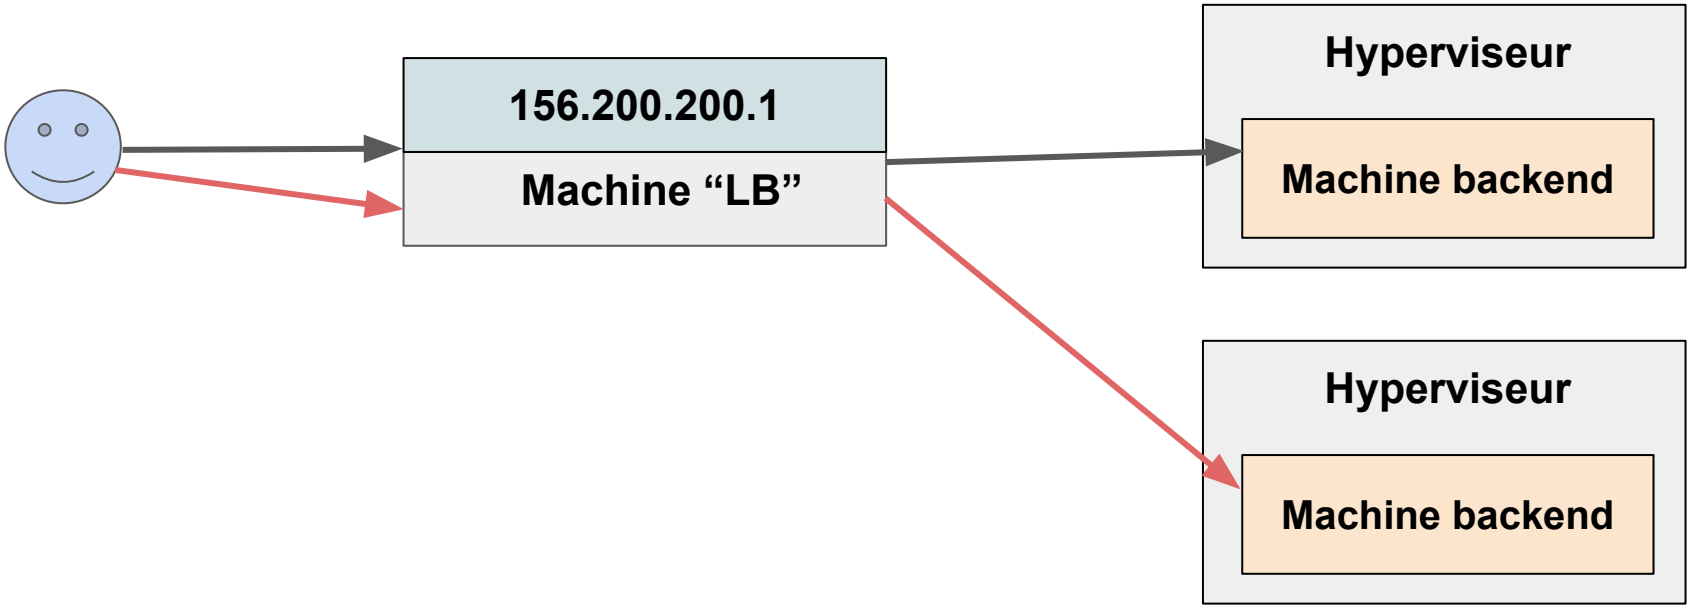

En réalité

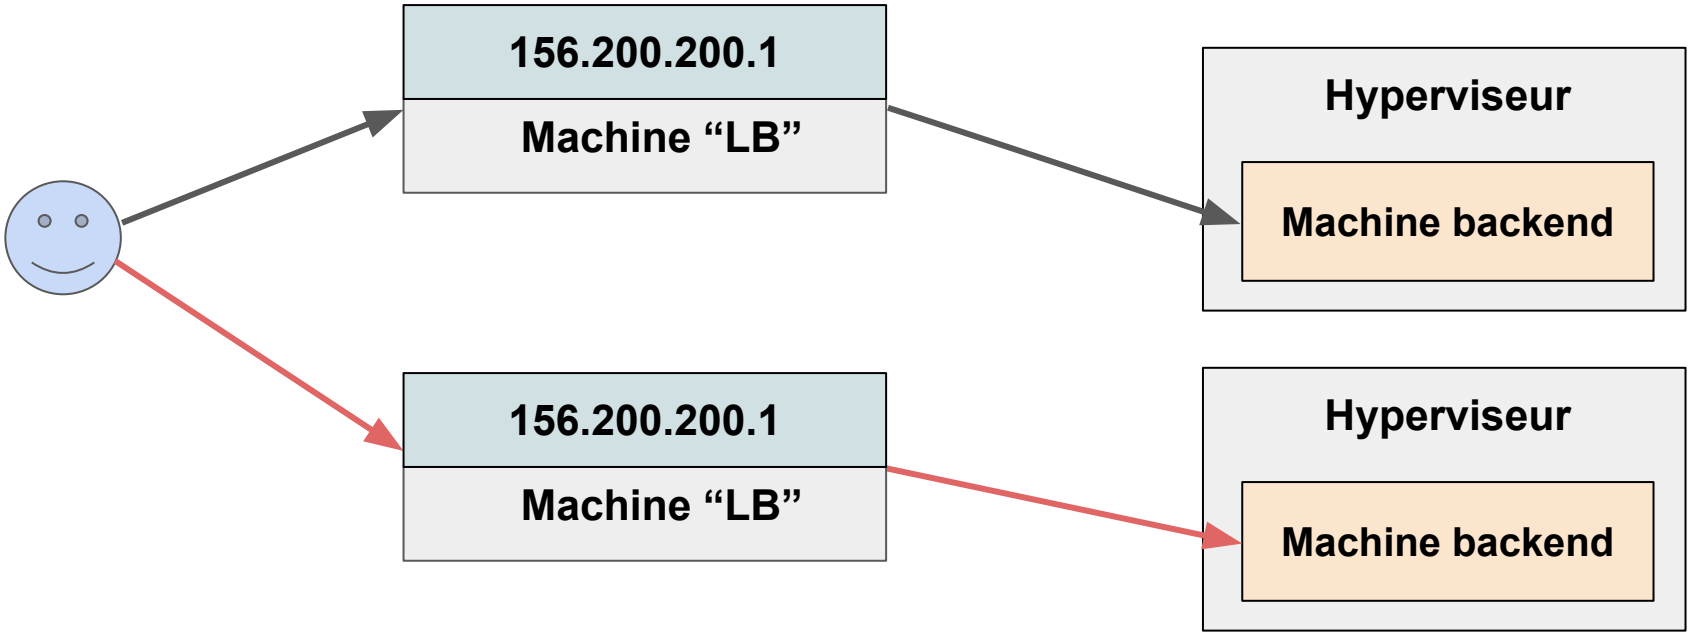
156.200.200.1
Machine “LB”
Hyperviseur
Machine backend
156.200.200.1
Machine “LB”
Hyperviseur
Machine backend

Deux instances de LB pour chaque load balancer

- Tolérance aux pannes
- Meilleures performances
  - actif/actif
- IP du load balancer partagée par les deux machines

Elastic IPS

- Les IPs des load balancers sont des Elastic IPs
  - Produit dans notre catalogue

- IP pouvant être facilement associées à une/plusieurs instances

Equal Cost Multi-Path

Plusieurs routes pour une même IP

BGP pour annoncer les routes

Equal Cost Multi-Path

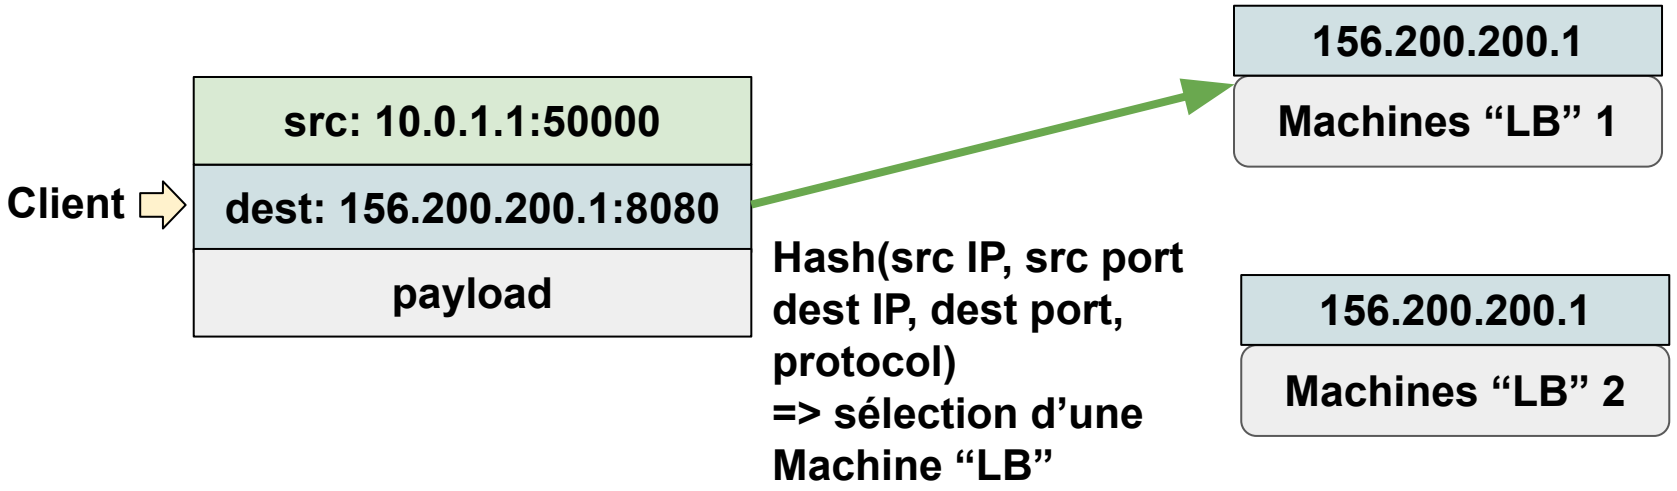

Equal Cost Multi-Path

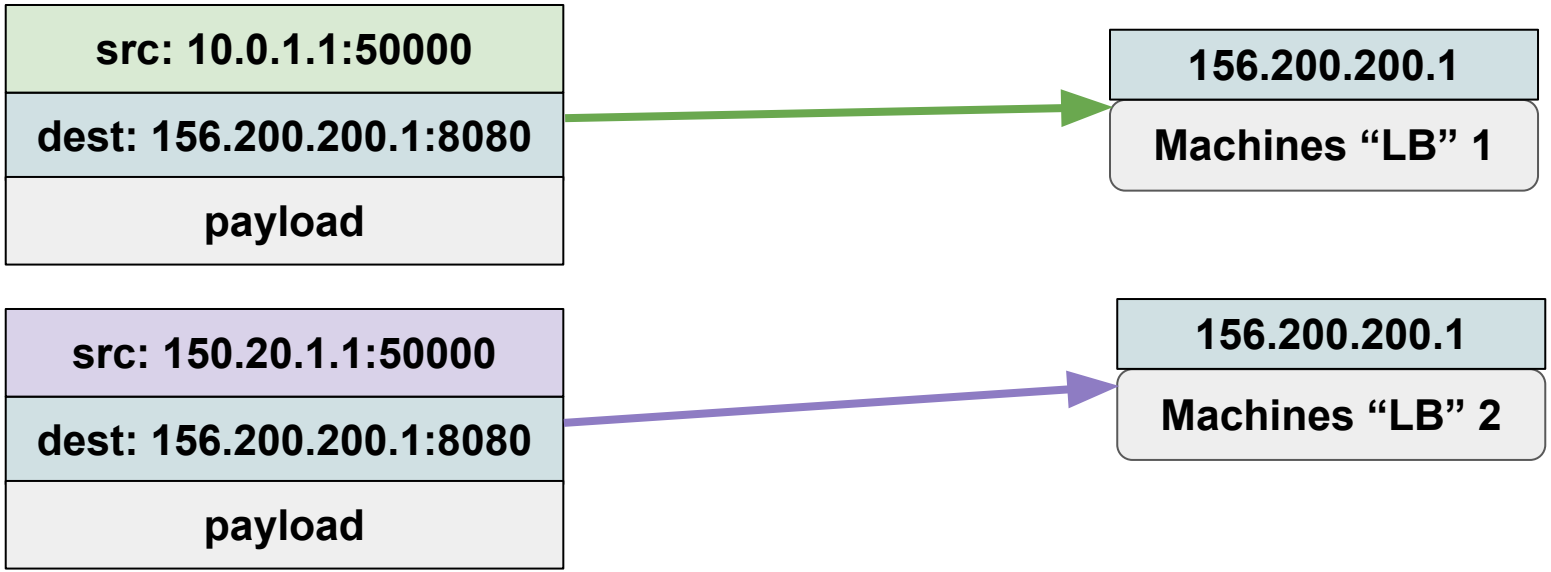

Chaque connexion est distribuée sur les machines “LB” en fonction du hash

Equal Cost Multi-Path

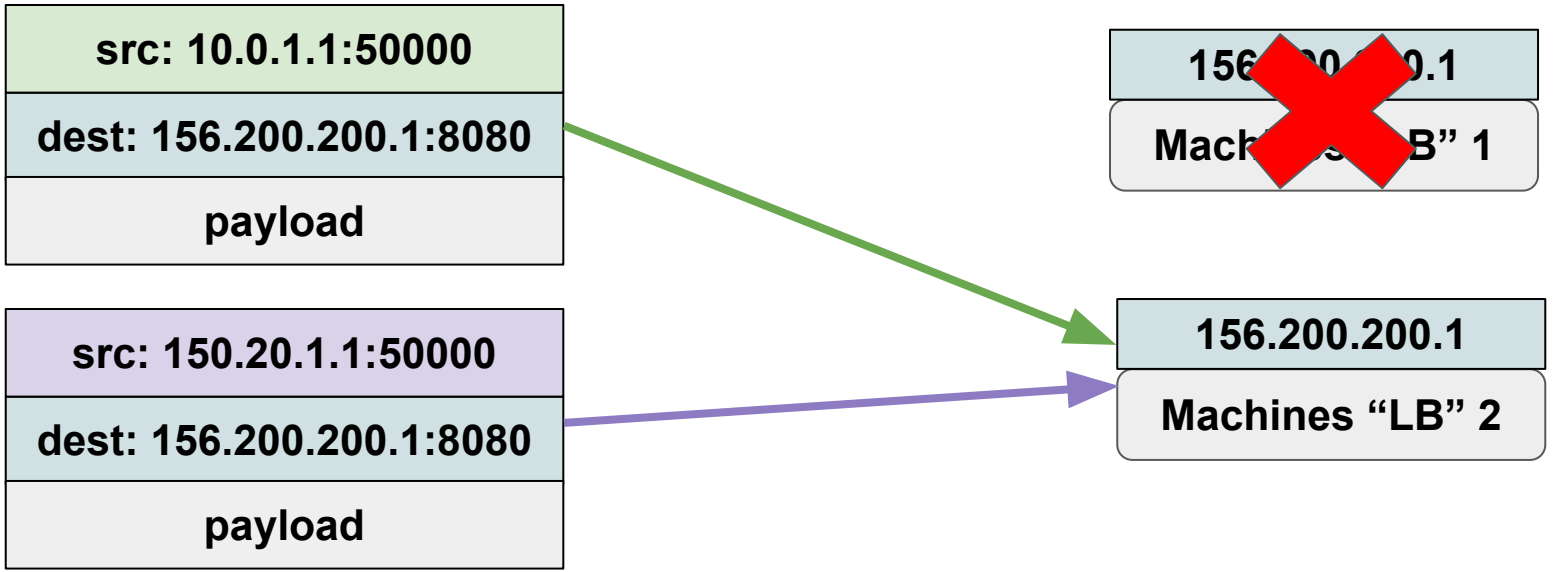

En cas de crash d’une machine, reroutage vers les autres machines disponibles

Machines LB: Keepalived

- Exécute les healthchecks et pilote IPVS
  - Chaque load balancer client a sa propre instance de keepalived, sur deux machines distinctes
  - Des tonnes d’options
  - Très (très) léger
  - Fiable

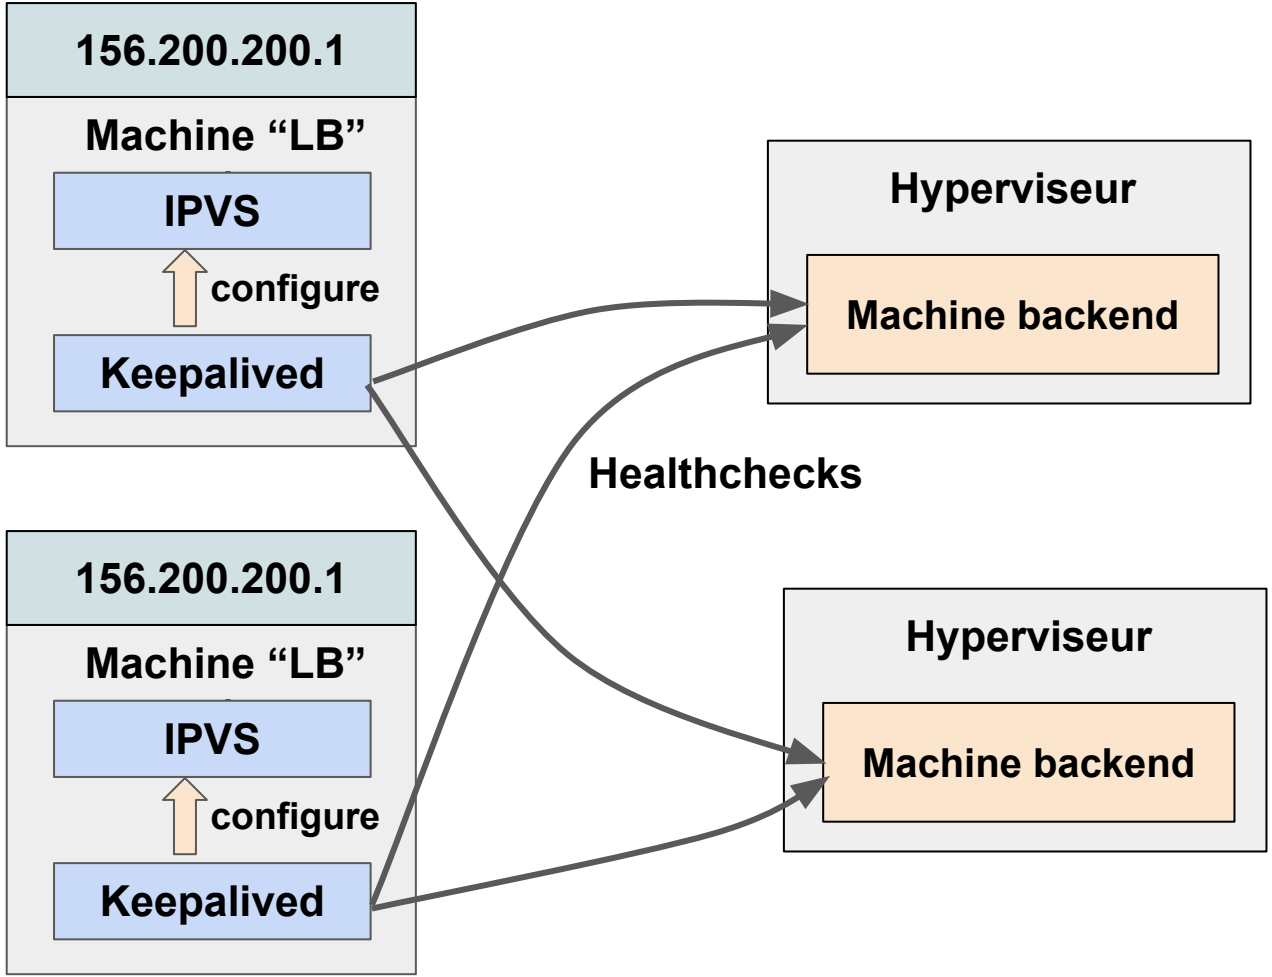
156.200.200.1
Machine “LB”
IPVS
configure
Keepalived
Hyperviseur
Machine backend
Healthchecks
156.200.200.1
Machine “LB”
IPVS
configure
Keepalived
Hyperviseur
Machine backend

Stratégies de load balancing

IPVS/Keepalived supportent plusieurs stratégies de load balancing

Round Robin

- Les connexions sont distribuées équitablement entre les serveurs backends

- Ajout optionnel d’un “poid” par serveur backend

Source Hash

- Un hash sur l'IP source (et optionnellement le port source) est calculé

- Algorithmes généralement simples
  - Que se passe t-il si on ajoute ou supprime un backend ?

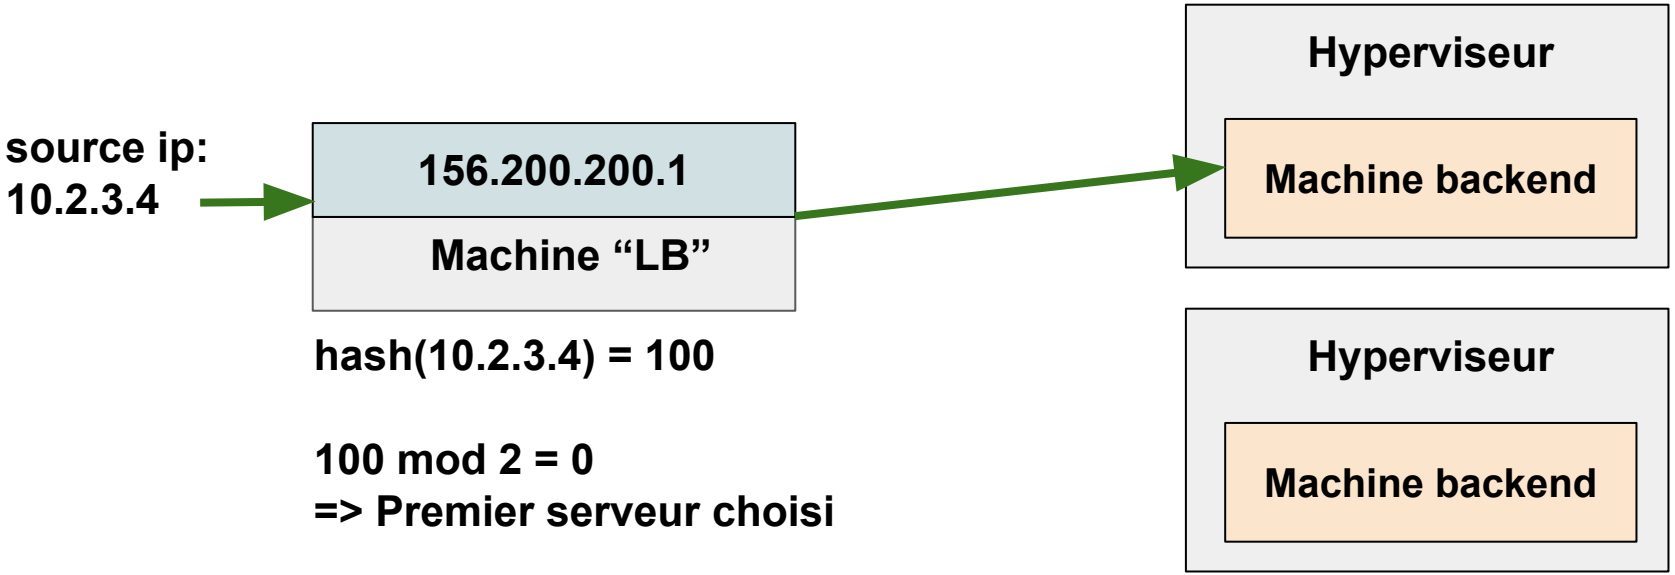
source ip:
10.2.3.4
156.200.200.1
Machine “LB”
hash(10.2.3.4) = 100
100 mod 2 = 0
=> Premier serveur choisi
Hyperviseur
Machine backend
Hyperviseur
Machine backend

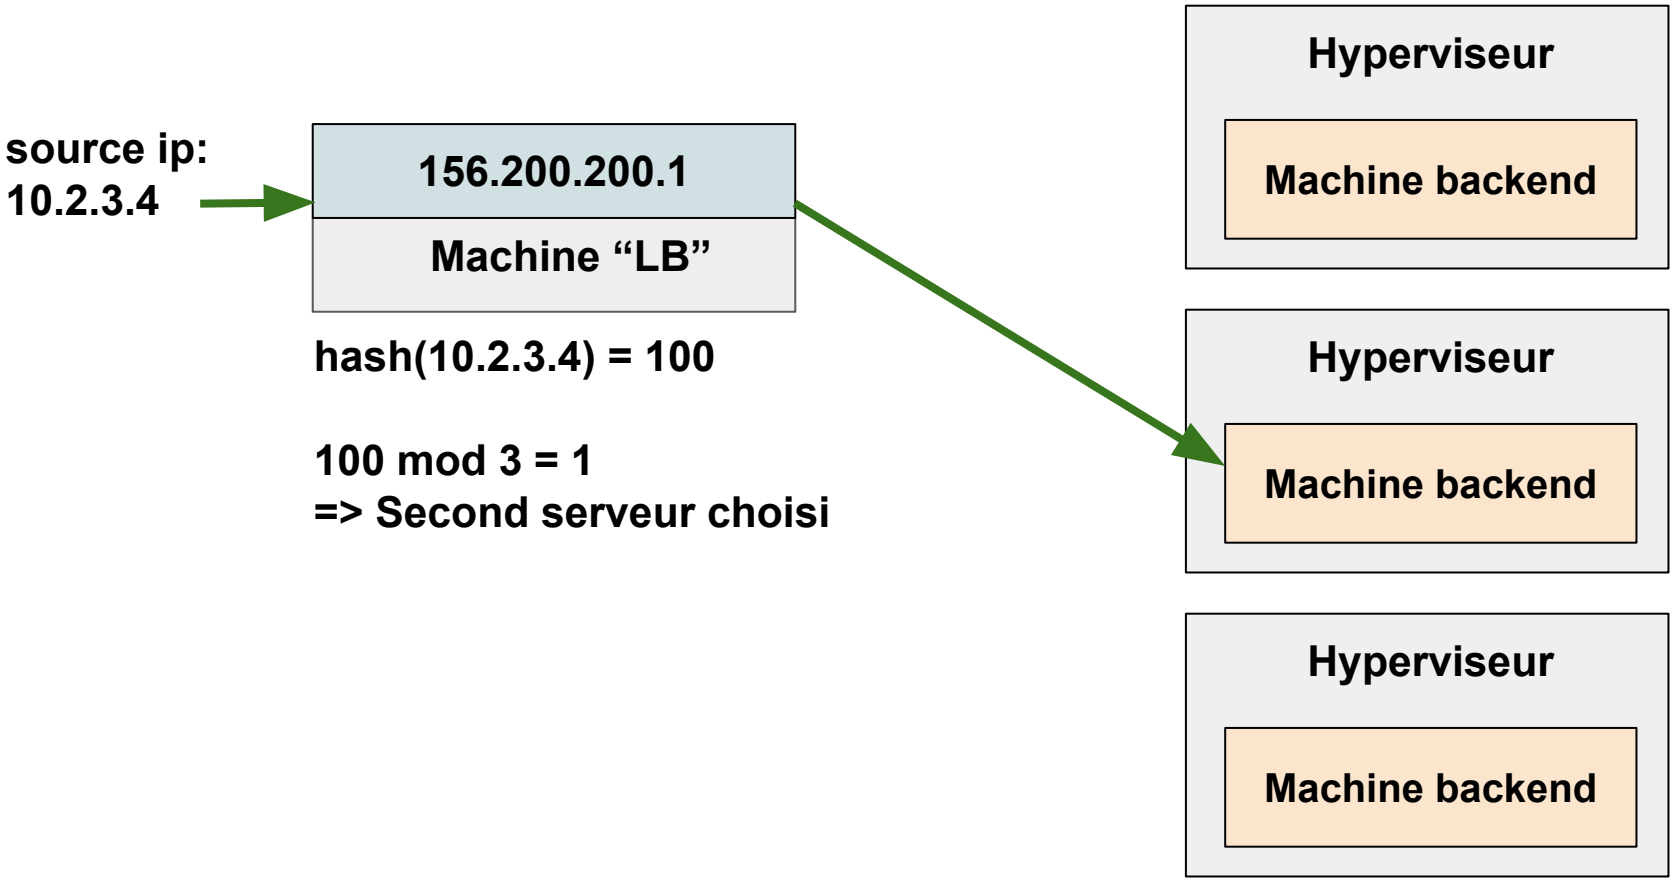
source ip:
10.2.3.4
156.200.200.1
Machine “LB”
hash(10.2.3.4) = 100
100 mod 3 = 1
=> Second serveur choisi
Hyperviseur
Machine backend
Hyperviseur
Machine backend
Hyperviseur
Machine backend

Source Hash

- En cas de modification des backends, la distribution est recalculée
  - Pour IPVS, cela arrive quand la connexion expire de la table des connexions IPVS

Equal Cost Multi-Path: mêmeproblème

Equal Cost Multi path

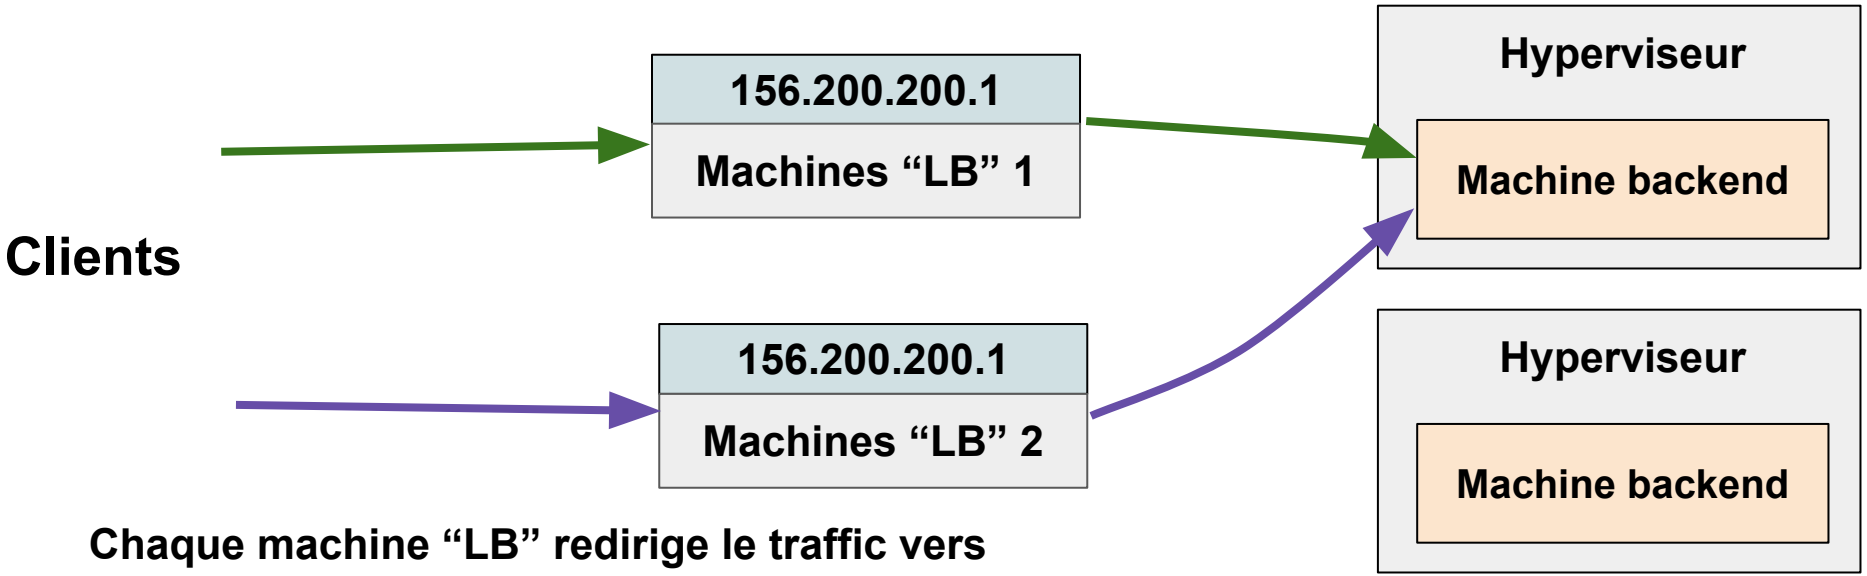

Chaque machine “LB” redirige le traffic vers un backend (par connexion)

Ajout d’une machine “LB”

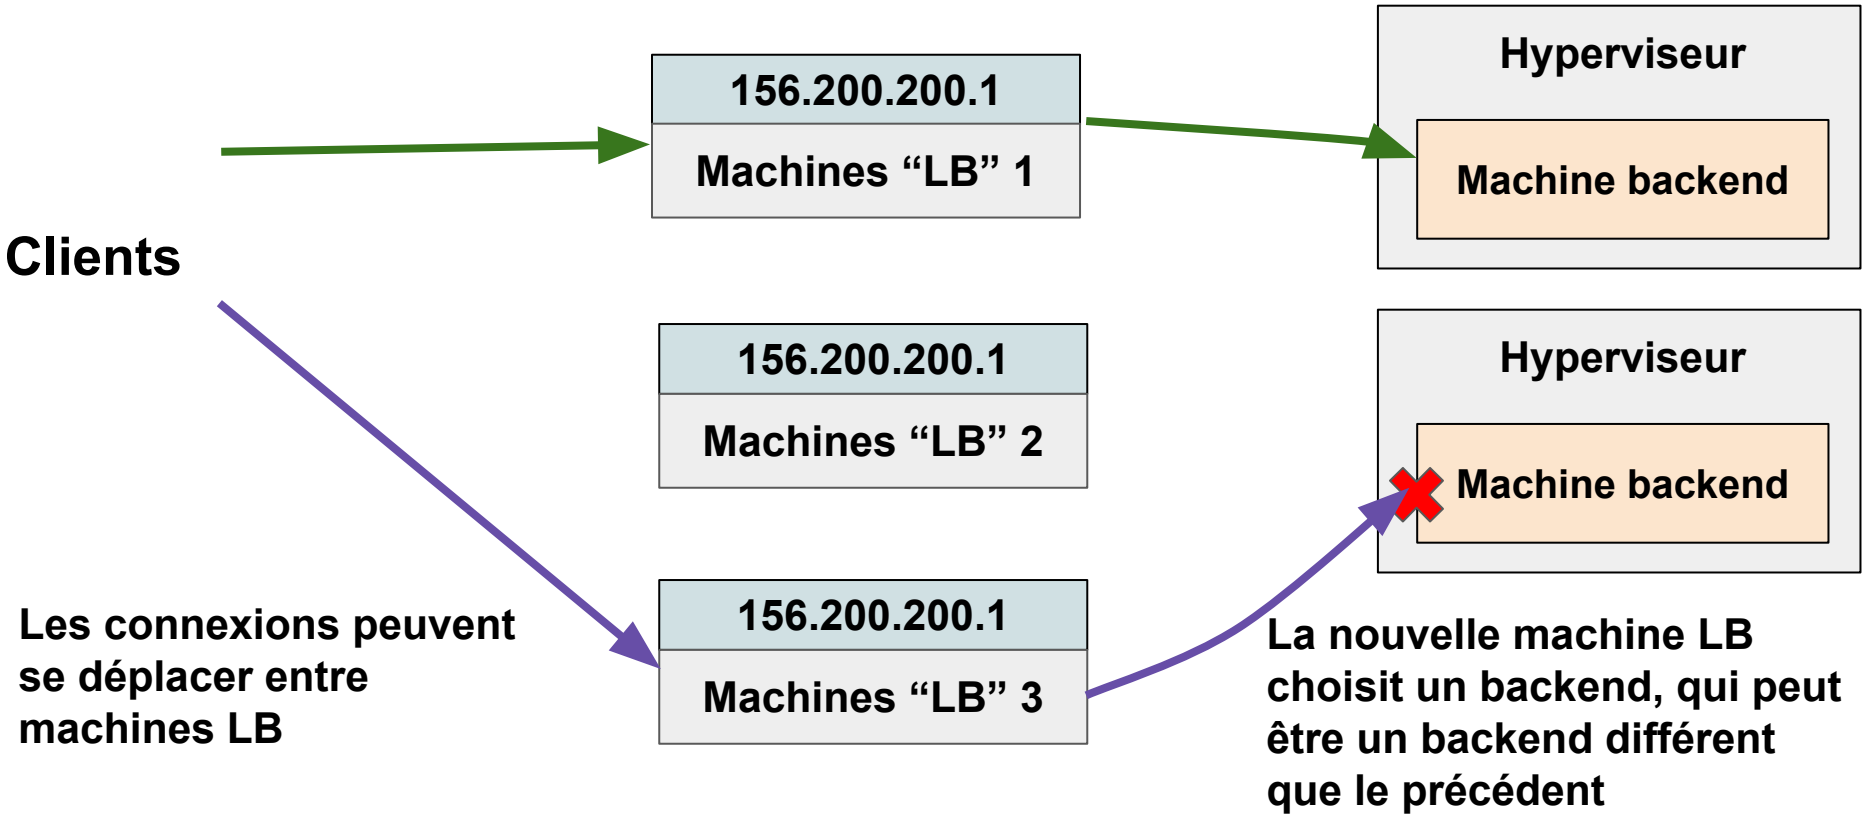

Suppression d’une machine “LB”

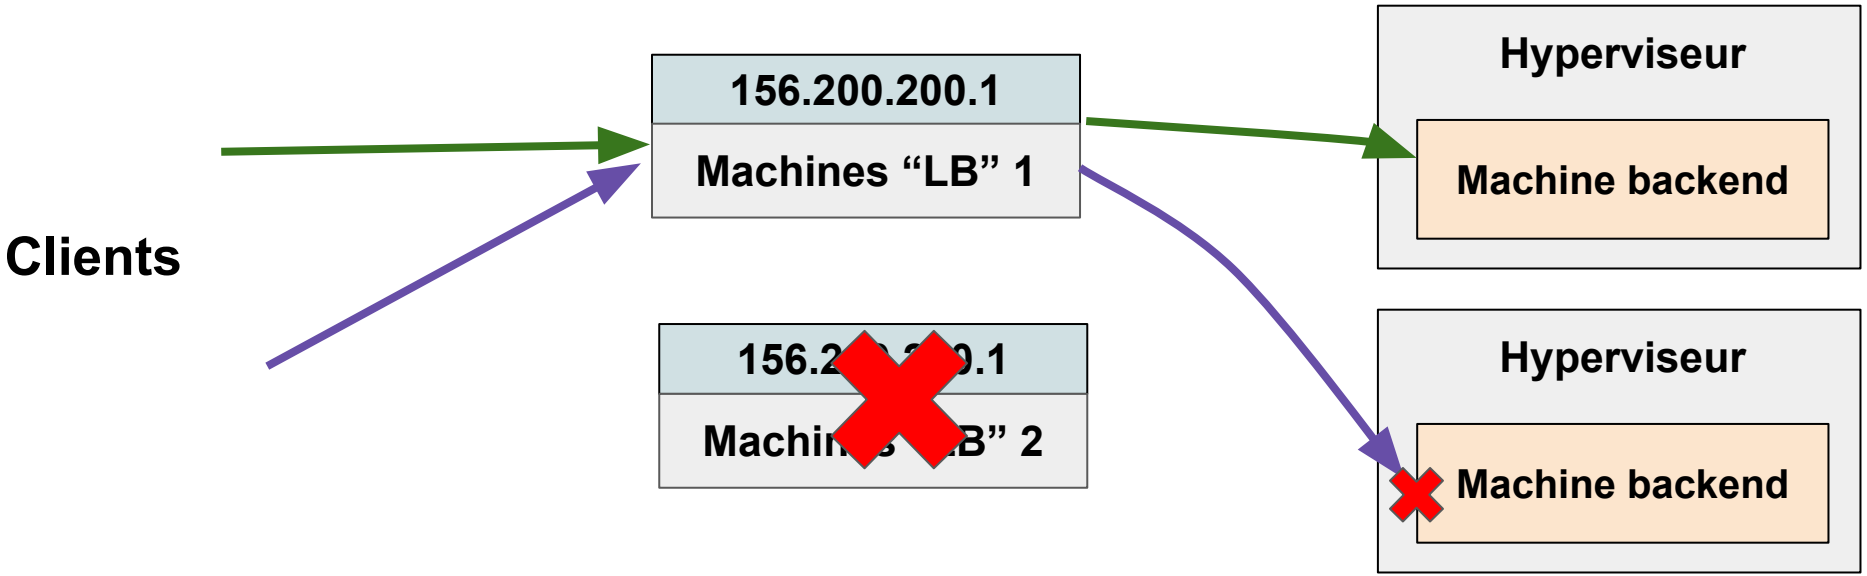

Partager la table des connexions ?

Compliqué, surtout avec IPVS

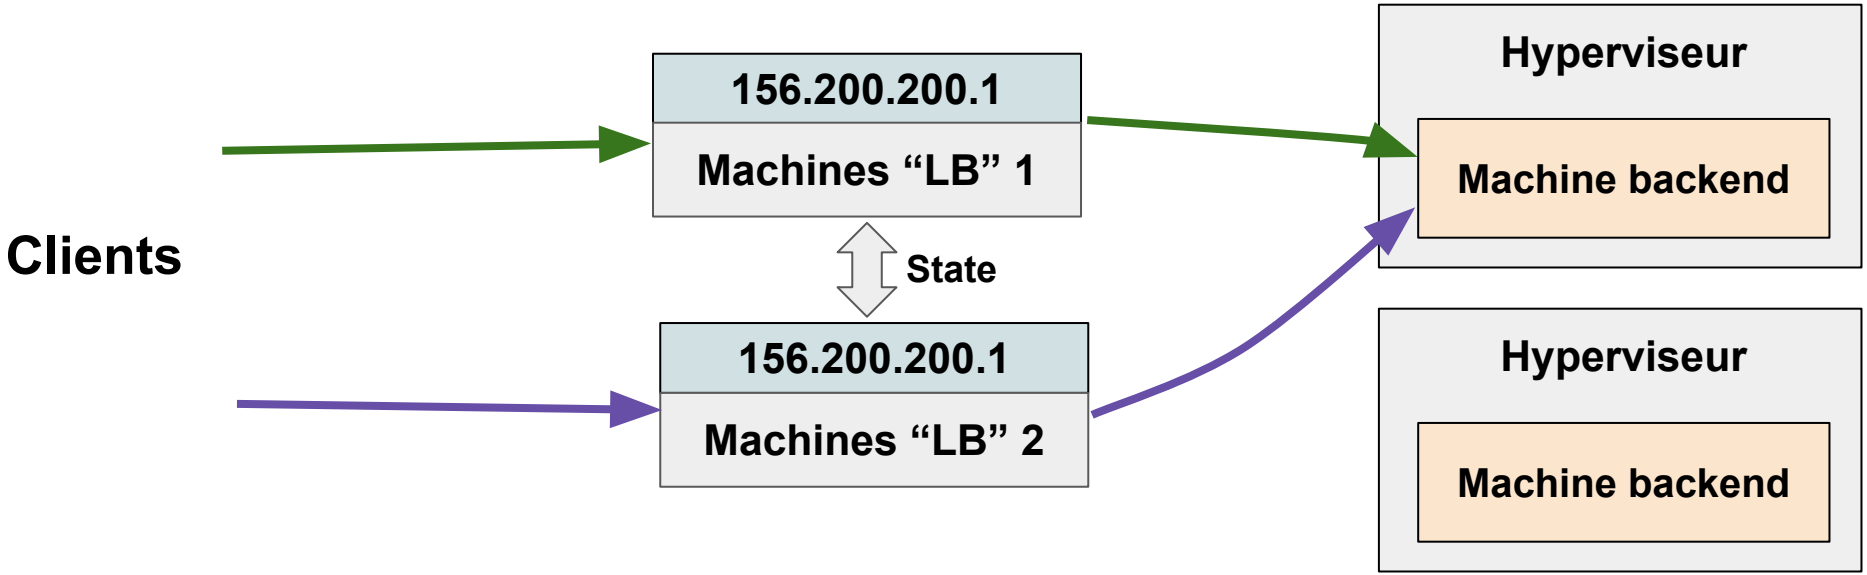

Solution: consistent hashing

Non dispo pour le moment, peut être bientôt ? ;)

- Algorithmes pour éviter les problèmes en cas d’ajout/suppressions de machines

- Toujours router les connexions vers les mêmes machines backends quand il y a:
  - Ajout/Suppression de machines backends
  - Ajout/Suppression de machines LB

- IPVS implémente Maglev (créé par Google)

Solution: consistent hashing

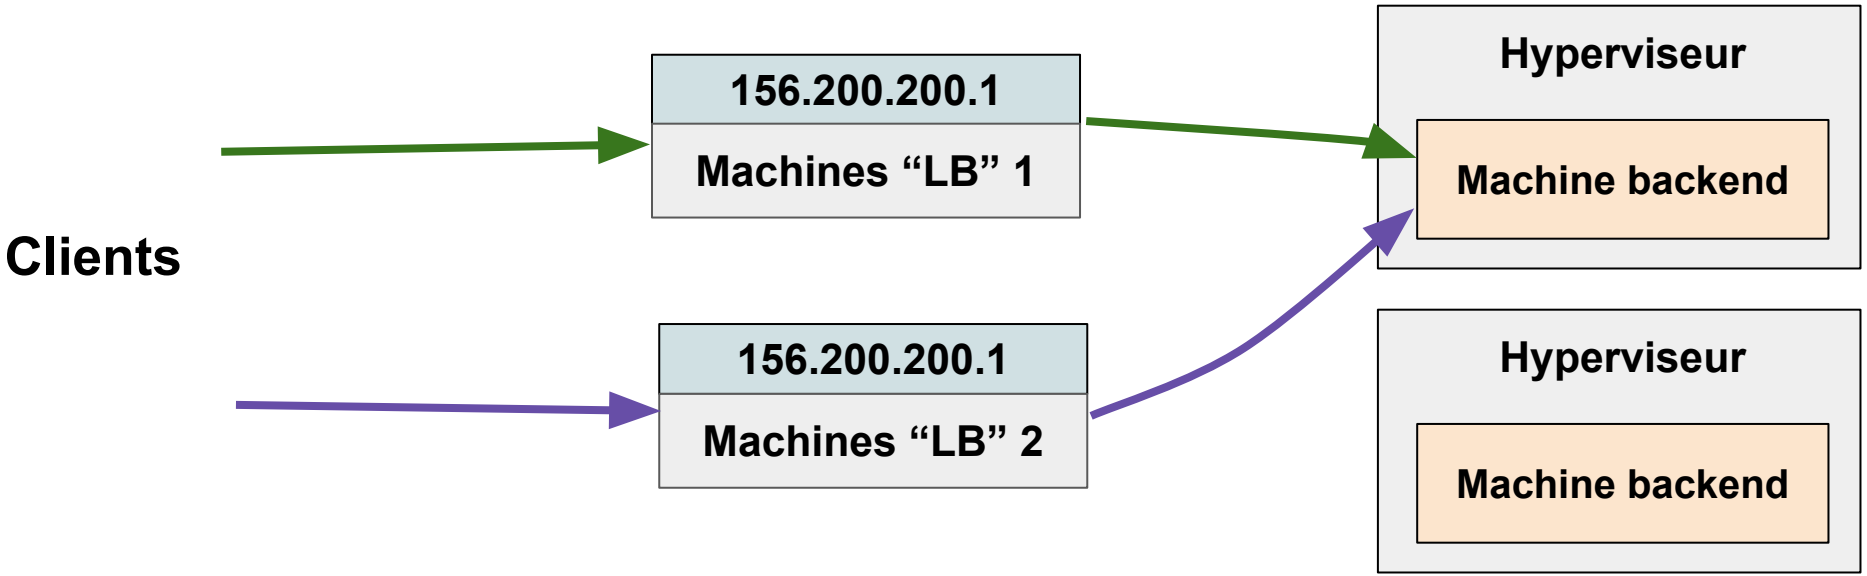

Solution: consistent hashing

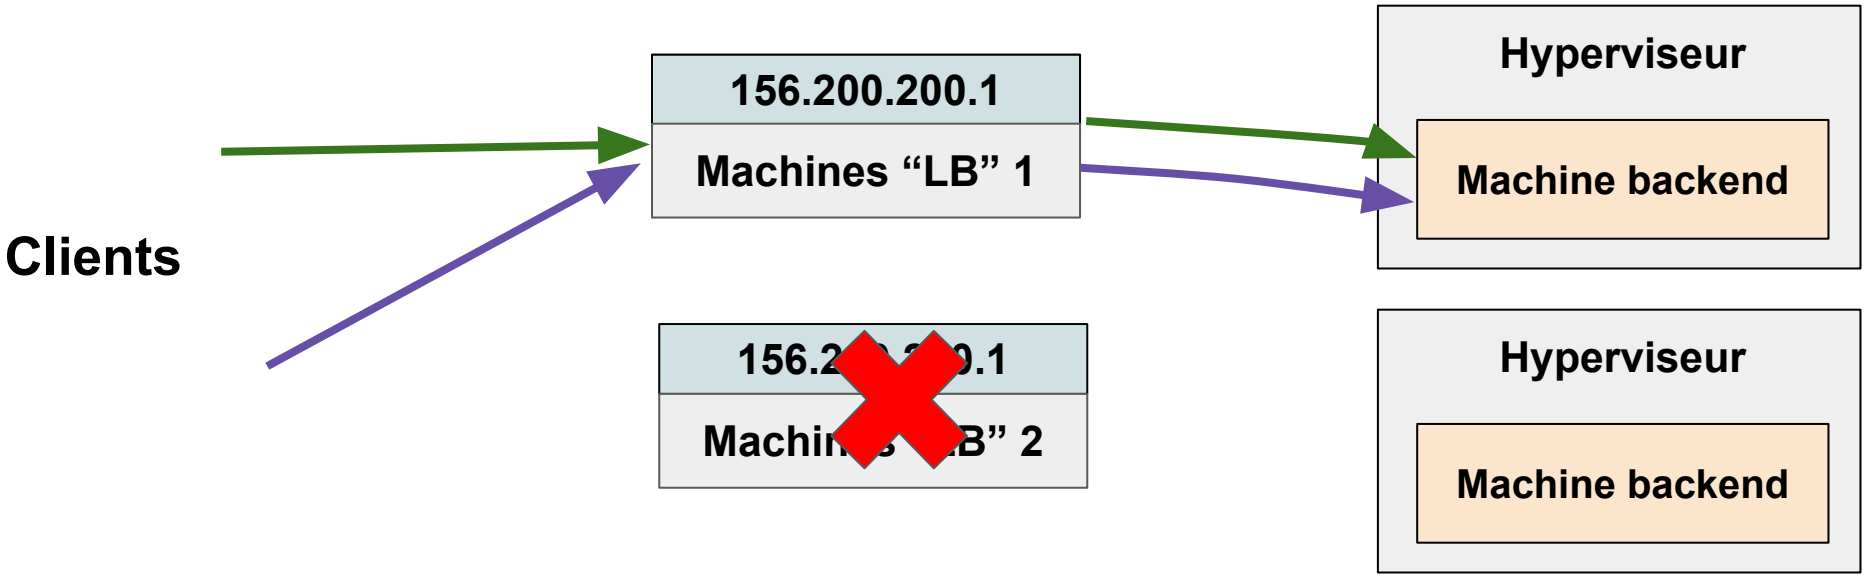

Toutes les machines “LB” prennent la même décision pour une même connexion.
L’ajout/suppression de backends a également un impact limité

Keepalived tourne dans Kubernetes

- Les machines “LB” sont des workers spécifiques
- Permet de facilement déplacer des load balancers d’un noeud à un autre (en cas de panne par exemple)

Vue d’ensemble

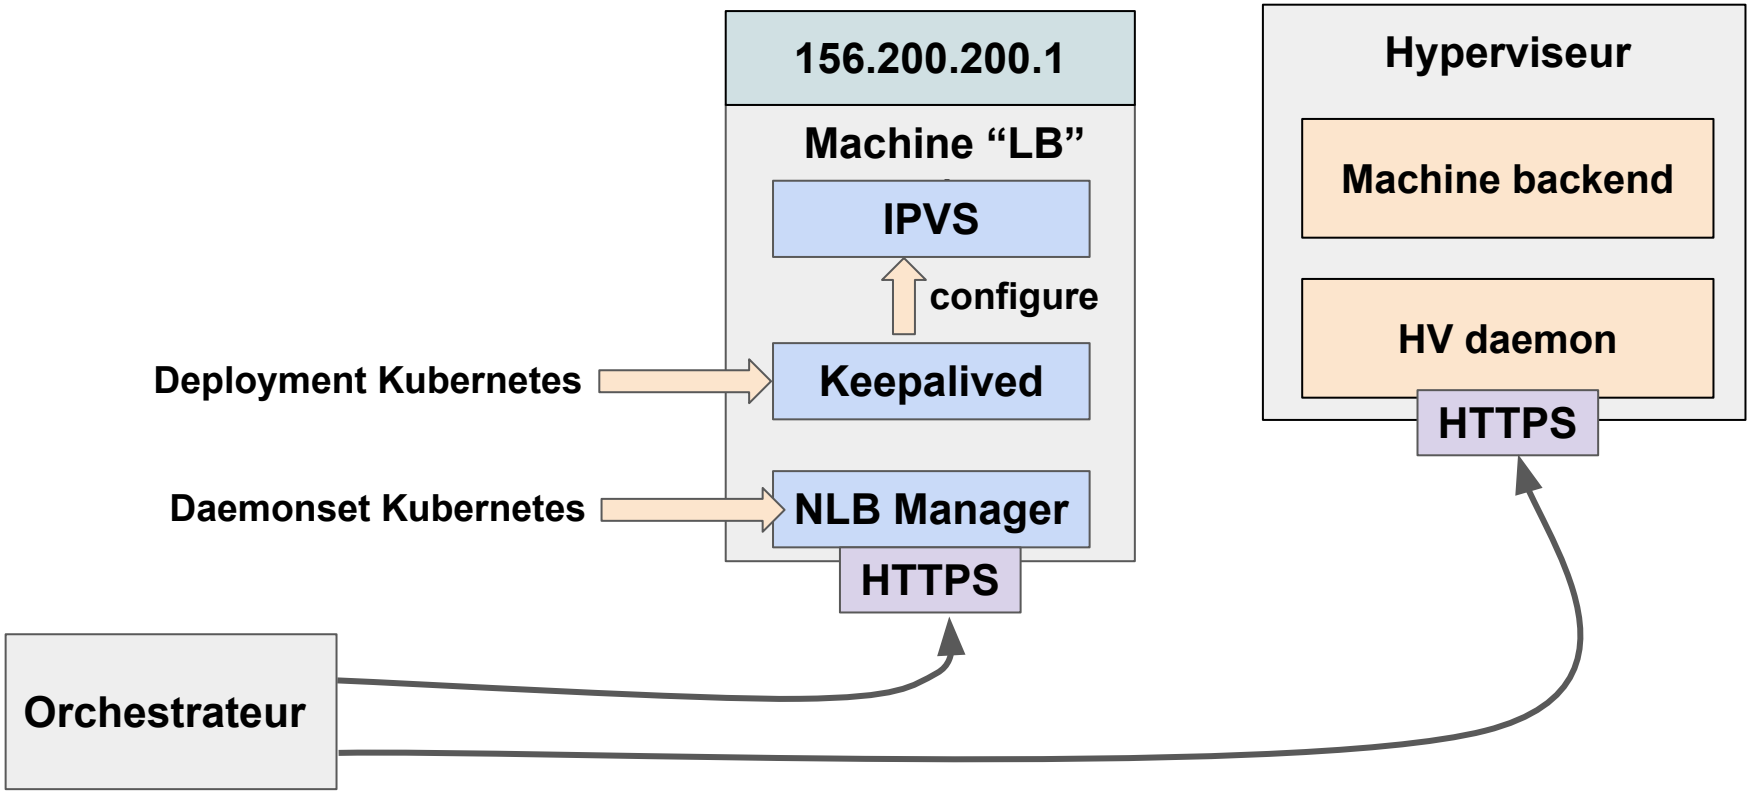

NLB Manager

- Un DaemonSet tournant sur toutes les machines “LB”
  - Exposant une API HTTP
- Attache/détache les Elastic IPs des load balancers des machines
- Configure/reload Keepalived
- Récupère l’état des serveurs backends dans IPVS
- Périodiquement, reçoit une requête lui faisant vérifier l’état des load balancers/IP

HV Daemon

- Tourne sur chaque hyperviseur
  - Expose aussi une API HTTP

- Permet d’ajouter ou supprimer les règles réseaux pour les load balancers

- Périodiquement, envoie toutes les règles de load balancing dans Kafka pour analyse/détection d’incohérences

Orchestration

- La difficulté du cloud: converger (très) rapidement vers le bon état:
  - Base de données de l'orchestrateur
  - Règles sur les machines "LB" (NLB Manager)
  - Règles sur l'hyperviseur (HV Daemon)

- De nombreux changements d'états
  - Actions utilisateurs
  - (live) migration de machines virtuelles
  - Incidents

Notre librairie d’orchestration

- Utilisée par plusieurs projets (dont le load balancer)
- Un moyen simple et efficace d’écrire des orchestrateurs
- 100 % Clojure

Orchestrateur: le store

- Une base de données (SQL) contenant l'état attendu

- Une API pour manipuler le store
  - Basé sur https://github.com/exoscale/seql/

Orchestrateur: l’inventaire

- Récupérer l’état du monde pour une entité
- Décide quoi faire en fonction de l’état actuel de l’entité

Orchestrateur: exécution du job

- Un job démarre et synchronise les différents systèmes en fonction de l’inventaire
  - https://github.com/exoscale/ablauf

Réconciliation

Inventaire + exécution du job

Un exemple: création d’un load balancer

Etape 1: un NLB est créé dans le store

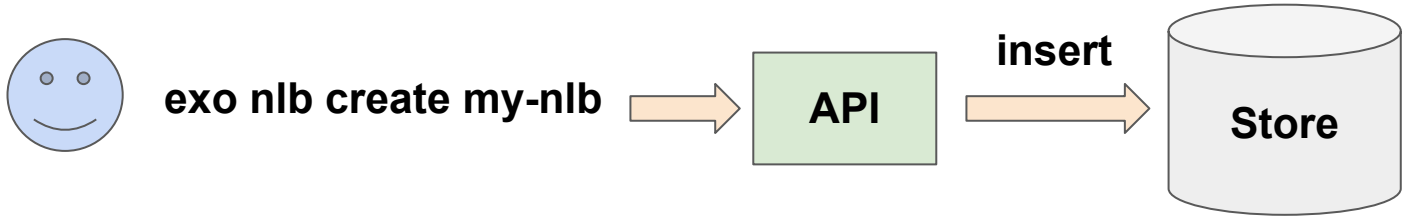

ID	fbc40446
Name	my-nlb
Description	Load balancer talk
IP Address	null
state	**creating**
...	...

Etape 2: appel de la fonction d’inventaire

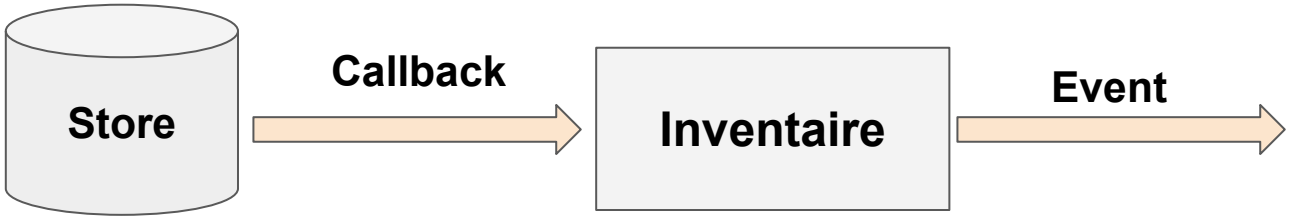

Un NLB en **state = creating**
=> Génération d’un event de type “Create”

L’event contient toutes les informations disponibles sur ce NLB

Etape 3: construction et exécution du job

Le job runner crée un “ast” contenant les étapes du job à réaliser en fonction de l’event

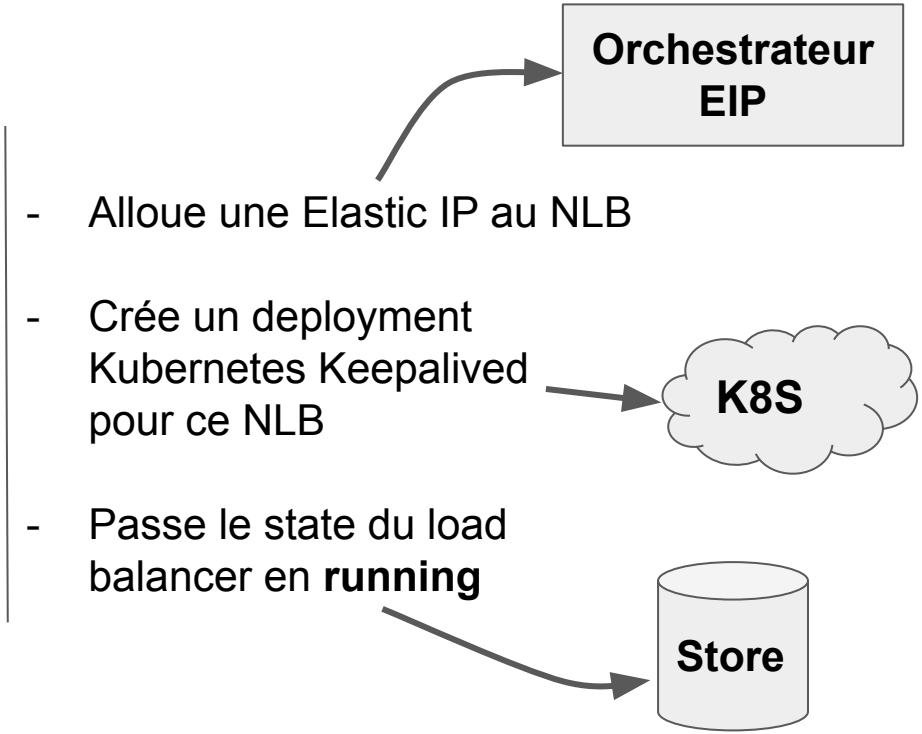

Le load balancer est créé

store

ID	fbc40446
Name	my-nlb
Description	Load balancer talk
IP Address	**159.200.1.2**
state	**running**
...	...

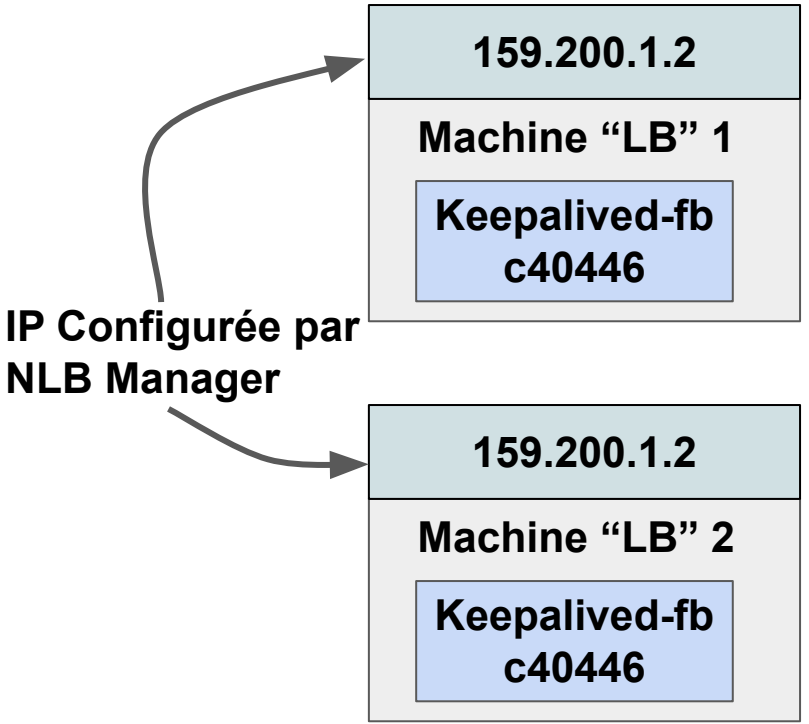

Ajoutons un service

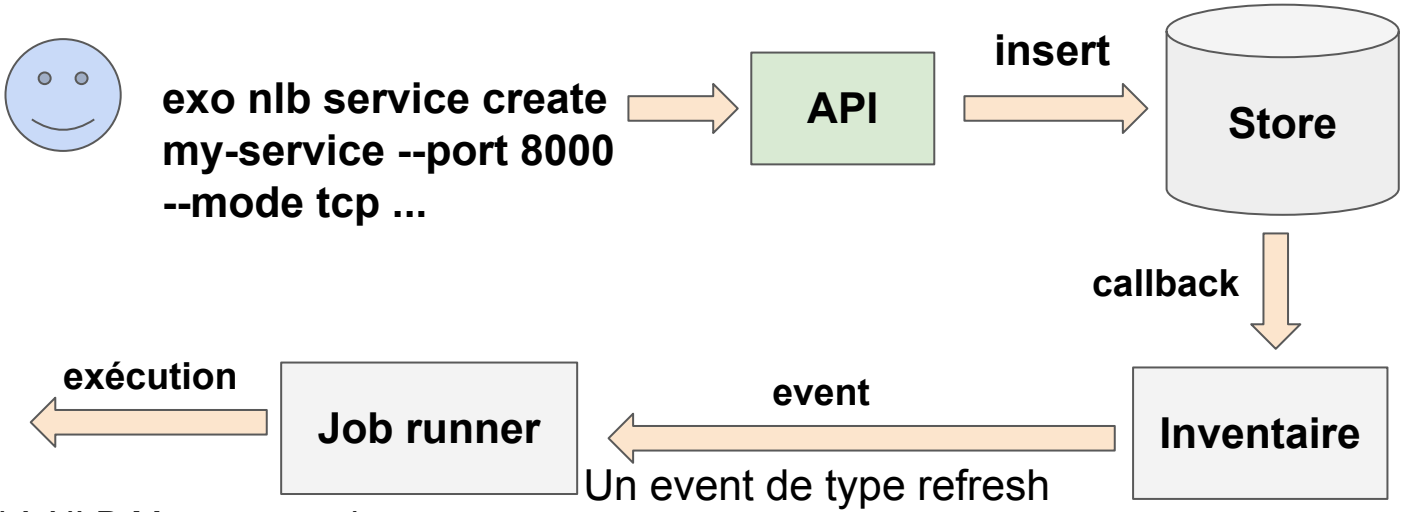

Un event de type refresh est généré

Un NLB en state **running**
Un service en state **creating**
Récupération des machines Backend
Vérification de l'état k8s

- Appel à NLB Manager sur les machines NLB pour mettre à jour Keepalived
- Appel de HV daemon pour configurer les hyperviseurs
- Diverses vérifications ...

Toujours le même principe

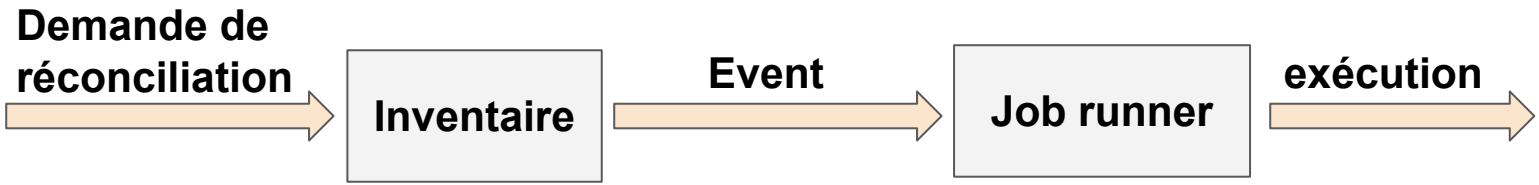

Mieux vaut réconcilier trop que pas assez

- Events Kafka de machines (création/suppression)
- Vérifications périodique
- Events Kubernetes
- Events générés par NLB Manager/HV daemon
- Action sur le load balancer
- Action déclenchée par un opérateur (admin)
- ….

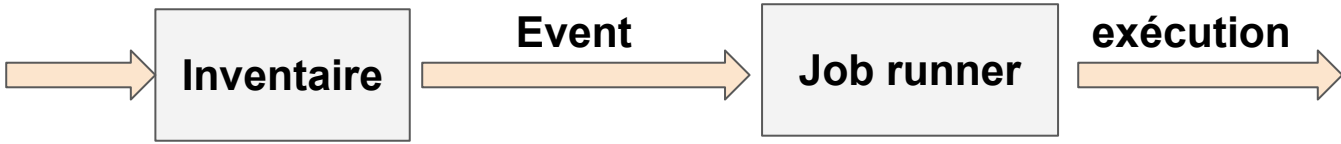

Une réconciliation ne coûte pas cher

- Dès que le système a un doute, il déclenche une réconciliation

- Les sous systèmes savent aussi détecter des états incohérents et demander des réconciliations

Orchestrateur: détails

- Garantie qu'une même entité ne peut pas être réconciliée plusieurs fois en parallèle
  - "File d'attente" en cas de réconciliations multiples

- Notion de priorité des événements

- Déduplication des événements
  - Plusieurs événements en priorité basse => une seule réconciliation

Orchestrateur: détails

- Gestion des erreurs
  - Erreur de réconciliation => retry => Pagerduty => Oncall

- Design modulaire à tous les niveaux
  - Car chaque orchestrateur a ses propres besoins

Merci

Questions ?

@_mcorbin

mcorbin.fr