Orchestration de conteneurs: Illustration avec Kubernetes

Emmanuel Coquery
Intergiciels et services - Master 2 Technologies de l'Information et Web
Janvier 2019

Survol

- Retour sur certaines problématiques autour des microservices
- Orchestrateurs
- Focus sur Kubernetes

Retour sur les microservices

- Application = assemblage de « petits » services
- Microservice :
  - processus/périmètre métier (gestion d’une commande, des personnel, etc)
  - ou préoccupation transverse (authentification, audit/ supervision, persistance des données, équilibrage de charge)

Granularité plus fine

- Meilleure possibilités de passage à l'échelle:
  - plus de flexibilité pour combiner le passage à l'échelle horizontal suivants les 3 axes classiques: répartir les fonctionnalités, paralléliser les calculs indépendant, distribuer les traitements selon les données
- Impact des pannes *potentiellement* réduit
- Plus de déploiements

Complexité de déploiement

- Nombreuses briques à déployer → automatisation nécessaire
- Automatisation complexe
  - Plus de diversité
  - Plus de configuration: chaque microservice s’adresse à de nombreux autres

Isolation des conteneurs

- Une couche d’isolation supplémentaire à gérer
- mise en oeuvre de la communication plus complexe
    - en particulier entre machines
- gestion des données à conserver après disparition du conteneur

Dynamicité des services

- Plus de services sur plus de technologies:
  - plus de potentiel de dysfonctionnement
  - évolutions plus régulières
- Un microservice peut être arrêté et replacé plus souvent
  - robustesse des clients
  - problèmes de reconfiguration

Supervision

- Nombreux microservices à surveiller
- Localisation des logs
- Exploitation des informations
  - levées d’alertes
  - réactions automatisées

Orchestrateurs

- Objectif: aider à la gestion de nombreux déploiements
  - indispensables dans le cadre d’une architecture à base de microservices

- Fournissent des services support pour faciliter la gestion des microservices

Quelques orchestrateurs de conteneurs

- `docker-compose`: surcouche à Docker, simple (mise en place et appréhension), capacités assez limitées

- Docker Swarm: gestion de cluster de machines, scaling, intégré à Docker

- Mesos/Marathon/DCOS: gestion de (très gros) clusters de machines, scaling, gestion fine des ressources, templates et bibliothèques de déploiement

- Kubernetes (k8s): nombreuses fonctionnalités (clusters, scaling, templates, ressources, stockage), templates et bibliothèques (via helm), contrôle d'accès

k8s: ressources

- Point de vue générique ce qui est géré par k8s:
  - Conteneurs et assimilés
  - Stockage (volumes et ressources connexes)
  - Réseau (services, load balancer)
- Système de *labels* et de *selectors*:
  - clé/valeur, utilisable comme label ou comme sélecteur
    `app: cinema`
  - mini langage de sélecteurs:
    ```
    environment in (production, qa)
    tier notin (frontend, backend)
    ```

k8s: utilisation

- kubectl: CLI pour gérer le cluster
- Utilise de nombreux fichiers YAML permettant de décrire les différentes ressources à mettre en place
- Exemple:

```
kubctl create -f mondeploiement.yml
```

Description de la ressource à créer

k8s: exemple de fichier de ressource

```yaml
apiVersion: apps/v1 # for versions before 1.9.0 use apps/v1beta2
kind: Deployment
metadata:
  name: nginx-deployment
spec:
  selector:
    matchLabels:
      app: nginx
  replicas: 2 # tells deployment to run 2 pods matching the template
  template:
    metadata:
      labels:
        app: nginx
    spec:
      containers:
      - name: nginx
        image: nginx:1.7.9
        ports:
        - containerPort: 80
```

https://kubernetes.io/docs/tasks/run-application/run-stateless-application-deployment/

Orchestration
Déploiement de conteneurs

- Fonctionnalité de base
- Déclaratif
- Sous forme d’un fichier de configuration,
  pas une commande avec des options
- Limite la quantité de script pour l’automatisation
- Gestion de la configuration (environnement, fichiers)

Orchestration
Déploiement de conteneurs: scaling

- Gérer plusieurs conteneurs ayant:
  - Même image
  - Même configuration
- Pouvoir in/décrémenter le nombre de copies (a.k.a. *scaling*)

Orchestration
Déploiement et supervision

- Surpervision simple: état du conteneur
    - en construction, en marche, arrêté, etc
- Plus avancé
    - Le service est-il fonctionnel ?
      Un process peut tourner en renvoyer des 503
    - *Health check*: code exécuté pour vérifier le bon fonctionnement du service
      → code *ad-hoc* pour chaque service
- Réaction
    - Que faire si un service est défaillant ?
      → kill/reboot ?

k8s: conteneurs, pods, sets

Encapsulation des conteneurs

- Pods: groupe de conteneurs
  - partage de ressources
  - démarrage et terminaison simultanés
- Controleurs
  - ensemble de pods
  - surveillance, redémarrage
  - Replica/Stateful/Daemon Set
  - Deployments

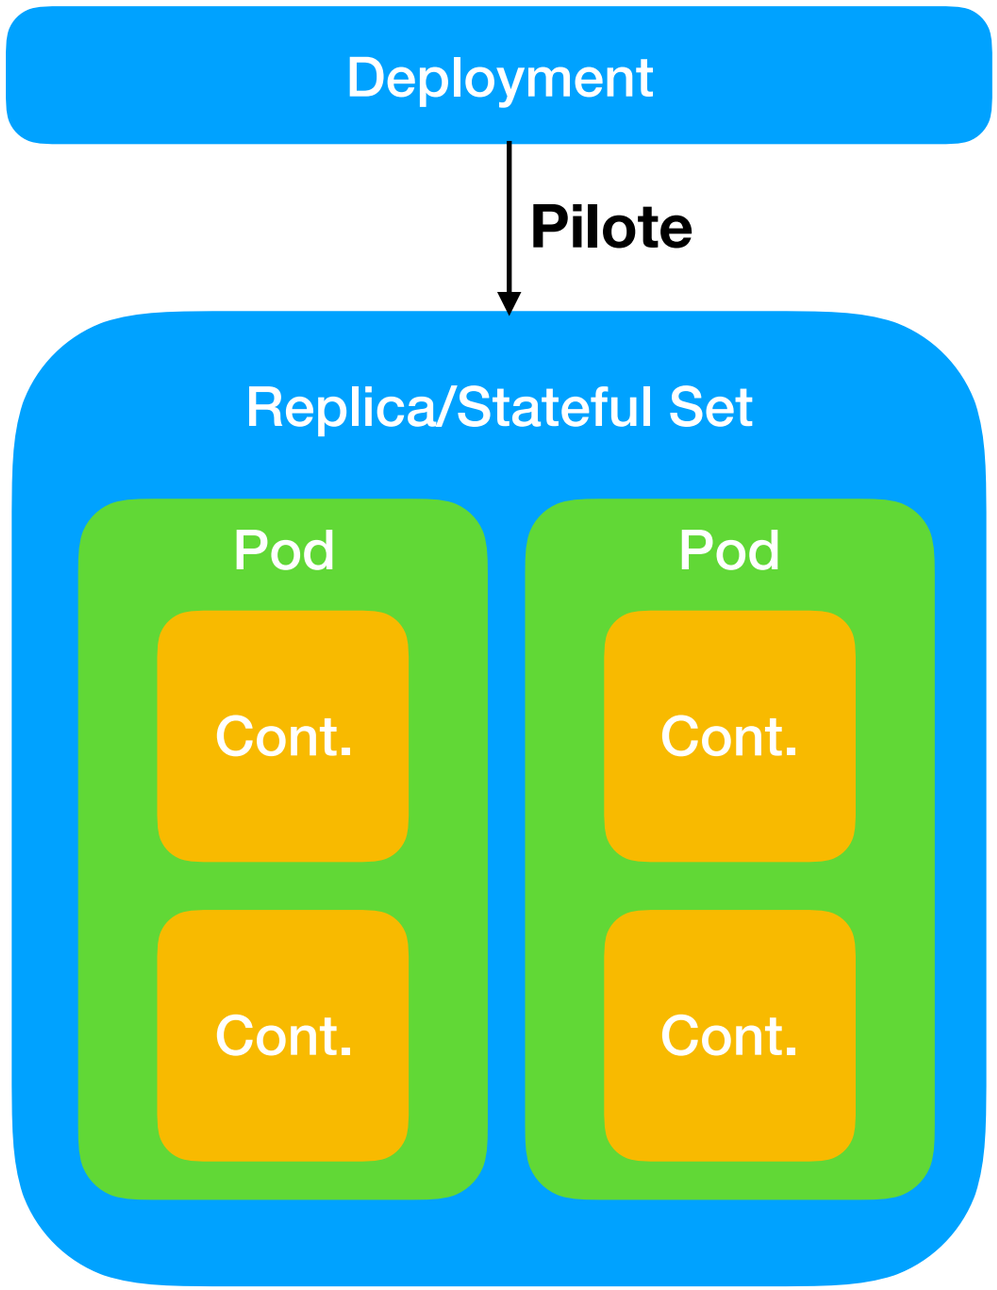

k8s: configuration

- à la Docker: command line, variables d'environnement
- ConfigMap:
    - dictionnaire clés-valeurs
    - visible comme un répertoire,
      clé ↔ fichier
      valeur ↔ contenu
    - ou visible via des variables d'environnement
    - gestion distincte des deployments
    - peut être partagée
- Secrets:
    - Similaire à ConfigMap, mais sécurisé

k8s: supervision applicative

- Health checks (probes)
    - Readyness / Liveness
    - différents types de sondes
        - commande exécutée dans le conteneur
        - requête HTTP
        - vérification port TCP
    - succès: code retour = 0
- À utiliser avec `restartPolicy`

Orchestration Batchs

- Processus à durée de vie limitée
- À gros grain, certaines problématiques similaires aux services
  - Supervision
  - Relance (partielle) en cas d’échec
- Nécessite parfois un accès privilégié à certains services
  → exécution au sein de l’environnement d’orchestration

k8s: Jobs

- Possibilité d’avoir plusieurs pods : parallèlisme
- Redémarrage en cas d’échec,
  avec limite sur le nombre d’essais
  - Attention à la restartPolicy: OnFailure ou Always
- Cron Jobs
- TTL Controllers: pour nettoyer les ressources
- Pas de système type Spring Batch pour redémarrer un job à mi-chemin

Orchestration
Stockage

- Partage de données entre différents conteneurs
- Persistence des données au delà de la vie des conteneurs
- Utilisation de systèmes de stockage externes fiables

k8s: volumes

- Système de volumes
  - Proche de celui de Docker dans l'usage
  - Plus générique
- Volume lié à un pod
  - même durée de vie
  - montable par les conteneurs du pod (possibilité de montage partagé)

k8s: stockage persistant

- Données à durée de vie plus longue que celle du pod
  - PersistentVolume : données
    - Hébergée en général sur un système tiers (e.g. Ceph, NFS)
  - PersistentVolumeClaim (PVC) : demande d’utilisation des données (binding)
  - Utilisation dans un pod: création d’un volume basé sur un certain PVC
- Peut être créé à la demande lors d’un déploiement de Stateful Set

Orchestration
Réseau et API Management

- Pouvoir questionner l'orchestrateur pour savoir qui fait quoi
- Fourniture de services réseau support
    - IPs virtuelles
    - DNS
    - Intégration de reverse proxies / de load balancers

k8s: services

- Points d’accès virtuel pour un XXX Set
- Peut intégrer un load balancer
- Permet d’offrir un point d’accès depuis l’extérieur du cluster

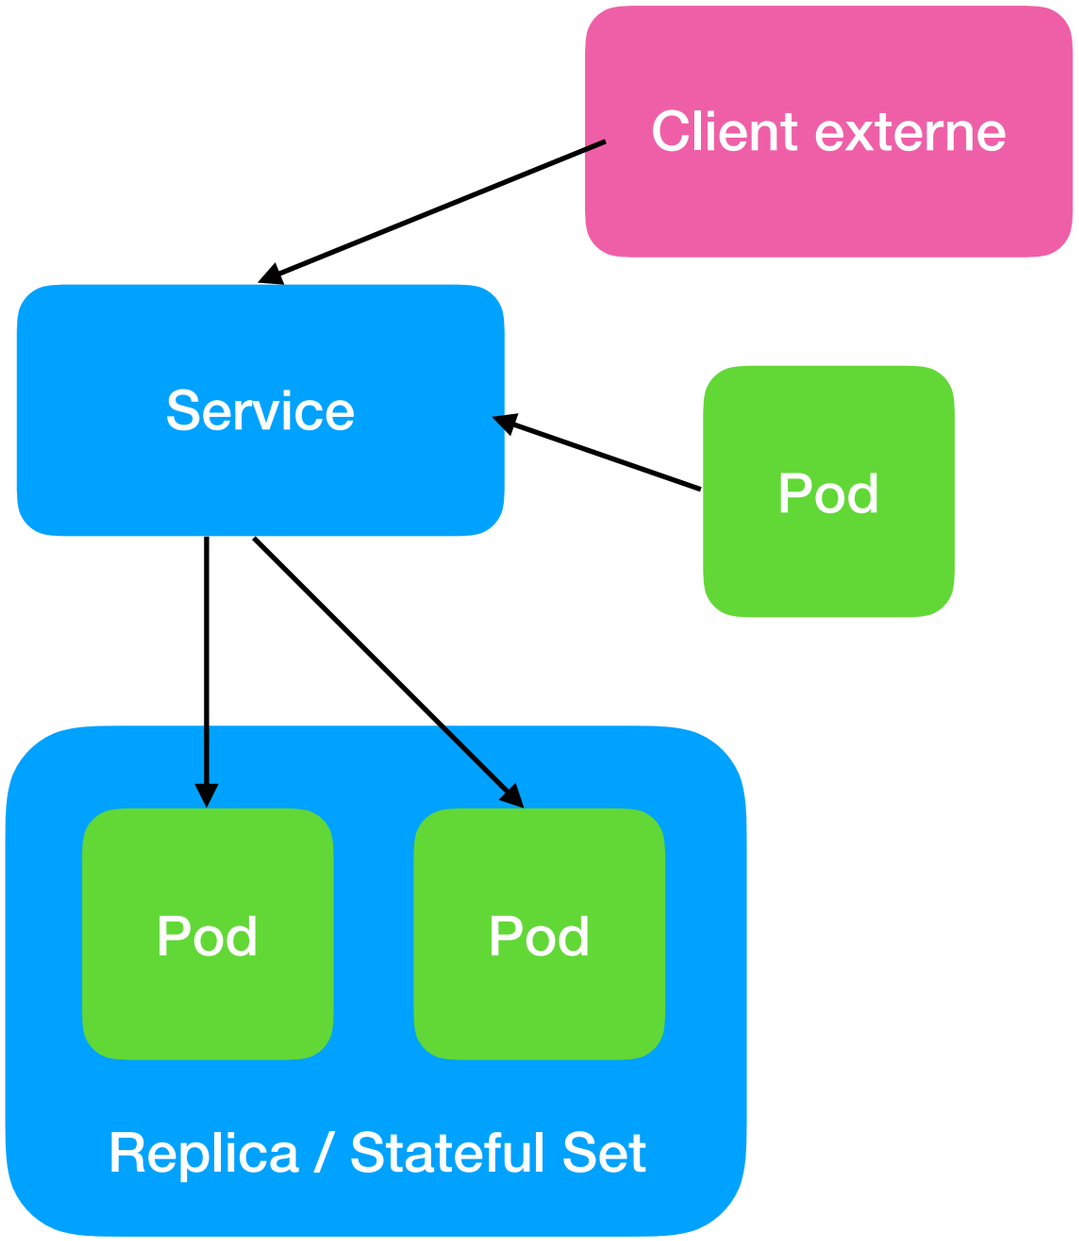

k8s: dns

- Plugin pour déployer un DNS interne:
  - Adresse pour chaque pod
  - Adresse pour chaque service

Orchestration
Sécurité et isolation

- Organisation des services en espaces logiques
- Possibilités d’isolation réseau
- Utilisateurs multiples et droits associés
- Limites imposées par pod/set/namespace

k8s: utilisateurs

- Deux types: humains vs pods (User vs Service Account)
- Authentification: mécanismes variés, possibilité d’injection par secret pour les Service Accounts
- Systèmes d’autorisations variés: RBAC, ABAC, etc

k8s: isolation réseau

- Network Policies
- Permet de restreindre l’accès à certains pods
  - traffic entrant et/ou sortant
  - pods/namespaces/ips

k8s: limitations de ressources

- Possibilité de limiter les ressources associées à un pod
  - Bonne pratique: toujours fixer des limites CPU/RAM
  - système de ressources ouvert, e.g.

```
        limits:
          nvidia.com/gpu: 1 # requesting 1 GPU
```