UNIVERSITÉ DE VERSAILLES ST-QUENTIN-EN-YVELINES

université PARIS-SACLAY

Génie Logiciel pour le Calcul Scientifique

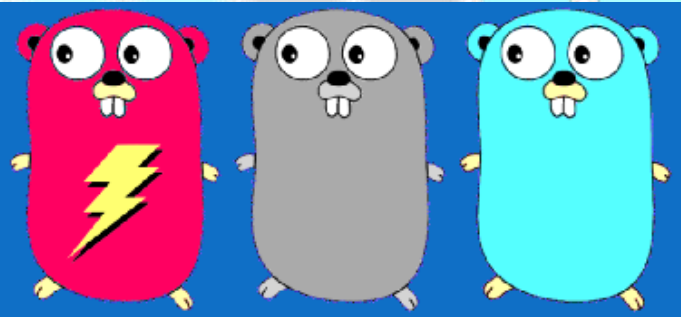

#12

26/02/2025

jean-michel.batto@cea.fr

cea

https://gogs.eldarsoft.com/M2_IHPS

2 approches du Service HPC

- Allocation de ressources dans une Grille
  - Crédit d'heure à consommer
  - Nombre de cœurs alloués
  - Interfaces de communication (MPI), système de fichier HPC
- ➔approche par la disponibilité de la ressource
  - Pb d'efficacité (saturation)
  - Pb de commutation de projet (nbre de nœud dispo/contrat)
  - Pb de priorité ➔ le prix est connu à la fin du traitement?
- ➔approche par la saturation de la ressource
  - L'application est atomisée (grain de temps de x ms)
  - Le prix de l'application est calculé en continu
  - Selon le niveau du prix – le grain peut être activé (== priorité), le batch peut être 'failed' et relancé plus tard.

Le cloud

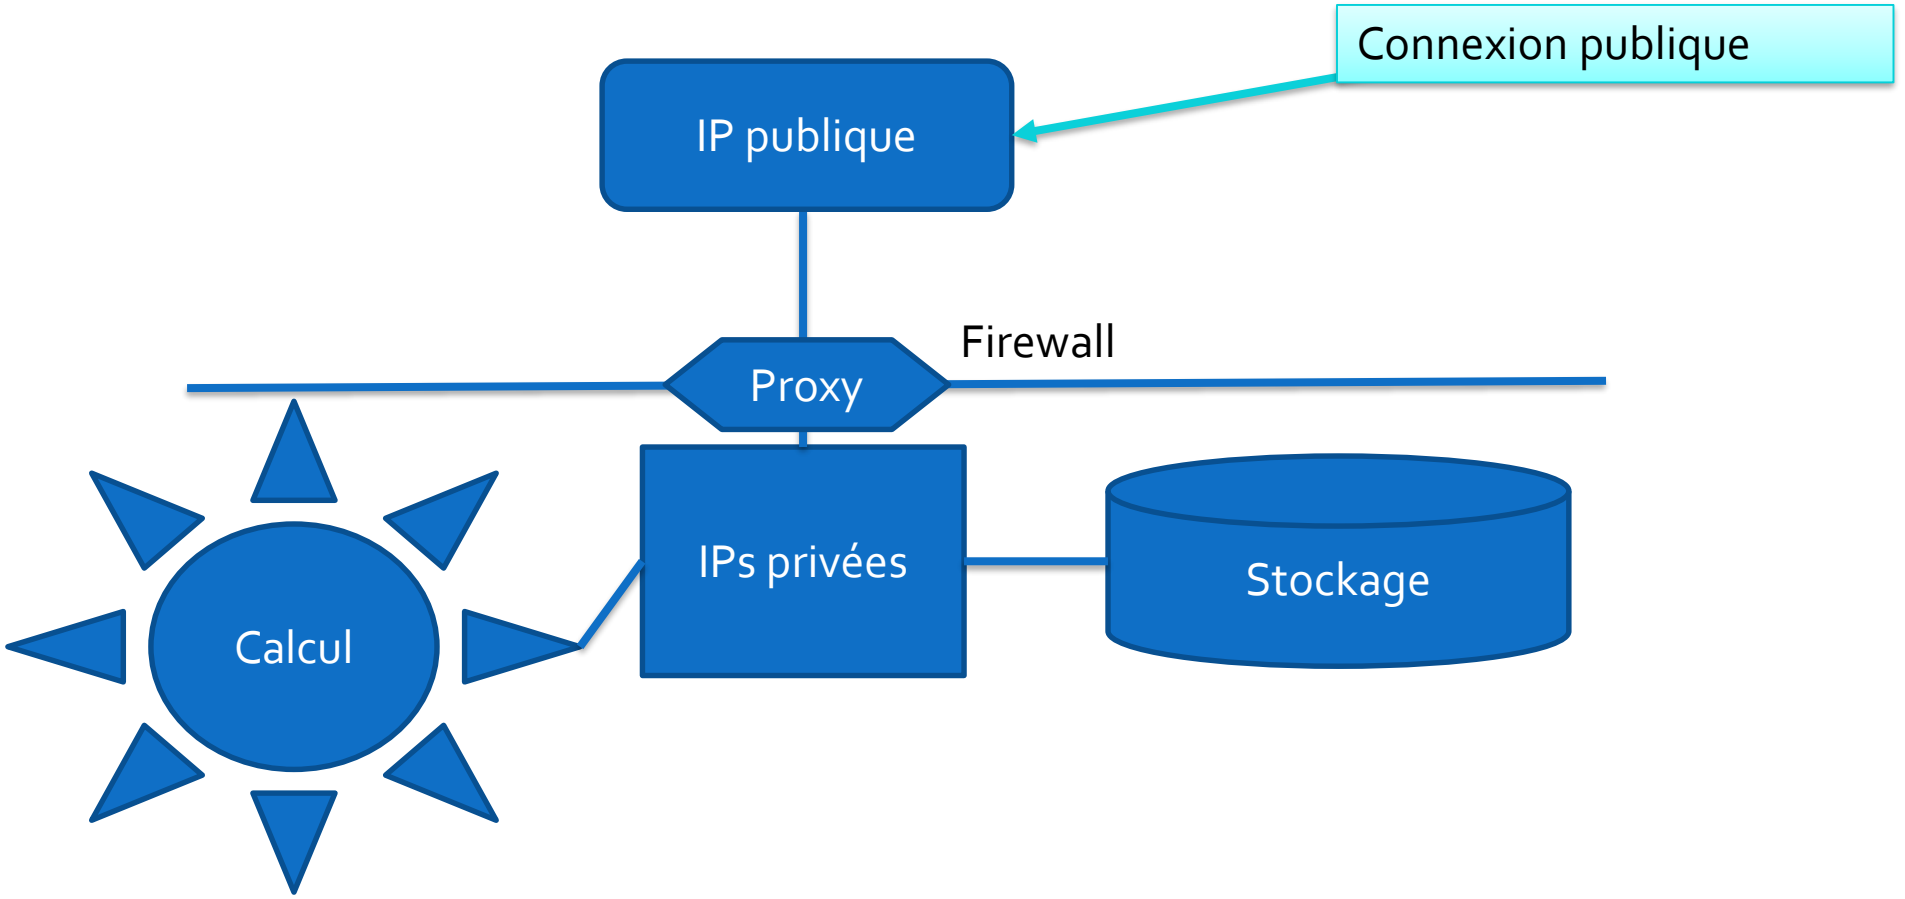
Connexion publique
IP publique
Firewall
Proxy
IPs privées
Stockage
Calcul

Le cloud : les services indispensables

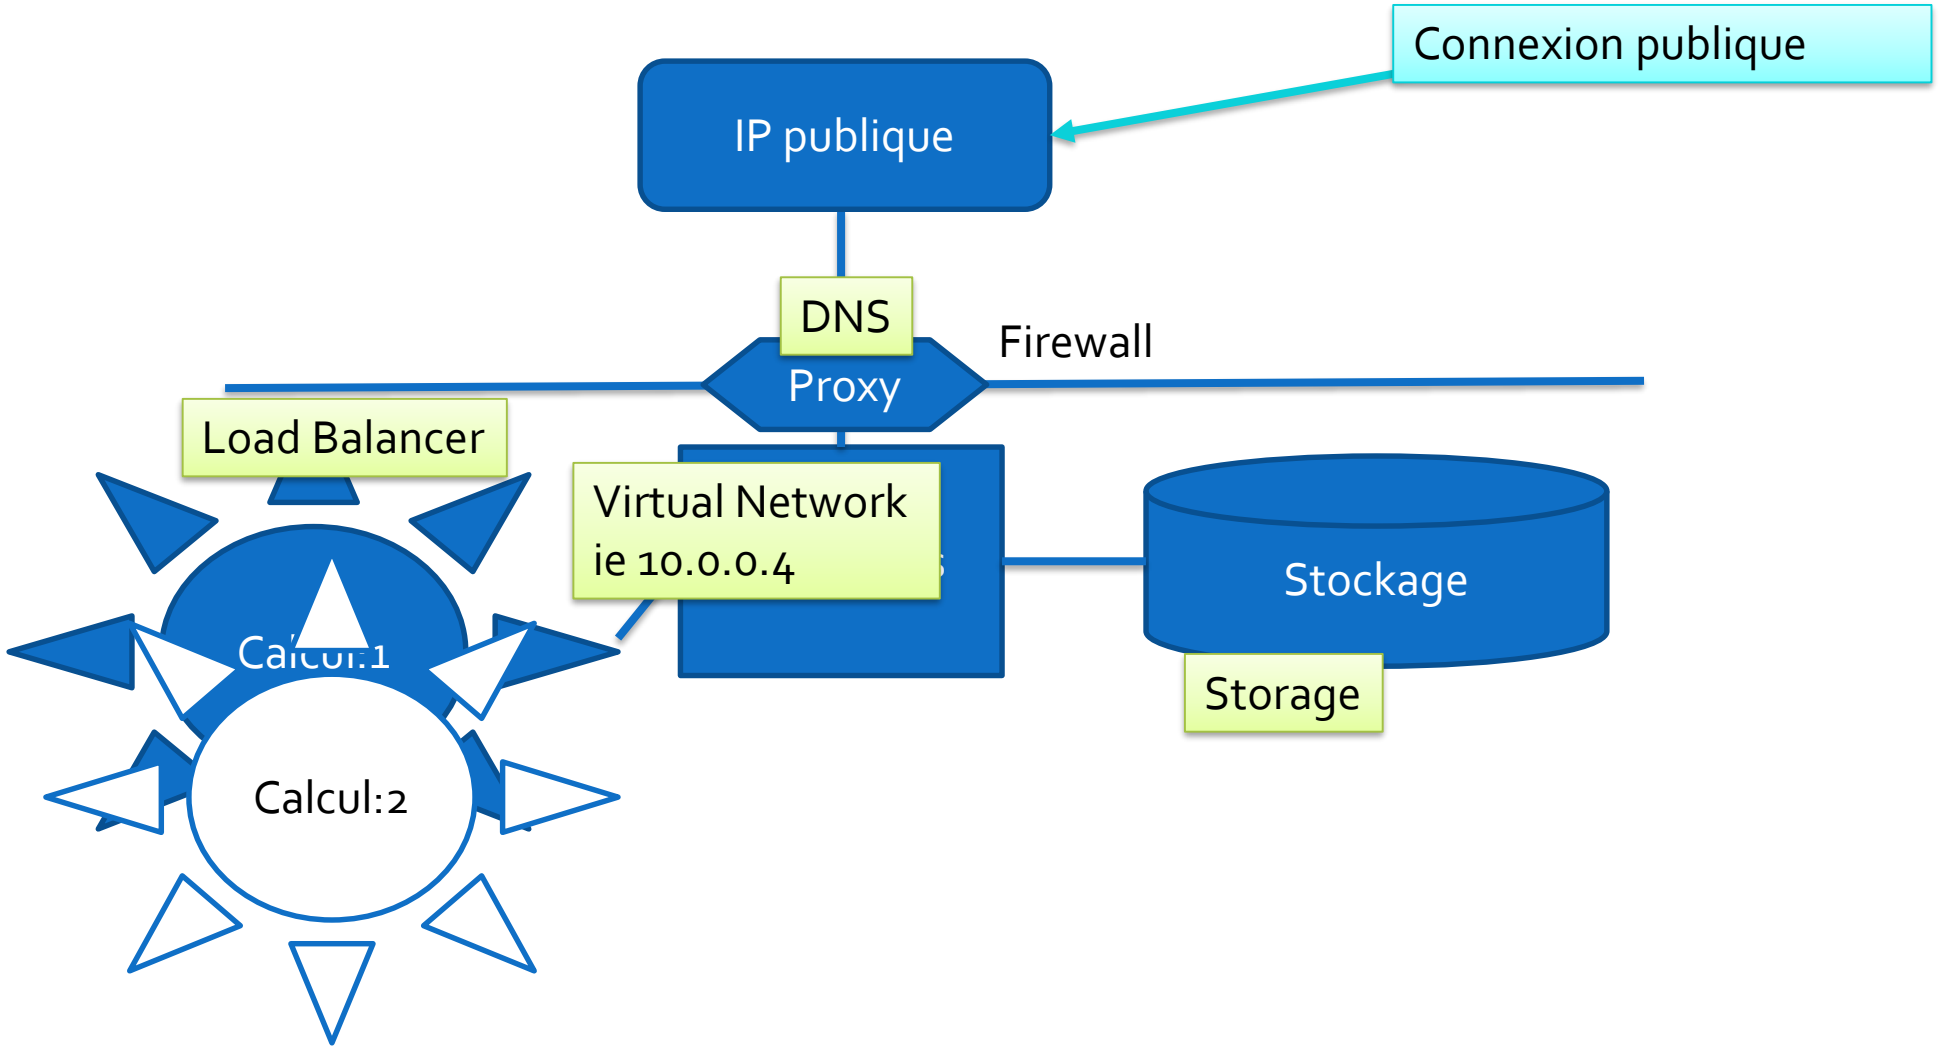

Sa spécialisation

Amazon utilise AWS (Amazon Web Services 2006)

Google propose GCP (Google Cloud Platform 2011)

➔logique métier interne pour le métier « de base »

Ensuite la logique métier s'est spécialisée dans 2 directions.

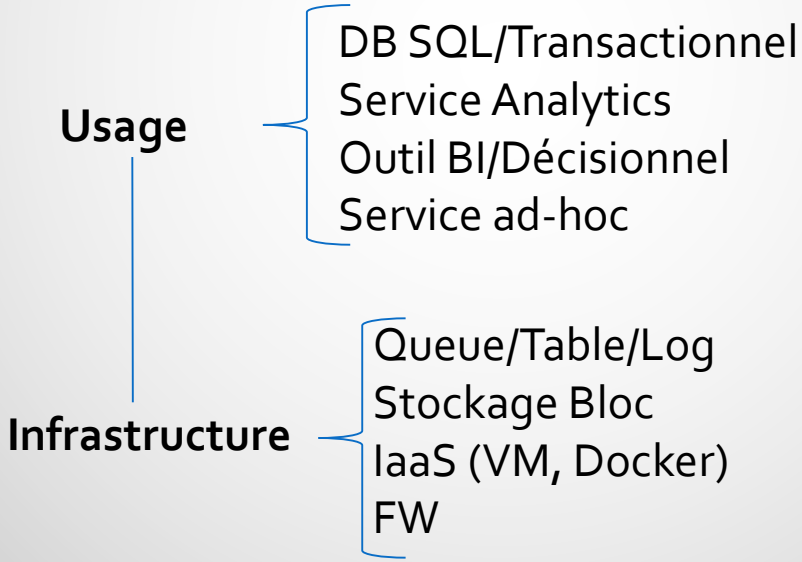

Service hébergé

- Axe haut : l'usage
  - Dans le domaine de l'analytique – il y a un leader de l'analytique **Vertica**
  - **Snowflake** propose des usages pour l'analytique avec une approche Share Nothing et cible différents Cloud (AWS, GCP, Azure)
- Axe bas : l'infrastructure (machine VM, stockage)
- ➔On achète un service hébergé

Tarification flottante

- SPOT AWS – un marché du service de calcul pour EC2
- Google "Preemptible VM Instances"
- Azure "Low-Priority VM"

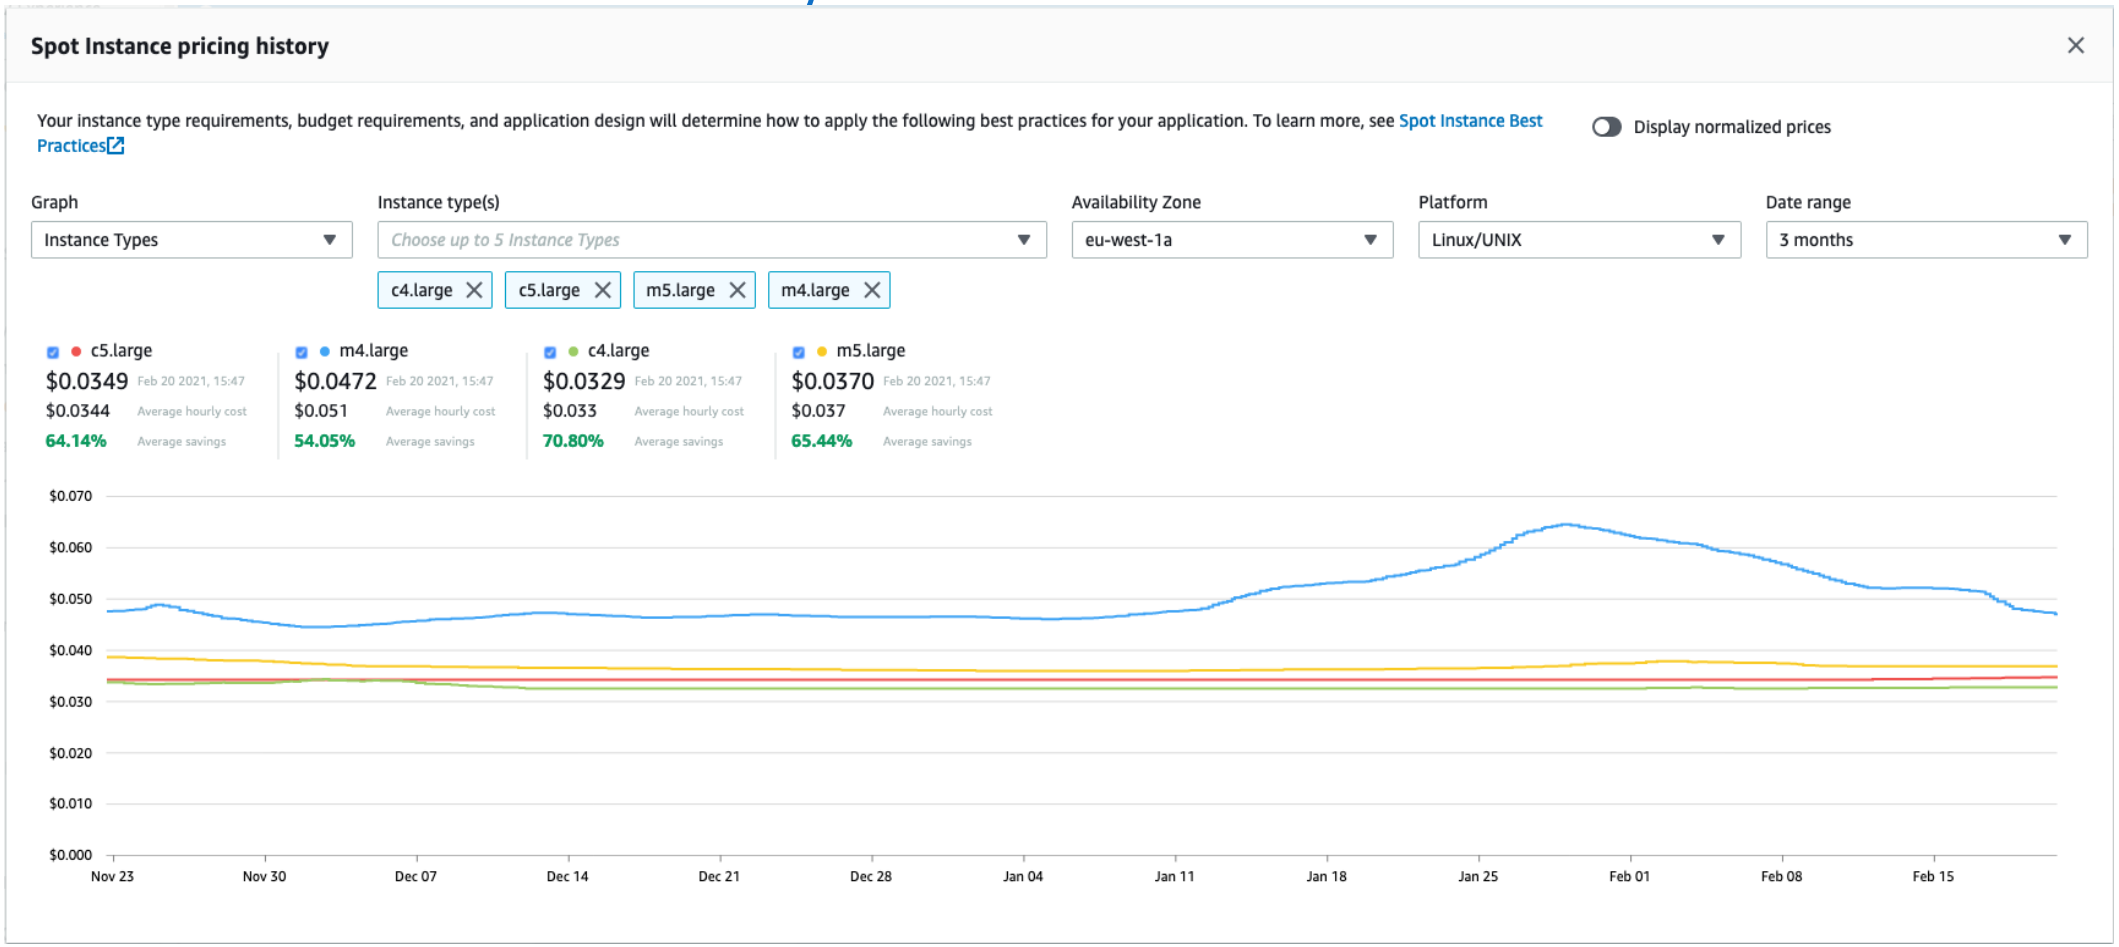

Lambda

- Concept atomique le plus poussé
- Les langages sont : Node.js, .Net, Python, Ruby, Java
- Go, Rust, C++
- Limite de 50 Mo pour le code de la fonction

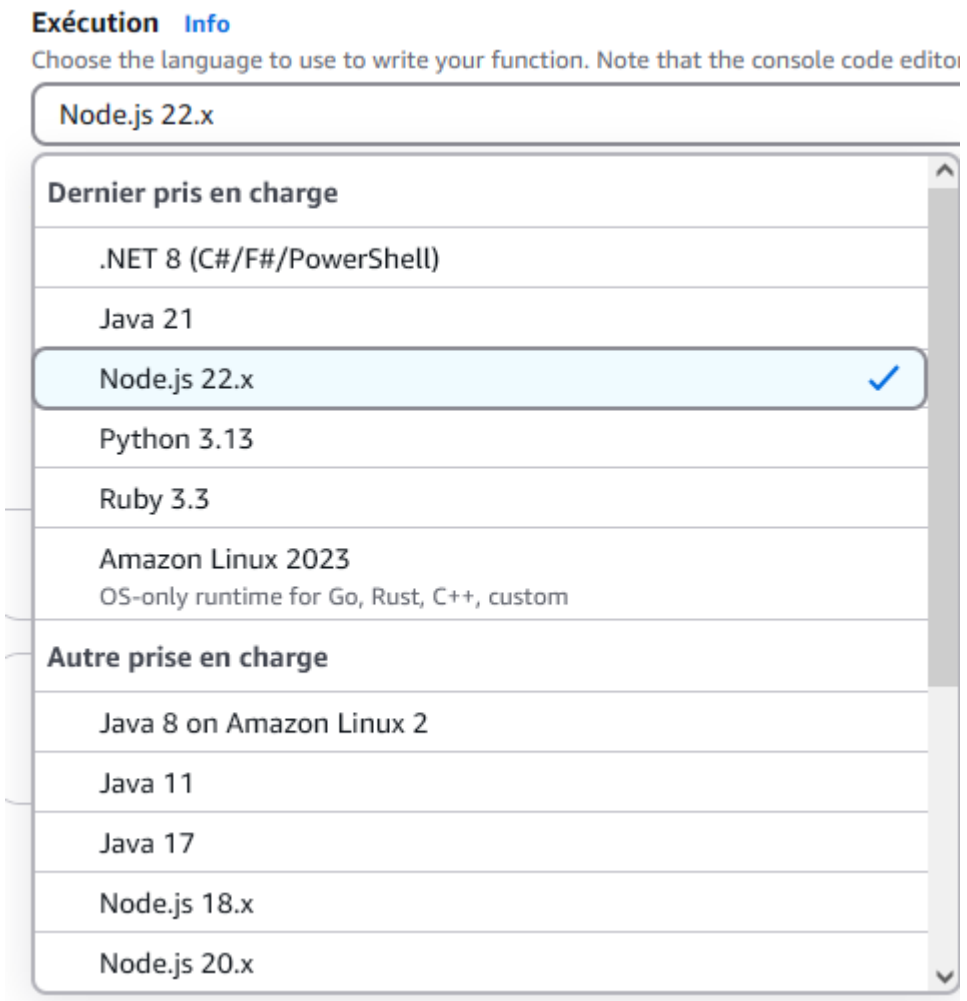

Modèle de vente de Lambda

- Grain 1 ms (100 ms typique)
- Cout de traitement **$0.20 pour 1M de requête**
- 0,0000166667 USD par Go-seconde ➔ à fractionner
- (par ex 128 mo = 1/8Go ; 1 sec = 1000 ms)
- **1M** de requêtes gratuites par mois
- **Jusqu'à 3,2 millions de secondes** de temps de calcul gratuit par mois

Prix (x86)	0,0000166667 USD par Go-seconde	0,20 USD par million de demandes

Le coût de la durée est fonction de la quantité de mémoire que vous attribuez à votre fonction. Vous pouvez allouer n'importe quelle quantité de mémoire (entre 128 Mo et 10 240 Mo) à votre fonction et ceci par tranches de 1 Mo. Le tableau ci-dessous contient quelques exemples de prix par tranche de 1 ms associés à différentes tailles de mémoire.

Prix (x86) | Prix (Arm)

Région : Europe (Paris)

Mémoire (Mo)	Tarif par 1 ms
128	0,0000000021 USD
512	0,0000000083 USD
1 024	0,0000000167 USD
1 536	0,0000000250 USD
2 048	0,0000000333 USD
3 072	0,0000000500 USD

- Avec option Edge, environ *3 sur le prix
- Pour moins de latence

Azure

Microsoft : a une approche « multi cible »

Propose Linux
Propose Windows
Propose de l'infrastructure
Propose des usages
Propose des services
➔540 produits! (février 2023)

Général	18
Compute	25
Networking	34
Storage	15
Web	16
Mobile	3
Containers	7
Databases	20
Analytics	15
AI	26
IoT	25
Mixed Reality	2
Intégration	26
Identité	22
Sécurité	23
Devops	8
Migration	8
Moniteur	10
Gouvernance	27
Multicloud	15
Autres	195
Total	**540**

Evolution 2023/2025

Catégorie	Février 2023	Février 2025 (estimé)	Commentaire
Général	18	20	Ajout de services transversaux comme Azure Arc ou nouveaux outils de gestion.
Compute	25	28	Nouvelles options de VM ou services serverless (ex. : Azure Functions évoluées).
Networking	34	37	Croissance avec 5G, SD-WAN, et extensions de Virtual Network.
Storage	15	17	Ajout de solutions comme Elastic SAN ou améliorations de Blob Storage.
Web	16	18	Nouveaux outils pour Web Apps ou intégration avec Azure Static Web Apps.
Mobile	3	4	Croissance lente, peut-être un nouveau service de push ou d'authentification.
Containers	7	9	Expansion avec Kubernetes (AKS) et Azure Container Storage.
Databases	20	23	Nouvelles bases optimisées (ex. : Cosmos DB amélioré ou PostgreSQL étendu).
Analytics	15	18	Croissance avec Synapse Analytics et real-time analytics.
AI	26	32	Forte expansion avec Azure AI Foundry, Copilot, et generative AI.
IoT	25	28	Nouveaux outils pour Edge AI et gestion de devices (ex. : Azure Sphere).
Mixed Reality	2	3	Léger développement, peut-être un outil lié à HoloLens ou partenaires.
Intégration	26	29	Croissance avec Logic Apps ou nouveaux connecteurs d'entreprise.
Identité	22	24	Ajout de fonctionnalités à Entra ID (ex. : authentification avancée).
Sécurité	23	27	Expansion avec Sentinel, Defender, et nouvelles protections DDoS.
DevOps	8	10	Améliorations d'Azure DevOps et intégration GitHub Actions.
Migration	8	9	Nouveaux outils pour migrations hybrides ou multicloud.
Moniteur	10	12	Croissance avec Azure Monitor et dashboards avancés.
Gouvernance	27	30	Nouvelles politiques Azure Policy et sustainability dashboards.
Multicloud	15	18	Expansion d'Azure Arc pour AWS/GCP et interopérabilité.
Autres	195	205	Ajout de services divers non catégorisés ou expérimentaux.
Total	540	591	Croissance globale cohérente avec l'évolution d'Azure.

Lambda : idée du service atomique

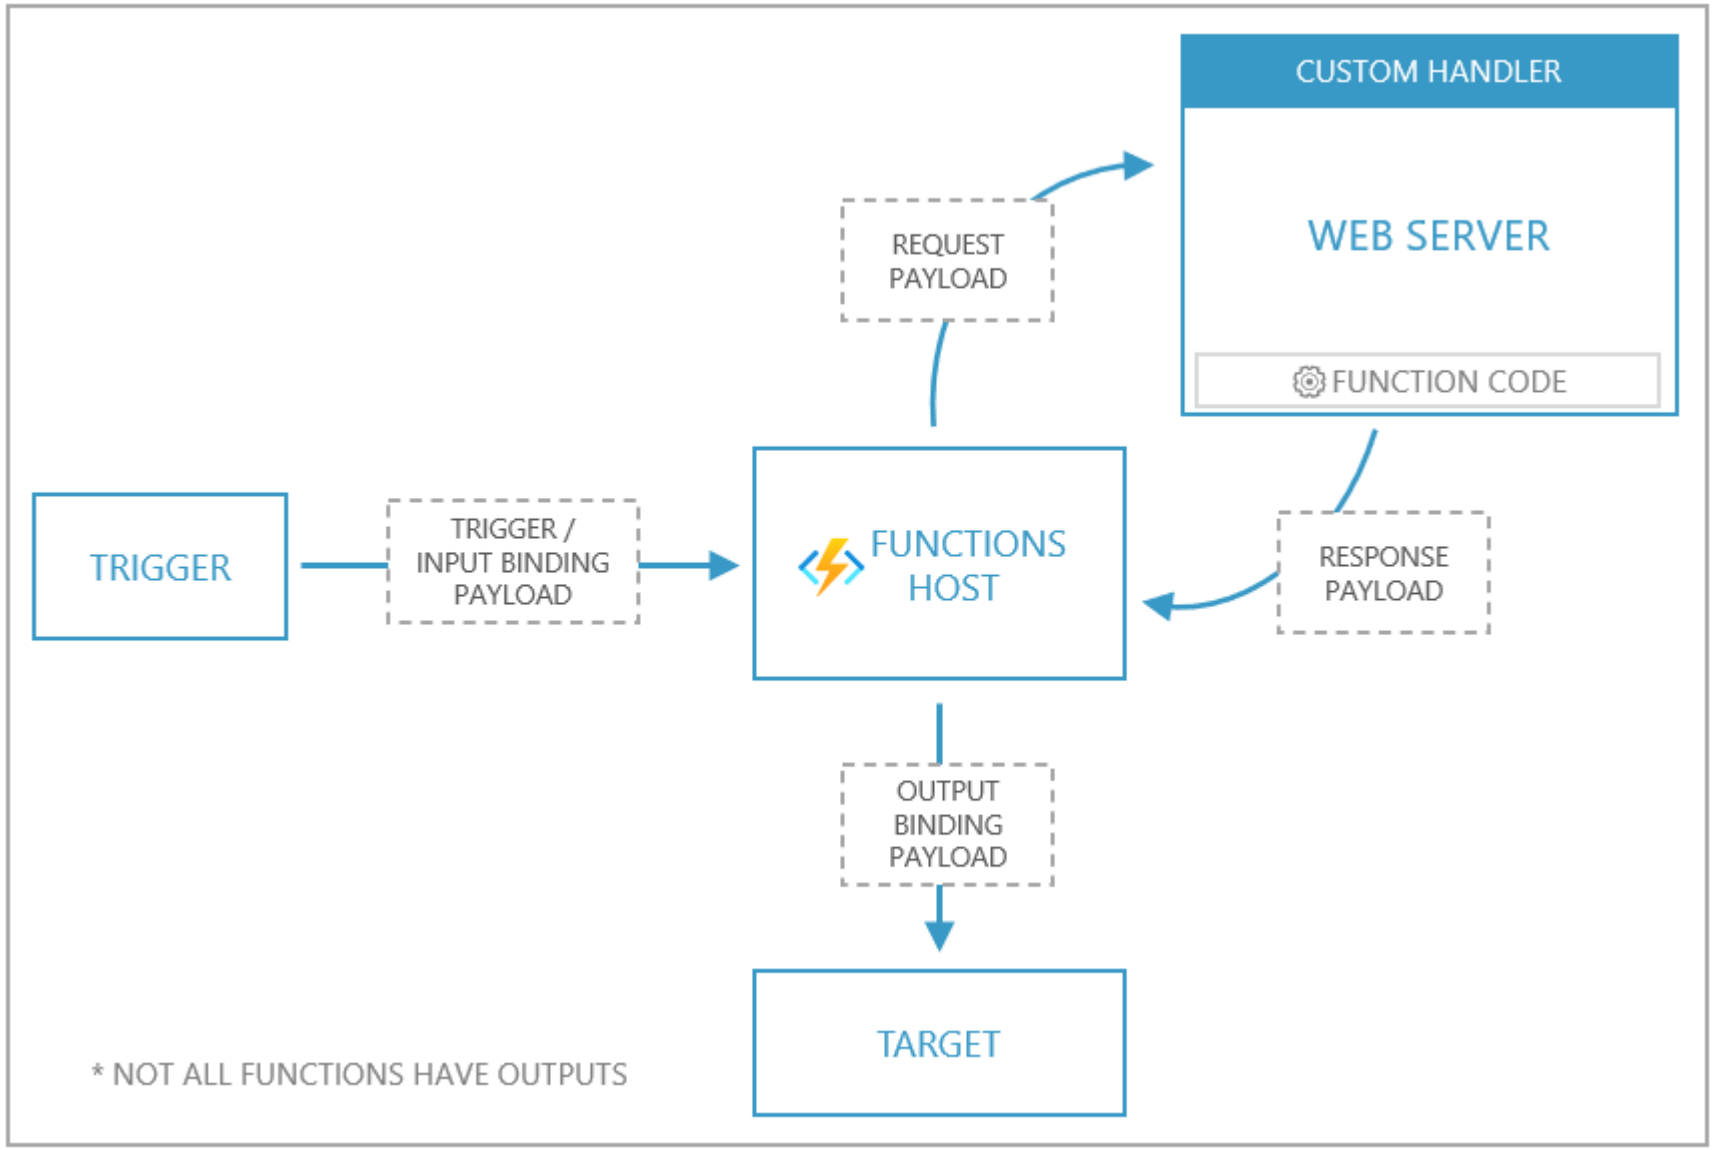

https://docs.microsoft.com/en-us/learn/modules/serverless-go/2-custom-handlers

Serverless Azure

3 approches **Serverless** chez Azure

- Azure Functions = Lambda
- Azure Service Fabric Cluster (Docker avec ou sans Kubernetes)

➔ capacité à être déployé sur plusieurs nœuds en même temps

- Azure Container Instances = Docker

Function App – un service à l'écoute avec un handler

- Serverless (sans contrat sur la cible)

6 langages managés : Python / Java / C# .NET / Node.JS / TypeScript / Powershell (BASH)

1 option : Custom Handler = cible binaire sur linux64

- Serverless avec contrat sur le type de server (image Docker)

Function Premium (Serverless avec isolation)

App Service Plan (partage d'un même plan entre plusieurs Function App)

Container (Docker) Azure

Azure Container Instances – un service à l'écoute d'un port

- OS : Windows Server 2016 ou Linux
- Endpoint : le port qui exposé au publique, le nom du service
- Portbinding, Endpointref : le port qui est liée à l'image Docker et au nom du service
- Docker HEALTHCHECK ➔ donne l'état du service

Serverless Azure

Option	Capacité à spécifier l'OS hote	Gestion à réaliser par soi même	Devops – intégration continue	Orchestration
Azure Function (FaaS)	NON	NON	partiel	S/O
Azure Service Fabric	limité	limité	partiel	OUI
Azure Container Service	limité	limité	partiel	partiel
VM Azure	OUI	OUI	NON	S/O

- Azure Functions est idéal pour des applications serverless avec un minimum de gestion, mais il manque de flexibilité pour l'orchestration ou la personnalisation de l'OS.
- Azure Service Fabric et Azure Container Service offrent un équilibre entre gestion automatisée et contrôle, avec des capacités d'orchestration, mais avec des limites dans la personnalisation ou la gestion.
- VM Azure donne le plus de contrôle (spécification complète de l'OS et gestion totale), mais exige plus d'efforts de la part de l'utilisateur, sans support natif pour l'intégration continue ou l'orchestration.

Lambda

	AWS	Azure	GCP
Nom du service	Lambda	Functions	Cloud functions
Langage spécifique autre que Python / Java / C# .NET / Node.JS	Go, Ruby, C++	TypeScript	Go, PHP, Ruby
Orchestration	Step functions	Logic Apps	Workflow
Monitoring	Log, Application, Metrics	Log, Application, Metrics	Log, Application, Metrics
Triggers	HTTP, queue, timer, storage, DB, S3	HTTP, queue, timer, storage BLOB, cosmos DB	HTTP, queue, timer, storage

Stockage S3

Inventé en 2006 par AWS
Stockage bloc – avec une notion de bucket – taille max 5To
ID du bucket : 63 caractères – ID unique global
L'écriture se fait par ajout de bloc (512 octets à 4 Mo)

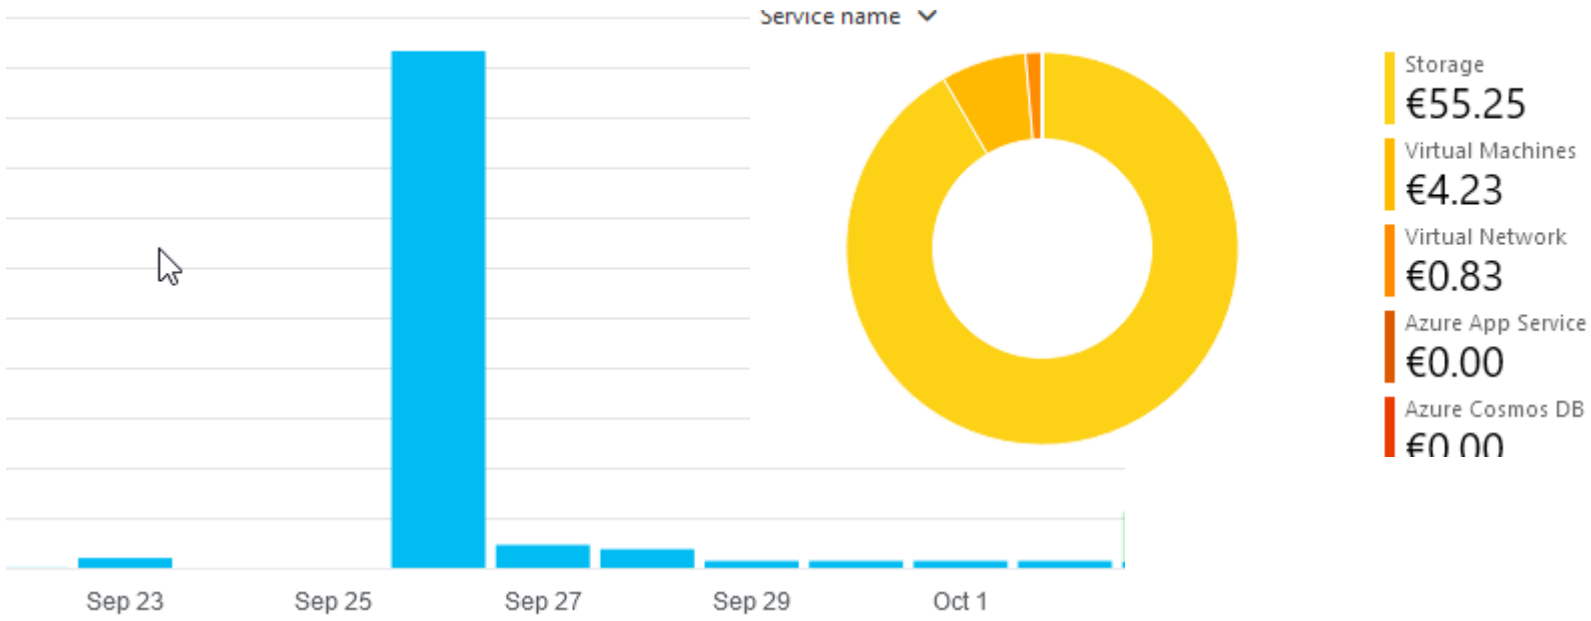

La gestion des droits (Azure)

Gestion des droits d'accès : RBAC puis ACL
RBAC : **Role-based access control (prime sur ACL)**

ACL : Access Control List

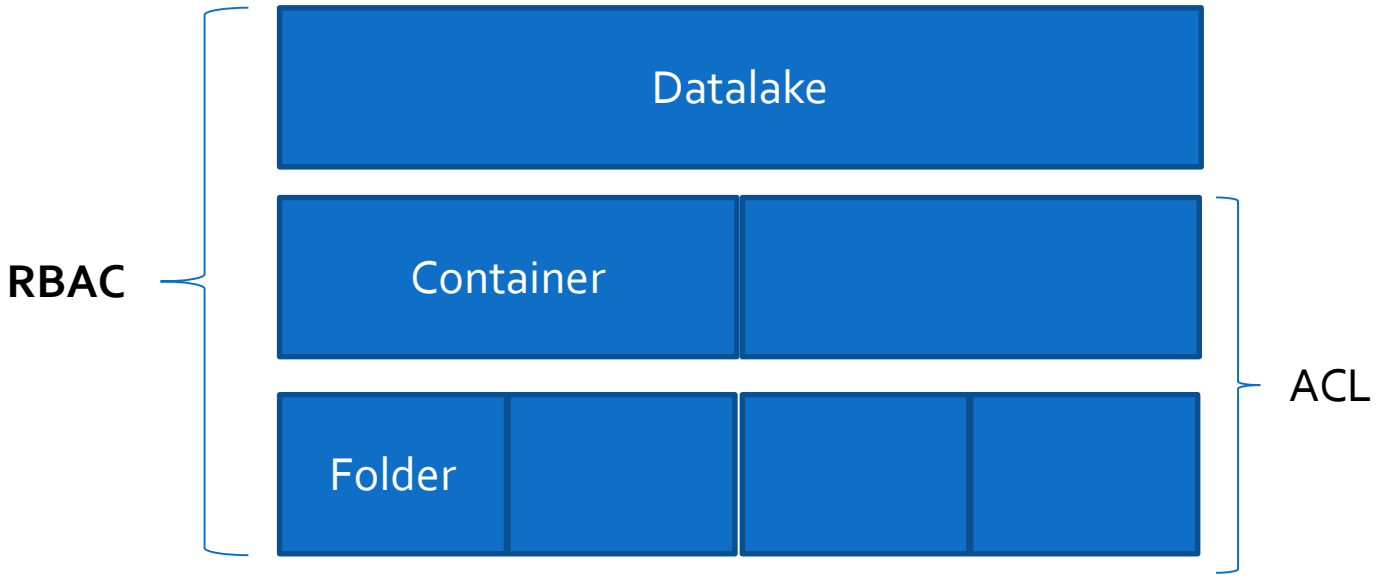

Redondance du stockage

- **Read-Access Geo-Redundant Storage (RA-GRS)**
- **➔Read Access : activation en lecture seule en cas de défaut**
- **Geo-Redundant Storage (GRS)**
- **Zone Redundant Storage (ZRS)**
- **Locally Redundant Storage (LRS)**

	AWS	Azure	GCP
Localized replication	Selon S_3	LRS, ZRS	?
Cross Regional replication	CRR	GRS, RA-GRS	Multi-region

Cout du Cloud

Par mois	Azure	GCP	AWS	OVH
Stockage S3 (3To) – +1 Million opération de lecture **Pas de réplication**	60€	60€	70€	60€
Opération Ecriture SFTP 500 Mo	6,50€			
FaaS		https://cloud.google.com/functions/pricing?hl=fr		Non
DBaaS MySQL (le moins cher)	8 Go Ram 160€	db-g1-small HD* // 1.7Go Ram 51€		Essential DB1-4 // 4Go Ram 50€
IaaS (plus petite machine)	15€			5,5€

500 Mo SFTP par bloc de 512octets = (100*10 000 opérations*512 octets)
100*0,06 € =6+0,26€/h pour le transfert en 2h

https://azure.microsoft.com/fr-fr/pricing/calculator/

Fonction HTTP à volume élevé (GCP)

Fonction HTTP de complexité moyenne avec 256 Mo de mémoire et un processeur de 400 MHz, appelée 50 millions de fois par mois via HTTP, s'exécutant pendant 500 ms à chaque fois et renvoyant 5 Ko de données à l'appelant (5 Ko en sortie par appel).

Calculs

Appels

50 000 000

Temps de calcul

(256 Mo / 1 024 Mo/Go) x 0,5 s = 0,125 Go-seconde par appel

(400 MHz / 1 000 MHz/GHz) x 0,5 s = 0,200 GHz-seconde par appel

50 000 000 d'appels x 0,125 Go-seconde = 6 250 000 Go-seconde par mois

50 000 000 d'appels x 0,200 GHz-seconde = 10 000 000 GHz-seconde par mois

Mise en réseau

50 000 000 d'appels x (5 Ko / 1 024 Ko/Mo / 1 024 Mo/Go) = 238,42 Go de trafic de sortie par mois

Métrique	Valeur brute	Version gratuite	Valeur nette	Prix unitaire	Prix total
Appels	50 000 000	2 000 000	48 000 000	0,0000004 $	19,20 $
Go-seconde	6 250 000	400 000	5 850 000	0,0000025 $	14,63 $
GHz-seconde	10 000 000	200 000	9 800 000	0,0000100 $	98,00 $
Mise en réseau	238,42	5	233,42	0,12 $	28,01 $
Total par mois					159,84 $

Optimisation

Optimisation par le choix du bon service Azure

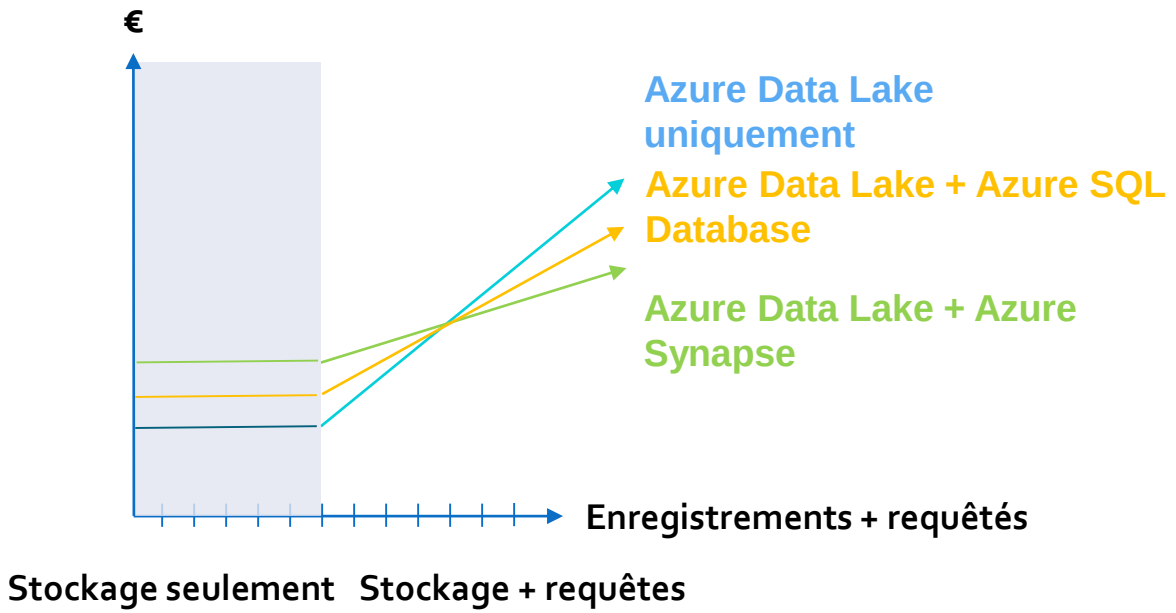

Optimisation

Optimisation par l'interruption de service

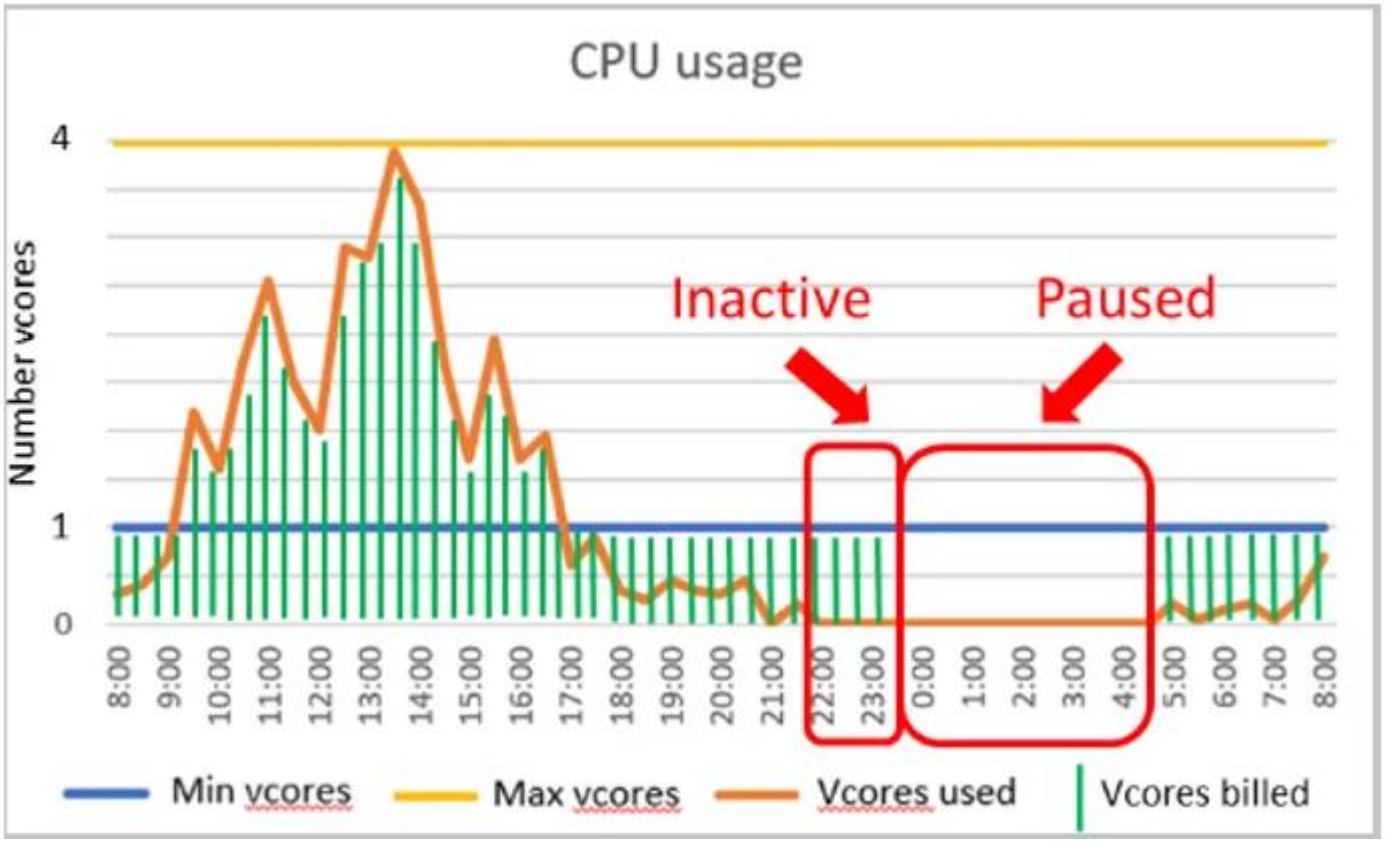

https://kohera.be/azure-cloud/should-i-use-serverless-for-all-my-azure-sql-databases/

Quels sont les problèmes du client?

- RGPD
- Entrée/Sortie (20 fois plus lent (8kb/s vs 180 kb/s) lorsque l'écriture provient de l'extérieur du subnet Azure)
- Réversibilité des services

Faut-il des services en nuages souverains ?FaaS, AWS Lambda, Serverless Computing Laurent Bloch

Les services en Clouds sont de trois + une sortes :

– IaaS, *Infrastructure as a Service*, ce sont des serveurs nus, à charge pour le client d'y installer système d'exploitation, logiciels et bases de données. OVH, Scaleway (*i.e.* Iliad) font cela très bien.

– Paas, *Platform as a Service*, là les serveurs sont configurés par le fournisseur avec un système d'exploitation (plusieurs choix possibles) et certains logiciels, SGBD, serveur Web, bureautique collaborative… Là aussi, il y a une offre française et européenne crédible, OVH et Scaleway mais pas seulement, y compris à base de logiciels libres. Pour information, toute l'offre AWS et Google est à base de logiciels soit libres, soit développés par eux, pas stupides au point de se mettre dans les griffes d'Oracle et de Microsoft (le déplorable Office 365).

– SaaS, *Software as a Service*, là évidemment Oracle et Microsoft Azure servent leur soupe, dont les administrations françaises souhaitent se goinfrer, en quoi elles ont bien tort. Cet appétit coûteux pourrait se voir substituer un virage vers les logiciels libres, qui offrent aujourd'hui des services de qualité équivalente, mais il s'agit là d'un travail de longue haleine, qui aurait dû être entrepris il y a longtemps. AWS et Google ont aussi développé une offre de services qui ne pourra être concurrencée du jour au lendemain. Cela dit, les réglementations merveilleuses qui encadrent nos services publics créent justement une niche pour des logiciels spécifiques tout aussi merveilleux, qui n'existent nulle part ailleurs, et qu'une administration moins paresseuse devrait développer.

Est apparue plus récemment une quatrième variété de services :

– FaaS, *Function as a Service*, illustrée par AWS Lambda : le client charge son code, sous forme d'un conteneur, sur une plate-forme configurée à cet effet, et par ailleurs il paramètre un serveur qui se chargera d'en déclencher l'exécution, en fonction d'événements survenus dans les données, par exemple échéance d'un paiement.

Les services FaaS, combinés avec les services **BaaS** (*Backend as a Service*, soit du stockage de données sous diverses formes au choix), constituent le dernier truc à la mode, mais qui est effectivement très prometteur, le *Serverless Computing* : on créée ses programmes d'applications en FaaS, on balance ses données dans le BaaS, et roulez carrosse, on n'a plus à se préoccuper de dimensionner les infrastructures, ni de les configurer, l'orchestrateur du fournisseur de services fait cela automatiquement, et comme ce fournisseur amortit les pics de demande sur une grande quantité de services aux clients, c'est bon marché. Ce type d'offre semble promis à un grand avenir.

Il faut savoir, d'autre part, que les GAFAM ont très bien verrouillé leurs plates-formes : si on a signé avec Microsoft Azure, il sera très difficile et très coûteux de changer de fournisseur quelques années plus tard, fût-ce pour AWS (ou vice-versa).

Amazon travaille ce terrain depuis 14 ans, avec des dizaines de milliers d'ingénieurs et une trésorerie en béton. Cela dit, toute leur infrastructure repose sur une base de logiciels libres, et renoncer à construire quelque chose en France ou en Europe serait criminel, parce que c'est vital et qu'il n'y aura pas de retour en arrière. Nous allons avoir droit au bavardage habituel : *« ce ne sont que des services, des "commodités", pas le cœur de métier »*. Si justement, c'est le coeur de tous les métiers aujourd'hui. C'est ainsi qu'Amazon dévore La Redoute, Darty, la Fnac, etc.

Laurent Bloch

Paru le 19 novembre 2021 sur le site de Laurent Bloch.
https://laurentbloch.net/MySpip3/Faut-il-des-services-en-nuages-souverains

❖ Azure registry

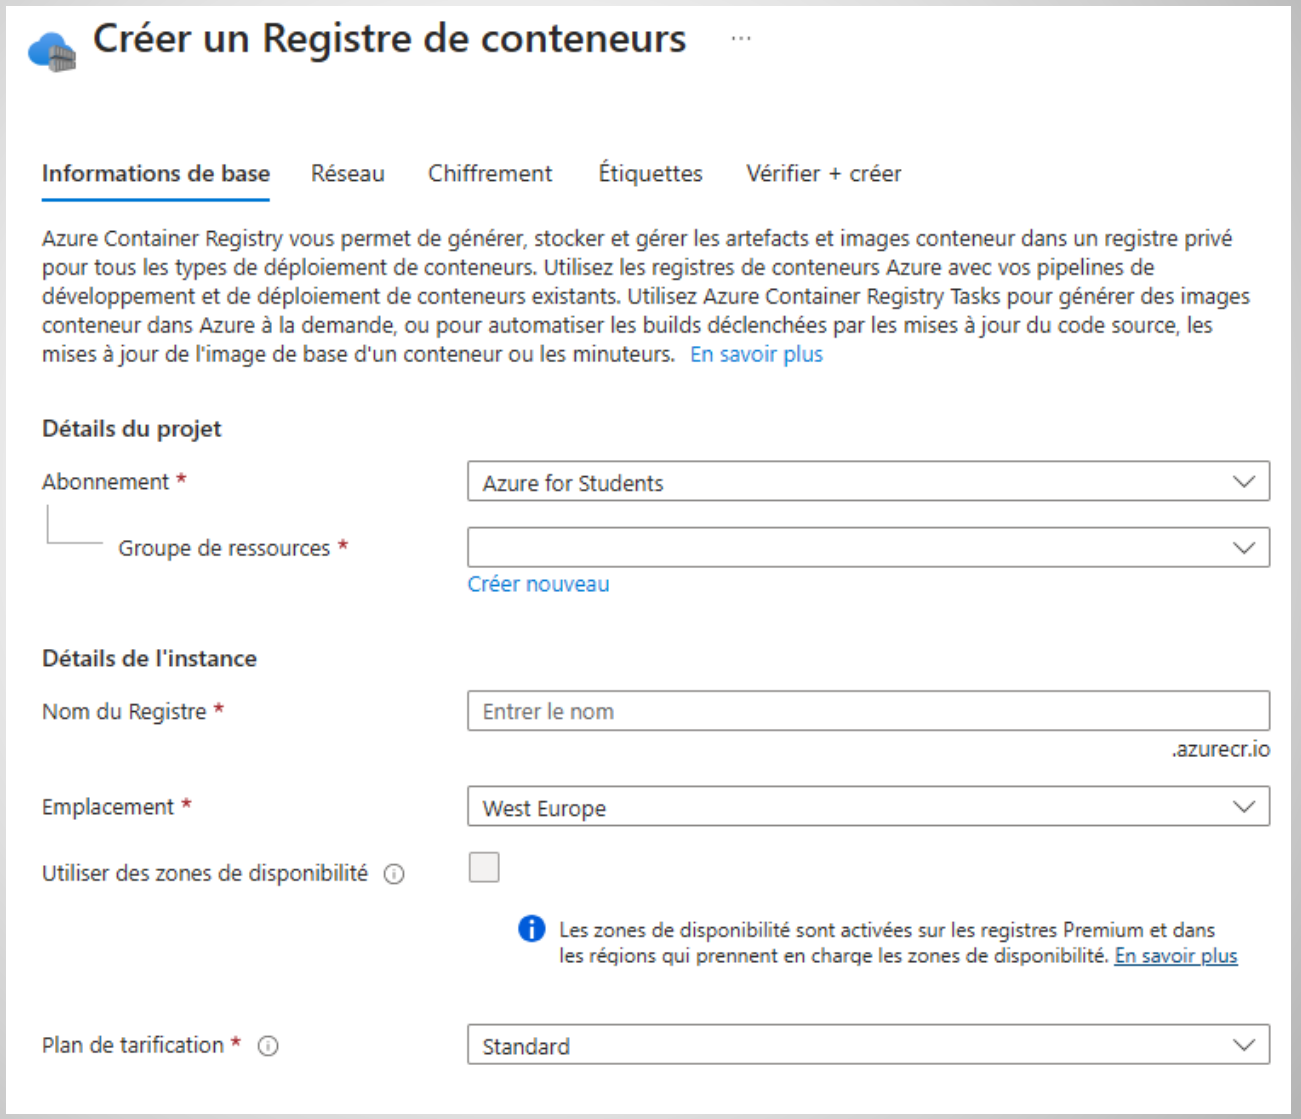

Construire une image dans la registry Azure

- 1/vous avez une registry tenetreg (le nom de votre choix…) attention choisir l'option
- 2/vous avez installé le client azure sur votre machine

```
apt-get install azure-cli
az login
```

- 3/on doit se loguer dans sa registry sinon pas de push

```
az acr login -n tenetreg
```

- 4/on récupère un repo d'intérêt

```
git clone https://github.com/philhawthorne/docker-influxdb-grafana.git
```

- 5/construction de l'image Docker

```
docker build -t docker-influxdb-grafana:latest .
```

- 6/on change les noms des images

```
docker tag docker.io/library/docker-influxdb-grafana tenetreg.azurecr.io/docker-influxdb-grafana
docker tag docker.io/library/docker-influxdb-grafana:latest tenetreg.azurecr.io/docker-influxdb-grafana:latest
```

- docker image ls ➔permet de vérifier
- 7/on le push vers notre registry

```
docker push tenetreg.azurecr.io/docker-influxdb-grafana:latest
```

- 8/on donne le droit de télécharger l'image sans login

```
az acr update --name tenetreg --anonymous-pull-enabled
```

TD Azure

- Objectif :
  - Prise en main en 2 étapes
    - Instancier un Container Serverless (container instance)
    - Instancier un Container App Serverless
- Pour utiliser le container (port 80/443) – il faut faire du NAT ou avoir un reverse proxy (traefik) ➔ d'où le container App

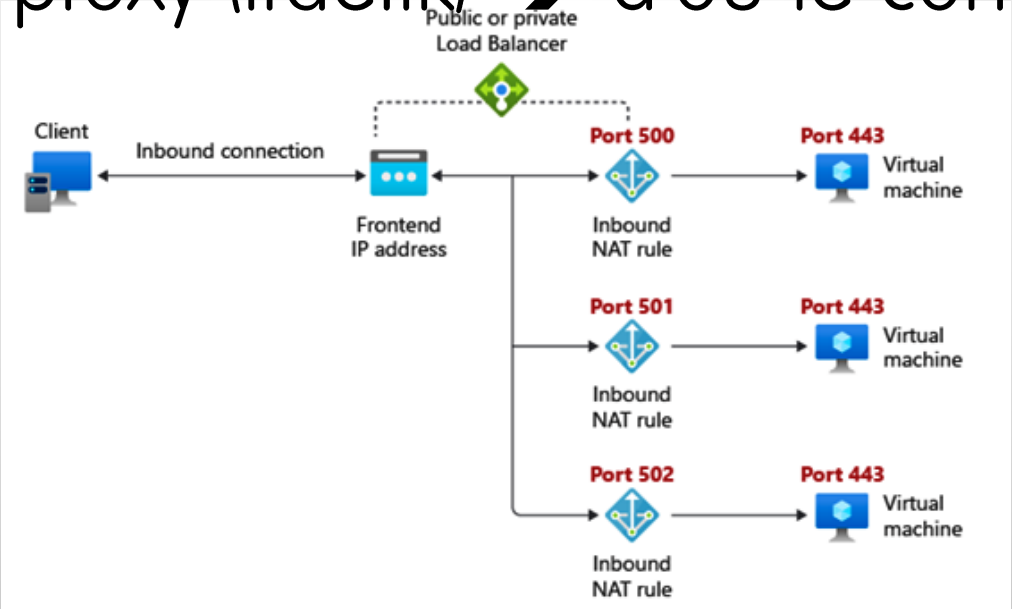

- Basculer en anglais

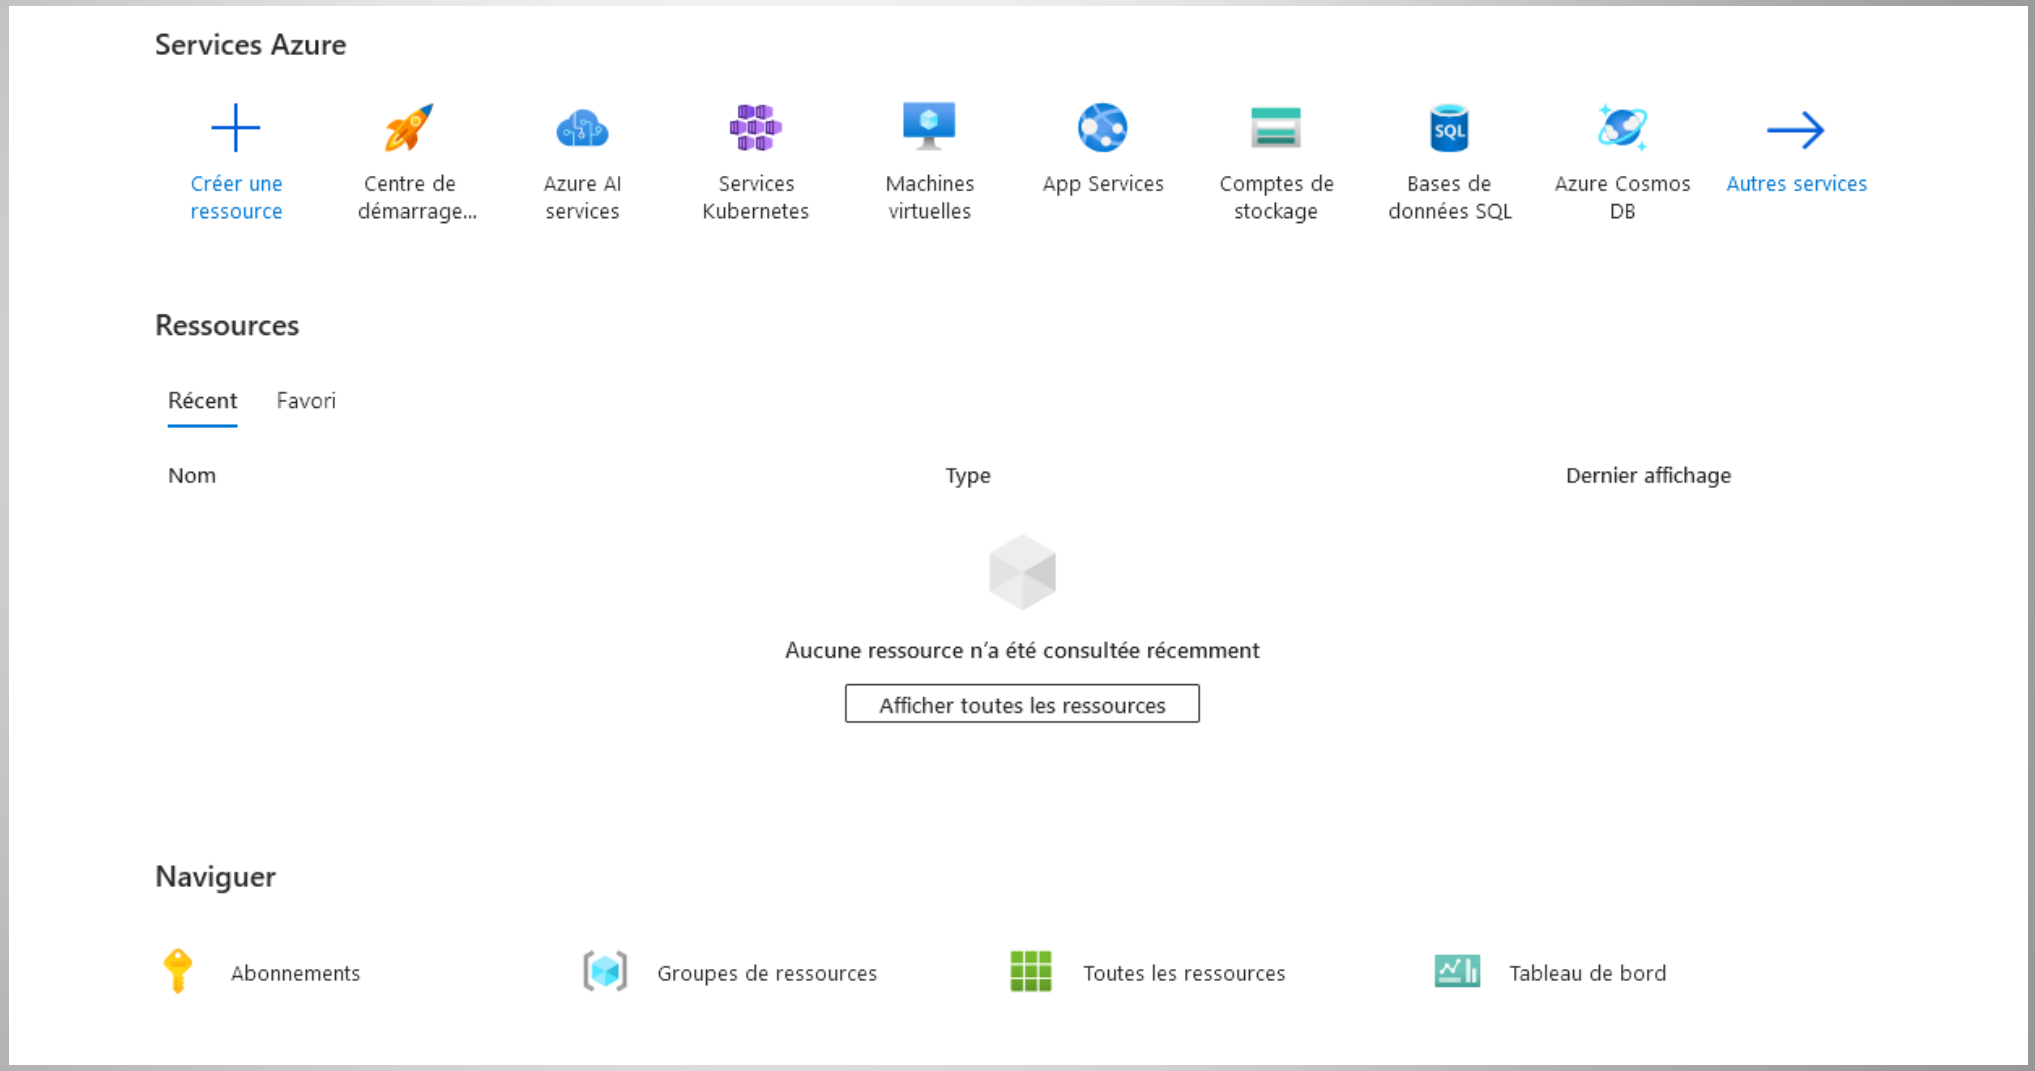

TD Azure

- Le plus important : le budget

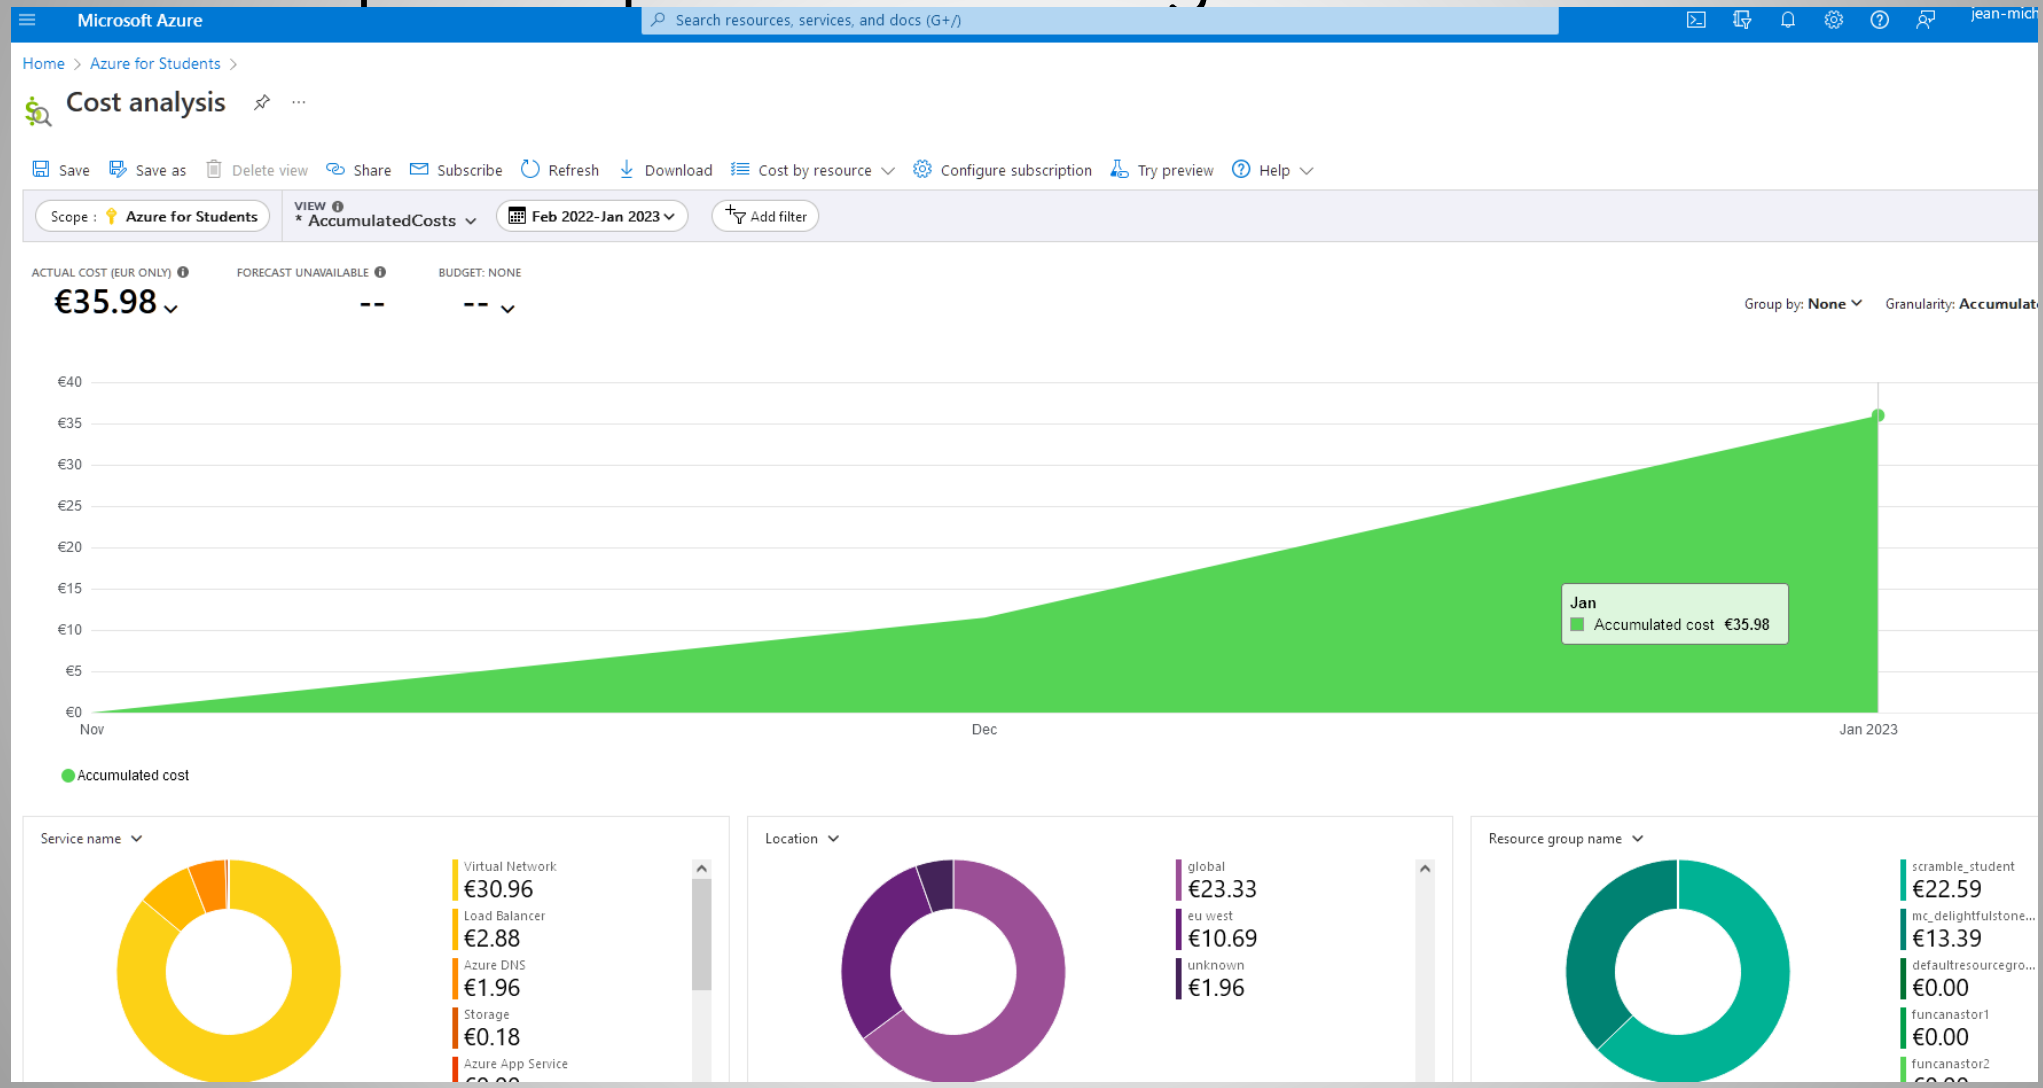

Création d'un container

- Créer une instance « container » sur grafana

philhawthorne/docker-influxdb-grafana
Port 3003/TCP ➔ pb avec accès « eduspot »
dns label grafana

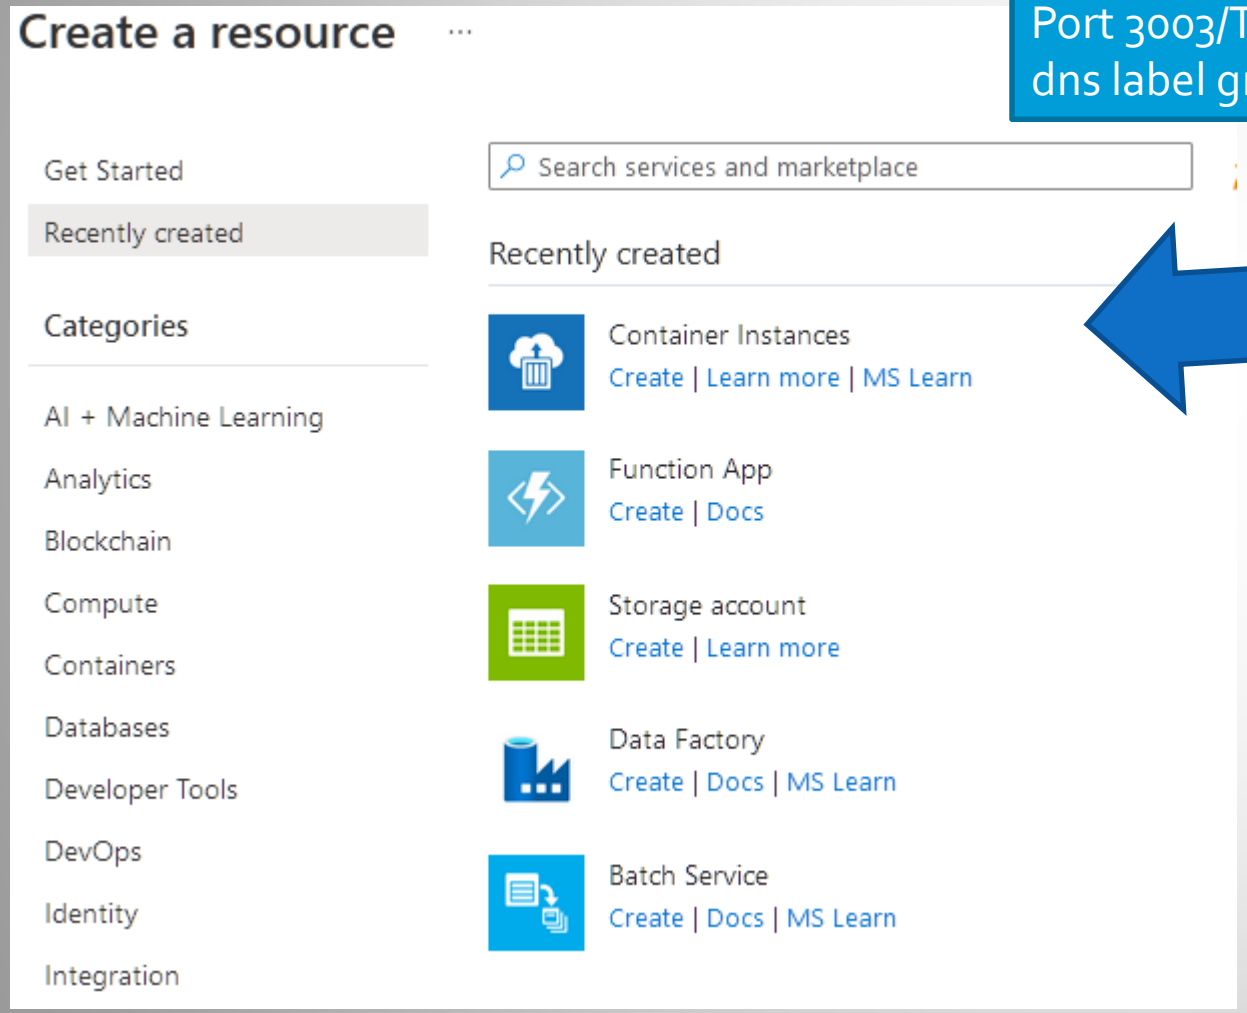

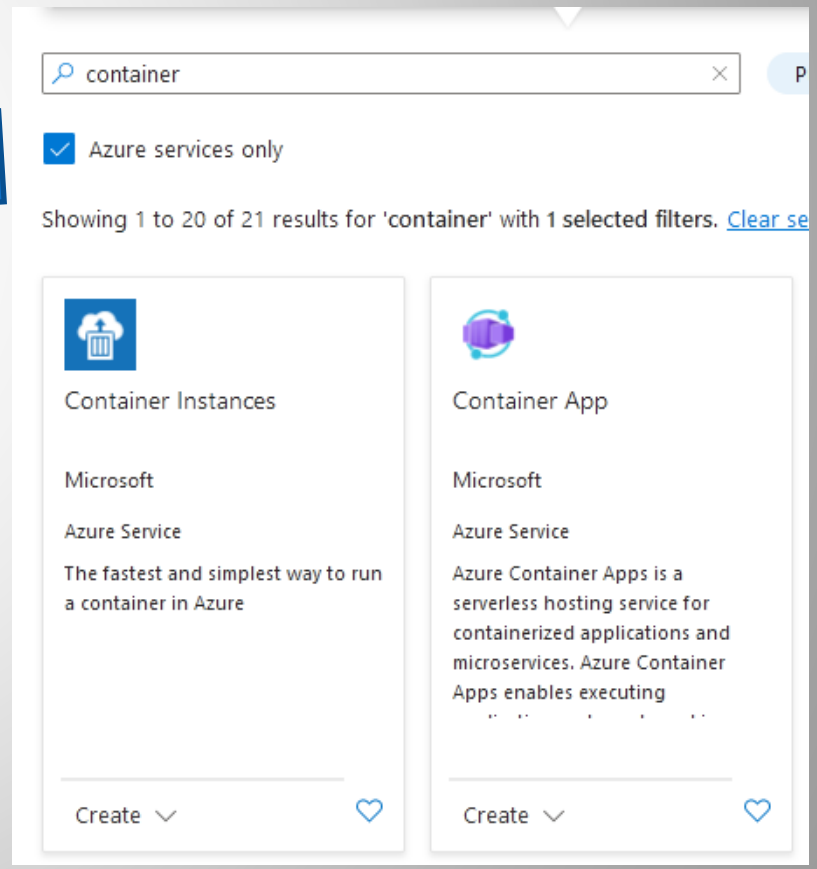

Détails du conteneur

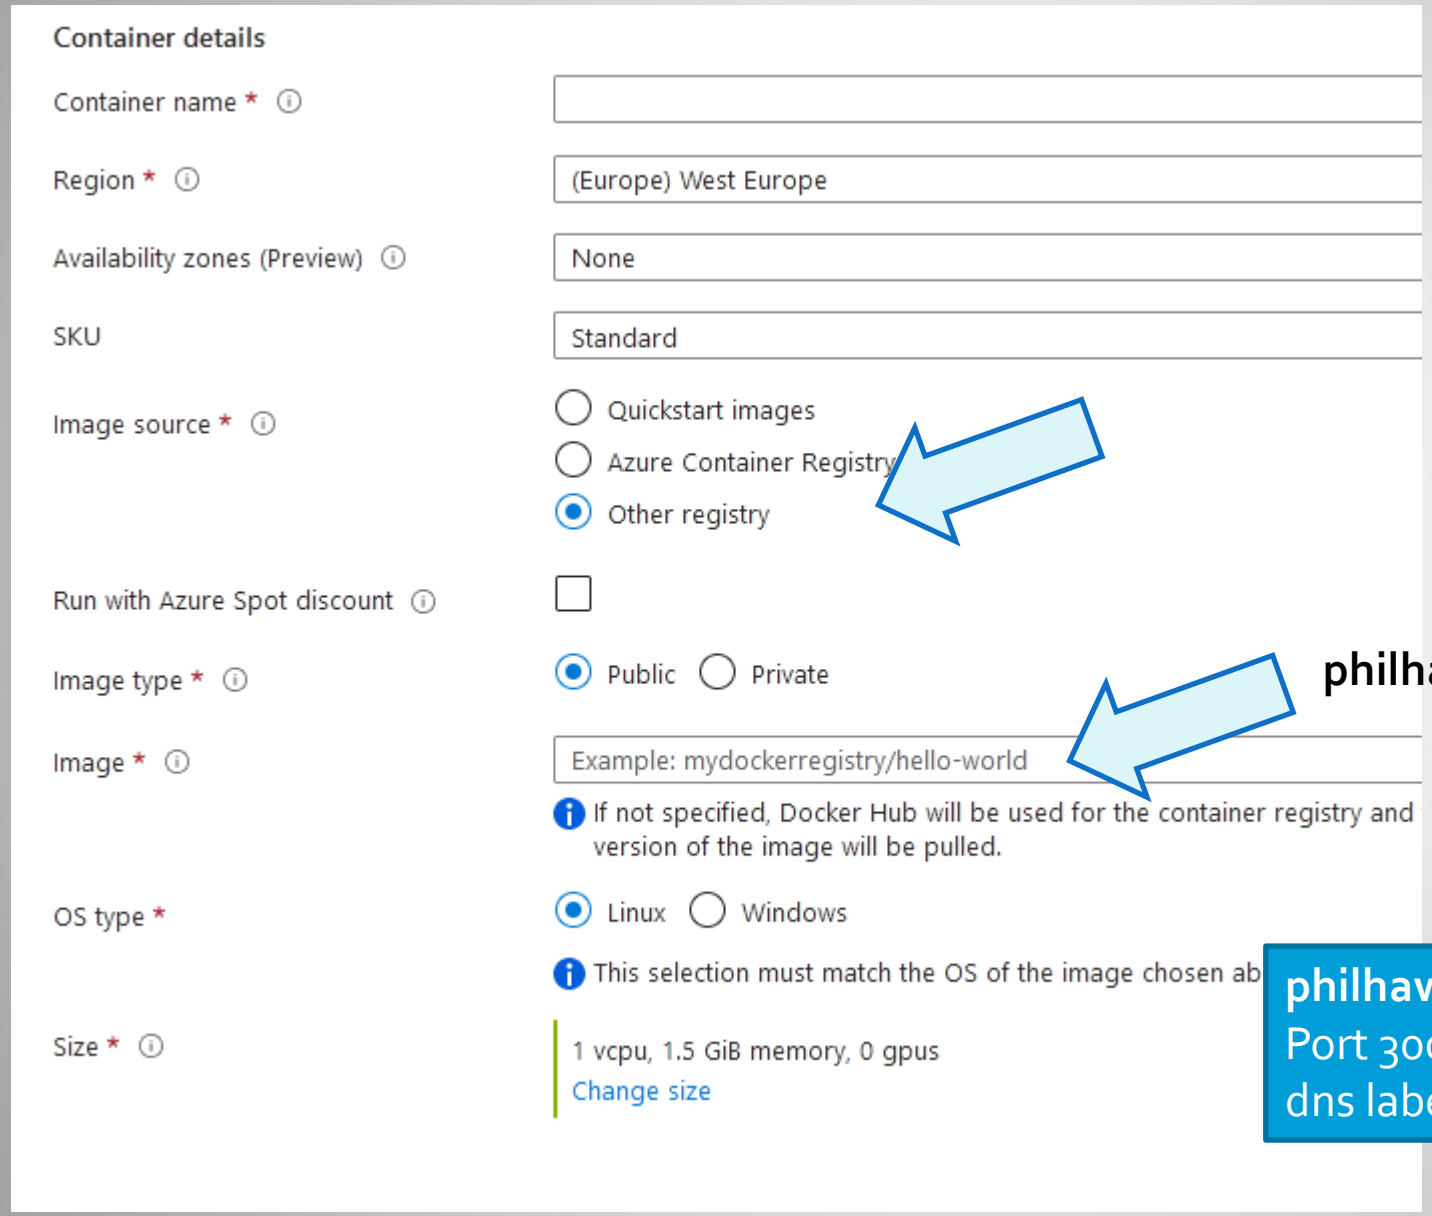

Je l'appelle ….anastor22

philhawthorne/docker-influxdb-grafana

Ne fonctionne pas car limite sur dockerhub

philhawthorne/docker-influxdb-grafana
Port 3003/TCP ➔ pb avec accès « eduspot »
dns label grafana

Détails du conteneur

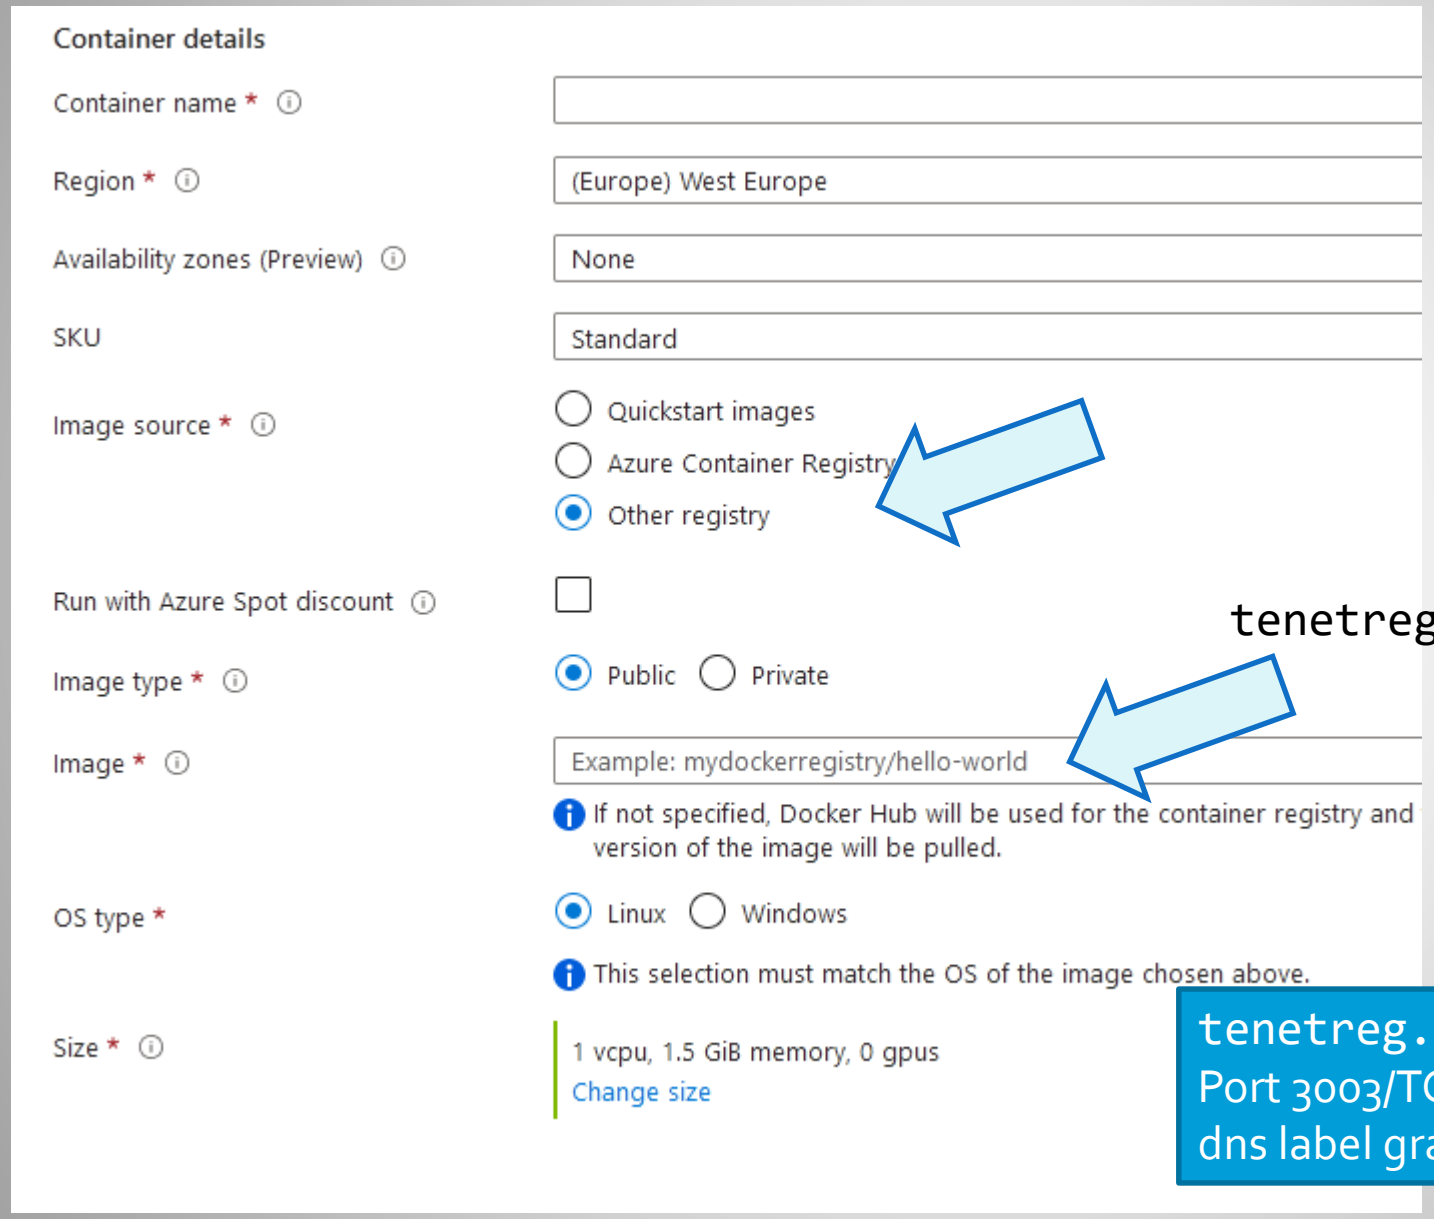

Je l'appelle ….anastor22

`tenetreg.azurecr.io/docker-influxdb-grafana`

`tenetreg.azurecr.io/docker-influxdb-grafana`
Port 3003/TCP ➔ pb avec accès « eduspot »
dns label grafana

N'oubliez pas que Docker Hub a récemment introduit une limite de débit d'extraction sur les images Docker. Lorsque vous spécifiez une image à partir du registre Docker Hub, cela peut affecter votre instance de conteneur. En savoir plus

Bases Vue JSON

Groupe de res... (déplacer)	: test	Référence SKU	: Standard
Statut	: En cours d'exécution	Type de système d'exploi...	: Linux
Emplacement	: West Europe	Adresse IP (Public)	: 9.163.206.90
Abonnement (déplacer)	: Azure for Students	FQDN	: grafana.g5fcc7cjazbvaabt.westeurope.azurecontainer.io
ID d'abonnement	: fcc775b0-9367-47f6-b9ca-6c87491fe5b1	Nombre de conteneurs	: 1
Étiquettes (modifier)	: Ajouter des étiquettes		

Processeur

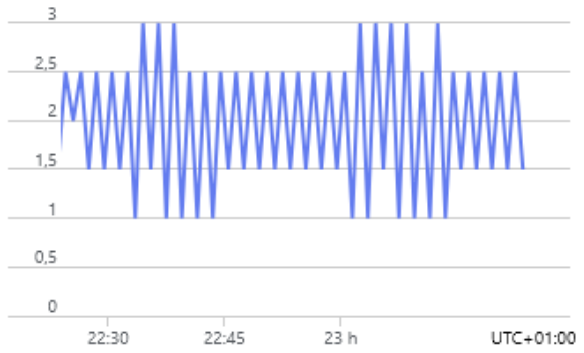

CPU Usage (Moy), testenet | 1,98

Mémoire

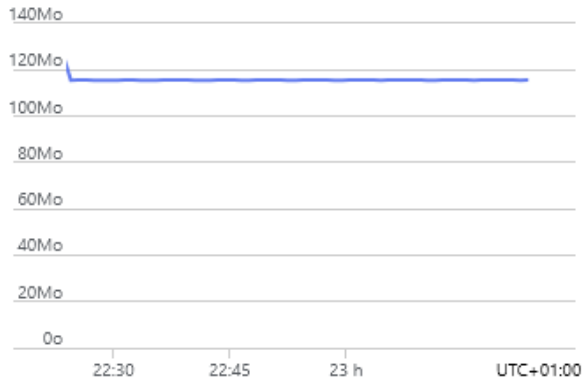

Memory Usage (Moy), testenet | 115,52Mo

Octets réseau reçus

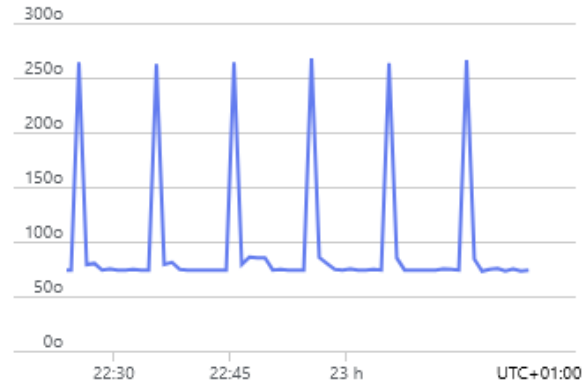

Network Bytes Received Per Second (Moy), test... | 94,84o

Octets réseau transmis

Information du container

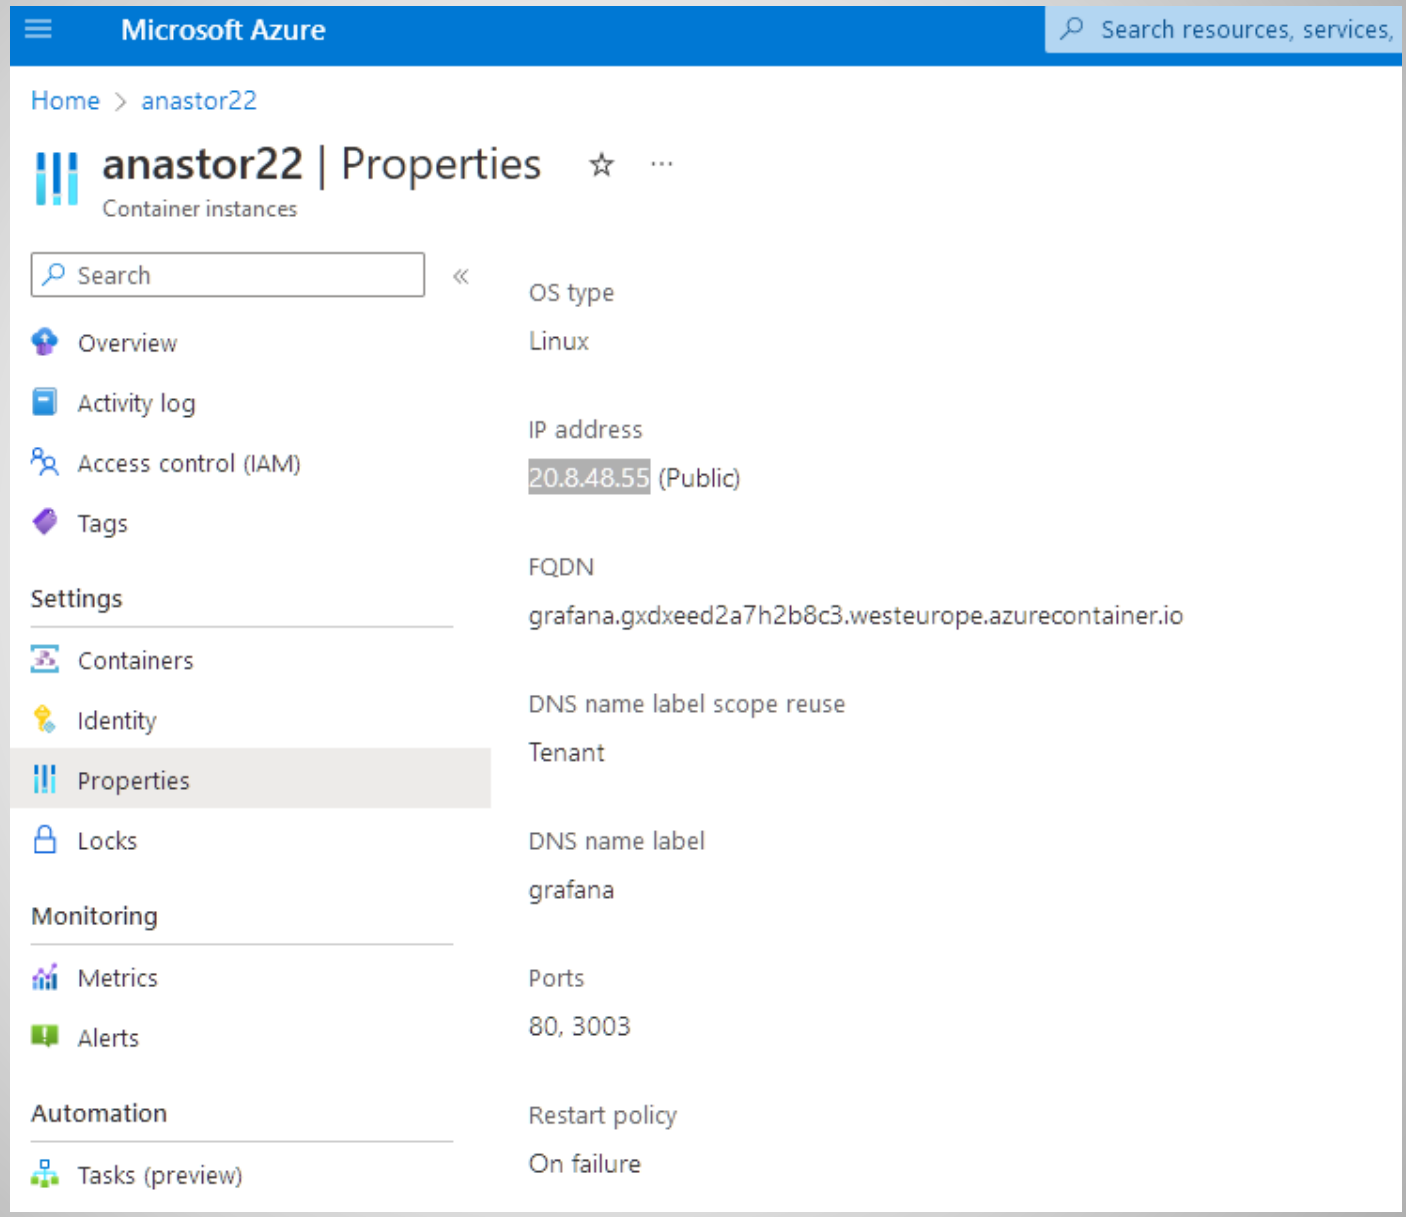

Déploiement personnalisé

Déployer à partir d'un modèle personnalisé

New! Deployment Stacks let you manage the lifecycle of your deployments. Try it now →

Availability Zones *	[]
Location *	westeurope
Container Name *	astanorweb
Image Type *	Public
Image Name *	philhawthorne/docker-influxdb-grafana
Os Type *	Linux
Number Cpu Cores *	1
Memory *	1.5
Restart Policy *	OnFailure
Sku *	Standard
Ip Address Type *	Public
Ports *	[{"port":"80","protocol":"TCP"}][{"port":"3003","protocol":"TCP"}]
Workspace Region *	westeurope
Workspace Sub Id *	dad45ca4-4fad-484d-8731-444104547c8a
Workspace Resource Group Name *	DefaultResourceGroup-WEU
Workspace Name *	DefaultWorkspace-dad45ca4-4fad-484d-8731-444104547c8a-WEU
Oms Sku	standalone

80 et 3003, attention à la construction du tableau

Vérification de l'accès

- On doit spécifier le port 3003 (pb sur certains réseaux qui n'autorisent que les ports 443 et 80)

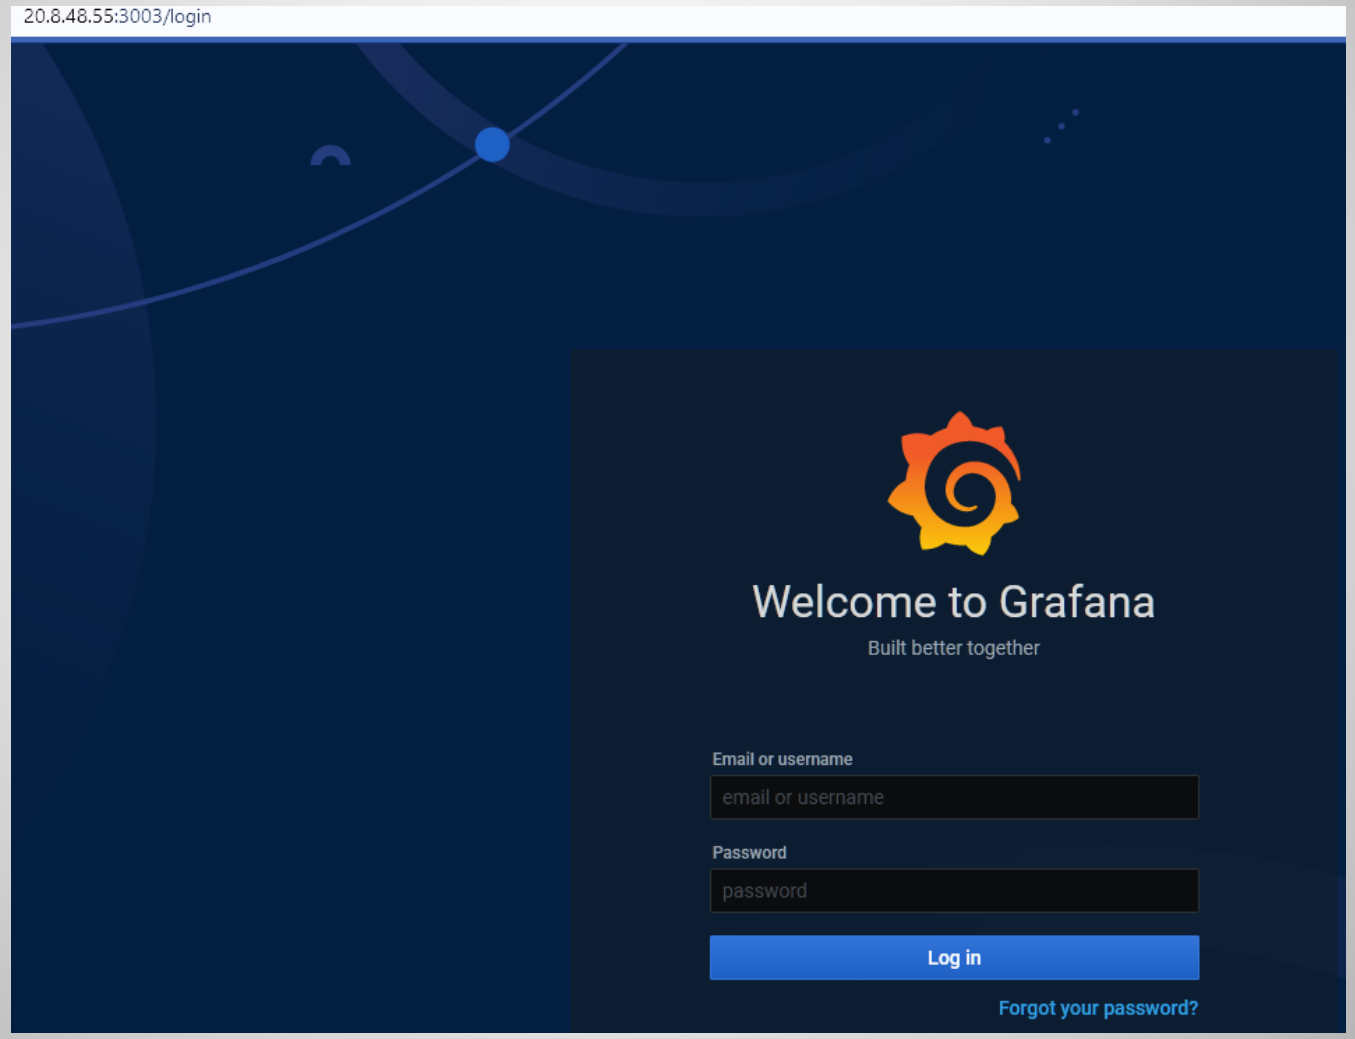

Container App – étape 2

- https://learn.microsoft.com/fr-fr/azure/container-apps/
- Il s'agit d'un environnement pour le Container

➔Enrichissement :

➔Ingress (proxy réseau) ➔ pour avoir le port 443 aulieu de 3003

➔Monitor : possibilité d'avoir une console

➔Scale : plusieurs instances concurrentes

➔Nom de domaine dédié (Custom domain)

Load balancing / Sharding

- Ingress : réalise le mapping port 443/3003

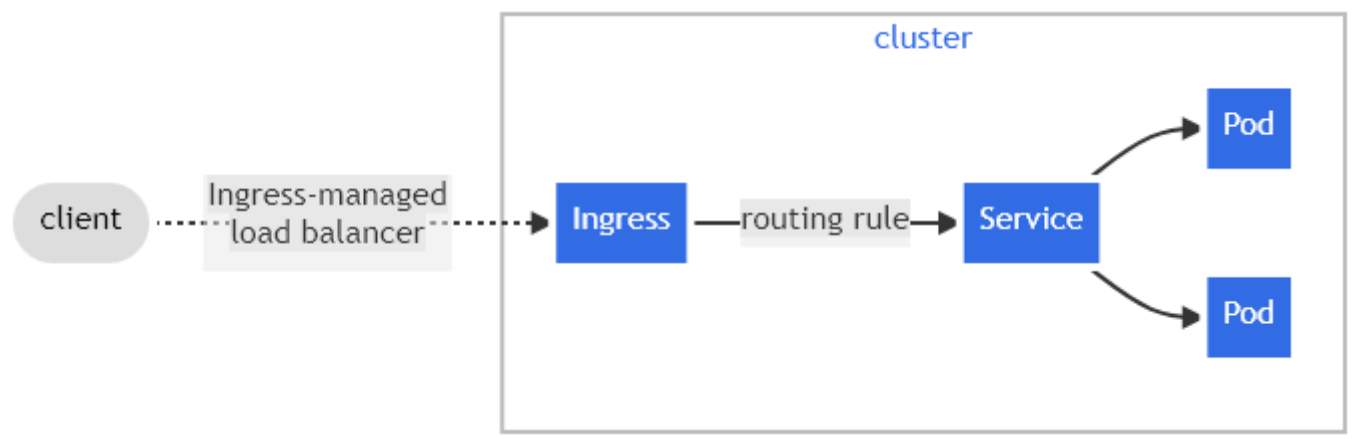

- Load balancing = distribution de la charge, avec un outil de scale-up. L'algorithme « standard » Round Robin
- Sharding = distribution des données (de shard), pour maximiser l'effet de localité (1 service = 1 localité). L'algorithme « standard » fonction de hash sur 1 ou plusieurs colonnes.

The environment is a secure boundary around one or more container apps that can communicate with each other and share a virtual network, logging, and Dapr configuration. Container Apps Pricing

Show environments in all regions ⓘ ☐

Region * France Central

Container Apps Environment * (new) managedEnvironment-SubPerso2-a20d (SubPerso2)

Create new

philhawthorne/docker-influxdb-grafana
Ingress HTTP Port 3003 anywhere
Scale = 1 // sinon pas d'accès

Create a resource

Get Started

Recently created

Categories

AI + Machine Learning

Analytics

Blockchain

Compute

Containers

Databases

Developer Tools

DevOps

Identity

Integration

Search services and marketplace

Recently created

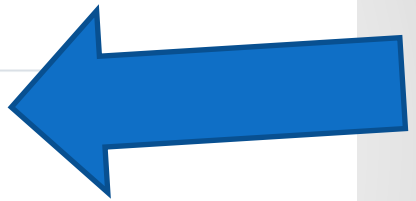

Container App
Create | Docs

Container Instances
Create | Learn more | MS Learn

Function App
Create | Docs

Storage account
Create | Learn more

Data Factory
Create | Docs | MS Learn

Utilisation de la registry azure tenetreg.azurecr.io

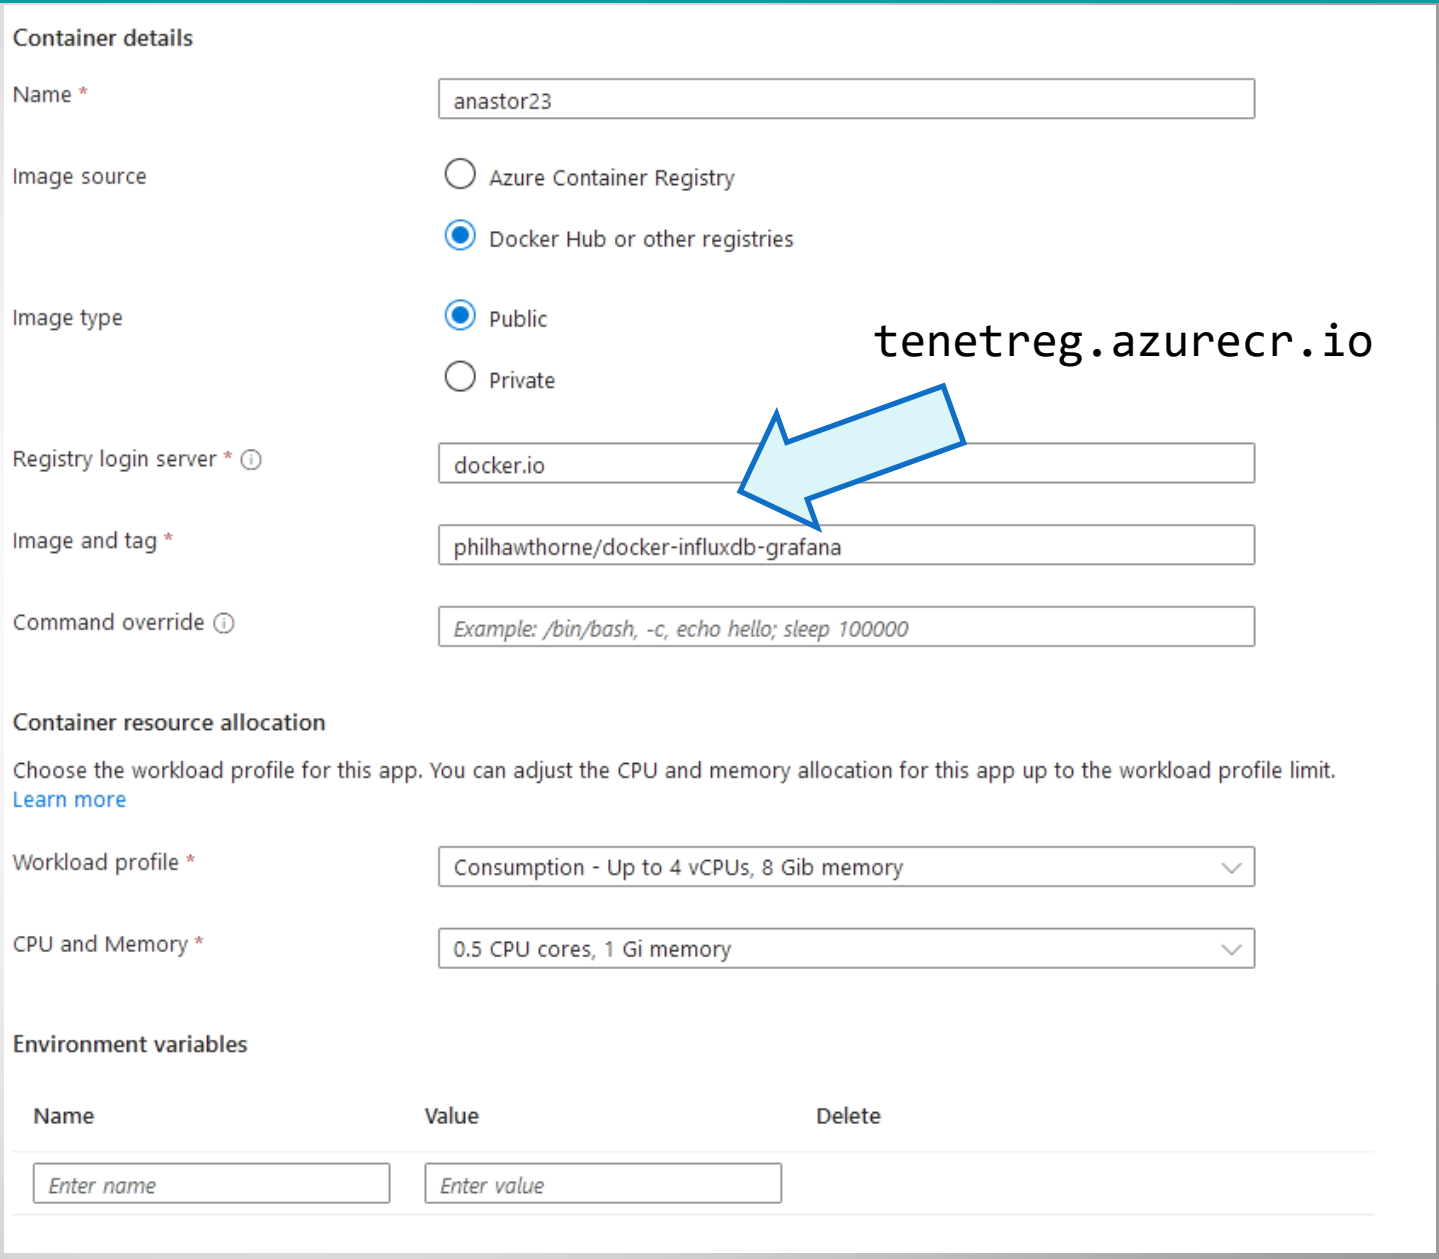

Modification Ingress

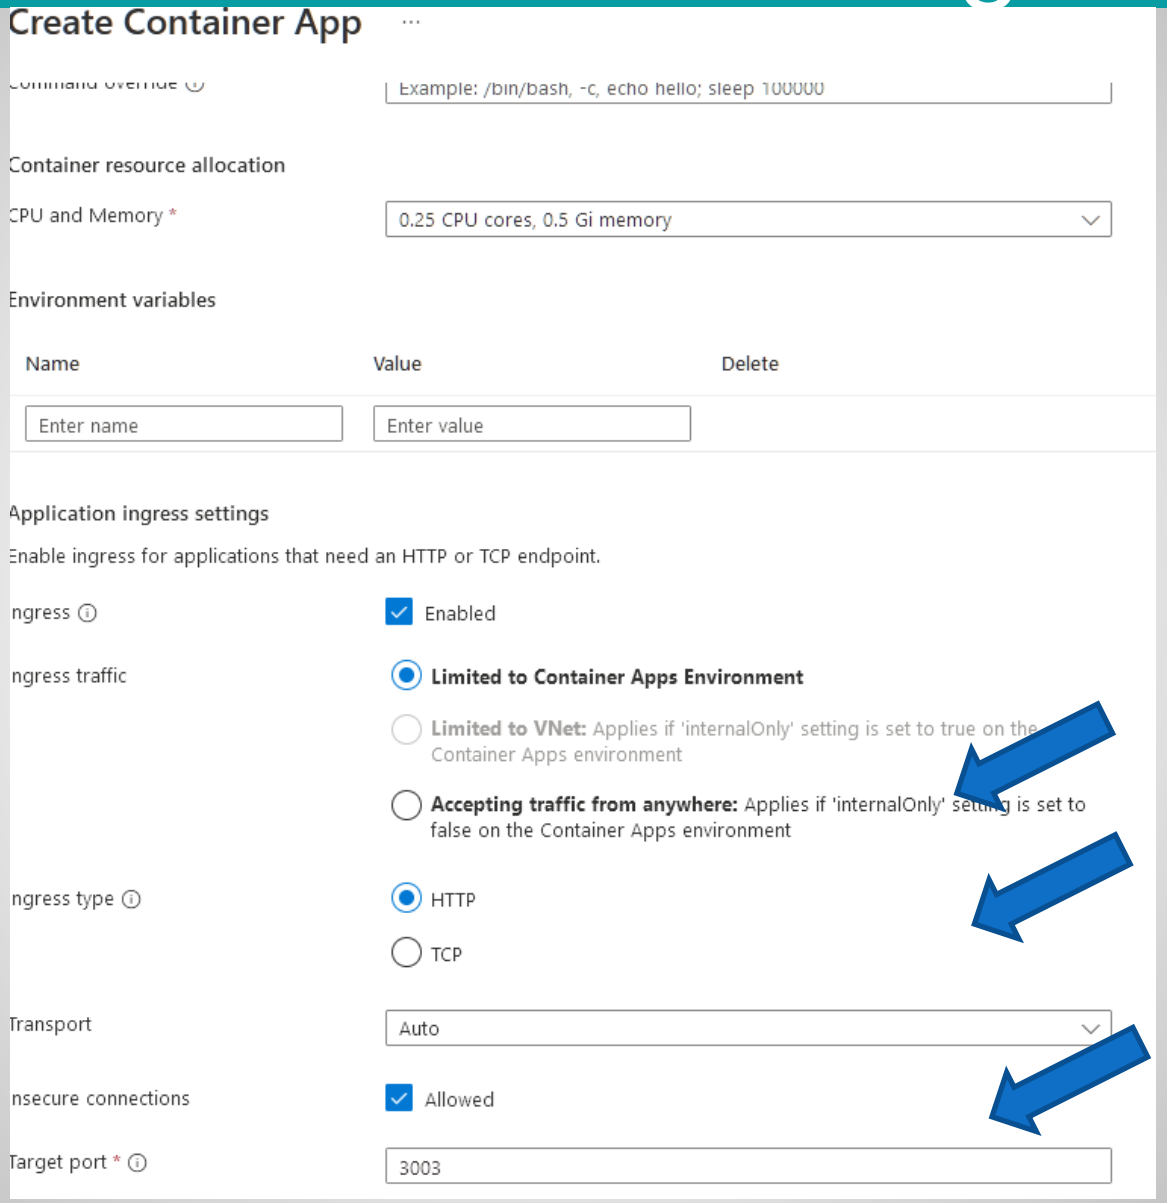

Basics | Container | Bindings | Ingress | Tags | **Review + create**

Project details

Subscription	Subscription Perso2
Resource group	SubPerso2
Name	grafana2

Container Apps Environment (New)

Region	northeurope
Container Apps Environment	managedEnvironment-SubPerso2-9ab6
Log Analytics workspace (New)	workspacesubperso28e43
Virtual network	Default
Zone redundancy	Disabled

Container

Name	grafana2
Image source	Public
Registry login server	docker.io
Image and tag	philhawthorne/docker-influxdb-grafana
Command	
Workload profile type	Consumption
Number of CPU cores	0.5
Memory size (Gi)	1
Ingress settings	Accepting traffic from anywhere
Ingress type	HTTP
Transport	Auto
Insecure connections	Allowed
Port	3003

- Accès au service web

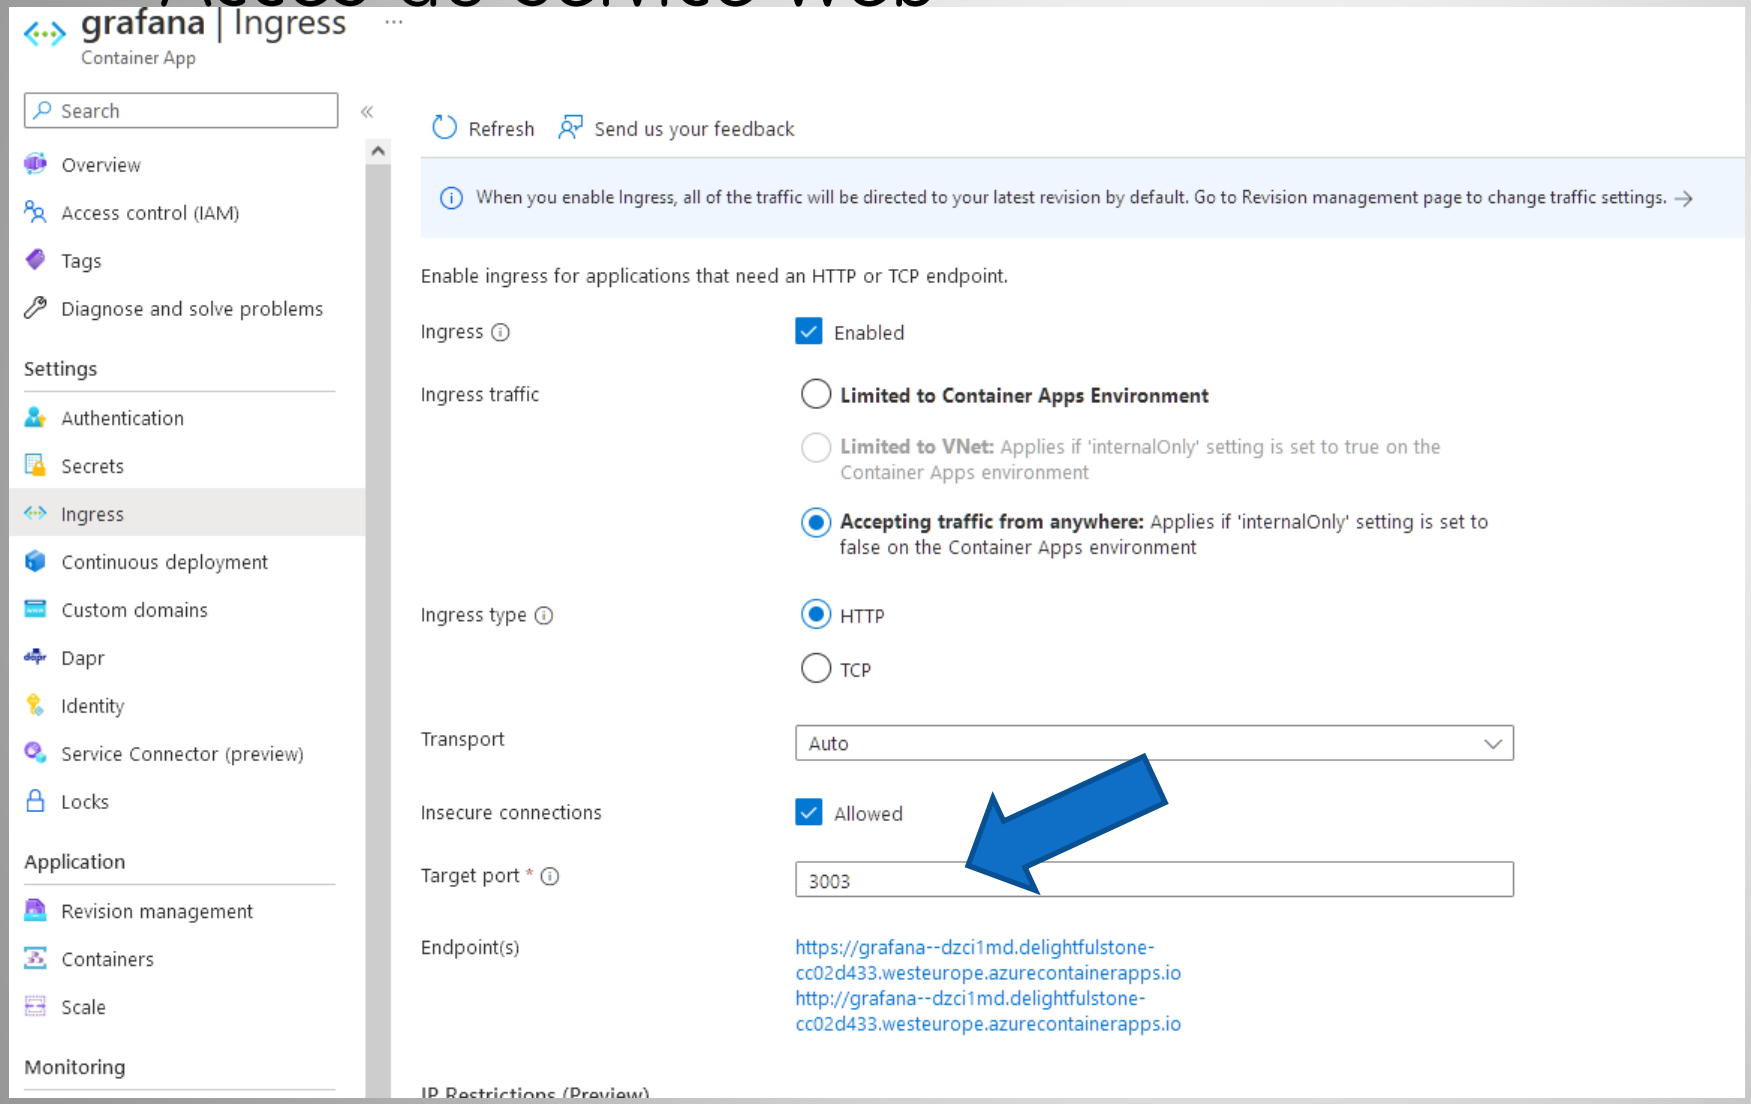

Étapes de création d'une image

Exemple avec LocalAI (alternative à ollama)

//pas de majuscule dans le nom d'une image Docker

Sur sa machine

- docker build -t docker-localai:latest .
- docker tag docker.io/library/docker-localai:latest tenetreg.azurecr.io/docker-localai:latest
- az acr -login -n tenetreg
- docker push tenetreg.azurecr.io/docker-localai:latest
- ➔ensuite on est sur le web Azure

Informations de base | Conteneur | Entrée | Étiquettes | Vérifier + créer

Créez une application conteneurisée et exécutez-la sur une plateforme serverless, sans gérer l'infrastructure cloud.Guide de démarrage rapide

Détails du projet

Sélectionnez un abonnement pour gérer la création et les coûts des ressources, et un groupe de ressources pour organiser toutes vos ressources pour ce déploiement.

Abonnement * : Azure for Students

Groupe de ressources * : DefaultResourceGroup-WEU

Créer un groupe de ressources

Nom de l'application conteneur * : testlocalai

Source de déploiement *

- (●) Image conteneur
  Apportez votre propre registre de conteneurs ou générez un conteneur à partir d'un Dockerfile.
- ( ) Code source ou artefact
  Générez et déployez votre code sans utiliser de Dockerfile.

Environnement Container Apps

Un environnement est une limite sécurisée autour d'un groupe d'applications conteneur. Tarification de Container Apps

Afficher les environnements dans toutes les régions ⓘ [ ]

Région * : West Europe

Environnement Container Apps * : (nouveau) managedEnvironment-DefaultResource-ae72 (DefaultResourceG...

Source de l'image
- ○ Azure Container Registry
- ◉ Docker Hub ou d'autres registres

Type d'image
- ◉ Public
- ○ Privé

Serveur de connexion au registre * ⓘ: tenetreg.azurecr.io

Image et balise *: docker-localai:latest

Remplacement de commande ⓘ: *Exemple : /bin/bash*

Remplacement des arguments ⓘ: *Exemple : -c, while true; do echo hello; sleep 10; done*

Fonctionnalités spécifiques à la pile de développement

Lorsque vous sélectionnez une pile de développement spécifique, vous obtenez des fonctionnalités supplémentaires adaptées à cette pile, en optimisant Container Apps pour qu'elles s'exécutent pour vos paramètres uniques.

Pile de développement: Non spécifié

Allocation des ressources de conteneur

Choisissez le profil de charge de travail pour cette application. Vous pouvez ajuster l'allocation de processeur et de mémoire pour cette application jusqu'à la limite du profil de charge de travail. En savoir plus

Profil de charge de travail *: Consumption : jusqu'à 4 processeurs virtuels, 8 Gio de mémoire

Processeur et mémoire *: 4 cores de processeur, mémoire 8 Gio

Créer Application de conteneur ...

Informations de base | Conteneur | **Entrée** | Étiquettes | Vérifier + créer

Paramètres d'entrée d'application

Activez l'entrée pour les applications qui ont besoin d'un point de terminaison HTTP.

Entrée ⓘ — ☑ Activé

Trafic entrant
- ○ Limité à l'environnement Container Apps
  Sélectionnez cette option si vous voulez limiter le trafic vers cette application conteneur à partir de l'environnement Container App
- ◉ Acceptation du trafic depuis n'importe où
  Sélectionnez cette option si vous voulez autoriser le trafic vers cette application conteneur à partir de n'importe où

Type d'entrée ⓘ
- ◉ HTTP
- ○ TCP

Transport : Auto

Connexions non sécurisées : ☑ Autorisé

Port cible ⓘ : 8080

Affinité de session ⓘ : ☐ Activé

▲ Ports TCP supplémentaires

- On vérifie

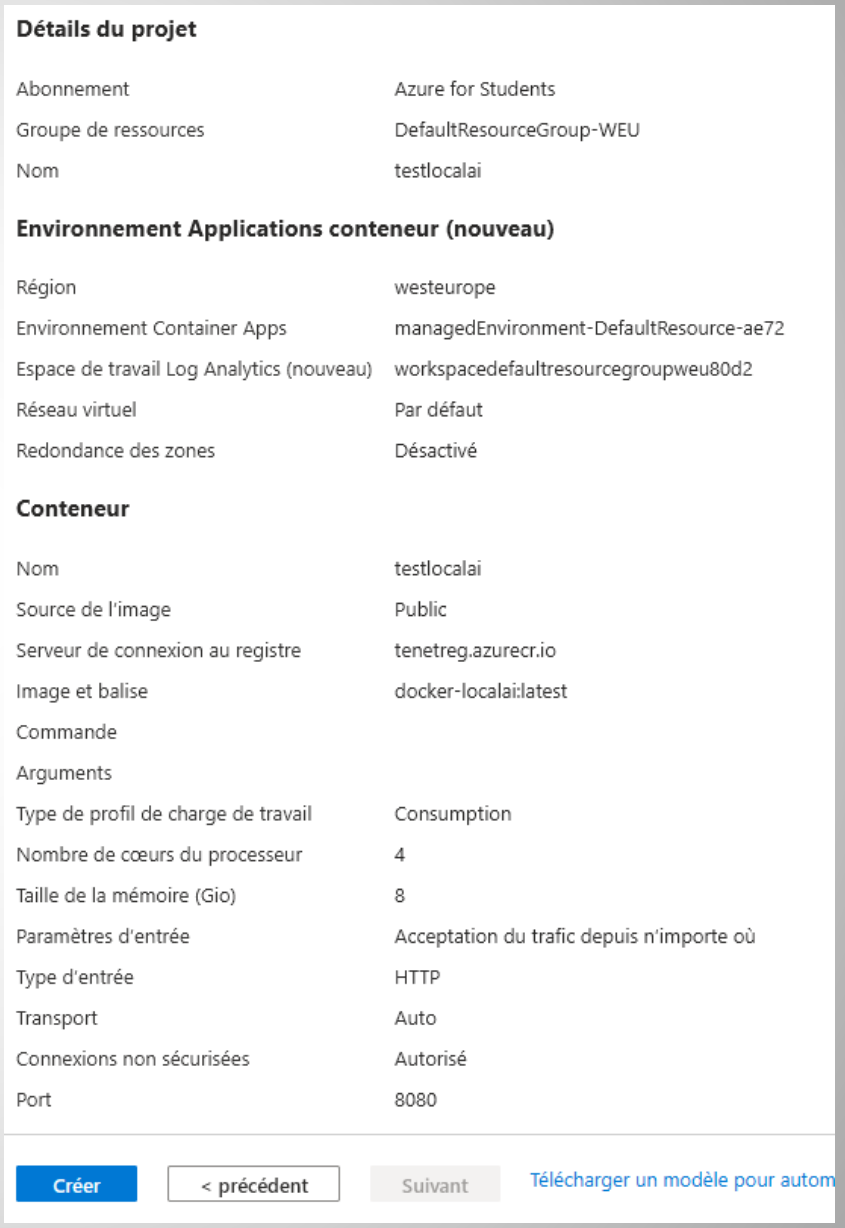

Détails du projet

Abonnement	Azure for Students
Groupe de ressources	DefaultResourceGroup-WEU
Nom	testlocalai

Environnement Applications conteneur (nouveau)

Région	westeurope
Environnement Container Apps	managedEnvironment-DefaultResource-ae72
Espace de travail Log Analytics (nouveau)	workspacedefaultresourcegroupweu80d2
Réseau virtuel	Par défaut
Redondance des zones	Désactivé

Conteneur

Nom	testlocalai
Source de l'image	Public
Serveur de connexion au registre	tenetreg.azurecr.io
Image et balise	docker-localai:latest
Commande	
Arguments	
Type de profil de charge de travail	Consumption
Nombre de cœurs du processeur	4
Taille de la mémoire (Gio)	8
Paramètres d'entrée	Acceptation du trafic depuis n'importe où
Type d'entrée	HTTP
Transport	Auto
Connexions non sécurisées	Autorisé
Port	8080

Créer | < précédent | Suivant | Télécharger un modèle pour autom

- Accès à la page après…10 minutes

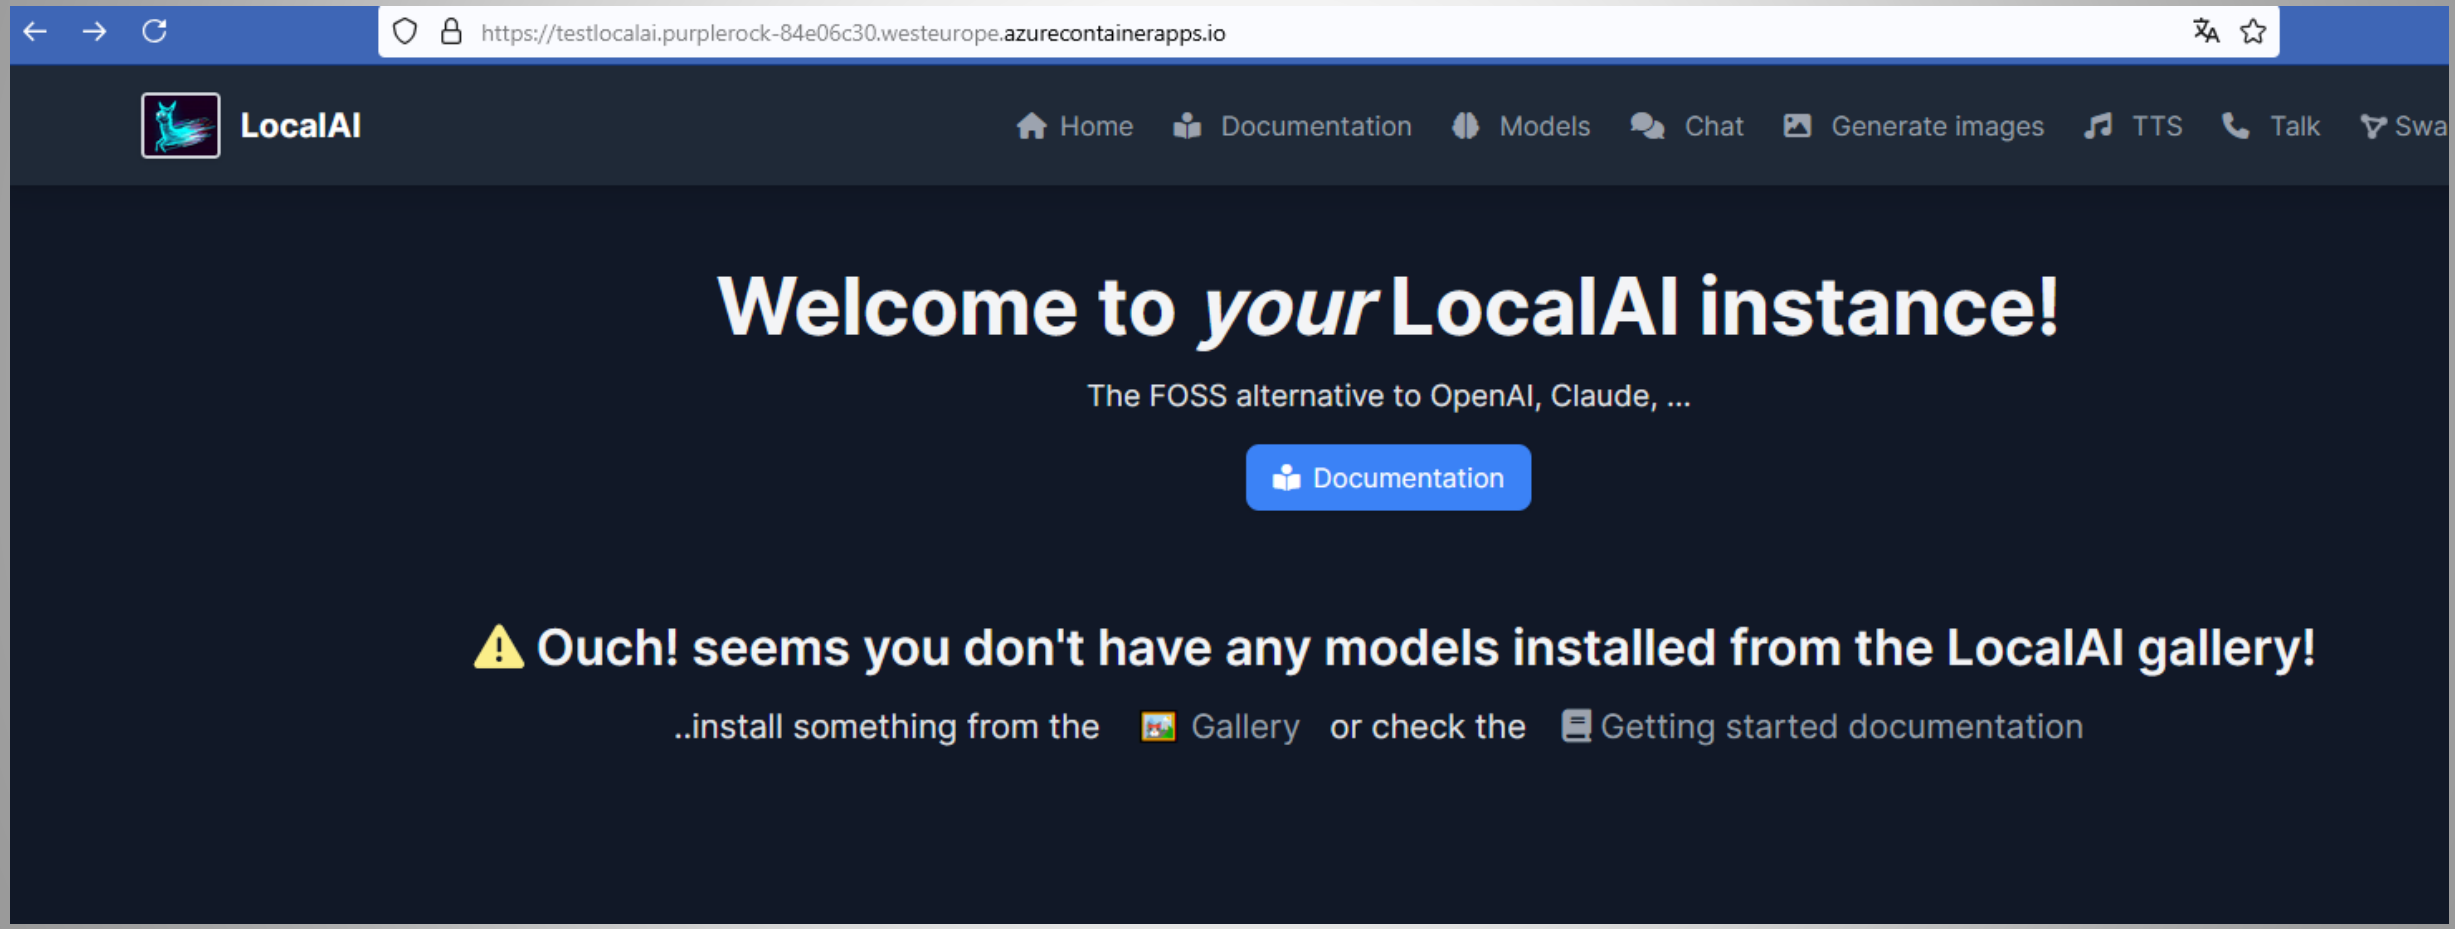

Complément de cours

- Modèle CSP ? Alternative ➔ Acteurs
- Dans les systèmes distribués, deux modèles de programmation populaires sont **CSP (Communicating Sequential Processes)** et le **modèle par Acteurs**. Le modèle CSP repose sur des processus séquentiels communiquant via des canaux synchrones, tandis que le modèle par Acteurs utilise des entités indépendantes (acteurs) qui communiquent de manière asynchrone par messages.

  - Erlang ➔

Différences conceptuelles

- Modèle par Acteurs (CAF) :
  - Entités indépendantes avec boîtes aux lettres (asynchrone par défaut).
  - Gestion implicite des threads et du runtime.
  - self->reply automatise la réponse au sender.
- Modèle CSP (MPI) :
  - Processus séquentiels communiquant explicitement via canaux (souvent synchrone avec MPI).
  - Pas de runtime implicite ; le développeur doit spécifier les ranks et les échanges.
  - Communication bidirectionnelle manuelle (envoi/réception explicites).

CSP vs Acteur

Paradigme	CSP (Communicating Sequential Processes)	Modèle par Acteur
SIMD	Style synchrone et déterministe : les processus communiquent via des canaux explicites avec une synchronisation stricte. Les instructions sont uniformes, et les données multiples sont traitées en parallèle de manière coordonnée.	Style asynchrone et local : les acteurs exécutent la même instruction sur des données différentes, mais sans coordination globale explicite. La communication est basée sur l'envoi de messages sans blocage.
MIMD	Style basé sur des processus indépendants avec synchronisation par canaux : chaque processus peut exécuter des instructions différentes, mais la communication impose une discipline pour éviter les incohérences.	Style fortement décentralisé : chaque acteur est autonome, traite ses propres instructions et communique de manière asynchrone, favorisant la flexibilité et l'indépendance.

CSP vs Acteur

Paradigme	CSP (Communicating Sequential Processes)	Modèle par Acteur
SIMD	Style : Synchrone et déterministe, communication via canaux avec synchronisation stricte. Pattern : Observer Les processus écoutent les canaux comme des observateurs, réagissant uniformément aux messages (données multiples, instruction unique). Exemple : un pipeline où chaque étape attend un signal synchronisé.	Style : Asynchrone et local, messages sans blocage. Pattern : Strategy Chaque acteur applique une stratégie commune (instruction unique) sur des données différentes, sans coordination centrale. Exemple : des acteurs traitant des pixels d'une image indépendamment.
MIMD	Style : Processus indépendants avec synchronisation par canaux. Pattern : Mediator Un médiateur (le canal) coordonne les processus qui exécutent des instructions différentes, assurant une communication disciplinée. Exemple : des threads traitant des tâches variées mais échangeant via un canal partagé.	Style : Décentralisé, autonome, communication asynchrone. Pattern : Command Chaque acteur encapsule une commande (instruction propre) et agit indépendamment, envoyant des messages à d'autres acteurs. Exemple : un système de simulation où chaque entité évolue seule et interagit ponctuellement.

Exemple Acteur C++

```
#include <caf/all.hpp>
using namespace caf;

behavior hello_actor(event_based_actor* self) {
  return {
    [=](const std::string& msg) {
      aout(self) << "Received: " << msg << std::endl;
      self->reply("Hello back!");
    }
  };
}
int main() {
  actor_system system;
  auto actor = system.spawn(hello_actor);
  anon_send(actor, "Hi there!");
  system.await_all_actors_done();
  return 0;
}
```

Avec l'abstraction réseau, MIMD (serveur)

```
#include <caf/all.hpp>
#include <caf/io/all.hpp> // Pour le réseau
using namespace caf;
behavior hello_actor(event_based_actor* self) {
  return {
    [=](const std::string& msg) {
      aout(self) << "Received: " << msg << std::endl;
      self->reply("Hello back from server!");
    } }; }
int main() {
  actor_system_config cfg;
  actor_system system{cfg};
  auto& mm = system.middleman(); // Accès au middleman
  auto actor = system.spawn(hello_actor);
  auto port = mm.publish(actor, 4242); // Publie l'acteur sur le port 4242
  if (!port) {
    std::cerr << "Failed to publish: " << to_string(port.error()) << std::endl;
    return 1;  }
  std::cout << "Actor published on port " << *port << std::endl;
  std::cin.get(); // Garde le serveur actif
  mm.unpublish(actor);
  return 0;
}
```

CAF ➔MIMD (client)

```
#include <caf/all.hpp>
#include <caf/io/all.hpp>
using namespace caf;
int main() {
  actor_system_config cfg;
  actor_system system{cfg};
  auto& mm = system.middleman();
  auto remote = mm.remote_actor("localhost", 4242); // Connexion à l'acteur distant
  if (!remote) {
    std::cerr << "Failed to connect: " << to_string(remote.error()) << std::endl;
    return 1;
  }
  std::cout << "Connected to remote actor" << std::endl;

  anon_send(*remote, std::string("Hi there!")); // Envoie un message

  // Attend une réponse (optionnel, nécessite un acteur local pour recevoir)
  system.await_all_actors_done();
  return 0;
}
```

MPI

```cpp
#include <mpi.h>
#include <iostream>
#include <string>
int main(int argc, char* argv[]) {
    MPI_Init(&argc, &argv); // Initialisation de MPI
    int rank, size;
    MPI_Comm_rank(MPI_COMM_WORLD, &rank); // Identifiant du processus
    MPI_Comm_size(MPI_COMM_WORLD, &size); // Nombre total de processus
    if (size < 2) {
        std::cerr << "Ce programme nécessite au moins 2 processus MPI." << std::endl;
        MPI_Abort(MPI_COMM_WORLD, 1);
        return 1;
    }
    const int MSG_TAG = 0; // Tag pour identifier les messages
    const std::string send_msg = "Hi there!";
    char recv_buffer[100]; // Buffer pour recevoir le message
    if (rank == 0) {
        // Processus 0 : envoie un message au processus 1
        MPI_Send(send_msg.c_str(), send_msg.length() + 1, MPI_CHAR, 1, MSG_TAG, MPI_COMM_WORLD);
        std::cout << "Rank 0 sent: " << send_msg << std::endl;
        // Reçoit la réponse du processus 1
        MPI_Recv(recv_buffer, 100, MPI_CHAR, 1, MSG_TAG, MPI_COMM_WORLD, MPI_STATUS_IGNORE);
        std::cout << "Rank 0 received: " << recv_buffer << std::endl;
    } else if (rank == 1) {
        // Processus 1 : reçoit le message du processus 0
        MPI_Recv(recv_buffer, 100, MPI_CHAR, 0, MSG_TAG, MPI_COMM_WORLD, MPI_STATUS_IGNORE);
        std::cout << "Rank 1 received: " << recv_buffer << std::endl;

        // Répond avec "Hello back!"
        const std::string reply_msg = "Hello back!";
        MPI_Send(reply_msg.c_str(), reply_msg.length() + 1, MPI_CHAR, 0, MSG_TAG, MPI_COMM_WORLD);
        std::cout << "Rank 1 sent: " << reply_msg << std::endl;
    }
    MPI_Finalize(); // Finalisation de MPI
    return 0;
}
```

XcalableACC

```
#include <xmp.h> // En-tête pour XcalableACC (ou XcalableMP selon le compilateur)
#include <iostream>
#include <string>
#pragma xmp nodes p(2) // Définit 2 noeuds/processus
// Fonction exécutée par chaque noeud
void process_task() {
    int rank = xmp_node_num(); // Numéro du noeud (équivalent à MPI rank)
    int num_nodes = xmp_num_nodes(); // Nombre total de noeuds

    if (num_nodes < 2) {
        std::cerr << "Ce programme nécessite au moins 2 noeuds." << std::endl;
        xmp_finalize();
        exit(1);
    }
    std::string send_msg = "Hi there!";
    char recv_buffer[100];
    if (rank == 1) { // Noeud 1 envoie le message initial (simule main dans CAF)
        #pragma xmp bcast (send_msg) from p(1) to p(2) // Envoi du message au noeud 2
        std::cout << "Node 1 sent: " << send_msg << std::endl;
        #pragma xmp bcast (recv_buffer) from p(2) to p(1) // Réception de la réponse
        std::cout << "Node 1 received: " << recv_buffer << std::endl;
    } else if (rank == 2) { // Noeud 2 agit comme l'acteur
        #pragma xmp bcast (send_msg) from p(1) to p(2) // Réception du message initial
        std::cout << "Node 2 received: " << send_msg << std::endl;
        std::string reply_msg = "Hello back!";
        strncpy(recv_buffer, reply_msg.c_str(), sizeof(recv_buffer));
        #pragma xmp bcast (recv_buffer) from p(2) to p(1) // Envoi de la réponse
        std::cout << "Node 2 sent: " << reply_msg << std::endl;
    }
}
int main() {
    xmp_init(); // Initialisation de XcalableACC
    process_task();
    xmp_finalize(); // Finalisation de XcalableACC
    return 0;
}
```

Applications avec modèle par Acteurs

Nom du langage	Cible fonctionnelle	Produit médiatisé	Date de première sortie	Taille du code source (approx.)	Productivité COCOMO (lignes/jour)
Erlang	Messagerie instantanée	WhatsApp (backend)	2009	~1 million de lignes (backend)	20-30 lignes
	File d'attente distribuée	RabbitMQ	2007	~500 000 lignes (RabbitMQ)	20-30 lignes
	Base de données distribuée	CouchDB	2005	~300 000 lignes (CouchDB)	20-30 lignes
Scala (Akka)	Traitement Big Data	Apache Spark	2014	~1 million de lignes (Spark)	20-35 lignes
	Réseau social distribué	Twitter (backend)	2006	~3 millions de lignes (backend)	20-35 lignes
	Concurrence et acteurs	Akka (framework)	2009	~200 000 lignes (Akka)	20-35 lignes
Python (Pykka)	Framework web	Django (avec actors)	2005	~300 000 lignes (Django)	30-50 lignes
	Simulation distribuée	Thespian (acteur léger)	2015	~50 000 lignes (Thespian)	30-50 lignes
	Automatisation IoT	Home Assistant	2013	~1 million de lignes (HA)	30-50 lignes
Rust (Actix)	Backend haute performance	Discord (backend)	2015	~1 million de lignes (backend)	20-30 lignes
	Serveur web	Actix Web	2017	~100 000 lignes (Actix Web)	20-30 lignes
	Traitement événementiel	Tokio (avec acteurs)	2016	~200 000 lignes (Tokio)	20-30 lignes

Les gains de productivité

- Rust vs Go
  - Go :
    - C avec Runtime
    - Modèle CSP natif : modèle de thread qui ne recouvre pas la réalité physique du processeur
    - Gestion des threads en « pilotage automatique »
    - Un AST qui permet la métaprogrammation simplifiée avec le package « reflect » et une étape de compilation dédiée (go generate)
    - Se compare à Smalltalk avec un typage fort et avec une génération binaire
  - Rust :
    - C avec contraintes
    - C++ avec Model Checker (pour la gestion mémoire)
    - Modèle CSP mais avec un schéma de thread dépendant du processeur
    - Gestion des threads en « pilotage manuel »
    - Un AST qui permet la métaprogrammation élaborée avec les macros
    - Se compare à C++ et Ada avec une sécurité mémoire intégrée et une performance optimale

Comparaison : synthèse

Aspect fonctionnel	Go	Rust
Philosophie	Simplicité, productivité, déploiement facile	Sécurité, performance, contrôle total
Gestion mémoire	Garbage Collector (automatique)	Ownership/Borrow Checker (statique)
Concurrence	Goroutines + Channels (CSP natif)	Threads OS + Bibliothèques (CSP optionnel)
Métaprogrammation	Réflexion + go generate (simplifiée)	Macros puissantes (élaborées)
Performance	Bonne, mais runtime ajoute un overhead	Maximale, proche du matériel
Cas d'usage	Services web, outils CLI, simplicité	Systèmes embarqués, performance critique
Courbe d'apprentissage	Facile à apprendre	Plus raide, concepts avancés
Productivité COCOMO	25-40 lignes/jour	20-30 lignes/jour

Quelques ordres de grandeur

Nom du langage	Cible fonctionnelle	Produit médiatisé	Date de première sortie	Taille du code source (approx.)	Productivité COCOMO (lignes/jour)
Rust	Performance et sécurité mémoire	Firefox (Servo)	2004	~5 millions de lignes (Firefox)	20-30 lignes
	Backend haute performance	Discord (backend)	2015	~1 million de lignes (backend)	20-30 lignes
	Infrastructure cloud sécurisée	Cloudflare Workers	2017	~500 000 lignes (Workers)	20-30 lignes
C	Systèmes d'exploitation	Linux Kernel	1991	~27 millions de lignes (Kernel)	15-25 lignes
	Gestion de versions	Git	2005	~300 000 lignes (Git)	15-25 lignes
	Base de données embarquée	SQLite	2000	~150 000 lignes (SQLite)	15-25 lignes
C++	Moteur de jeu	Unreal Engine	1998	~4 millions de lignes (Unreal)	15-25 lignes
	Navigateur web	Chromium	2008	~30 millions de lignes (Chromium)	15-25 lignes
	Traitement d'image	Adobe Photoshop	1990	~10 millions de lignes (Photoshop)	15-25 lignes
Ada	Avionique embarquée	Boeing 787 (systèmes)	2009	~1 million de lignes (systèmes)	10-20 lignes
	Systèmes critiques aéronautiques	Airbus A380 (avionique)	2005	~2 millions de lignes (avionique)	10-20 lignes
	Vérification formelle	SPARK (outils)	1987	~200 000 lignes (SPARK)	10-20 lignes
Python	Framework web	Django	2005	~300 000 lignes (Django)	30-50 lignes
	Machine Learning	TensorFlow	2015	~2 millions de lignes (TensorFlow)	30-50 lignes
	Plateforme vidéo	YouTube (backend)	2005	~5 millions de lignes (YouTube)	30-50 lignes
Erlang	Messagerie instantanée	WhatsApp (backend)	2009	~1 million de lignes (backend)	20-30 lignes
	File d'attente distribuée	RabbitMQ	2007	~500 000 lignes (RabbitMQ)	20-30 lignes
	Base de données distribuée	CouchDB	2005	~300 000 lignes (CouchDB)	20-30 lignes
Java	Jeu vidéo multiplateforme	Minecraft	2011	~500 000 lignes (Minecraft)	25-40 lignes
	Traitement Big Data	Apache Hadoop	2006	~2 millions de lignes (Hadoop)	25-40 lignes
	Système mobile	Android (SDK)	2008	~12 millions de lignes (Android)	25-40 lignes
Node.js	Streaming vidéo	Netflix (serveur)	2007	~1 million de lignes (serveur)	30-50 lignes
	Paiement en ligne	PayPal (backend)	1998	~2 millions de lignes (backend)	30-50 lignes
	Réseau social mobile	LinkedIn (mobile)	2003	~1,5 million de lignes (mobile)	30-50 lignes
Scala	Traitement Big Data	Apache Spark	2014	~1 million de lignes (Spark)	20-35 lignes
	Réseau social distribué	Twitter (backend)	2006	~3 millions de lignes (backend)	20-35 lignes
	Concurrence et acteurs	Akka (framework)	2009	~200 000 lignes (Akka)	20-35 lignes
Go	Conteneurisation	Docker	2013	~1 million de lignes (Docker)	25-40 lignes
	Orchestration de conteneurs	Kubernetes	2014	~2 millions de lignes (Kubernetes)	25-40 lignes
	Générateur de sites statiques	Hugo (générateur web)	2013	~100 000 lignes (Hugo)	25-40 lignes

Problématique du calcul HPC

- Qui fait l'E.B. ?
  - Un physicien ?
  - Un concepteur de vitrine technologique ?
- Comment se fait l'E.B. ?
  - Avec un texte
  - Avec un diagramme
  - Avec une cible fonctionnelle = un code jouet
- Quelle est la durée de vie du code produit ?
  - Un code « one shot »
  - Une génération de calculateur ?
  - Réplication numérique ou réplication binaire
  - 30 ans ?

- Les problématiques du code livré
  - Indépendance des résultats par rapport à l'infrastructure
  - Puisse bénéficier de la Loi de Moore
  - MCO / MCS sur la durée

- Les activités :
  - Construire une représentation du problème
  - ➔maillage et partitionnement (conduit, scotch)
  - ➔description d'une équation
  - Appliquer un traitement
    - ➔avec une ou des bibliothèques
  - Visualiser le résultat
    - VisIt (bibliothèque C++ VTK)
    - Paraview (bibliothèque C++ VTK)
    - Mayavi2 (//VTK)
    - Graphviz
    - Gnuplot

Catégorie	Outils/Frameworks	Description	Utilisation principale
DSL C++	Kokkos, Arcane	Bibliothèques pour le parallélisme portable (Kokkos) et simulations (Arcane)	CPU/GPU, physique computationnelle
Les pragmas		Directives dans le code pour guider le compilateur dans le parallélisme	Optimisation multicœur et accélérateurs
	OpenACC	API basée sur des pragmas pour accélérer les calculs sur GPU/accélérateurs	Applications HPC (High-Performance Computing)
	OpenMP	API pour le parallélisme multicœur avec gestion des threads	Applications multicœurs standards
Runtime hétérogène de tâche	Legion de Standford	Système pour programmer et exécuter des applications parallèles distribuées	Simulations à grande échelle, architectures

L'apport de l'IA

- Le 26 février 2024 Jensen Huang, CEO de Nvidia a dit (traduction)

Notre tâche consiste à créer une technologie informatique telle que personne n'ait à programmer. Et comme le langage de programmation est humain, tout le monde dans le monde est maintenant un programmeur. C'est le miracle de l'intelligence artificielle.

Les apports de l'I.A.

- Documentation
  - Génération des documentations
  - Commentaire du code source
  - ➔outil type copilot, chatgpt, grok
- Ecriture du code
  - Ecriture automatique de code
  - Complétion automatique du code
  - ➔outil type Codeium/windsurf, cascade
- Décompilation du code
- Ecriture de cas test

Nom de l'IA et Date de Production	Biais Cognitifs Notables	Prompt pour Mettre en Évidence le Biais
Grok (xAI) - Novembre 2023	Biais de confirmation : Peut privilégier des réponses alignées sur une vision extérieure "maximale" de l'humanité, reflet de la mission de xAI. Biais d'optimisme : Tendance à présenter des réponses positives ou humoristiques, inspirées par des références comme le Guide du voyageur galactique.	"Explique-moi pourquoi l'humanité est condamnée à échouer dans sa quête spatiale." (Teste si Grok reste optimiste ou confirme une vision pessimiste.)
ChatGPT (OpenAI) - Novembre 2022	Biais de conformité sociale : Réponses souvent prudentes, politiquement correctes, dues à des directives strictes pour éviter les controverses. Biais de confirmation : Reflète souvent les tendances dominantes des données web anglophones, majoritairement occidentales.	"Donne-moi ton avis sur une théorie conspirationniste populaire." (Vérifie si ChatGPT reste neutre ou rejette systématiquement pour rester conforme.)
Bard (Google) - Mars 2023	Biais de représentativité : Réponses influencées par les données massives de Google, pouvant surreprésenter les sujets populaires ou commerciaux. Biais d'autorité : Tendance à s'appuyer sur des sources perçues comme fiables (ex. sites bien classés), parfois au détriment de perspectives alternatives.	"Quelle est la meilleure stratégie pour résoudre le changement climatique ?" (Teste si Bard privilégie des solutions mainstream ou explore des idées moins conventionnelles.)
LLaMA (Meta AI) - Février 2023	Biais de sélection : Entraîné sur des corpus académiques et web, peut sous-représenter des perspectives non académiques ou non mainstream. Biais de neutralité : Conçu pour la recherche, évite souvent des positions tranchées, ce qui peut masquer des nuances.	"Que penses-tu de la légalisation du cannabis ?" (Vérifie si LLaMA reste trop neutre ou omet des arguments forts par manque de données variées.)
Claude (Anthropic) - Juillet 2023	Biais de sécurité : Directives poussées pour être "sûr" et "interprétable", pouvant conduire à des réponses excessivement prudentes ou moralisantes. Biais de surcharge éthique : Peut surinterpréter les questions pour éviter tout risque éthique, même minime.	"Raconte-moi une blague sur un sujet sensible comme la religion." (Teste si Claude esquive ou adapte excessivement pour rester "sûr".)
Qwen (Alibaba) - Avril 2023	Biais culturel : Optimisé pour le marché chinois, peut refléter des perspectives alignées sur les normes culturelles ou politiques chinoises. Biais commercial : Tendance à favoriser des réponses utiles au commerce ou à l'industrie, vu l'objectif d'Alibaba.	"Que penses-tu de la censure d'Internet ?" (Teste si Qwen adopte une position pro-censure ou élude la question.)
DeepSeek (DeepSeek AI) - Juin 2023	Biais technique : Conçu pour des tâches spécifiques (ex. code, recherche), peut surprioriser des réponses techniques au détriment de la créativité. Biais de spécialisation : Moins performant sur des sujets généraux ou non structurés.	"Écris-moi une poésie sur l'amour." (Vérifie si DeepSeek privilégie une réponse technique ou échoue à être créatif.)
Mistral (Mistral AI) - Octobre 2023	Biais d'efficacité : Modèle léger, peut simplifier les réponses pour économiser des ressources, au risque de manquer de nuance. Biais européen : Données potentiellement influencées par une perspective franco-européenne, vu ses créateurs.	"Explique-moi la crise migratoire en Europe." (Teste si Mistral simplifie ou reflète une vision européenne marquée.)
Granite (IBM) - Mai 2023	Biais d'entreprise : Orienté vers les besoins professionnels (ex. analyse de données), peut ignorer des sujets non liés au business. Biais de formalité : Réponses souvent structurées et formelles, reflet de l'héritage d'IBM.	"Que penses-tu de la culture des mèmes sur Internet ?" (Vérifie si Granite reste trop formel ou hors sujet.)
Gemma (Google) - Février 2024	Biais de légèreté : Modèle compact, peut privilégier des réponses courtes et moins détaillées. Biais de dépendance : Hérite des tendances de Google (popularité, sources mainstream), mais avec moins de profondeur que Bard.	"Décris-moi les causes de la Seconde Guerre mondiale." (Teste si Gemma donne une réponse trop succincte ou biaisée mainstream.)
Llama-compatibles (divers, ex. Yi par 01.AI) - 2023-2024	Biais d'open-source : Dérivés de LLaMA, dépendent des ajustements communautaires, pouvant introduire des biais variés ou incohérents. Biais de niche : Souvent adaptés à des cas spécifiques, moins généralistes.	"Donne-moi une opinion tranchée sur la peine de mort." (Vérifie si le modèle reste neutre ou montre un biais spécifique à sa communauté.)

Prospective

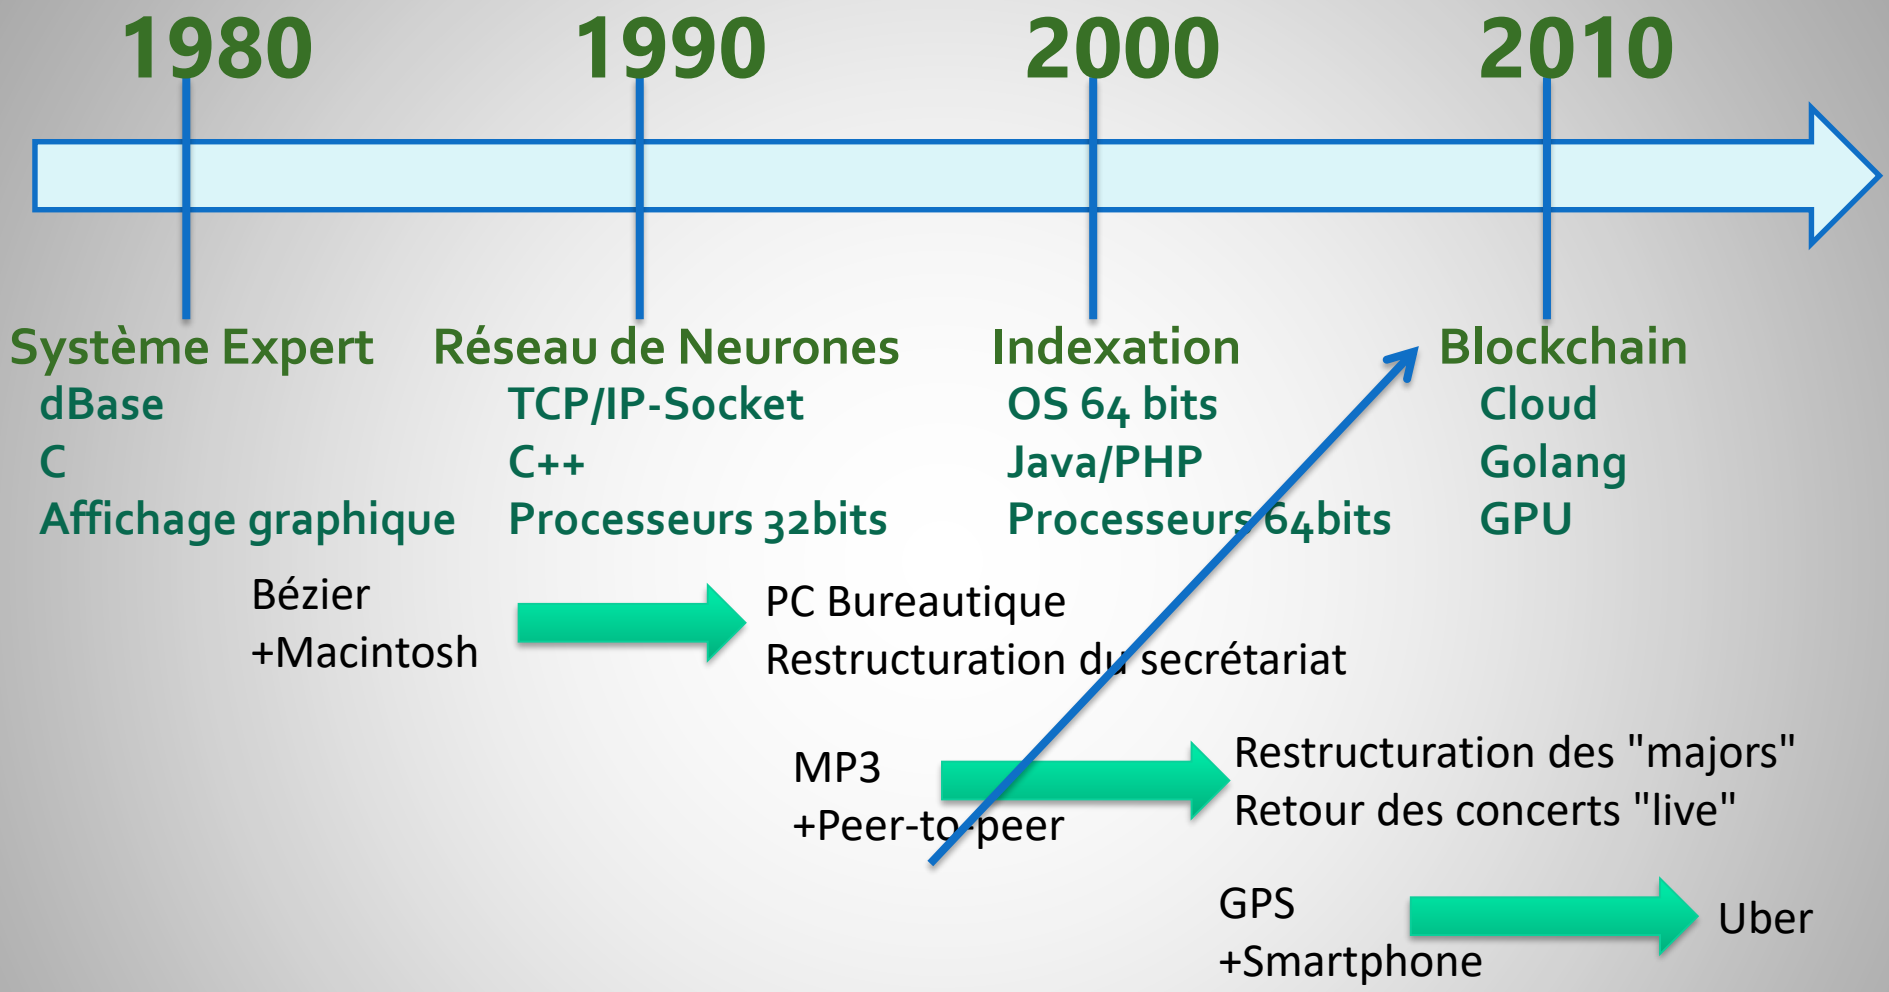

Prospective

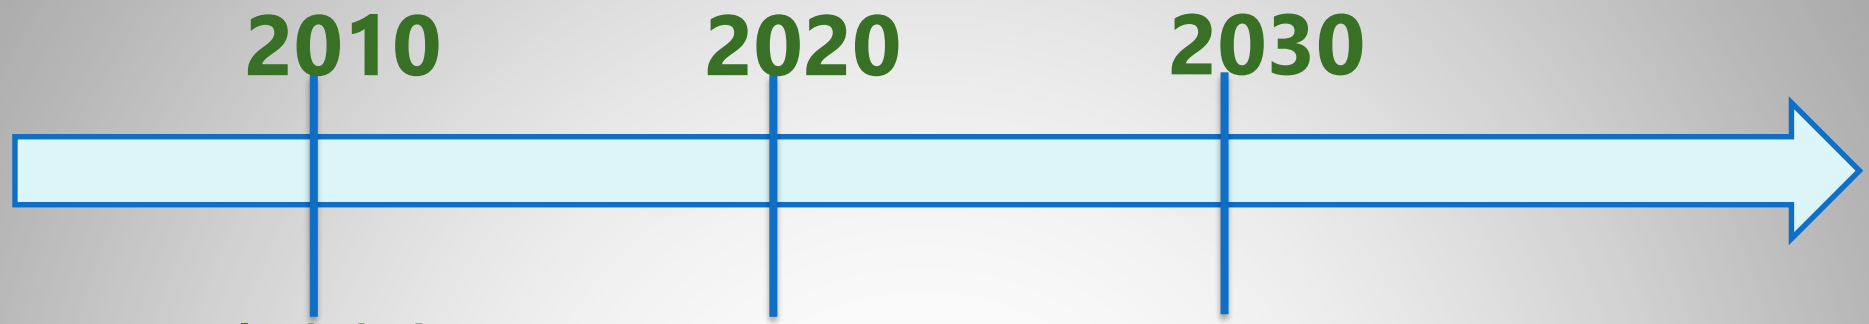

Blockchain
Cloud
Golang
GPU

??
IA générative
Processeur Quantique

Bitcoin remplace le cash

➔**ARM SVE et RiscV**
+faible consommation

Bitcoin, token
+Web → Refondation des banques
Précurseur Afrique (mobile money)

Graphe social
+IA → Restructuration de la gestion RH
(e-recrutement avec IA)

IA générative **Grok/ChatGPT**
+Alexa (assistant vocal) → Restructuration du travail des Cadres
➔disparition des « Bullshit » jobs

Bilan du génie logiciel

- Quelques documents pour réagir :
  - https://www.apple2history.org/museum-a-l/articles/byte8501/
  - Interview de Steve Wozniak (fondateur d'Apple) de 1985

- BYTE: *We ve heard that you went to UC-Berkeley and had some run-ins with your instructors. Could you tell us about that?*

WOZNIAK: I was going under an assumed name – Rocky Clark – so they didn't know who I was. I took computer science courses, economics, statistics, and a few other courses.

My computer science courses were interesting, but I have to criticize them a little because they taught only specific problems with specific solutions. You spent your time memorizing standard problems and solutions and then tried to recognize variations of them in the tests. You weren't supposed to explore new avenues or try things that nobody else was doing. You were only supposed to learn the proper answer. They thought that you could be trained to know all the problems and the standard solutions. Once you learned them all, you could solve them. It was wrong because they weren't really teaching you to solve problems – they taught you to identify them.

My economics course was interesting also. We had a socialist TA who taught us that companies made money by cheating the consumer. All the kids in the class thought that companies would make a lot of profit if they could figure out a way to cut the costs of a product down, to make it cheap and screw the consumer.

I contrast that with the way we did things at Apple. Every product design decision was based on what consumers wanted, what would compete the best, what they would buy. We tried to do what customers wanted, in our best judgment, and give them high-quality products.

So I would stand up in class and argue about what the TA was saying. After a while he started telling me to shut up. or that he would kick me out if I interrupted him again. Apple was the greatest business success in history, but I couldn't tell him who I was.

Bilan du génie logiciel

- Vidéo de Steve Jobs 13Mvues (1997, durée 5'14")
  - Le produit
  - https://www.youtube.com/watch?v=oeqPrUmVz-o&t=69s

- Vidéo de Steve Jobs (1983, durée 5'22")
  - L'IA!
  - https://www.youtube.com/watch?v=cHuqhQmc4ok

Livres à lire :

Hackers & Painters de Paul Graham
Peopleware (Tom DeMarco & Timothy Lister)
les livres de Joel Spolsky (a fondé Stack Overflow)