



HORIZONTALNO SKALIRANJE K8S POD-OVA POMOĆU KEDA AUTOSCALER-A

HORIZONTAL SCALING K8S PODS USING KEDA AUTOSCALER

Marko Stanić, *Fakultet tehničkih nauka, Novi Sad*

Oblast - SOFTVERSKO INŽENJERSTVO I INFORMACIONE TEHNOLOGIJE

Kratak sadržaj - U radu je prikazana implementacija upravljanja konfiguracijom za automatsko skaliranje Kubernetes pod-ova zasnovano na broju poruka u SQS-u. Opisan je princip rada Kubernetes kontejner orkestratora sa KEDA autoscaler-om uz integraciju sa Python bibliotekom za upravljanje cloud servisima i K8s resursima.

Ključne reči: Kubernetes, KEDA, SQS, horizontalno skaliranje

Abstract - The paper presents the implementation of a configuration management software for K8s pods and auto-scaling based on number of messages in SQS. It is described how to use KEDA autoscaler with K8s container orchestrator and Python library for cloud and K8s resource management.

Keywords: Kubernetes, KEDA, SQS, horizontal scaling

1. UVOD

U savremenom softverskom inženjeringu, skaliranje aplikacija postaje sve važniji aspekt koji utiče na njihovu pouzdanost i performanse. Kada aplikacije rastu i korisnički zahtevi se povećavaju, potrebno je da se skalira infrastruktura koja podržava aplikaciju.

Dva osnovna pristupa skaliranju su vertikalno i horizontalno skaliranje. Horizontalno skaliranje podrazumeva dodavanje novih mašina u postojeću infrastrukturu, što omogućava raspoređivanje opterećenja na više mašina i obezbeđuje bolju otpornost na kvarove [1]. U ovom radu će fokus biti horizontalno skaliranje Kubernetes pod-ova uz pomoć KEDA autoscaler-a i metrika iz AWS SQS servisa i broja poruka u redu.

2. TEHNOLOGIJE

2.1. Kubernetes

Kubernetes (K8s) [2] je open-source platforma za automatizovanu upravu kontejnerima.

Kontejnerizacija je tehnologija koja omogućava pakovanje aplikacija i njenih zavisnosti u izolovane kontejnere, što omogućava da se aplikacija izvršava u bilo kojoj okolini koja podržava kontejnere. Kubernetes pruža alate i mehanizme za automatizovanu upravu kontejnerima i njihovim

resursima, kao što su skaliranje, *load balancing*, *selfhealing* i *rollout* aplikacija. Kubernetes ima nekoliko ključnih komponenti koje omogućavaju automatizovanu upravu kontejnerima. Kontejneri se pokreću u Kubernetes klasteru, koji se sastoji od čvorova (eng. *nodes*) i kontrolne ravni (eng. *control plane*). Svaki čvor je fizička ili virtualna mašina koja izvršava kontejnere, dok kontrolna ravan sadrži alate za upravljanje čvorovima i kontejnerima.

2.2. KEDA

KEDA (*Kubernetes-based Event Driven Autoscaler*) [3] je open-source komponenta za automatsko skaliranje Kubernetes aplikacija (*Deployment* i *ReplicaSet*) na osnovu različitih događaja i metrika koje se dešavaju u Kubernetes klasteru ili u drugim *cloud* servisima.

KEDA podržava veliki broj događaja i metrika, uključujući AWS SQS [4], Azure Service Bus, Apache Kafka, RabbitMQ i brojne druge.

2.3. SQS

Amazon Simple Queue Service (SQS) je *fully-managed* servis u okviru Amazon Web Services (AWS) platforme, koji omogućava korisnicima da lako kreiraju i upravljaju redovima poruka u *cloud* okruženju. SQS je dizajniran da pomogne korisnicima da odvoje komponente svojih aplikacija, tako što će omogućiti različitim delovima aplikacije da komuniciraju asinhrono, bez potrebe za direktnom vezom.

SQS je skalabilan i otporan na greške, što ga čini idealnim izborom za različite aplikacije koje se zasnivaju na *cloud* tehnologijama i koje moraju da podrže veliki broj korisnika i visok nivo opterećenja. SQS je dostupan u dve verzije: standardna verzija i FIFO verzija (*First-In-First-Out*). Standardna verzija podržava veliki broj poruka u redu, sa minimalnim kašnjenjem u isporuci poruka, dok FIFO verzija omogućava garanciju da će poruke biti isporučene tačno onim redosledom kojim su postavljene u red.

SQS pruža fleksibilnost u upravljanju porukama, uključujući mogućnost slanja, primanja, brisanja i promene prioriteta poruka. Takođe omogućava i definisanje pravila za ponovno slanje poruka koje nisu uspešno isporučene.

SQS se može integrisati sa drugim AWS servisima, kao što su Amazon S3, Amazon EC2, AWS Lambda i mnogi drugi, kako bi se omogućilo jednostavno upravljanje porukama i stvaranje pouzdanih, skalabilnih i otpornih aplikacija u *cloud* okruženju.

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Željko Vuković, docent.

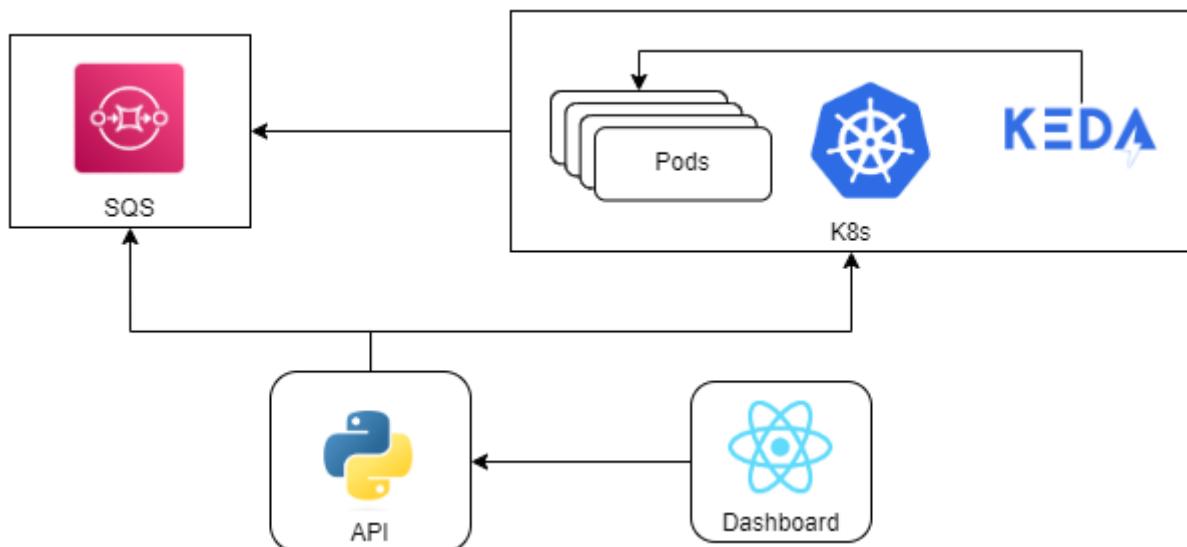
3. ARHITEKTURA

Na slici 1 nalaze se sledeće komponente:

- *K8s* klaster na kome će biti *deploy*-ovana aplikacija koja će se dinamički skalirati. Podrška za *Kubernetes* je dostupna na gotovo svim većim *cloud* provajderima. Za testiranje u lokalnom okruženju korišćen je *Minikube* [5].
- *KEDA autoscaler* gde će se definisati skalirajući resursi (*Scalers*) koji se koriste za prikupljanje metrika o opterećenju aplikacije. U ovom slučaju to će biti broj poruka koji se nalazi u redu (*queue*)
- Za korišćenje *SQS* servisa je neophodan AWS korisnički nalog, tako da alternativa za njegovu upotrebu može biti *ElasticMQ* [6] koji ima isti interfejs kao i *SQS*. To znači da

je moguće testirati lokalno bez ikakvih troškova, a za prelazak na *SQS* je potrebno samo izmeniti odgovarajuću konfiguraciju.

- *Backend* je *REST API* koji pruža interakciju sa *Amazon SQS* i *K8s* klasterom. Sve dostupne funkcionalnosti mogu se pregledati kroz *OpenAPI* dokumentaciju na */docs* putanji.
- *Dashboard* je korisnički interfejs za komunikaciju sa prethodnim *REST* servisom, koji omogućava grafički pregled, dodavanje novih kao i brisanje redova. Takođe u svaki red je moguće dodati navedeni broj poruka ili obrisati sve (*purge*). Kreiranje *Scaled Object* resursa je dostupno popunjavanjem forme.



Slika 1. Arhitektura Sistema

4. IMPLEMENTACIJA

Za pokretanje *minikube* klastera, na Windows operativnom sistemu potrebno je izvršiti komandu *minikube start* u *PowerShell*-u. Status je moguće proveriti kroz *Docker Desktop* gde će se pojaviti kontejner sa nazivom *minikube* u stanju *running* (slika 4.1.2) ili kroz *Lens* - radno okruženje za *K8s*. Instalacija *KEDA autoscaler*-a se vrši pomoću *helm* [7] menadžera paketa za *Kubernetes*. Pravila skaliranja se mogu definisati na osnovu željene maksimalne i minimalne veličine broja replika aplikacije. Na primer, ako se želi imati minimalno dve i maksimalno pet replika aplikacije u *Kubernetes* klasteru, mogu se definisati pravila skaliranja koja će skalirati aplikaciju prema gore kada broj poruka u redu poraste iznad određenog praga, a skalirati aplikaciju prema dole kada broj poruka u redu padne ispod nekog drugog praga.

KEDA ima dve različite faze tokom procesa automatskog skaliranja:

Faza aktiviranja (ili deaktiviranja) je trenutak kada *KEDA* operator mora da odluči da li je opterećenje takvo da treba skalirati od nule ili na nulu. Ova akcija je bazirana na rezultatu funkcije *IsActive* i primenjuje se samo na 0-1 skaliranje. Postoje slučajevi kada su pravila za aktiviranje

potpuno drugačija, na primer sa *Prometheus* skalarom gde vrednosti mogu ići od -x do x.

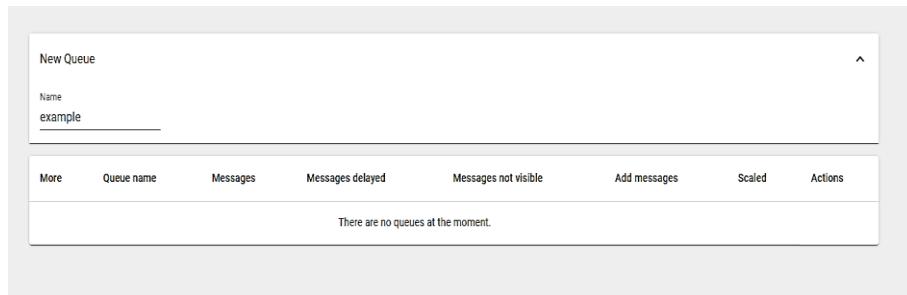
Faza skaliranja je trenutak kada postoji jedna instanca i tada *Horizontal Pod Autoscaler (HPA)* donosi odluke zasnovane na konfiguraciji koja je generisana na osnovu podataka u *ScaledObject* resursu. Ova faza se primenjuje na 1-n skaliranje.

Web API koji služi za upravljanje redovima i *Kubernetes* resursima je kreiran uz pomoć *FastAPI* radnog okvira u *Python* programskom jeziku.

Za kreiranje novog reda je potrebno proslediti samo naziv u formi koja je prikazana na slici 2.

Akcije koje je moguće izvršiti nad redom su: dodavanje poruka, brisanje poruka, brisanje i kreiranje *ScaledObject* resursa (slika) za koje je potrebno izabrati *deployment* iz odgovarajućeg *namespace*-a.

Nakon uspešnog kreiranja *ScaledObject*-a skaliranje se aktivira i status je moguće videti na slici 4 gde je prikazan *progress bar* koji predstavlja odnos trenutnog i maksimalnog broja instanci, koji su definisani za *ScaledObject*.



Slika 2. Tabela formom za dodavanje reda

Create KEDA ScaledObject

To create this resource, first select namespace and deployment. There are base and additional parameters to set

Namespace: apps-dev

Deployment: nginx-deployment

Min replicas: 0 Max replicas: 10 Queue length: 10

Additional settings

CANCEL SUBMIT

Slika 3. Forma za kreiranje ScaledObject-a

Messages delayed	Messages not visible	Add messages	Scaled	Actions
5	0	0	<div style="width: 100px; height: 20px; background-color: #f0f0f0;"></div> 4/10	⋮

Slika 4. Status skaliranja

5. ZAKLJUČAK

U ovom radu je predstavljen primer horizontalnog skaliranja aplikacija u *Kubernetes* klasteru uz pomoć *KEDA autoscaler-a*. Objasnjen je princip rada *Kubernetes-a* kao kontejner orkestratora i način upotrebe *autoscaler-a* zasnovano na događajima, tačnije broja poruka u *AWS SQS*. Time je omogućena brža obrada podataka ukoliko je to zahtevano na osnovu definisane konfiguracije, a sa druge strane ušteda resursa kada nije neophodno da aplikacija bude aktivna.

Horizontalno skaliranje se može primeniti u nekoliko slučajeva: za povećanje performansi ukoliko nije moguće dodati više resursa na jednoj mašini (fizičkoj ili virtualnoj), kada je potrebno omogućiti maksimalnu dostupnost, u slučaju da dođe do otkaza neke mašine, ostale nastavljaju da rade bez zastoja.

6. LITERATURA

- [1] IBM Data Science - Best Practices
<https://ibm.github.io/data-science-best-practices/scaling.html>

[2] Kubernetes <https://kubernetes.io/>

[3] KEDA <https://keda.sh/>

[4] SQS <https://aws.amazon.com/sqs/>

[5] Minikube <https://minikube.sigs.k8s.io/docs/start/>

[6] ElasticMQ <https://github.com/softwaremill/elasticmq>

[7] Helm <https://helm.sh/>

Kratka biografija:



Marko Stanić rođen je 31.5.1997. godine u Šapcu. Završio je osnovne akademske studije 2020. godine na Fakultetu tehničkih nauka. Upisao je master studije iste godine, studijski program Softversko inženjerstvo i informacione tehnologije

kontakt: marko.stanic97@icloud.com