




멀티클러스터에서 가시성 구축 사례 (feat. Thanos)

임성일

- Software Developer @ SK Telecom
- TACO development
 - LMA deployment
 - GitOps tools
 - Micro services
- OSS Contributor (~2019)
 - Openstack
 - Fluentbit
- eMail: si.im@sk.com, usnexp@gmail.com



Contents



Prometheus

Federation




Thanos

component




Thanos 적용사례 (TACO)

Prometheus



Prometheus?

- **a multi-dimensional data model with time series data** identified by metric name and key/value pairs
- PromQL, a **flexible query language** to leverage this dimensionality
- no reliance on distributed storage; single server nodes are autonomous
- time series collection happens via a **pull model over HTTP**
- pushing time series is supported via an **intermediary gateway**
- targets are discovered via service discovery or static configuration
- multiple modes of graphing and dashboarding support




출처: prometheus.io


TACO-LMA의 멀티클러스터

(feat. Prometheus federation)

- 클러스터별 수집용 Prometheus 배포
- 모든 클러스터의 모니터링 정보를 모으는 전용 클러스터 구성 (논리적/물리적)
- Prometheus의 federation 기능 활용



Thanos



Thanos?



Global Query View

Scale your Prometheus setup by enabling querying of your Prometheus metrics across multiple Prometheus servers and clusters.



Unlimited Retention

Extend the system with the object storage of your choice to store your metrics for unlimited time. Supports GCP, S3, Azure, Swift and Tencent COS.



Prometheus Compatible

Use the same tools you love, such as Grafana and others, that support the Prometheus Query API.



Downsampling & Compaction


Downsample historical data for massive query speedup when querying large time ranges or configure complex retention policies.

출처: thanos.io

Thanos Compactor



- prometheus 2.0 저장소 엔진(storage engine)의 compaction 과정에 적용되는 Thanos의 명령어 compact
- Compaction
 - 객체저장소(Obj storage)에 저장된 블록 데이터를 대상으로 수행
 - 완전한 동시성을 제공하지 않으므로 개별 버킷에 대한 singleton에 따라 수행해야 함
- Downsampling
 - 시간범위에 따라 정확도를 유지하면서 통합된 데이터를 저장
 - 요청시 활용하여 질의성능 향상




Thanos Compactor



- 주요 활용 방법
 - rollout: 수집된 데이터를 기준에 따라 장기보관용 데이터로 전환
 - rollover: aggregated 데이터 생성
 - deduplication: 동일한 데이터에 대한 복수의 수집기를 활용하고 복수제거를 사용하여 가용성을 향상(H.A.)
 - 비동기 동작: cron 또는 daemon 형태로 사용
- 리소스 사용 관련 주의사항
 - 원격 저장소의 대용량의 데이터를 다루는 작업으로 메모리와 네트워크의 사용량이 많음
 - 실행주기와 동시진행 작업 수 등을 조절이 필요

```
thanos compact --data-dir /tmp/thanos-compact \  
--objstore.config-file=bucket.yml \  
--retention.resolution-raw=10d \  
--retention.resolution-5m=30d \  
--retention.resolution-1h=365d \  
--compaction.concurrency=2
```





Thanos querier/query



- 다양한 backend의 데이터에 질의
 - Prometheus (see [Sidecar](#))
 - Object Storage (see [Store Gateway](#))
 - Global alerting/recording rules evaluations (see [Ruler](#))
 - Metrics received from Prometheus remote write streams (see [Receiver](#))
 - Another Querier (you can stack Queriers on top of each other)
 - Non-Prometheus systems! (e.g [OpenTSDB](#))
- Run-time deduplication of HA groups

```
thanos query \  
  --http-address      "0.0.0.0:9090" \  
  --query.replica-label "replica" \  
  --store             "<store-api>:<grpc-port>" \  
  --store             "<store-api2>:<grpc-port>"
```




Thanos query frontend



- Thanos Queriers의 앞단에 읽기 성능 향상을 위한 서비스 제공
- [Cortex Query Frontend](#) 차용
- 주요기능
 - Splitting
 - Retry
 - Caching (in-memory, memcached)
 - Slow query logging
- 주요 활용
 - 수평적 읽기성능 확장
 - Safeguard

```
thanos query-frontend \  
  --http-address "0.0.0.0:9090" \  
  --query-frontend.downstream-url="<thanos-querier>:<querier-http-port>"
```





Thanos Ruler



- 실시간 rule처리
 - Alerting rule: 알람발생
 - Recording rule: raw metric을 저장하는 방법지정
- 주의: 지속적으로 query를 사용하므로 성능에 영향이 발생

```
thanos rule \  
  --data-dir      "/path/to/data" \  
  --eval-interval "30s" \  
  --rule-file     "/path/to/rules/*.rules.yaml" \  
  --alert.query-url "http://0.0.0.0:9090" \  
  --alertmanagers.url "http://alert.thanos.io" \  
  --query         "query.example.org" \  
  --query         "query2.example.org" \  
  --objstore.config-file "bucket.yml" \  
  --label         'monitor_cluster="cluster1"' \  
  --label         'replica="A"'
```







Thanos Sidecar



- 주요기능
 - 백업: 일정 시간마다 tsdb데이터를 thanos object storage에 저장
 - 질의: Thanos Querier(Query)가 StoreAPI를 호출하여 Prometheus (local)에 질의
- 참고: 데이터 누락을 방지하기 위한 --min-time 설정
 - store-api를 통해 요청온 내용에 대한 처리에 대한 지침으로 -2h를 설정하면 2시간 전까지의 데이터는 처리
 - sidecar가 2시간에 한번씩 2시간 데이터를 object store에 기록하고 compactor는 30분의 대기 후 (consistencyDelay) 처리하므로 2:30 이상 설정해야 함






Thanos Store Gateway



- Store API를 제공하며 이를 통해 오브젝트 스토리지 버킷에 저장된 Long-term 데이터를 접근하기 위한 서비스를 제공
- 기능
 - Shading / Partitioning: 시간, 레이블기반
 - Caching: index cache
 - In-memory, memcached

전환사례



TKS (Taco Kubernetes Service)



TKS 는

- TACO를 기반으로 **hybrid cloud** 서비스 예정 (2022.1Q)
- 사용자가 TACO(kubernetes) 클러스터를 요청하면 실시간 생성 및 삭제 등 기능제공
 - decapod v2 도 함께 사용한 기술
 - 사용자는 할당된 범위에서 자유롭게 클러스터 생성/사용/삭제

TKS 요건


- 클러스터별 역할(ex. master, admin, manger...)을 부여하지 않고 모두 동일한 구조로 구성 (최소변경요건)
- 사용자는 접근하는 클러스터에 관계없이 동일하게 전체 클러스터의 상태를 확인할 수 있어야 함
- 클러스터에서 발생한 장애가 다른 클러스터로 전파되면 안됨

Thanos 도입




TKS(**Taco Kubernetes Service**) 서비스를 준비


- 멀티클러스터의 멀티 소스에 대한 통합적 가시성 확보 필요
 - 클러스터에 다양한 메트릭을 추가하기 위해 용도별 prometheus를 배포 (ex> 서비스 매시, 사용자 서비스,....)
 - 조회 및 활용 수준의 일관성 제공은 필수
- 장기데이터 보관을 필요



#1 알람 중복 이슈



#1 알람 중복 이슈





#1 알람 중복 이슈

- 동일한 형상유지를 위해 모든 클러스터에 알람 기능이 들어가고 기존의 룰을 그대로 사용하면서 발생
 - 모든 클러스터에 알람기능(Thanos rule)이 설치되고 클러스터의 개수 만큼의 alert이 발생
 - Thanos alert은 알럿의 수에 비례하여 질의가 발생하고 이는 성능상 과부하 문제가 있음
- 해결방법
 - 알람룰을 개별 클러스터로 분배하고 Prometheus rule engine에서 처리하도록 함
- Prometheus와 Thanos rule은 완전 호환되므로 형식을 바꿀 필요는 없으나 cluster별 query를 하기 위해 들어갔던 내용을 삭제할 필요가 있었음
- 클러스터간 연관관계를 통한 알람을 정의하기 위해서는 thanos의 ruler를 사용해야 하며 이경우는 대상클러스터에 하나의 ruler만 설치/운영해야 함

#2 데이터 쓰기경합 체크





- Thanos는 Object storage를 공유하여 데이터를 저장하고 이를 조회하도록 구성되어 있음
- 다수의 thanos에 동일한 작업을 수행하도록 하면서 문제가 발생할 수 있는 부분을 체크필요

Thanos Component	Read	Write	비고
Bucket Web	O	X	
Compactor	O	O	전체 데이터를 대상으로 rollout, rollover등 재가공이 이뤄지므로 전체 클러스터에 하나만 운영해야 함
Minio	X	X	
Query	O	X	
Query-frontend	X	X	
Ruler	O	X	
Store Gateway	O	X	
Thanos sidecar(in Prometheus)	O	O	sidecar는 해당 클러스터에서 발생하는 데이터를 백업하므로 클러스터별 sidecar사용에 문제는 없음

#3 순환 Graph 발생 주의

- Thanos는 query/querier를 통해 다양한 backend를 연동
- Thanos의 query는 또 다른 query를 backend로 연결가능
- 결정된 멀티클러스터 구조에는 모든 노드에 prometheus, thanos가 있고 서로 연동되어야 함
- 두가지 연결방법이 존재
 - 1안의 경우 순환 graph가 발생하게 되므로 2안의 방식으로 연동해야 함



Github에서 구체적 설정확인 가능


- <https://url.kr/bsfl76>
- <https://url.kr/dwlr8h>

```
995 queryFrontend:
996   enabled: false
997   nodeSelector: {}
998   service:
999     type: TO_BE_FIXED
1000   http:
1001     port: 9090
1002     nodePort: TO_BE_FIXED
1003   config: |-
1004     type: IN-MEMORY
1005     config:
1006       max_size: TO_BE_FIXED
1007       max_size_items: TO_BE_FIXED
1008       validity: TO_BE_FIXED
1009   extraFlags: []
1010   # query-range.split-interval: TO_BE_
1011   # query-range.max-retries-per-reques
1012   # query-frontend.log-queries-longer-
```


```
1023 compactor:
1024   enabled: TO_BE_FIXED
1025   logLevel: info
1026   retentionResolutionRaw: TO_BE_FIXED
1027   retentionResolution5m: TO_BE_FIXED
1028   retentionResolution1h: TO_BE_FIXED
1029   consistencyDelay: TO_BE_FIXED
1030   resources:
1031     limits:
1032       memory: TO_BE_FIXED
1033       cpu: TO_BE_FIXED
1034   nodeSelector: {}
1035   service:
1036     type: ClusterIP
1037     http:
1038       port: 9090
1039   persistence:
1040     enabled: true
1041     accessModes:
1042       - ReadWriteOnce
1043     size: TO_BE_FIXED
1044   extraFlags: []
1045   # Compaction 수행 관련 커멘트
1046   # 아래와 같은 block stream들이 있을때
1047   # external_labels: {cluster="eu1", replica="1", receive="true", environment="production"}
1048   # external_labels: {cluster="eu1", replica="2", receive="true", environment="production"}
1049   # external_labels: {cluster="us1", replica="1", receive="true", environment="production"}
1050   # external_labels: {cluster="us1", replica="1", receive="true", environment="staging"}
1051   # --compact-parallelism=vertical-compaction 와 함께 --deduplication-replicas-label="replicas" 라고 설정
```

```
969 apiVersion: helm.fluxcd.io/v1
970 kind: HelmRelease
971 metadata:
972   labels:
973     name: thanos
974   name: thanos
975 spec:
976   helmVersion: v3
977   chart:
978     type: helmrepo
979     repository: https://charts.bitnami.com/bitnami
980     name: thanos
981     version: 3.4.0
982     releaseName: thanos
983     targetNamespace: lma
984     values:
985       global:
986         storageClass: local-path
987         clusterDomain: TO_BE_FIXED
988         existingObjstoreSecret: TO_BE_FIXED
989       query:
990         nodeSelector: {}
991         dnsDiscovery:
992           enabled: true
993           sidecarsService: TO_BE_FIXED
994           sidecarsNamespace: lma
995       queryFrontend:
996         enabled: false
```

Demo



Demo



Demo - 참고

<https://devocean.sk.com/blog/techBoardDetail.do?ID=163458>

<https://devocean.sk.com/blog/techBoardDetail.do?ID=163447>

<https://youtu.be/-sfWvPgilrU>




Thanos를 이용한 멀티클러스터 모니터링

지난 블로그(<https://devocean.sk.com/blog/techBoardDetail.do?ID=163447>)에서는 Prometheus를 사용하여 Kubernetes를 모니터링하는 방법과 TACO의 예를 통해 실제 배포하는 예를 설명하였다. 이어서 본 블로그에서는 Prometheus에서 부족했던 부분을 채우고 다양한 통합기능을 제공하는 Thanos에 대해 설명하고자 하고 설치하는 방법을 알아본다. Prometheus의 H.A. 문제 Prometheus는 cloud native 환경에...

#Prometheus



sungil | 21.11.10 @ 298 ♡ 5 □ 2



Prometheus를 사용한 Kubernetes 모니터링

기존의 모놀리식 방식의 소프트웨어와 달리, 다수의 Micro service들을 통해 서비스가 만들어지는 Container 및 Kubernetes 환경에서 개별 동작에 대한 가시성의 확보는 점점 중요해지고 있다. 시스템, 소프트웨어, 서비스 등 IT 전반에서 정상적 운영과 활용을 위해 운영 자원들에 대한 모니터링은 필수 요소이다. TACO는 Cloud Native한 환경을 지원하기 위한 Container 플랫폼을 제공하고 있으며, 플랫폼 및 내부의 구성요소를 모니터링...

#Programming Language #Prometheus



sungil | 21.11.02 @ 1599 ♡ 5 □ 0



Lesson learned

- Thanos는 prometheus간 호환성 확인
- 많은 튜닝/확장 포인트 제공
- 다양한 객체저장소 활용가능
- Bucket web 등 툴은 아직 이른단계(early stage)



+
•
○

Thanks