

Raspodijeljeni podatkovni sustav BeeGFS

Emir Imamagić

Sveučilišni Računski Centar (Srce)



Sveučilište u Zagrebu
Sveučilišni računski centar



srce
otvoreni pristup

Sadržaj

- Raspodijeljeni podatkovni sustavi
- BeeGFS
- Instalacija i konfiguracija
- Ostali raspodijeljeni podatkovni sustavi
- Raspodijeljeni podatkovni sustavi u Srcu
- Reference






Raspodijeljeni podatkovni sustavi

Uvod

- Spajanje više podatkovnih poslužitelja u jedinstven podatkovni prostor



Uvod

- Prednosti

- učinkovitiji pristup podacima – raspodjeljivanje opterećenja
- proširivanje ili smanjivanje prostora prema potrebama

- Problemi

- nedostupnost poslužitelja – potrebna replikacija podataka
- konzistentnost podataka kod replikacije
- mrežna povezanost
- podržane platforme

Vrste

- Mrežni datotečni sustavi
 - jedan podatkovni poslužitelj
 - primjeri: CIFS, NFS
- Paralelni datotečni sustavi
 - više podatkovnih poslužitelja
 - visoka učinkovitost
 - podatkovni poslužitelji na jednoj fizičkoj lokaciji
 - primjeri: GlusterFS, Lustre, **BeeGFS**, PNFS



Vrste


- Raspodijeljeni datotečni sustavi
 - veliki broj podatkovnih poslužitelja
 - podatkovni poslužitelji raspodijeljeni na više fizičkih lokacija
 - primjeri: Google FS, Hadoop FS, MogileFS

BeeGFS




BeeGFS

- Raspodijeljeni podatkovni sustav
- Razvijen od strane Fraunhofer Institute for Industrial Mathematics (ITWM)
 - inicijalno razvijen 2005. za potrebe HPC (engl. *High Performance Computing*) klastera
- Prethodno ime FhGFS
 - engl. *Fraunhofer Gesellschaft File System*
 - 2014. objavljeno novo ime i osnovan spin-off ThinkParQ
- Komercijalna programska potpora
 - dostupan je besplatno ili uz plaćanje podrške
 - neke funkcionalnosti zahtijevaju plaćanje podrške



Arhitektura




Komponente

- Upravljački servis (engl. *management*)
 - katalog svih servisa
 - omogućava dinamičko dodavanje i uklanjanje servisa
 - samo jedan za cijeli klaster
- Imenički servis (engl. *metadata*)
 - struktura datotečnog sustava
 - atributi i smještaj datoteka
 - proizvoljan broj u klasteru
 - raspodjela: jedan direktorij se sprema u jedan imenički servis



Komponente

- Podatkovni servis (engl. *storage*)
 - pohrana podataka
 - proizvoljan broj u klasteru
 - moguće koristiti više particija (engl. *target*) po podatkovnom servisu
 - raspodjela: jedan podatak se sprema u jedan ili više podatkovnih servisa
- Nadzorni servis (engl. *admon*)
 - nadzire i prikuplja statistike ostalih servisa
 - grafički alat pisani u Javi
 - instalacija i upravljanje ostalim komponentama
 - opcionalan



Komponente

- Klijenti
 - poseban kernel modul
 - ne zahtijeva izmjenu kernela



Podržane platforme

- Operacijski sustavi
 - Red Hat Linux 5, 6 i 7
 - Suse Linux 11 i 12
 - Debian Linux 7 i 8
- Datotečni sustavi za pohranu podataka
 - XFS - preporučeni sustav za podatkovni servis
 - ext4 - preporučeni sustav za imenički servis
 - drugi datotečni sustavi sukladni specifikaciji POSIX (ext3, ext4, RaiserFS)
- Mrežne tehnologije
 - Ethernet (1Gb/s i 10Gb/s)
 - Infiniband (RDMA)



Oblici spremanja datoteka

- Moguće podešavati na razini direktorija
- Dijeljenje datoteke (engl. *stripe*)
 - pogodno za velike datoteke
- Spremanje na više lokacija (engl. *mirror*)
 - omogućava visoku dostupnost datoteka
 - zahtjeva plaćenu podršku
- Spremanje podataka imeničkog servisa na više lokacija
 - eksperimentalna funkcionalnost
 - nije moguć automatski oporavak



Napredne funkcionalnosti

- Odabir preferiranih imeničkih i podatkovnih servisa
- Korištenje više mrežnih sučelja
 - automatski prijelaz na drugu mrežu u slučaju ispada
 - postavljanje prioriteta mreža i automatski povratak na primarnu (engl. *fallback*)
- Funkcionalnosti *extended attributes* i POSIX ACL
- Postavljanje korisničkih kvota
 - zahtjeva plaćenu podršku
- BeeOND (engl. *BeeGFS on demand*)
 - automatska uspostava klastera
 - korisno za računalne klastere i uspostavu testnih okolina

Mane

- Nije u potpunosti implementirana visoka dostupnost
 - moguće ju ostvariti korištenjem dodatnih alata (npr. Red Hat Cluster Suite)
- Nadogradnje na glavne nove verzije zahtijevaju gašenje klastera
- Nije moguće balansirati podatke prilikom proširenja



Instalacija i konfiguracija

Instalacija

- Oblici instalacije
 - grafičko sučelje (admon) - ograničen skup mogućnosti
 - pomoću paketa - Red Hat, Suse i Debian
- Zadnja verzija je **2015.03**



Instalacija

Komponenta	Paketi	Servisi	Konfiguracijske datoteke
Upravljački servis	beegfs-mgtd	beegfs-mgtd	/etc/beegfs/beegfs-mgtd.conf
Imenički servis	beegfs-meta	beegfs-meta	/etc/beegfs/beegfs-meta.conf
Podatkovni servis	beegfs-storage	beegfs-storage	/etc/beegfs/beegfs-storage.conf
Nadzorni servis	beegfs-admon	beegfs-admon	/etc/beegfs/beegfs-admon.conf
Klijent	beegfs-client beegfs-helperd	beegfs-client beegfs-helperd	/etc/beegfs/beegfs-client.conf /etc/beegfs/beegfs-helperd.conf /etc/beegfs/beegfs-mounts.conf

Konfiguracija - zajedničke opcije

Opcija	Opis
sysMgtdHost	Adresa upravljačkog servisa
storeAllowFirstRunInit	Da li je dozvoljeno inicijalizirati direktorij - postaviti u true prilikom instalacije, kasnije u false
connAuthFile	Datoteka koja sadrži dijeljeni ključ svih komponenata klastera
connInterfacesFile	Popis mrežnih sučelja koje servisi trebaju koristiti, lista je ujedno i prioritet pojedinih sučelja
connNetFilterFile	Popis mreža putem kojeg servisi mogu komunicirati s drugim servisima
tuneNumWorkers	Broj procesa koje će servis pokrenuti, 0 - broj procesorskih jezgri na stroju

Konfiguracija - upravljački servis

Opcija	Opis
storeMgmtDirectory	Direktorij u koji se spremaju podaci
sysAllowNewServers	Da li je dozvoljena prijava novih komponenata - postaviti u true prilikom instalacije, kasnije u false
sysAllowNewTargets	Da li je dozvoljena prijava novih particija - postaviti u true prilikom instalacije, kasnije u false
tune(Storage Meta)InodesLowLimit	Broj inodeova ispod kojeg servis prelazi u grupu <i>low</i>
tune(Storage Meta) InodesEmergencyLimit	Broj inodeova ispod kojeg servis prelazi u grupu <i>emergency</i>
tune(Storage Meta)SpaceLowLimit	Količina diska ispod kojeg servis prelazi u grupu <i>low</i>
tune(Storage Meta)SpaceEmergencyLimit	Količina diska ispod kojeg servis prelazi u grupu <i>emergency</i>

Konfiguracija - imenički servis

Opcija	Opis
storeMetaDirectory	Direktorij u koji se spremaju podaci
storeUseExtendedAttrs	Podaci o direktorijima se spremaju u <i>extended attribute</i> - preporučeno uključiti zbog veće učinkovitosti servisa
storeClientXAttrs	Omogućiti funkcionalnost <i>extended attribute</i> - koristiti isključivo ukoliko postoji potreba jer smanjuje učinkovitost servisa
storeClientACLs	Omogućiti korištenje POSIX ACL (engl. <i>Access Lists</i>) - koristiti isključivo ukoliko postoji potreba jer smanjuje učinkovitost servisa; klijent mora koristiti kernel > 3.2.

Konfiguracija - podatkovni servis

Opcija	Opis
storeStorageDirectory	Popis direktorija u koje se spremaju podaci

Konfiguracija - klijent

Opcija	Opis
connCommRetrySecs	Broj sekundi nakon kojeg će pristup datoteci završiti greškom u slučaju ispada servisa, 0 - klijent će čekati beskonačno
connFallbackExpirationSecs	Broj sekundi nakon kojeg će klijent pokušati ponovno koristiti mrežno sučelje višeg prioriteta
tunePreferredMetaFile	Popis adresa imeničkih servisa koje će klijent primarno koristiti
tunePreferredStorageFile	Popis adresa podatkovnih servisa koje će klijent primarno koristiti

Konfiguracija - klijent

- Klijent zahtjeva dva servisa
 - beegfs-helperd - pomoćni servis za upravljanje sistemskim zapisima
 - beegfs-client - učitava kernel modul i montira BeeGFS sustave
- Popis BeeGFS sustava u datoteci /etc/beegfs/beegfs-mounts.conf
- Priprema kernel modula
 - automatski prilikom prvog pokretanja ili izmjene verzije BeeGFS-a ili kernela

Pokretanje klastera

- Instalirati paketi
- Podesiti konfiguraciju svih servisa
- Pokrenuti upravljački servis
- Pokrenuti sve imeničke i podatkovne servise
- Provjeriti dostupnost svih servisa
- Pokrenuti montiranje na klijentima



Upravljačke naredbe

- Potrebno instalirati paket beegfs-utils
- Provjera dostupnosti servisa

beegfs-check-servers

- Ispis svih aktivnih mrežnih veza sa servisima

beegfs-net

Upravljačke naredbe

- Provjera iskorištenja direktorija svih servisa

```
beegfs-df
```

- Provjera stanja cjelokupnog BeeGFS datotečnog sustava

```
beegfs-fsck --checkfs
```

- koristi se u slučaju problema u pristupanju datotečnom sustavu
- moguće je izvođenje dok se sustav koristi (*online*)

Upravljačke naredbe

- Glavna upravljačka naredba

```
beegfs-ctl
```

- Ispis servisa

```
beegfs-ctl --listnodes
```

- Ispis particija

```
beegfs-ctl --listtargets
```

Upravljačke naredbe

- Uklanjanje servisa

```
beegfs-ctl --removenode
```

- Dohvat informacija o direktoriju

```
beegfs-ctl --getentryinfo /beegfs
Path:
Mount: /beegfs
EntryID: root
Metadata node: storage01 [ID: 18627]
Stripe pattern details:
+ Type: RAID0
+ Chunksize: 512K
+ Number of storage targets: desired: 1
```

Upravljačke naredbe

- Postavljanje parametara direktorija (npr. *stripe*, *mirror*)


```
beegfs-ctl --setpattern --chunksize=1m --numtargets=4  
/beegfs/mydir
```

- Prikaz korištenja servisa


```
beegfs-ctl --serverstats
```

Nadzorni servis

- Potrebno pokrenuti servis beegfs-admon
- Pristupiti web sučelju za dohvata Java grafičkog alata
- Početne lozinke
 - Administrator: admin
 - Information: information
- Ograničenje alata
 - moguć prikaz podataka do 5 dana u prošlosti
- Prikaz statistika
 - podatkovni servisi
 - imenički servisi
 - klijenti
 - korisnici



Nadzorni servis





Ostali raspodijeljeni podatkovni sustavi

GlusterFS

- Paralelni datotečni sustav
 - namijenjen ostvarivanju velikih datotečnih sustava
 - izgradnja podatkovnih *clouda*
- Komponente
 - čvorovi
 - klijenti
- Prednosti
 - jednostavnost održavanja (nema imeničkih servisa)
 - podržani različiti oblici spajanja čvorova u podatkovne cjeline
- Mane
 - sporiji rad kroz modul FUSE (engl. *Filesystem in Userspace*)
 - neki oblici (*distributed, striped*) ne osiguravaju visoku dostupnost podataka



Lustre

- Paralelni datotečni sustav
 - prvenstveno namijenjen HPC klasterima
- Komponente
 - *Metadata Server (MDS)* – imenički servis
 - *Object Storage System (OSS)* – podatkovni čvorovi
- Podržane mrežne tehnologije
 - Ethernet, Infiniband, Myrinet, Quadrics
- Mane
 - složena implementacija visoko dostupnog servisa MDS (Heartbeat ili RHEL Cluster Suite)
 - potrebno koristiti nestandardnu jezgru



Ceph

- RedHat-ov raspodijeljeni sustav za podatkovni *cloud*
- Tri oblika spremanja podataka
 - objektno spremište
 - *block device* - za spremanje diskova virtualnih poslužitelja
 - standardni datotečni sustav
- Mane
 - datotečni sustav nije u potpunosti spreman za produkcijske sustave

Hadoop File System

- Raspodijeljeni datotečni sustav
 - velika razina replikacije
 - pogodan za veliki broj zemljopisno raspodijeljenih čvorova
- Sastavni dio sustava Apache Hadoop
 - izvođenje aplikacija *Map-Reduce*
- Mane
 - implementacija u programskom jeziku Java



MogileFS

- Raspodijeljeni datotečni sustav
 - prvenstveno namijenjen web poslužiteljima
- Zasnovan na HTTP-u i WebDAV-u
- Mane
 - pristup podacima putem komandno linijskog sučelja







Raspodijeljeni podatkovni sistemi u Srcu

BeeGFS



- Klaster Isabella i CRO NGI
- Korisnički direktorij (*home*)
 - ukupno 110 TB
 - 4 podatkovna poslužitelja
 - 1 imenički servis
 - iSCSI spremišni element
- Direktorij za pohranu privremenih datoteka (*scratch*)
 - učinkovit rad s velikim datotekama
 - ukupno 90 TB
 - 4 podatkovna poslužitelja
 - 4 imenička servisa



BeeGFS



BeeGFS



BeeGFS

- Podatkovne usluge **Filesender** i **MojOblak**
 - usluge dijele isti datotečni sustav
- Dijeljeni prostor
 - 1 podatkovni i imenički poslužitelj
 - iSCSI spremišni element



Sustavi korišteni u prošlosti

- GlusterFS
 - CRO NGI
 - podatkovne usluge Filesender, GSS, JKP
 - ukupno preko 200 TB prostora
 - napušten zbog slabije učinkovitosti od BeeGFS-a i ujednačavanja raspodijeljenih podatkovnih sustava
- Lustre
 - klaster Isabella
 - 6 poslužitelja (2 MDS, 2 OSS, 2 mosta između mreža Infiniband i Ethernet)
 - visoka dostupnost (Heartbeat)
 - napušten zbog složenosti održavanja, korištenja nestandardne jezgre i prestanka održavanja od strane Oraclea

Sustavi korišteni u prošlosti

- GFS

- klaster Isabella i CRO NGI
- klasterski datotečni sustav
- omogućava pristup istom logičkom disku na spremišnom sustavu s više poslužitelja
- napušten zbog loše učinkovitosti


- NFS

- klaster Isabella i CRO NGI
- korisnički direktorij (*home*)
- napušten zbog loše učinkovitosti pri velikom opterećenju
- još uvijek se koristi na manjim klasterima



Reference

- Službena web stranica BeeGFS
 - <http://www.beegfs.com>
- Korisnička dokumentacija BeeGFS
 - <http://www.beegfs.com/content/documentation/>
 - kvalitetni članci o testiranju učinkovitosti odabiru broja podatkovnih i imeničkih servisa
- Korisnički wiki
 - <http://www.beegfs.com/wiki/TableOfContents>
 - detaljne informacije o instalaciji i podešavanju svih komponenata sustava





Hvala na pažnji!

Pitanja?



Sveučilište u Zagrebu
Sveučilišni računski centar

www.srce.unizg.hr

Ovo djelo je dano na korištenje pod licencom
Creative Commons *Imenovanje-Nekomercijalno*
4.0 međunarodna.

creativecommons.org/licenses/by-nc/4.0/deed.hr



Srce politikom otvorenog pristupa široj javnosti
osigurava dostupnost i korištenje svih rezultata rada
Srca, a prvenstveno obrazovnih i stručnih informacija
i sadržaja nastalih djelovanjem i radom Srca.

www.srce.unizg.hr/otvoreni-pristup



srce
otvoreni pristup