



UNIVERSITETET  
I OSLO



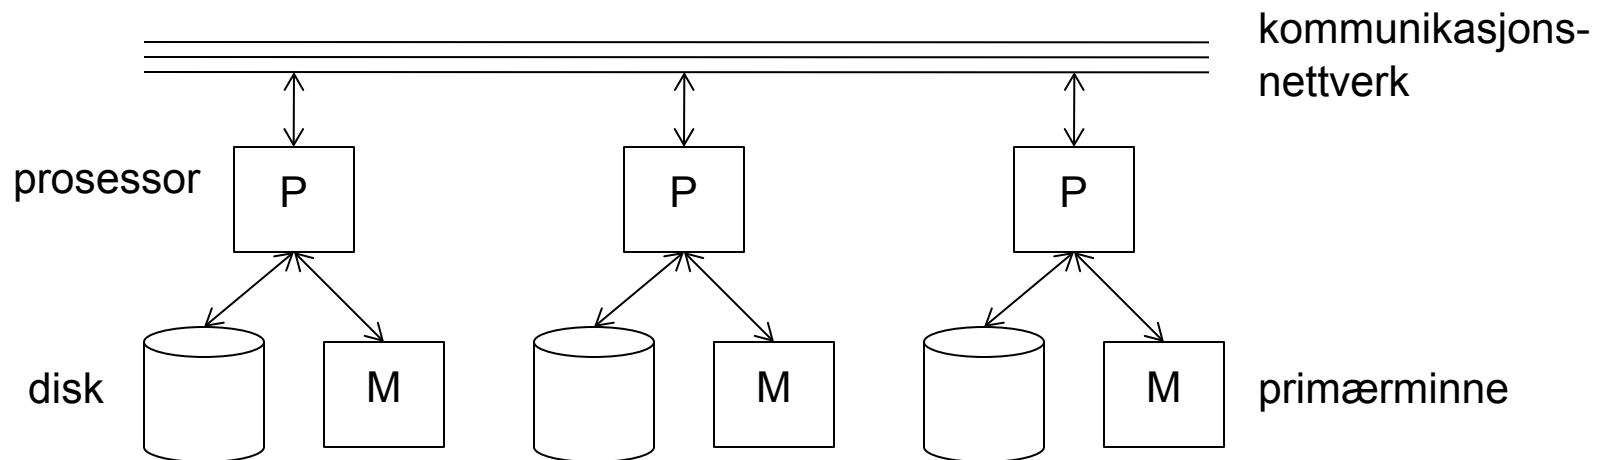
# Parallelle og distribuerte databaser

## Del I

# Parallelberegninger

- **Database på én storskala parallelmaskin:**  
Utnytter paralleliteten på dyre operasjoner, f.eks. join
- Modeller for parallelitet:
  - **Shared-memory-arkitektur**
    - Ett felles fysisk adresserom; hver prosessor har aksess til (deler av) primærminnet til de andre prosessorene
    - Hver prosessor har lokale disker
  - **Shared-disk-arkitektur**
    - Hver prosessor har lokalt primærminne
    - Hver prosessor har aksess til alle disker
  - **Shared-nothing-arkitektur**
    - Hver prosessor har lokalt primærminne og lokale disker
    - Er den arkitekturen som benyttes mest for databasesystemer

# Shared-nothing-arkitekturen



- Hver prosessor har lokal cache, lokalt primærminne og lokale disker
- All kommunikasjon skjer ved meldingsutveksling over nettverket som forbinder prosessorene
  - Kostbart å sende data mellom prosessorer  
(betydelig overhead på hver enkelt melding)
  - Data bør om mulig bufres opp og sendes i større enheter

# Parallelle algoritmer for shared-nothing-arkitekturen

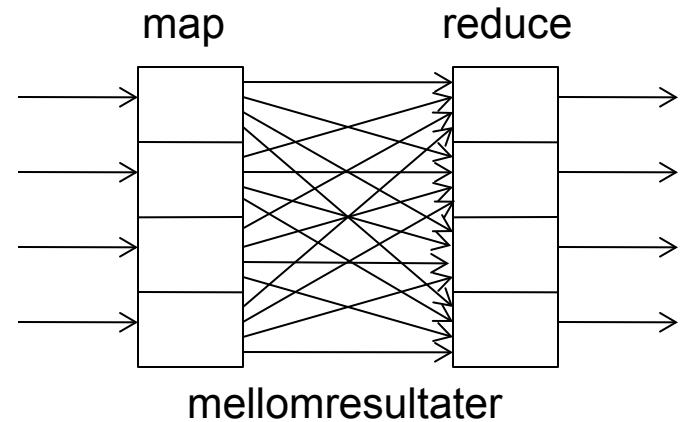
- Hovedprinsippet bak slike algoritmer er å fordele tuplene og arbeidsbelastningen mellom prosessorene. Tuplene fordeles slik at
  - kommunikasjonen minimeres
  - prosessorene kan utføre vanlige algoritmer lokalt på sine tupler
- Eksempler:
  - $\sigma_c(R)$ : Fordel tuplene i R jevnt på alle diskene. Hver prosessor utfører  $\sigma_c$  lokalt på sine tupler
  - $R(X,Y) \bowtie S(Y,Z)$ : Bruk en hashfunksjon  $h$  på  $Y$  til å fordele tuplene i  $R$  og  $S$  på  $p$  bøtter (der  $p$  er antall prosessorer). Tuplene i bøtte  $j$  sendes til prosessor  $j$ , som så kan utføre en lokal join på sine tupler

# Map-reduce-rammeverket for parallelisering

- Rammeverk som tillater å enkelt beskrive/programmere databaseprosesser og utføre et høyt antall av dem i parallel
  - Brukeren skriver kode for to funksjoner, **map** og **reduce**.
- Arkitektur:
  - Massiv parallelmaskin eller maskincluster
  - Vanligvis shared-nothing-arkitektur
- Datalagring:
  - Filer, typisk svært store
  - Filene er oppdelt i chunks, hver chunk er replikert på tvers av disker for å overleve diskkræsj

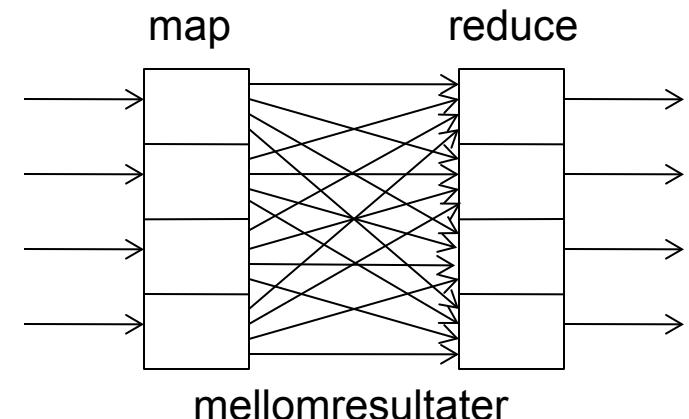
# Map

- **Map-funksjonen** tar som input par av formen  $(k, v)$  der  $k$  er en nøkkel og  $v$  en verdi.
- Output (**mellomresultater**) er en liste av par  $(h, w)$  der  $h$  er en nøkkel og  $w$  en verdi
- **Rammeverket** samler prinsipielt alle mellomresultatene for all input i par på formen  $(h, [w_1, w_2, \dots, w_{n_h}])$ , ett for hver verdi av  $h$



# Reduce

- **Reduce-funksjonen** produserer for hvert par  $(h, [w_1, w_2, \dots, w_{n_h}])$  ett par  $(h, x)$  der  $x$  er reduksjonen av  $[w_1, w_2, \dots, w_{n_h}]$  ( $x$  er ofte av samme type som  $w_i$ -ene)



- **Mastercontrolleren**
  - bestemmer hvor mange map- og reduce-prosesser som skal eksekveres, og på hvilke prosessorer
  - fordeler chunks av inputdata blandt map-prosessene
  - bestemmer hvordan verdier i mellomresultatet skal pipelines mellom map- og reduce-prosessene

# Eksempel: Beregning av invertert indeks

- Map:
  - Input: Par på formen  $(i, d)$  hvor  $i$  er en dokumentID og  $d$  et dokument.
  - Virkemåte: Scanner  $d$  tegn for tegn; for hvert ord  $w$  produseres output  $(w, i)$  hvor  $w$  brukes som nøkkel
- Reduce:
  - Input: Par på formen  $(w, [i_1, i_2, \dots, i_{n_w}])$
  - Virkemåte: Fjerner flerforekomster i  $[i_1, i_2, \dots, i_{n_w}]$  og sorterer etter stigende  $i_k$

# Distribuerte databaser

- En database kalles **distribuert** hvis den er spredt over flere datamaskiner, kalt **noder** (sites), som er bundet sammen i et nettverk
- Hver node har sitt eget operativsystem og sitt eget DBMS
- Tre viktige formål med distribuerte databaser er:
  - større lagringskapasitet og raskere svartider
  - økt sikkerhet mot tap av data
  - økt tilgjengelighet av data for flere brukere
- Databasen kalles **distribusjonstransparent** hvis brukerne (applikasjonene) ikke merker noe til at databasen er distribuert (bortsett fra variasjon i svartidene)
- I dag er det en selvfølge at en distribuert database er distribusjonstransparent

# Distribusjonsmodeller

- **Sharding:**  
Hver node har ansvaret for et utsnitt  
(sin del) av dataelementene
- **Replikering:**  
Hvert dataelement er lagret på flere noder
- De to modellene er uavhengige:  
Et system kan bruke en eller begge teknikker

# Distribusjon av relasjonelle data

- Et eksempel på distribuerte data kan vi finne i en butikkjede hvor alle salg registreres av kassaapparatene og lagres lokalt på en datamaskin (node) i hver enkelt butikk
- Logisk sett har butikkjedens relasjonsdatabase én relasjon som inneholder alle salgsdata fra alle butikkene
- Salgsdataene er **horisontalt fragmentert** med ett fragment på hver node
- Hvis de horisontale fragmentene er disjunkte, er fragmenteringen **total**
- En relasjon er **vertikalt fragmentert** hvis ulike attributter er lagret på ulike noder
- Vertikale fragmenter må inneholde primærnøkkelen
- En vertikal fragmentering er **total** hvis ingen andre attributter enn primærnøkkelen ligger på flere noder

# Replikerte data

- I en konsistent tilstand er replikatene like (de er kopier av hverandre)
- Hvis alle data er replikert til alle noder, har vi en **fullreplikert** database (**speildatabase**)
- Internt bruker DBMS et replikeringsskjema som forteller hvilke data som ligger på hvilke noder
- Distribusjonstransparens medfører at applikasjonene ikke må ha kjennskap til replikeringsskjemaet og at de ikke har ansvar for å oppdatere replikatene
- Replikering er dyrt, men det gir økt lesehastighet og økt tilgjengelighet til data

# Distribuerte transaksjoner og queries

- Når optimalisereren og planleggeren skal lage fysiske eksekveringsplaner, må de ta hensyn til hvilke noder de ulike dataene ligger på (denne informasjonen finnes i replikeringsskjemaet som er kopiert til alle noder)
- Det er to hovedstrategier å velge mellom:
  - Kopier (på billigste måte) de data som trengs, til samme node og utfør eksekveringen der
  - Splitt eksekveringen opp i subtransaksjoner på de aktuelle nodene og gjør mest mulig eksekvering der dataene er (viktig for projeksjon og spesielt seleksjon)
- En god optimaliserer kombinerer de to strategiene for å minimalisere datatransmisjonen mellom nodene

# Distribuert commit

- En transaksjon i en distribuert database kan oppdatere data på flere noder (spesielt må dataelementer som er endret, oppdateres på alle noder med replikater)
- Den noden der en transaksjon T initieres, kalles **startnoden** (eller **utgangsnoden**) til T
- Planleggeren finner ut hvilke noder T trenger å aksessere og starter en subtransaksjon på hver av disse (inklusive startnoden) for å gjøre Ts jobb lokalt
- For å oppnå global atomositet må enten alle subtransaksjonene gjøre commit, eller alle må abortere
- Følgelig kan ikke T gjøre commit før alle subtransaksjonene har gjort det

# Tofasecommit

- **Tofasecommit (2PC)** er en protokoll for å sikre atomisitet av distribuerte transaksjoner
- 2PC bygger på følgende forutsetninger:
  - Det finnes ingen global logg
  - Hver node logger sine operasjoner (inklusive 2PC-meldinger som den har sendt til andre noder)
  - Hver node sikrer atomisitet for sine lokale transaksjoner
  - Ingen node går ned permanent
  - To vilkårlige noder kan kommunisere med hverandre
- 2PC forutsetter at en av nodene utpekes til **koordinator**. Vanligvis, men ikke alltid, er det startnoden som velges

# 2PC-protokollen – fase I

- Koordinatoren for en distribuert transaksjon  $T$  bestemmer seg for å gjøre commit
  - Koordinatoren skriver  $\langle \text{Prepare } T \rangle$  i loggen på sin node
  - Koordinatoren sender meldingen **prepare  $T$**  til alle noder som har subtransaksjoner av  $T$
- Hver mottaker fortsetter eksekveringen til den vet om dens subtransaksjon  $T_i$  kan gjøre commit
  - Skriv nok i loggen til at det ved behov kan gjøres gjenoppretting på  $T_i$
  - Hvis kan committe,
    - skriv  $\langle \text{Ready } T \rangle$  i loggen og skriv loggen til disk
    - send meldingen **ready  $T$**  til koordinatoren
- Deretter: Vent på fase II
- Hvis må abortere,
  - skriv  $\langle \text{Don't commit } T \rangle$  i loggen
  - send meldingen **don't commit  $T$**  til koordinatoren
- Deretter: Kan rulle transaksjonen tilbake mens den venter på fase II

# 2PC-protokollen – fase II

- Hvis koordinatoren har mottatt **ready T** fra alle nodene (subtransaksjonene), skriver koordinatoren **<AgreeCommit T>** i sin logg og sender **commit T** til alle andre involverte noder
  - En node som mottar **commit T**, gjør commit på sin subtransaksjon, skriver **<Commit T>** i loggen sin og sender **ack T** til koordinatoren
  - Når koordinator har mottatt **ack T** fra alle nodene, skriver koordinator **<Commit T>** i sin logg og foretar avsluttende commit på transaksjonen
- Hvis koordinatoren har mottatt **don't commit T** fra minst én node eller ikke alle har svart ved «timeout», skriver koordinatoren **<Abort T>** i sin logg og sender **abort T** til alle andre involverte noder.
  - En node som mottar **abort T**, skriver **<Abort T>** i loggen sin og ruller tilbake sin subtransaksjon hvis ikke dette alt er gjort

# Feilhåndtering ved 2PC – I

- Hvis en ordinær node går ned, er det opplagt hva den skal gjøre med mindre dens siste loggpost er <Ready T>. I så fall må den spørre en annen node om den skal gjøre commit T eller abort T.
- Hvis koordinatoren går ned, velges en ny koordinator
- Den nye koordinatoren starter med å innhente status fra alle oppegående noder

# Feilhåndtering ved 2PC – II

- Med ett unntak kan den nye koordinatoren fullføre 2PC
- Unntaket er hvis alle nodene har <Ready T> som siste loggpost. Da kan man ikke avgjøre om den opprinnelige koordinatoren har forberedt commit eller abort
  - Hvis den opprinnelige koordinatoren var den eneste noden som gikk ned, kan den nye koordinatoren anta at ingen commit har funnet sted og fortsette med abort T
  - Hvis det i tillegg til den opprinnelige koordinatoren var minst én ordinær node som gikk ned, kan den ordinære noden alt ha mottatt commit T fra den opprinnelige koordinatoren og rukket å committe. Det er to mulige fortsettelse:
    - Vente til koordinatoren kommer opp igjen
    - DBA griper inn og fatter en manuell avgjørelse

# Låsing i distribuerte systemer

- Låsing av en replikat krever varsomhet:
  - Anta at T har leselås på en replikat  $A_1$  av et dataelement A
  - Anta at U har skrivelås på en annen replikat  $A_2$  av A
  - Da kan U oppdatere  $A_2$ , men ikke  $A_1$
  - Resultatet blir en inkonsistent database
- Med replikerte data må vi skille mellom to typer låsing:
  - låsing av et logisk dataelement A (global lås)
  - fysisk låsing av en av replikatene av A (lokalt lås)
- Reglene for logiske lese- og skrivelåser er de samme som de som gjelder for vanlige låser i en ikke-distribuert database
- Logiske låser er fiktive – de må implementeres ved hjelp av de fysiske

# Sentralisert låsing

- Den enkleste måten å implementere logiske låser på er å utnevne en av nodene til **låsesjef**
- Låsesjefen håndterer alle ønsker om logiske låser og bruker sin egen låstabell som logisk låstabell
- Det er to viktige svakheter ved et slikt sentralisert låsesystem:
  - låsesjefen blir fort en flaskehals ved stor trafikk
  - systemet er svært sårbart; hvis låsesjefen går ned, får ingen satt eller hevet noen lås
- Kostnaden er minst tre meldinger for hver lås som settes:
  - en melding til låsesjefen for å be om en lås
  - en svarmelding som innvilger låsen
  - en melding til låsesjefen for å frigi låsen

# Primærkopilåsing

- Primærkopilåsing er en annen type sentralisert låssystem
- I stedet for en felles låsesjef velger vi for hvert logisk dataelement ut en av replikatene som **primærkopi**
- Den fysiske låsen på primærkopien brukes som logisk lås på dataelementet
- Metoden reduserer faren for flaskehals ved låsing
- Ved å velge replikater som ofte blir brukt, til primærkopier, reduseres antall meldinger ved håndtering av låser

# Avledede logiske låser

- Metoden går ut på at en transaksjon får en logisk lås ved å låse et tilstrekkelig antall av replikatene
- Mer presist:

Anta at databasen har  $n$  replikater av et dataelement A  
Velg to tall  $s$  og  $x$  slik at  $2x > n$  og  $s+x > n$

- En transaksjon får logisk leselås på A ved å ta leselås på minst  $s$  replikater av A
- En transaksjon får logisk skrivelås på A ved å ta skrivelås på minst  $x$  replikater av A

Det er maksimalt  $n$  låser til utdeling:

- At  $2x > n$  medfører at to transaksjoner ikke begge kan ha logisk skrivelås på A
- At  $s+x > n$  betyr at to transaksjoner ikke samtidig kan ha henholdsvis logisk leselås og logisk skrivelås på A

# Leselås-én, skrivelås-alle

- Dette oppnår vi ved å velge  $s = 1$  og  $x = n$
- Logisk skrivelås krever i verste fall minst  $3(n-1)$  meldinger og blir svært dyr
- Logisk leselås krever høyst 3 meldinger, og hvis det finnes en replikat på transaksjonens startnode, krever den ingen meldinger
- Metoden egner seg der skrivetransaksjoner er sjeldne
- Eksempel:  
Elektronisk bibliotek der nodene har kopi av ofte leste dokumenter

# Majoritetslåser

- Dette oppnår vi ved å velge  $s = x = \lceil (n+1)/2 \rceil$
- Logisk skrivelås kan ikke bli billigere enn dette
- Men det at logisk leselås også krever omtrent  $3n/2$  meldinger, virker svært dyrt
- I systemer som tilbyr kringkasting av meldinger, blir kostnaden lavere
- Fordelen er at metoden er robust mot nettverksfeil
- Eksempel:

Dersom en nettverksfeil deler databasen i to, kan den delen som inneholder flertallet av nodene, fortsette som om intet var hendt.

I minoritetsdelen kan ingen få så mye som en leselås

# Distribuert vranglås

- Faren for vranglås i et distribuert låsesystem er stor
- Det finnes mange varianter av Vent-på-grafer som kan forhindre distribuert vranglås
- Erfaring sier at det enkleste og beste i de fleste tilfeller er å bruke «timeout»:  
Transaksjoner som bruker for lang tid, rulles tilbake

# Peer-to-peer-systemer

- Et P2P-nettverk er et nettverk av maskiner som
  - er **autonome**: noder kan bli med i eller forlate nettverket etter eget forgodtbefinnende
  - er **løst koblet**: kommunikasjon via et universalnett (f.eks. Internett)
  - har **lik funksjonalitet**: ingen leder- eller kontrollnoder
  - er villige til å **dele ressurser** med hverandre

# Databaser på peer-to-peer-systemer

- En database i et P2P-nettverk må ivaretas kollektivt av nodene i nettverket. Krav til databasesystemet:
  - **Distribuert**: data er fordelt på nodene i nettverket
  - **Desentralisert**: alle nodene har samme administrative ansvar for databasen
  - **Feiltolerant**: systemet må være pålitelig selv om noder feiler og selv om den mengden av noder som utgjør nettverket, kontinuerlig endres
  - **Skalerbart**: systemet må være effektivt også for store nettverk

# Distribuert hashing

- **Distributed hash tables** (DHT) er en klasse av teknikker for å realisere **oppslagstjenester i P2P-nettverk**
- Anta at databasen består av skjemaet  $R(\underline{K}, V)$  der  $K$  er primærnøkkel og  $V$  tilhørende verdi. En DHT består av
  - en **nøkkelpartisjonering**, dvs. en hashfunksjon  $h$ 
    - For hvert tuppel  $(k, v)$  i  $R$  brukes  $h(k)$  til å beregne identiteten til den noden som har ansvaret for å lagre tuppelet  $(k, v)$
  - et **overleggsnettverk (overlay network)**, dvs. en logisk struktur som knytter sammen nodene i nettverket
    - Hver node trenger bare å ha direkte kjennskap til en liten del av nettverket
    - Likevel kan noden som lagrer  $(k, v)$ , nås fra en hvilken som helst annen node med et lite antall meldingsutvekslinger

# Eksempel på en DHT: Chord

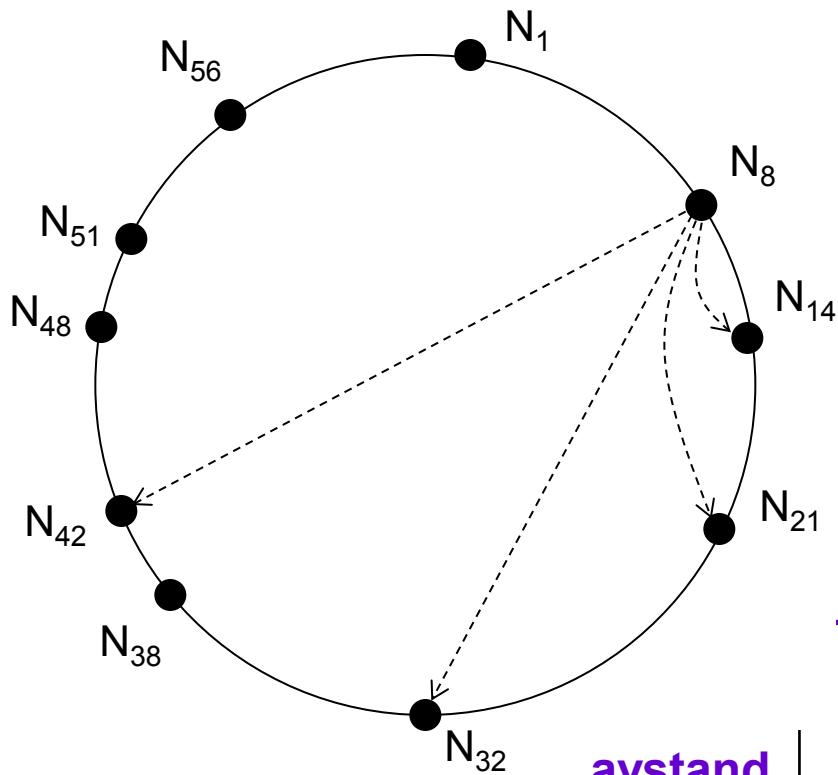
- Overleggsnettverket består av
  - en (logisk) **sirkel** som omfatter alle nodene i nettverket
  - strenger (**chords**) "på tvers" i sirkelen
- Hashfunksjon:
  - $h(x) = x \text{ mod } 2^m$  for et passende heltall  $m$
  - maksimalt antall noder er  $2^m$

# Overleggsnettverket i Chord

- En node med ID  $w$  plasseres i sirkelen i posisjon  $h(w)$ 
  - Vi antar at alle noder har en ID og at disse er entydige
- Hver node har en **fingertabell** med peker til de nodene som har posisjon  $j+1, j+2, j+4, \dots, j+2^{m-1}$  i sirkelen, der  $j$  er nodens egen posisjon i sirkelen
  - Hvis det ikke er noen node i posisjon  $j+2^i$  for en  $i$ , inneholder fingertabellen den noden med urviseren som er nærmest denne posisjonen. (Posisjonene beregnes modulo  $2^m$ .)
  - Fingertabellen har lengde  $m$  og tar derfor ikke stor plass selv for store nettverk (dvs. stor  $2^m$ )
- I tillegg har hver node en peker til sin forgjenger

# Eksempel: m=6

## Maksimalt $2^6 = 64$ noder



De stiplede pilene viser nodene som er med i fingertabellen til  $N_8$ . I tillegg vet  $N_8$  hvilken node som kommer foran den i sirkelen.

Under er alle disse opplysningene samlet i én tabell.

Tabell for  $N_8$ :

avstand	-1	1	2	4	8	16	32
node	$N_1$	$N_{14}$	$N_{14}$	$N_{14}$	$N_{21}$	$N_{32}$	$N_{42}$

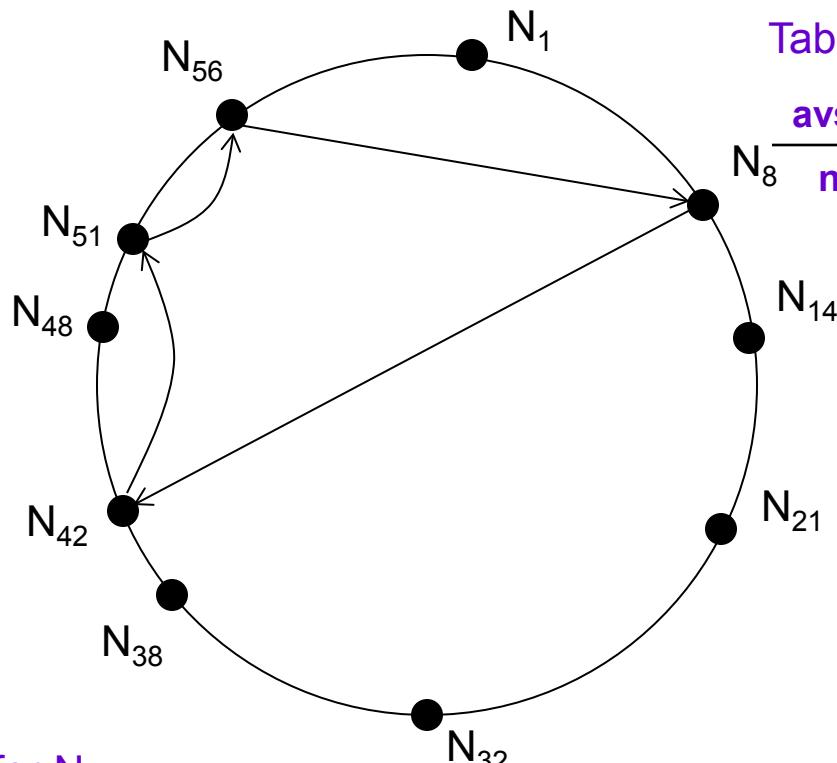
# Datahåndtering i Chord

- Et tuppel  $(k, v)$  i tabellen  $R(K, V)$  lagres på noden som har posisjon  $h(k)$ .
  - Hvis det ikke er noen node i posisjon  $h(k)$ , lagres tuppelet på den noden som er nærmest denne posisjonen (med urviseren).
- Hvordan finne et tuppel i nettverket: Anta at node  $N_i$  ønsker å finne  $v$  for en gitt  $k$ , men ikke har tuppelet lagret lokalt.
  1. Beregn  $j = h(k)$ . Sett  $N_c = N_i$ .
  2.  $N_c$  slår opp i tabellen sin og ser om den inneholder en node  $N_h$  der  $h$  er mindre eller lik  $j$ .
    - Hvis det ikke finnes noen slik  $h$ , er tuppelet  $(k, v)$  hos etterfølgernoden ( $N_e$ ).  $N_c$  sender en melding til  $N_e$  og ber den om å returnere tuppelet direkte til  $N_i$ .
    - Hvis det finnes en slik  $h$ , så velg  $h$  størst mulig (men mindre eller lik  $j$ ).
      - Hvis  $h = j$ , er tuppelet  $(k, v)$  hos  $N_h$ .  $N_c$  sender en melding til  $N_h$  og ber den om å returnere tuppelet direkte til  $N_i$ .
      - Hvis  $h < j$ , må tuppelet  $(k, v)$  befinne seg i en posisjon lenger ut i sirkelen enn  $h$ .  $N_c$  sender en melding til  $N_h$  og ber den om å overta rollen som  $N_c$ . Gjenta punkt 2.

Det trengs maksimalt  $m+1$  meldinger:  $m$  forespørselsmeldinger + 1 melding med resultatet.

# Eksempel:

## $N_8$ ønsker å finne $(k,v)$ der $h(k)=52$



Tuppelet  $(k,v)$  ligger på den noden som ligger nærmest posisjon 52 (regnet med urviseren), dvs. node  $N_{56}$ .  $N_8$  kan regne ut  $h(k)=52$ , men vet ikke at det ikke fins noen node  $N_{52}$ , og heller ikke at tuppelet befinner seg i node  $N_{56}$ .

1. Nærmeste foran posisjon 52 i tabellen til  $N_8$  er  $N_{42}$ .  $N_8$  sender en forespørsel til  $N_{42}$ .
2. Nærmeste foran posisjon 52 i tabellen til  $N_{42}$  er  $N_{51}$ .  $N_{42}$  sender en forespørsel til  $N_{51}$ .
3. Siden etterfølgeren til  $N_{51}$  er  $N_{56}$ , må tuppelet befinner seg der.  $N_{51}$  ber  $N_{56}$  sende tuppelet til  $N_8$ .

Totalt: 4 meldinger.