Järjestetty peräkkäisrakenne

- Sequential file
- Tietueet sijaitsevat tiedostossa jonkin kentän (esimerkiksi työntekijänumeron) mukaan järjestettyinä.
  - Tietueiden järjestys on jokin tyypillisesti käsittelyssä usein tarvittava järjestys
  - Rakenne tukee tietueiden käsittelyä peräkkäin halutussa järjestyksessä

Järjestetty peräkkäisrakenne

- Lisäykset pitää järjestetyssä peräkkäisrakenteessa sijoittaa oikealle kohdalleen järjestyksessä.

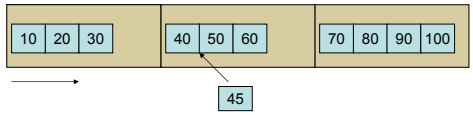

- Pahimmassa tapauksessa pitäisi siirtää koko tiedoston loppuosa uusiin paikkoihin
- Yleensä jätetään lisäyksille tilaa sivuille – täyttösuhde jää alhaiseksi
- Jos sivulle tulee lisäys, joka ei mahdu sinne, otetaan käyttöön ylivuotosivu, joka linkitetään sivuun. Lisäysten kasautuessa ylivuotoketjusta voi tulla pitkä
  - Rakenne degeneroituu nopeammin kuin kasa
  - Tarvitaan useammin uudelleenorganisointeja

Järjestetty peräkkäisrakenne

- Poistot ja muutokset tehdään kuten kasarakenteeseen.
- Tietueen haku tiedostosta järjestysavaimen perusteella vaatii tiedostoa läpilukemalla saman verran levyhakuja kuin kasarakenteessa, jos tietue löytyy eli N/2. Löytymättömyys voidaan todeta keskimäärin samalla levyhakujen määrällä. Tässä suhteessa rakenne on parempi kuin kasa.
- Järjestetty peräkkäisrakenne tukee myös järjestysavaimeen perustuvia arvovälihakuja sekä erisuuruusvertailuja !=,<,<=

Järjestetty peräkkäisrakenne

- Järjestetty peräkkäisrakenne mahdollistaa myös binäärihaun käytön.
- Periaate:
  - Etsi tietuetta tiedoston keskimmäiseltä (k=roof(N/2)) sivulta
  - Jos ei löytynyt ja avain<sivun pienin avain, jatka samalla periaatteella sivuilta 1 .. k-1.
  - Jos ei löytynyt ja avain>sivun suurin avain, jatka samalla periaatteella sivuilta k+1 .. N.
  - Haku päättyy kun
    - tietue löytyy tai
    - tietuetta ei löydy sivulta mutta avain sijoittuu sivun pienimmän ja suurimman avaimen väliin (ei ole tiedostossa) tai
    - etsintää pitäisi jatkaa tyhjästä sivujoukosta

Järjestetty peräkkäisrakenne

- Binäärihaussa tarvitaan enintään roof($\log_2 N$) levyhakua.
- *(roof(x) = pienin kokonaisluku, joka on suurempi kuin x)*
- Aiemman esimerkin 8000 employee-tietueen tiedostossa oli 800 lohkoa, eli tietueen haku järjestysavaimen perusteella vaatisi enintään roof($\log_2 800$) = 10 levyhakua, joka satunnaishakuajalla laskettuna samalla n 10 ms satunnaishakuajan levyllä olisi samaa luokkaa kuin keskimääräinen saantiaika kasarakenteesta (100ms vs 85 ms)
  - Tosin tämä tiedosto voidaan sijoittaa kahdelle vierekkäiselle sylinterille, joten hakuvarren siirtoja ei juurikaan tule ja oikeasti päästään pahimmillaan vähän alle kasarakenteen keskimääräisen saantiajan (vain pyörähdysviive 5 ms lasketaan)
  - isommilla tiedostoilla binäärihaku parantaa asemaansa suhteessa koko tiedoston peräkkäiseen läpikäyntiin

Järjestetty peräkkäisrakenne

- Järjestetty peräkkäisrakenne ei ole tyypillinen tietokantojen yhteydessä käytetty tiedostorakenne
- Vanhanaikaisissa eräsovelluksissa se oli laajasti käytetty
  - soveltuu erityisen hyvin tilanteisiin, jossa pitää tahdistaa usean laajan aineiston käsittely

- Hajautukseen perustuvissa tiedostorakenteissa on tavoitteena yksittäisen tietueen nopea haku.
- Tähän pyritään siten, että tietueen sijoituspaikan eli solun (cell, bucket) osoite lasketaan jonkin tietueessa olevan tiedon eli hajautusavaimen (hash key) perusteella.
- Parhaassa tapauksessa solu olisi tietty tiedoston lohko. Yleensä solu kuitenkin muodostuu useasta lohkosta
  - enintään yhdestä kotilohkosta ja
  - joukosta ylivuotolohkoja (tai jatkolohkoja)
    - ylivuotolohkot voivat olla solukohtaisia jai jaettuja

- Solun osoitteena on joko
  - kotilohkon osoite (tällöin ei käytetä soluhakemistoa) tai
  - soluhakemiston indeksi
    - soluhakemisto on taulukko, jonka alkioina on kotilohkojen osoitteita
- Mahdolliset soluosoitteet muodostavat osoiteavaruuden (address space)
  - soluhakemistoa käytettäessä saadaan pienellä lisätilalla kasvatettua osoiteavaruutta moninkertaiseksi

A) Solun osoite on soluhakemiston indeksi

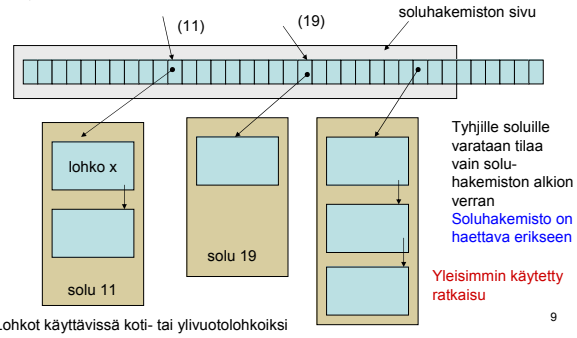

B) Solun osoitteena on kotilohkon osoite

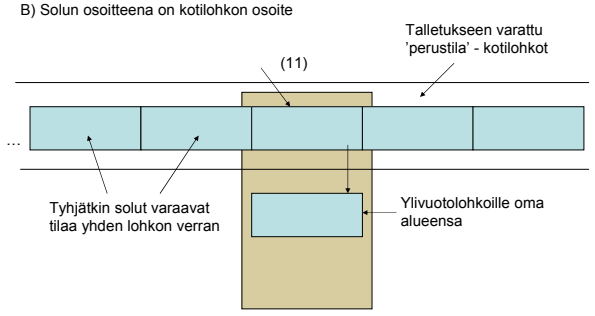

- Osoitteen laskentaan käytetään hajautusfunktiota (hajautinta) (hash function, randomizing function)
- Olkoon h(X) hajautus funktio ja R_K tietue, jonka hajautusavain on K
- Tällöin R_K:n sijoitussolun osoite = h(K).

- Solujen sisällä tietueet sijoitetaan kasarakenteen tapaan eli lisäykset loppuun

- Optimitapauksessa tietue löytyy yhdellä levyhaulla eli solun kotilohkosta*. Tämä edellyttää, että
  - hajautusfunktio jakaa tietueet tasaisesti osoiteavaruuden osoitteisiin
  - osoiteavaruus on määritelty riittävän isoksi niin, että kaikki tietueet voidaan sijoittaa solujen kotilohkoihin

* soluhakemistoa käytettäessä joudutaan satunnaisesti hakemaan myös soluhakemiston sivuja

Hajautukseen perustuvat tiedostorakenteet

- Haku avaimella K:
  - lasketaan hajautusfuktiolla solun osoite s=h(K)
  - jos käytössä on soluhakemisto haetaan kotilohkon osoite sieltä p=H[s] (jos hakemistoalkio on tyhjä, haku päättyy) muuten käytetään kotilohkon osoitteena solun osoitetta p=s.
  - haetaan sivu lohkosta s
  - ellei tietuetta löydy käydään läpi solun muut lohkot
  - Jos hajautusavain ei ole tietueen avain on haussa käytävä läpi kaikki solun sivut.

Hajautukseen perustuvat tiedostorakenteet

- Oletetaan, että tiedosto mahtuisi kasarakenteena N sivulle ja hajautusavaimella olisi k erilaista arvoa.
- Olkoon osoiteavaruus 0,..B-1
- Tällöin tulisi valita B<=k (muuten varataan tilaa soluille, jotka välttämättä jäävät tyhjiksi),
- Vain, jos B>=N, voidaan päästä yhteen levyhakuun tietuetta haettaessa
- B:n kokoon vaikuttavat mm.
  - hajautusfunktio
  - hajautusavaimen rakenne
  - käytetäänkö soluhakemistoa, jolloin osoiteavaruuden koon kasvattaminen on kevyempää

Hajautukseen perustuvat tiedostorakenteet

- Hajautusfunktio on tyypillisesti muotoa
  h(k) = int(k) mod B
  - missä int(k) muuntaa hajautusavaimen kokonaisluvuksi
- Hyvältä hajautusfunktiolta edellytetään, että se jakaa hajautusavaimen arvot tasaisesti osoiteavaruuteen
  - laskennan nopeus ei ole yhtä oleellista kuin keskusmuistihajautuksessa
- Hajautukseen perustuvat rakenteet nopeuttavat hakua vain kyselyissä, joissa tietueita haetaan hajautusavaimeen perustuvan yhtäsuuruusehdon avulla.