

# DM507 Algoritmer og datastrukturer

Forår 2018

## Projekt, del III

Institut for matematik og datalogi  
Syddansk Universitet

17. april, 2018

Dette projekt udleveres i tre dele. Hver del har sin deadline, således at arbejdet strækkes over hele semesteret. Deadline for del III er tirsdag den 22. maj. De tre dele I/II/III er ikke lige store, men har omfang omtrent fordelt i forholdet 15/30/55. Projektet skal besvares i grupper af størrelse to eller tre.

## Mål

Målet for del III af projektet er at lave sit eget værktøj til at komprimere filer. Komprimeringen skal ske via Huffman-kodning. Der skal laves to programmer: et til at kode/komprimere en fil, og et til dekode den igen.

Vær sikker på at du forstår Huffmans algoritme (Cormen et al. afsnit 16.3 indtil side 433) før du læser resten af denne opgavetekst.

## Opgaver

### Opgave 1

Du skal i Java implementere et program, der læser en fil og laver en Huffman-kodet version af den. Den præcise definition af input og output følger nedenfor. Programmet skal hedde `Encode.java`, og skal kunne køres sådan:

```
Java Encode nameOfOriginalFile nameOfCompressedFile
```

Input-filen skal ses som en sekvens af bytes (8 bits), dvs. der er  $2^8 = 256$  mulige forskellige tegn i input. Tegn kaldes i resten af opgaven for bytes. For at læse bytes fra en fil, skal man bruge `read`-metoden fra `FileInputStream` (eller evt. `BufferedInputStream`).<sup>1</sup> I Java repræsenteres bytes ved `int`'s,

---

<sup>1</sup>Man skal ikke bruge en stream fra `Reader`-familien.

hvor man kun bruger værdierne 0 til 255,<sup>2</sup> og dette er typen af output for `read`-metoden fra `FileInputStream` (samt typen af input for `write`-metoden fra `FileOutputStream`).

En byte er derfor otte bits i filer på disk, men er en `int` undervejs i Java-programmet.

Programmet `Encode` skal virke således:

1. Scan inputfilen og lav en tabel (et array med 256 entries) over hyppigheden af de enkelte bytes (husk at bytes er `int`'s mellem 0 og 255, og kan bruges som indekser i arrays).
2. Kør Huffmans algoritme med tabellen som input (alle 256 entries, også dem med hyppighed nul<sup>3</sup>).
3. Konverter Huffmans træ til en tabel (et array med 256 entries) over kodeord for hver af de mulige bytes (husk at bytes er `int`'s mellem 0 og 255, og kan bruges som indekser i arrays).
4. Scan inputfilen igen. Undervejs find for hver byte dets kodeord (ved opslag i tabellen over kodeord), og skriv dette kodeords bits til outputfilen.

I ovenstående scannes inputfilen to gange. Dette er at foretrække frem for at scanne den én gang og derefter gemme dens indhold i et array til videre brug, eftersom RAM-forbruget derved stiger fra  $O(1)$  til inputfilens størrelse (som kan være meget stor).

I punkt 3 skal man lave et rekursivt gennemløb (svarende til et inorder-gennemløb af et søgetræ) af Huffman-træet og derved generere alle kodeordene. Under gennemløbet vedligeholder man hele tiden et kodeord svarende til stien fra roden til den nuværende knude, og når man når et blad, kan dette kodeord gemmes i tabellen. Kodeord (som jo ikke er lige lange) skal i tabellen repræsenteres af `String`'s af '0' og '1' tegn. En sådan streng kan så under et opslag i tabellen gennemløbes tegn for tegn og konverteres til bits til output.

Huffman-kodning skal implementeres via en prioritetskø (jvf. Cormen et al. side 431). Hertil skal genbruges interfacet `PQ` fra del I, samt gruppens implementation `PQHeap` heraf. Også klassen `Element` skal genbruges, og skal her

---

<sup>2</sup>Bemærk at der findes en datatype `byte` i Java, men denne er et signed 8-bit heltal i two's complement og har derfor ikke de rette egenskaber, så den skal *ikke* anvendes.

<sup>3</sup>Huffmans algoritme virker kun for alfabeter med mindst to tegn. Hvis man udelader tegn med hyppighed nul, vil filer med indhold af typen `aaaaaa` give et alfabet af størrelse ét. Derfor dette krav.

repræsentere deltræer genereret under Huffman-algorithmens kørsel. Derfor skal `data` i `Element` være et træ-objekt, og `key` skal være dets tilhørende hyppighed. Træ-objektet gemt i `data`-delen er et binært træ med en byte (`int` med værdi mellem 0 og 255) gemt i blade. Se figuren i bogen side 432.<sup>4</sup> Træ-objekterne fra del II kan *ikke* direkte genbruges (vi skal f.eks. her bruge andre operationer på dem end søgetræsoperationer), men kan tjene som inspiration.

Den præcise specifikation af output programmet `Encode` er:

Først 256 `int`'s (hvilket fylder  $256 \cdot 32$  bits i alt), som angiver hyppighederne af de 256 mulige bytes i input, derefter de bits, som Huffman-kodningen af input giver.

Bemærk at for korte filer (eller lange filer, som ikke kan komprimeres væsentligt med Huffmans metode) kan output af `Encode` være længere end den oprindelige fil. Man kan tænke sig mange måder at undgå eller begrænse denne situation på, men dette er ikke en del af projektet.

Når man skriver et kodeord i output, har man brug for at skrive bits én ad gangen. Der er i Javas bibliotek ikke metoder til at læse og skrive enkelte bits til disk (mindste enhed er en byte), men underviseren har udleveret et bibliotek, som kan gøre dette. I dette er der også mulighed for at læse og skrive hele `int`'s (disse fylder 32 bits).

Recap: I opgave 1 skal man bruge `read`-metoden fra Java bibliotekets `FileInputStream` til at læse bytes fra inputfilen (den originale fil). Man skal bruge metoderne fra `BitOutputStream` fra det udleverede bibliotek til at skrive `int`'s (for hyppighedstabel) og bits (for Huffmans-koderne) til outputfilen (den komprimerede fil).

## Opgave 2

Du skal i Java implementere et program, som læser en fil med data genereret af programmet fra opgave 1, og som skriver en fil med dens originale (ukomprimerede) indhold. Programmet skal hedde `Decode.java`, og skal kunne køres sådan:

```
Java Decode nameOfCompressedFile nameForDecodedFile
```

Programmet skal virke således:

---

<sup>4</sup>Hyppigheden i knuderne behøves ikke implementeret, kun rodens tal er nødvendigt i Huffmans algoritme og det bliver her i stedet til `key` i `Element`

1. Indlæs tabellen over hyppighederne for de 256 bytes.
2. Generer samme Huffman-træ som programmet fra opgave 1 (dvs. *same* implementation skal bruges begge steder, så der i situationer, hvor Huffman-algoritmen har flere valgmuligheder, vælges det samme).
3. Brug dette Huffman-træ til at dekode resten af bits i input, og imens som output skriv den originale version af filen.

Alt dette kan gøres i ét scan af input.

Bemærk at det samlede antal bits fra udskrivningen af Huffman-koderne af det udleverede bibliotek om nødvendigt bliver rundet op til et multiplum af otte (dvs. til et helt antal bytes), ved at nul-bits tilføjes til sidst når filen lukkes. Dette skyldes, at man på computere kun kan gemme filer, som indeholder et helt antal bytes. Disse muligt tilføjede bits må ikke blive forsøgt dekodet, da ekstra bytes så kan opstå i output. Derfor må man under dekodning finde det samlede antal bytes i originalfilen ved at summere hyppighederne, og under rekonstruktionen af den ukomprimerede fil holde styr på hvor mange bytes, man har skrevet.

For at skrive bytes til en fil, skal man bruge `write`-metoden fra `FileOutputStream` (eller evt. `BufferedOutputStream`).<sup>5</sup>

Recap: I opgave 2 skal man bruge metoderne fra `BitInputStream` fra det udleverede bibliotek til at læse `int`'s (for hyppighedstabell) og bits (for Huffmans-koderne) fra inputfilen (den komprimerede fil). Man skal bruge `write`-metoden fra Java bibliotekets `FileOutputStream` til at skrive bytes til outputfilen (den genskabte originale fil).

## Formalia

Du skal kun aflevere dine Java source-filer. Disse skal indeholde grundige kommentarer. De skal også indeholde navnene og SDU-logins på gruppens medlemmer. Husk at levere alle nødvendige filer med, også f.eks. `PQHeap.java`, `PQ.java` og `Element.java` fra del I.

Dine programmer vil blive testet med mange typer filer (`txt`, `.doc`, `.jpg`, ...), og du bør selv gøre dette inden aflevering, men du skal ikke dokumentere denne test.

Filerne skal afleveres elektronisk i Blackboard med værktøjet "SDU Assignment", som findes i menuen til venstre på kursussiden i Blackboard. De

---

<sup>5</sup>Man skal ikke bruge en stream fra `Writer`-familien.

skal enten afleveres som individuelle filer eller som ét **zip**-arkiv (med alle filer på topniveau, dvs. uden nogen directory struktur). Der må ikke være **package** statements i filerne. Der behøves kun afleveres under én persons navn i gruppen.

Filerne skal *også* afleveres udprintet på papir i instruktorens boks på Imada (vælg én af instruktorerne, hvis personerne i gruppen går på forskellige hold). Spørg Imadas sekretær hvis man ikke ved, hvor instruktorboksene er. Der skal blot afleveres én kopi per gruppe. Afleveringens sider skal sættes sammen med hæfteklamme.

Det er *vigtigt* at overholde alle syntaktiske regler ovenfor (navngivning af klasser, måden programmerne køres, **zip**-arkiv uden directory struktur, ingen **package** statements), da programmerne vil blive testet på automatiseret måde.

Aflever materialet senest:

**Tirsdag den 22. maj, 2018, kl. 12:00.**

Bemærk at aflevering af andres kode eller tekst, hvad enten kopieret fra medstuderende, fra nettet, eller på andre måder, er eksamenssnyd, og vil blive behandlet som sådan. Man lærer desuden heller ikke noget.