


Select - Anfrag

a) $O(\lg n)$ Anfragezeit und $o(n)$ Bit Platz



1. Unterteile BV in Intervalle

2. Wir merken uns, wie viele 1en in Intervallen davor gesetzt sind

↳ Warum machen wir das?

Weil wir dann mit einer binären Suche das Intervall finden können

↳ Wie viel Platz braucht das?

#Samples $\cdot \lg n$ Bit

↳ Wir können Intervalle der Größe $\lg^2 n$ Bit betrachten, denn dann haben wir $\frac{n}{\lg^2 n}$ viele Samples und brauchen $o(n)$ Bit Platz ($\frac{n}{\lg n}$ Bit)

↳ Das gesuchte Intervall finden wir in $O(\lg n)$ Zeit

3. Jetzt müssen wir noch $\lg^2 n$ viele
Bib durchsuchen

↳ Können wir einfach scannen?
Nein, denn das benötigt $O(\lg^2 n)$ Zeit

↳ Idee: Berechne # 1en für Wörter
der Länge $(\lg n)/2$ vor.

Z.B.:
1101 → 3
1110 → 3
1111 → 4

↳ Wir müssen $2^{(\lg n)/2}$ Werte vorberechnen und jeder Wert braucht $\lg \lg n$ Bit Platz

↳ Wir können die Werte in $O(\sqrt{n} \cdot \lg \lg n)$ Bit Platz abspeichern. Das ist $o(n)$ Bit Platz.

↳ Jetzt können wir $(\lg n)/2$ Bit auf einmal scannen, in konstanter Zeit

↳ Wir scannen so lange bis

wir die $(\lg n)/2$ Bits gefunden haben, in denen das gesuchte Bit liegt.

↳ Danach müssen wir dann nur noch $(\lg n)/2$ Bits "manuell" scannen

↳ Das funktioniert in $O(\lg n)$ Zeit

b) $O(1)$ Anfragezeit, $O(n)$ Bit Platz und der BV ist dünn besetzt, d.h., es sind $o(\frac{n}{\lg n})$ Bits gesetzt.

↳ Wir überlegen uns, was es bedeutet, dass $o(\frac{n}{\lg n})$ Bits gesetzt sind.

→ z.B. $\frac{n}{\lg^2 n}$, $\frac{n}{\lg n \cdot \ln}$, ...

$$\frac{n}{\lg n \cdot \lg \lg \dots \lg n}$$

→ Wir können die Positionen, an denen die 1en vorkommen direkt in einem Array abspeichern

→ $O(\#1en \cdot \lg n)$ Bit Platz $\stackrel{\#1en = o(\frac{n}{\lg n})}{=} O(n)$ Bit Platz

Implementierung Bit-Vektor

→ Wir befüllen die 64-Bit Wörter in unserem Bitvektor falsch herum



Index 0 1 2 3 ... 64 65 ...


Falsch 63 62 61 ... 0 1 2 7 126 ... 64 herum

↳ Warum machen wir das? → Es ist schneller

Entwicklung: Geht das besser?


`(block >> (63-(i%64))) & 1ULL;`

▶ Fülle Bit-Vektor von links nach rechts



`(block >> (i%64)) & 1ULL;`

▶ Fülle Bit-Vektor von rechts nach links



▶ Assembler-Code: `mov ecx, edi
not ecx
shr rsi, cl
mov eax, esi
and eax, 1`

▶ Assembler-Code: `mov ecx, edi
shr rsi, cl
mov eax, esi
and eax, 1`

↳ Wir sparen uns diese Negation

<https://graphics.stanford.edu/~seander/bithacks.html>

↳ Bit-Tricks wie hier genutzt


Operator - Überladung in C++

↳ T operator { [], (), ++, <<, >>, ... } (...)

↳ Wir können kein „Bit“ zurückgeben

Ramb für unseren Bitvektor


↳ Die Datenstruktur besteht aus drei
Leveln L0, L1, L2
grob —————> fein



→ Um 512 darzustellen brauchen wir
10 Bit

→ L1 512 Bit - Blöcke erhalten einen
L1 Eintrag → Wie viele Bit sind
vor mir gesetzt
→ Nutze nur 32 Bit-Wert


→ L0 Eintrag für jeweils 2^{31} Bits
 L1 Eintrag relativ zum aktuellen
 L0 Eintrag




An diesen Stellen fangen die L1-Einträge bei
 0 an

L2-Eintrag enthält die Anzahl
 der gesetzten Bits für einen
 512-Bit-Block

→ 3 L2-Einträge pro L1 Block




In der Praxis speichern wir die
 L1 und L2-Einträge in einem 64-Bit
 Wort



Die Rank-Anfrage benötigt nur 3 L2-Einträge

↳ Wenn wir unseren L1-Block identifiziert haben, dann



wenn die rank-Position hier ist, gucken wir im nächsten L1-Eintrag

Hier könnten wir den letzten L2-Eintrag gar nicht verwenden

Basiert auf:

Space-Efficient, High-Performance Rank & Select Structures on Uncompressed Bit Sequences

Dong Zhou, David G. Andersen, Michael Kaminsky[†]
Carnegie Mellon University, [†]Intel Labs

Abstract. Rank & select data structures are one of the fundamental building blocks for many modern *succinct data structures*. With the continued growth of massive-scale information services, the space efficiency of succinct data structures is becoming increasingly attractive in practice. In this paper, we re-examine the design of rank & select data structures from the bottom up, applying an architectural perspective to optimize their operation. We present our results in the form of a recipe for constructing space and time efficient rank & select data structures for a given hardware architecture. By adopting a *cache-centric* design approach, our rank & select structures impose space overhead as low as the most space-efficient, but slower, prior designs—only 3.2% and 0.39% extra space respectively—while offering performance competitive with the highest-performance prior designs.