Woche 2 – Übersicht & Tricks

(Disclaimer: Die hier vorzufindenden Notizen haben keinerlei Anspruch auf Korrektheit oder Vollständigkeit und sind nicht Teil des offiziellen Vorlesungsmaterials. Alle Angaben sind ohne Gewähr.)

O-Notation:

Def.: Sei $f: \mathbb{N} \rightarrow \mathbb{R}^+$ eine Kostenfunktion. Wir definieren nun eine Menge von Funktionen, die auch nicht schneller wachsen als f , konkret:

$$O(f) := \{g: \mathbb{N} \rightarrow \mathbb{R}^+ \mid \text{es gibt } c > 0, n_0 \in \mathbb{N} \text{ so, dass } g(n) < c * f(n) \text{ für alle } n > n_0\}$$

- Aus der Definition folgt:
 - Die Funktion f ist asymptotisch eine obere Schranke für alle $g \in O(f)$
 - Beim Untersuchen des asymptotischen Verhaltens von Funktionen im Kontext der O-Notation können wir konstante Faktoren ignorieren
 - Abgeschlossenheit unter Addition:

$$g_1 \in O(f), g_2 \in O(f) \Rightarrow g_1 + g_2 \in O(f)$$

Beweis für Abgeschlossenheit unter Addition¹:

Seien $g_1: \mathbb{N} \rightarrow \mathbb{R}$ und $g_2: \mathbb{N} \rightarrow \mathbb{R}$ Funktionen mit $g_1 \in O(f), g_2 \in O(f)$. Dann gilt per Def. der O-Notation: $\exists c_1 > 0, n_1 \in \mathbb{N} : g_1(n) < c_1 * f(n) \quad \forall n > n_1$ and

$\exists c_2 > 0, n_2 \in \mathbb{N} : g_2(n) < c_2 * f(n) \quad \forall n > n_2$

Es gilt: $g_1 + g_2 \in O(f) \Leftrightarrow \exists c_0 > 0, n_0 \in \mathbb{N} : g_1(n) + g_2(n) < c_0 * f(n) \quad \forall n > n_0$

Nun zeigen wir, dass solche c_0 und n_0 existieren: Wir wählen $c_0 := c_1 + c_2$ und $n_0 := \max\{n_1, n_2\}$, und sehen: $g_1(n) + g_2(n) \leq c_1 * f(n) + c_2 * f(n) = (c_1 + c_2) * f(n) = c_0 * f(n) \quad \forall n > n_0$ ■

Analyse	O-Notation	Beschreibung
$\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = 0$	$f \in O(g)$ und $g \notin O(f)$	„f wächst langsamer* als g“
$\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = C \in \mathbb{R}^+$	$f \in O(g)$ und $g \in O(f)$	„f und g wachsen gleich schnell* “
$\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = \infty$	$f \notin O(g)$ und $g \in O(f)$	„f wächst schneller* als g“

Wichtige Komplexitätsklassen der Laufzeitanalyse:

Konstant: $O(1)$	Linear: $O(n)$	Polynomiell: $O(n^c), c \in \mathbb{R}^+$
Logarithmisch: $O(\log(n))$	Superlinear: $O(n * \log(n))$	Exponentiell: $O(c^n), c \in \mathbb{R}^+$

Tricks zum Umformen und Abschätzen von Summen:

1. $\sum_{i=1}^n i = \frac{n*(n+1)}{2}$
2. $\sum_{j=1}^n \sum_{k=j}^n 1 = \sum_{j=1}^n (n - j + 1) = \frac{n*(n+1)}{2}$ (denn $\sum_{j=1}^n (n - j + 1)$ ist letzten Endes nur die Summe aus 1., bloss "andersherum gezählt")
3. $\sum_{j=1}^n \sum_{k=1}^n \sum_{l=1}^n 1 = n^3$
4. $\sum_{i=1}^n i^3 = \frac{n^2*(n+1)^2}{4}$
5. $\sum_{i=1}^n \sum_{k=1}^i 1 = \sum_{i=1}^n i = \frac{n*(n+1)}{2}$
6. $\sum_{i=1}^n i * \log(i) \geq \sum_{i=\frac{n}{2}}^n i * \log(i) \geq \sum_{i=\frac{n}{2}}^n \frac{n}{2} * \log\left(\frac{n}{2}\right) \geq \frac{n^2}{4} * \log\left(\frac{n}{2}\right)$
7. $\sum_{i=1}^n i * \log(i) \leq \sum_{i=1}^n n * \log(n) = n^2 * \log(n)$

Maximum Subarray-Sum Algorithmus ("Kadane's Algorithm"):

In der Vorlesung wurden verschiedene Lösungsansätze für das Maximum Subarray-Sum Problem vorgestellt. Hier werde ich nun den schnellsten, induktiven Algorithmus noch einmal mit einem Beispiel präsentieren:

Wir iterieren von links nach rechts über das Array A, d.h., wir bewegen uns in jeder Iteration um eine Position nach rechts.

a_0	a_1	a_2	a_3	a_4	a_5	a_6	a_7
0	1	2	3	4	5	6	7

Dabei merken wir uns zwei Werte, MSS und RANDMAX. In MSS speichern wir die bislang berechnete Maximum Subarray-Sum (am Anfang initialisieren wir diesen Wert also mit 0) und in RANDMAX (anfänglich auch 0) speichern wir die Subarray-Sum bis zu der Position im Array, an der wir uns gerade befinden. In jeder Iteration aktualisieren wir nun $\text{RANDMAX} := \text{RANDMAX} + a_i$ (Also addieren wir in der i-ten Iteration das Element an Stelle i zu unserer Randsumme) und prüfen, ob diese neue Randsumme jetzt grösser als die bislang berechnete Maximum Subarray-Sum ist, sprich ob $\text{RANDMAX} > \text{MSS}$. Falls dem so ist, aktualisieren wir: $\text{MSS} := \text{RANDMAX}$, andernfalls lassen wir MSS unverändert. Abschliessend prüfen wir noch in jeder Iteration, ob unser neues $\text{RANDMAX} < 0$ (und setzen $\text{RANDMAX} := 0$, falls dem so ist), denn sollte die Subarray-Sum bis zur Position i (also bis an den Rand) negativ sein, müssen wir ab der nächsten (i+1-ten) Position wieder bei 0 beginnen. Denn bspw. ist $-2 + 4 + \dots < 0 + 4 + \dots$ und die MSS kann grundsätzlich an jeder Position starten.

Hier nun ein Beispiel:

Wir wollen die Maximum Subarray-Sum für dieses Array berechnen:

4	-4	3	5	-1
0	1	2	3	4

Zunächst setzen wir $\text{RANDMAX} := 0$ und $\text{MSS} := 0$.

Jetzt beginnen wir, von links durch das Array zu iterieren, beobachten also zunächst Position $i = 0$: Wir setzen $\text{RANDMAX} := \text{RANDMAX} + 4$ (also gilt jetzt: $\text{RANDMAX} == 4$) und vergleichen: $\text{RANDMAX} > \text{MSS}$? Da $\text{MSS} == 0$, also $\text{RANDMAX} > \text{MSS}$ setzen wir $\text{MSS} := \text{RANDMAX}$.

4	-4	3	5	-1
0	1	2	3	4

Nun sind wir bei Position $i = 1$: Für den grünen Teil kennen wir jetzt schon die MSS. Wir setzen $\text{RANDMAX} := \text{RANDMAX} - 4$ (also gilt jetzt: $\text{RANDMAX} == 0$). Da

4	-4	3	5	-1
0	1	2	3	4

RANDMAX < MSS, verändern wir MSS nicht. Da RANDMAX > 0, verändern wir RANDMAX nicht.

Nun sind wir bei Position $i = 2$: Für den grünen Teil kennen wir schon die MSS. Wir setzen $\text{RANDMAX} := \text{RANDMAX} + 3$ (also gilt jetzt: $\text{RANDMAX} == 3$). Da $\text{RANDMAX} < \text{MSS}$, verändern wir MSS nicht. Da $\text{RANDMAX} > 0$, verändern wir RANDMAX nicht.

Nun sind wir bei Position $i = 3$: Für den grünen Teil kennen wir schon die MSS. Wir setzen $\text{RANDMAX} := \text{RANDMAX} + 5$ (also gilt jetzt: $\text{RANDMAX} == 8$). Da $\text{RANDMAX} > \text{MSS}$, setzen wir: $\text{MSS} := \text{RANDMAX}$. Da $\text{RANDMAX} > 0$, verändern wir RANDMAX nicht.

Nun sind wir bei Position $i = 4$: Für den grünen Teil kennen wir schon die MSS. Wir setzen $\text{RANDMAX} := \text{RANDMAX} - 1$ (also gilt jetzt: $\text{RANDMAX} == 7$). Da $\text{RANDMAX} < \text{MSS}$, verändern wir MSS nicht. Da $\text{RANDMAX} > 0$, verändern wir RANDMAX nicht.

Wir sind am Ende des Arrays angekommen und haben $\text{MSS} == 8$ als Maximum Subarray-Sum berechnet.

Hands-On: O-Notation:

(Das hier ist eine Aufgabe aus seiner Altklausur, HS19 Algorithmen & Datenstrukturen):

Gilt: $\sum_{i=1}^n \log_2(i) \in O(n * \log(n))$?

Lösungsweg 1: Da die O-Notation asymptotisch obere Schranken für Funktionen definiert, versuchen wir, die Summe nach oben abzuschätzen:

$$\sum_{i=1}^n \log_2(i) \leq \sum_{i=1}^n \log_2(n) = n * \log_2(n) \in O(n * \log(n))$$

Lösungsweg 2: Es gilt: $\log(a * b) = \log(a) + \log(b)$. Dies verwenden wir nun:

$$\sum_{i=1}^n \log_2(i) = \log_2\left(\prod_{i=1}^n i\right) = \log_2(n!) \leq \log_2(n^n) = n * \log_2(n) \in O(n * \log(n))$$

Erklärung zu Lösungsweg 2: $\log(n!) \leq \log(n^n)$, denn der Logarithmus ist eine streng monoton wachsende Funktion, also gilt: $\log(x) < \log(y) \Leftrightarrow x < y$ und $n! < n^n$, da offensichtlich:

$n! = 1 * 2 * \dots * n$ (insgesamt n Faktoren) während $n^n = n * n * \dots * n$ (insgesamt n Faktoren)