

LU07.L09 - Datenstruktur begründet auswählen

Die drei Fassungen

```
def mit_liste(ausleihen, gesperrte):
    out = []
    for k in ausleihen:
        for konto, grund in gesperrte:
            if konto == k:
                out.append((k, grund))
                break
    return out

def mit_set(ausleihen, gesperrte):
    konten = {k for k, _ in gesperrte}
    gruende = dict(gesperrte)
    return [(k, gruende[k]) for k in ausleihen if k in konten]

def mit_dict(ausleihen, gesperrte):
    index = dict(gesperrte)
    return [(k, index[k]) for k in ausleihen if k in index]

assert mit_liste(ausleihen, gesperrte) == mit_set(ausleihen, gesperrte) == mit_dict(ausleihen, gesperrte)
```

Messung

5000 Ausleihen, wachsende Sperrliste (Python 3.12, Werte eines Testlaufs):

Gesperrte Konten	Liste	Set + Dict	Dict	Indexaufbau
100	0.0057 s	0.00026 s	0.00028 s	0.000004 s
2 000	0.1159 s	0.00044 s	0.00042 s	0.000076 s
20 000	1.1453 s	0.00282 s	0.00142 s	0.001014 s

Die Liste wird bei zehnfacher Datenmenge rund zehnmal langsamer ($O(n)$ pro Abfrage, $O(n \cdot m)$ gesamt). Dict und Set bleiben nahezu konstant - der Anstieg dort stammt fast vollständig aus dem **Aufbau** des Index, nicht aus den Abfragen.

Antworten

Ab wann lohnt sich der Index? Schon bei 100 Einträgen ist die Dict-Fassung 20-mal schneller, und der Aufbau kostet vier Mikrosekunden. Die Faustregel lautet deshalb: Sobald in einer Schleife gesucht wird, lohnt sich der Index praktisch immer. Nicht lohnen tut er sich, wenn die Struktur für **eine einzige** Abfrage aufgebaut wird - dann kostet der Aufbau mehr, als die Suche spart.

Was geht verloren?

- Set und Dict verlieren die **Reihenfolge** der Originaldaten (Dict behält die Einfügereihenfolge, aber nicht die der Ausleihen).
- **Duplikate** verschwinden. Steht ein Konto zweimal mit verschiedenen Gründen in der Liste, gewinnt beim Dict der letzte Eintrag - stillschweigend.
- Die Schlüssel müssen **hashbar** sein.
- Es wird zusätzlicher **Speicher** belegt.

Wann ist die Liste richtig?

- Wenn nur **einmal** gesucht wird.
- Wenn die Sperrliste sehr klein ist und die Reihenfolge fachlich zählt (etwa «zuerst eingetragene Sperre zuerst anzeigen»).
- Wenn Duplikate erhalten bleiben müssen, weil jedes eine eigene Sperre mit eigenem Datum ist.

Warum Dict statt Set? Beide prüfen die Zugehörigkeit in $O(1)$. Das Set braucht aber eine **zweite** Struktur für den Grund, also zwei Durchläufe über dieselben Daten und zwei Lookups pro Treffer. Das Dict liefert Prüfung und Grund in einer Struktur - sichtbar in der Messung bei 20'000 Einträgen (0.00142 s gegenüber 0.00282 s).

Empfehlung: dict, sobald mehr als eine Abfrage stattfindet. Das set ist die richtige Wahl, wenn Sie nur die Frage «ist enthalten?» beantworten und keinen Wert dazu brauchen.

Formulierungsbeispiel für das Portfolio (D1A)

Für die Sperrprüfung habe ich die Liste durch ein Dict ersetzt. Gemessen mit 5000 Ausleihen gegen 20'000 gesperrte Konten: 1.145 s vorher, 0.0014 s nachher, bei identischem Ergebnis (per assert geprüft). Grund: Die Listenfassung durchsucht pro Ausleihe im Schnitt die halbe Sperrliste ($O(n)$), das Dict greift über den Hash direkt zu ($O(1)$). Der Preis ist zusätzlicher Speicher und der Verlust von Duplikaten - da eine Kontonummer nur einmal gesperrt sein kann, ist das hier unproblematisch. Wäre die Reihenfolge der Sperrinträge fachlich relevant, hätte ich stattdessen einen zusätzlichen Index neben der Liste gehalten.

[M323-LU07](#), [M323-D1A](#)

 © Kevin Maurizi

From:

<https://wiki.bzz.ch/> - **BZZ - Modulwiki**

Permanent link:

<https://wiki.bzz.ch/modul/m323/learningunits/lu07/loesungen/datenstruktur>

Last update: **2026/09/09 11:17**

