Fachbereich für Computerwissenschaften

Prof. Dr. Nikolaus Augsten
Jakob-Haringer-Str. 2
5020 Salzburg, Austria
Telefon: +43 662 8044 6347
E-Mail: nikolaus.augsten@sbg.ac.at

PARIS LODRON UNIVERSITÄT SALZBURG

Datenbanken II — Prüfung
Wintersemester 2021/2022 — 16.09.2022

Name: _____ **Matrikelnummer:** _____

Hinweise

- Bitte überprüfen Sie die Vollständigkeit des Prüfungsbogens (11 nummerierte Seiten).
- Schreiben Sie Ihren Namen und Ihre Matrikelnummer auf jedes Blatt des Prüfungsbogens und geben Sie alle Blätter ab.
- Grundsätzlich sollten Sie alle Antworten auf den Prüfungsbogen schreiben.
- Sollten Sie mehr Platz für eine Antwort benötigen, bitte einen klaren Verweis neben die Frage auf die Seitennummer des zusätzlichen Blattes setzen.
- Keinen Bleistift verwenden. Keinen roten Stift verwenden.
- Verwenden Sie die Notation und die Lösungsansätze, die während der Vorlesung besprochen wurden.
- Aufgaben mit mehr als einer Lösung werden nicht bewertet.
- Als Unterlage ist ein beliebig (auch beidseitig) beschriftetes A4-Blatt erlaubt.
- Zeit für die Prüfung: 90 Minuten

Unterschrift _____

Korrekturabschnitt — Bitte frei lassen

Aufgabe	1	2	3	4	5	6	7	8	9	10	Summe
Maximale Punkte	1	1	1	1	1	1	1	1	1	1	10
Erreichte Punkte											

Aufgabe 1 - *Slotted Page*. 1 Punkt

Gegeben sei eine Slotted Page mit folgenden Eigenschaften:

- Größe: $2^{13} = 8192$ Bytes,
- Adressierungstyp: **Byte-Adressierung** (es kann jedes Byte adressiert werden)

In dieser Slotted Page werden **3 Tupel** O, P, Q gespeichert:

- d_1: $|O| = 64$ Bytes
- d_2: $|P| = 128$ Bytes
- d_3: $|Q| = 256$ Bytes

Ergänzen Sie die Slotted Page um die **fehlenden Werte/Adressen** (numerische Werte erwartet, Pfeile reichen nicht aus), wobei p_i und g_i sich auf den jeweiligen Datensatz d_i beziehen. **(0.125 Punkte pro Wert/Adresse)**

a	f	g_3	p_3	g_2	p_2	g_1	p_1	$\ldots$	d_1	d_2	d_3
									O	P	Q

Aufgabe 2 - *Erweiterbares Hashing*. 1 Punkt

Die Hashfunktion $h(x)$ liefert die in der Tabelle angegebenen Binärwerte. Es soll das Tupel **Henry** aus dem gegebenen Hashcontainer **gelöscht** werden. Ein Bucket im Hashcontainer kann bis zu 3 Tupel speichern. Das Verzeichnis soll so klein wie möglich gehalten werden. **Illustrieren Sie den resultierenden Hashcontainer**.

x	$h(x)$
Abigail	0000
Burton	0010
Buzz	0001
Carlton	0100
Henry	0011
Juliet	0101
Karen	1110
Pierre	0111
Shawn	1100
Woodrow	0110

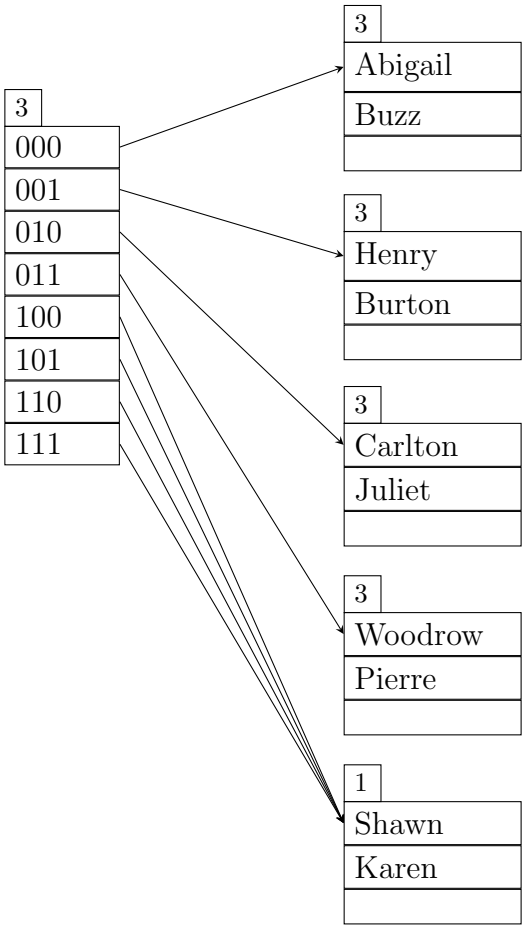

Aufgabe 3 - *B^+-Baum-Konstruktion.* 1 Punkt

Gegeben sind die Blätter eines B^+-Baumes ($m = 3$). Konstruieren Sie die **darüberliegenden Ebenen** (d.h. die inneren Knoten) so, dass ein **gültiger B^+-Baum mit minimaler Höhe** entsteht.

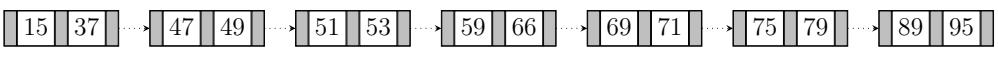

Aufgabe 4 - *B⁺-Baum-Löschen.* 1 Punkt

Gegeben ist ein B$^+$-Baum mit $m = 5$. Zeichnen Sie den B$^+$-Baum, der nach dem Löschen von **60** entsteht.

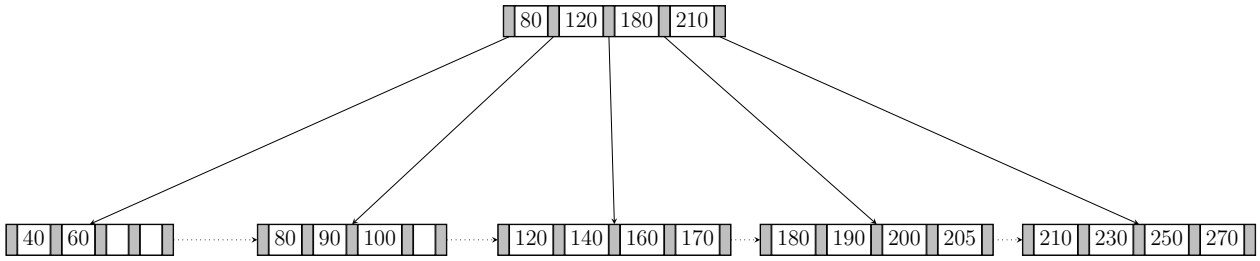

Aufgabe 5 - *Indexstrukturen*. 1 Punkt

Zeichnen Sie für die folgende Tabelle einen **3-stufigen Sekundärindex** auf dem Attribut `Stadt`. Die **erste Indexstufe** soll **dense** und die **zweite und dritte Indexstufe** sollen **sparse** sein. In einen **Indexblock** können **3 Einträge** gespeichert werden.

`Stadt`	`KFZ`
Rom	I
London	GBM
Prag	CZ
Kiew	UA
Berlin	D
Athen	GR
Krakau	PL
Oslo	N
Dublin	IRL
Wien	A

Aufgabe 6 - *Effiziente Anfragebearbeitung.* 1 Punkt

Gegeben sei eine Relation $R[A, B, C, D]$ mit folgenden Eigenschaften:

- $|R| = 2.000.000$ Tupel.
- Pro Datenblock werden 400 Tupel gespeichert.
- Attribut A hat ganzzahlige Werte gleichverteilt im Bereich $[1; 2.000.000]$.
- Attribut B hat ganzzahlige Werte gleichverteilt im Bereich $[400.001; 500.000]$.
- Attribut C hat ganzzahlige Werte gleichverteilt im Bereich $[100.001; 1.000.000]$.
- Attribut D hat ganzzahlige Werte gleichverteilt im Bereich $[1; 10.000.000]$.
- Es existieren folgende Indizes:
  - sparse B$^+$-Baum-Index auf Attribut A.
  - dense B$^+$-Baum-Index auf Attribut B.
  - dense B$^+$-Baum-Index auf Attribut D.
- Für alle B$^+$-Baum-Indizes gilt:
  - $m = 2^8 = 256$.
  - Sie besitzen minimale Höhe.
  - 1 Knotenzugriff entspricht 1 Blockzugriff.

Es soll folgende Anfrage beantwortet werden:

$$\sigma_{A>1.800.000 \wedge B=450.000}(R)$$

Geben Sie die **Strategie und die Blockzugriffe** an, um die Anfrage **möglichst effizient** zu beantworten.

Aufgabe 7 - *Join-Algorithmen*. 1 Punkt

Welcher Join Algorithmus (**Merge Join vs. Index Nested Loop Join**) generiert die minimalen Kosten für das folgende Szenario? Geben Sie in der Lösung die **Algorithmen** und die **dazugehörigen** Kosten an.

Berechnen Sie einen **Natural Join** zwischen zwei Relationen $R[A, B]$ und $S[A, C]$, wobei $|R| = 50$ Tupel und $|S| = 5000$ Tupel. Die Relationen sind auf $b_R = 10$ bzw. $b_S = 2000$ hintereinander liegenden Blöcken gespeichert. Es existiert ein sparse B^+-Baum Index auf $S.A$ mit $m = 8$. Auf $R.A$ existiert kein Index, falls Sie eine Sortierung benötigen, nehmen Sie an dass diese $\lceil b_R \cdot \log_2(b_R) \rceil$ viele Blockzugriffe zusätzlich kostet.

Aufgabe 8 - *Effiziente Anfragebearbeitung.* 1 Punkt

Gegeben ist die Relation $R[A]$. Auf $R.A$ existiert ein sparse B^+-Baum Index. Was ist die **effizienteste Strategie** um Bereichsanfragen von folgendem Typ zu beantworten?

$$\sigma_{a<A<b}(R)$$

Geben Sie **alle notwendigen Schritte** an.

Aufgabe 9 - *Join Kardinalität.* 1 Punkt

Gegeben sind folgende Relationen:

- $|R[A, B, C]| = 1000$, $V(R, A) = 100$, $V(R, B) = 200$, $V(R, C) = 300$
- $|S[A, D, E]| = 4000$, $V(S, A) = 50$, $V(S, D) = 200$, $V(S, E) = 300$
- $|T[C, D, F]| = 2000$, $V(T, C) = 100$, $V(T, D) = 200$, $V(T, F) = 600$

Die Werte in den Tupeln sind gleichverteilt und unabhängig. Schätzen Sie die Kardinalität des Ergebnisses der folgenden Anfrage ab ($\sigma_{A=100 \vee A=200}(R) \neq \emptyset$).

$$(\sigma_{A=100 \vee A=200}(R)) \bowtie S \bowtie T$$

Aufgabe 10 - *Anfrageoptimierung, Join-Reihenfolge.* 1 Punkt

Gegeben seien 3 Relationen $R[A, B, C]$, $S[C, D, E]$ und $T[C, F, G]$ mit folgenden Eigenschaften:

- $|R| = 10^5$ Tupel, $V(R, A) = 10^3$, $V(R, B) = 4 \cdot 10^3$, $V(R, C) = 10^4$
- $|S| = 10^7$ Tupel, $V(S, C) = 2 \cdot 10^3$, $V(S, D) = 5 \cdot 10^3$, $V(S, E) = 8 \cdot 10^3$
- $|T| = 10^9$ Tupel, $V(T, C) = 10^9$, $V(T, F) = 6 \cdot 10^3$, $V(T, G) = 9 \cdot 10^3$

Weiters sei folgende SQL-Anfrage gegeben:

```
SELECT R.C, S.E, T.F
FROM   R, S, T
WHERE  R.C = S.C AND S.C = T.C
```

a. Zeichnen Sie die **algebraische Normalform als Operatorbaum** für die gegebene SQL-Anfrage. **(0.5 Punkte)**
b. Wenden Sie **heuristische Optimierung** an, um den **Operatorbaum zu optimieren**. Im resultierenden Operatorbaum soll die **Join-Reihenfolge optimal** sein (d.h. es soll zuerst der Join mit dem kleinsten Zwischenergebnis durchgeführt werden). **(0.5 Punkte)**