Prof. Dr.-Ing. Dr. h. c. T. Härder
Fachbereich Informatik
AG Datenbanken und Informationssysteme
Universität Kaiserslautern

Übungsblatt 2

Unterlagen zur Vorlesung: „wwwdvs.informatik.uni-kl.de/courses/DBSREAL/“

Aufgabe 1: Indirekte Seitenadressierung, Schattenspeicher- und Zusatzdateikonzept 81

Eine Datenbank bestehe aus zwei Segmenten mit jeweils 8 Seiten, zu deren Abspeicherung insgesamt 32 Blöcke zur Verfügung stehen. Auf dieser DB laufen zeitlich überlappt zwei Transaktionen ab, die Seiten der DB in der nachfolgend aufgeführten zeitlichen Sequenz verändern:

T1: P12 P15 P24 P17 EOT

T2: P21 P25 P16 P27 EOT

Pij steht für Seite j in Segment i

EOT bezeichnet das Ende der Transaktion

Machen Sie sich an diesem Beispiel die Funktionsweise der indirekten Adressierung, des Schattenspeicher- und des Zusatzdateikonzeptes klar. Vor Beginn von T1 seien beide Segmente geschlossen.

Bei indirekter Adressierung sei folgende Zuordnung der Seiten (P) zu Blöcken (B) gegeben:

P11	P12	P13	P14	P15	P16	P17	P18	P21	P22	P23	P24	P25	P26	P27	P28
B1	B3	B6	B5	B7	B13	B9	B10	B15	B18	B19	B17	B21	B28	B24	B26

a) Bestimmen Sie den Aufbau der Seitenzuordnungstabellen bei indirekter Seitenadressierung.

b) Welche zusätzlichen Hilfsstrukturen werden beim Schattenspeicherkonzept benötigt? Bestimmen Sie deren Modifikationen beim Ablauf der Transaktionen.

c) Führen Sie für das Schattenspeicherkonzept nach EOT von T1 einen Sicherungspunkt für beide Segmente durch, nach EOT von T2 einen für Segment 2.

d) Was muss am Schattenspeicherkonzept geändert werden, um transaktionsbezogene Sicherungspunkte implementieren zu können? Vollziehen Sie einen solchen Sicherungspunkt bei EOT am Ende von T1 am Beispiel nach.

Aufgabe 2: Bloom-Filter 183

Mit Hilfe des Bloom-Filters kann beim Zusatzdatei-Verfahren einfach entschieden werden, ob eine Seite verändert worden sein kann und deshalb möglicherweise in der Zusatzdatei steht, oder ob dieses nicht der Fall sein kann.

Gegeben seien ein Bitvektor der Länge 8 und eine Hash-Funktion `h(x)`, welche die Positionen der 1-en liefert, die bei folgender Funktion `g(x)` gesetzt werden:

`g(x) = (Binärdarstellung von x) XOR (01010101).`

Die Seiten mit den Schlüsselwerten 31, 53 und 62 werden verändert. Anschließend sollen die Seiten mit den Schlüsselwerten 53, 93 und 124 gelesen werden.

Welche Ergebnisse liefert der Bloom-Filter bei den Leseoperationen?

Warum ist die angegebene Hash-Funktion für den Bloom-Filter ungeeignet und welche Eigenschaften muss eine bessere Hash-Funktion haben?

Aufgabe 3: Lokalität und Sequentialität 173

Eine Transaktion erzeuge folgenden Referenzstring:

AABBCEDABGHAAGGHHIIKKLKLKLKLMABABKLKLKLFMFAGHI

Beachten Sie hierbei, dass als sequentieller Reihenfolge angenommen wird: ABCDEFGHIKLMNO

Berechnen Sie folgende Größen:

- Die aktuelle Lokalität zu den Zeitpunkten t = 6, 18, 28 und der Fenstergröße 6.
- Die durchschnittliche Lokalität.
- Die sequentiellen Zugriffsfolgen sowie das Maß der Sequentialität der Transaktion.
- Die LRU-Stacktiefenverteilung.

Diskutieren Sie die dynamischen Zuordnungsentscheidungen von Pufferseiten für diese Transaktion. Wie sind die vorgestellten Entscheidungsgrößen effizient im DBMS zu ermitteln.

Aufgabe 4: Suche im DB-Puffer

Im Skript sind mehrere Verfahren zur Unterstützung der schnellen Suche einer DB-Seite im DB-Puffer skizziert. Analysieren Sie die folgenden Verfahren im Hinblick auf Wartungs- und Suchkosten:

1. **unsortierte Tabelle**
2. **sortierte Tabelle**
3. **Tabelle mit verketteten Einträgen (LRU-Reihenfolge)**
4. **AVL-Baum**
5. **Hash-Tabelle mit Überlaufketten**

Annahmen:

Bei jeweils 10 Suchvorgängen wird die Seite neunmal gefunden, einmal wird sie nicht gefunden (Fehlseitenbedingung), so dass eine Ersetzung erfolgen muss.

Das i-te Verfahren habe dabei m_i Kosteneinheiten w an Wartungskosten und pro Suchvorgang s_i Kosteneinheiten c an Suchkosten.

Jede Tabelle oder Datenstruktur habe $n = 2^{10}$ Einträge. Zur Aufrechterhaltug der Tabellensortierung nehmen wir an, dass n/2 Einträge verschoben werden müssen zu n/2 Kosteneinheiten w.

Bei LRU-Reihenfolge nehmen wir an, dass eine Seite, die sich im Puffer befindet, mit n/10 Kosteneinheiten c gefunden wird. Beim Hash-Verfahren sollen im Mittel 1,5 Vergleiche anfallen. Bestimmen Sie die Kosten C_i, die für jeweils 10 Suchvorgänge mit einer Ersetzung anfallen.

Schätzen Sie die anfallenden Kostenanteile in geeigneter Weise ab!

Welches Verfahren gewinnt, wenn w = 5 * c gesetzt wird?

Ändern sich diese prinzipiellen Aussagen, wenn die mittlere Lokalität nicht 90% (10/1), sondern x% ((x+y)/y) beträgt? Diskutieren Sie x = y.

Aufgabe 5: Analyse des *Paging*-Verhaltens 145

DB-Puffer im Hauptspeicher dienen dem DBMS zur Verarbeitung der Daten. Falls auf eine Datenbankseite zugegriffen wird, stellt die Speicherverwaltung zunächst fest, ob sich die betreffende Seite bereits in einem DB-Puffer befindet. Im Erfolgsfall wird dem entsprechenden Modul sofort der Zugriff gewährt. Andernfalls hat die Speicherverwaltung die angeforderte Seite aus der Datenbank vom externen Speicher zu holen und in einem DB-Puffer bereitzustellen. Dazu muss gegebenenfalls eine vorhandene Seite ersetzt werden. In Betriebssystemen mit virtuellem Speicher sind die DB-Puffer im virtuellen Adressraum, der seitenwechselbar ist, angeordnet. Die Speicherverwaltung des Datenbanksystems kontrolliert unabhängig vom Betriebssystem die DB-Puffer, während das Betriebssystem eigene Ersetzungsstrategien für den gesamten virtuellen Adressraum, also auch für die DB-Puffer einsetzt. Dabei tritt das Problem des sogenannten *Double Paging* auf.

Die Datenbank besteht aus D Seiten; die DB-Puffer können N Seiten aufnehmen. Im Hauptspeicher seien für die virtuellen DB-Pufferseiten M reale Seiten zugeordnet. Es gelte $M < N < D$.

Falls ein Zugriff zur Datenbank nötig ist, sprechen wir von einem *Database Fault* (DBF). Falls sich die angeforderte Seite im virtuellen Speicher befindet, aber ein Zugriff zur *Paging Area* nötig ist, sprechen wir von einem *Page Fault* (PF). Entsprechend werden die virtuellen DB-Puffer durch einen *Buffer-Replacement*-Algorithmus (BRA) und die realen Hauptspeicherseiten durch einen *Memory-Replacement*-Algorithmus (MRA) verwaltet.

- Unter der Voraussetzung, dass eine zufällige Zuweisung von Datenbankseiten zum virtuellen DB-Puffer und von virtuellen Pufferseiten zum Realspeicher geschieht, ist die Wahrscheinlichkeit für einen *Database Fault* (DBF) und für einen *Page Fault* zu berechnen.
- Stellen Sie ein einfaches Modell zur Berechnung der E/A-Kosten pro Datenbankaufruf als Funktion von D, N und M auf. Führen sie dabei einem konstanten Kostenfaktor für das Kostenverhältnis PF und DBF ein.