Politechnika Wrocławska

Dziedzina: Dziedzina nauk inżynieryjno-technicznych
Dyscyplina: informatyka techniczna i telekomunikacja

Rozprawa Doktorska

INDEKSOWANIE BAZ DANYCH NA NOWOCZESNYCH TYPACH PAMIĘCI

Mgr inż. Michał Kukowski

promotor: prof. dr hab. Jacek Cichoń
promotor pomocniczy: dr inż. Wojciech Macyna

Słowa kluczowe: bazy danych, flash, ssd, pcm, indeksowanie danych

Wrocław 2023

Streszczenie

Niniejsza praca poświęcona jest zagadnieniu indeksowania baz danych, z naciskiem na wykorzystanie różnorodnych, nowoczesnych typów pamięci, takich jak pojedyncze kości flash, dyski SSD oraz pamięć zmiennofazowa PCM. W dzisiejszych czasach indeks to nie tylko prosta struktura danych wyposażona w podstawowe procedury; to często duży, rozbudowany system, który uwzględnia wiele czynników, m.in. charakterystykę pamięci. Efektywny sposób indeksowania rekordów nie tylko powinien minimalizować czas potrzebny na wykonanie kwerendy, ale także powinien wydłużać czas życia nowych nośników pamięci. W hurtowniach danych codziennie zapisuje się terabajty informacji. W tym kontekście, minimalizacja zużycia pamięci jest bardzo istotna nie tylko z punktu widzenia ekonomicznego, ale także z ekologicznego.

Pierwszym głównym celem tej pracy jest analiza popularnych algorytmów i systemów indeksowania stosowanych w silnikach baz danych. Drugim celem jest opracowanie i implementacja nowych metod oraz struktur danych przeznaczonych do indeksowania. Praca przedstawia kilka innowacyjnych algorytmów i systemów porządkowania danych, które usprawniają proces indeksowania rekordów. Każdy z proponowanych algorytmów został szczegółowo przeanalizowany pod kątem teoretycznej złożoności obliczeniowej oraz poprawności działania.

W rozdziale **5** omówiono algorytmy indeksujące rekordy na pamięci flash. Przedstawiono także nowy algorytm indeksowania FA-Tree (ang. Flash Aware Tree) [1], który osiągnął 20-krotnie lepszy czas obsługi kwerendy od popularnego drzewa B+, a także zużył 6-krotnie mniej pamięci.

W rozdziale **6** omówiono sposoby indeksowania danych zapisanych na dyskach SSD. Przedstawiono nowe algorytmy indeksowania danych, takie jak wierszowy indeks FALSM-Tree (ang. Flash Aware LSM-Tree) [2], który znacząco poprawia osiągi bazy danych podczas wstawiania wielu elementów do indeksu zapisanego na dysku SSD. Podczas eksperymentów FALSM-Tree osiągnął 6-krotnie lepszy czas oraz zapisał 6 razy mniej bajtów niż klasyczny indeks LSM. W tym samym rozdziale omówiono także całkiem nowy kolumnowy indeks CFT (ang. Columned FD-Tree) [3]. Mimo kolumnowego ułożenia, indeks CFT osiągał czas modyfikacji struktury mocno zbliżony do czasu wykonania modyfikacji przez oryginalne wierszowe podejście z wykorzystaniem drzewa FD, jednocześnie znacząco poprawił czas obsługi kwerend wyszukujących. Również w rozdziale **6** przedstawiono nowy mechanizm indeksowania częściowego LAM (ang. Lazy Adaptive Merging) [4]. System ten jest w pełni przystosowany do charakterystyki dysków SSD. Nie tylko osiągał 2-krotnie lepsze wyniki od algorytmu AM podczas tworzenia samego indeksu, ale także wykonywał kwerendy modyfikujące tabelę średnio o 15

W rozdziale **7** omówiono indeksowanie baz danych używających pamięci zmiennofazową PCM do przechowywania danych. Przedstawiono także nową strukturę danych BB+-Tree (ang. Buffered B+-Tree) oraz nowy sposób częściowego indeksowania dostosowanego

do pamięci PCM - PAM (ang. PCM Adaptive Merging) [5]. Wyniki eksperymentów pokazały ogromną przewagę nowego przedstawionego systemu nad oryginalnym algorytmem Adaptive Merging. Algorytm PAM stworzył indeks nawet 5-krotnie szybciej, modyfikując także 5-krotnie mniej pamięci, co znacząco wydłużyło żywotność tego nośnika pamięci.

Abstract

This doctoral thesis explores the field of database indexing across various contemporary memory types, such as single flash memory chips, solid-state drives (SSDs), and phase-change memory (PCM). In today's technological landscape, an index transcends the role of a mere data structure furnished with basic functionalities. It often represents a substantial, intricate system designed to accommodate numerous considerations, including the peculiarities of memory technologies. An effective indexing methodology should endeavor not only to minimize the execution time of queries but also to prolong the service life of emerging memory mediums. Given that data warehouses are tasked with processing terabytes of information daily, it is crucial to reduce memory consumption from both an economic and environmental standpoint.

The primary objective of this paper is to scrutinize prevalent algorithms and frameworks employed by database engines for record indexing. A secondary aim is to forge novel indexing strategies and to actualize the proposed data structures. The study introduces several innovative algorithms and data ordering schemes tailored for indexing records. Each algorithm undergoes a comprehensive evaluation, encompassing theoretical analyses of computational complexity and validations of correctness.

Chapter **5** delves into algorithms tailored for indexing records on flash memory. It unveils the FA-Tree (Flash Aware Tree) [1], a pioneering indexing algorithm that outperforms the widely used B+ tree by achieving a twentyfold enhancement in query processing speed while consuming six times less memory.

Chapter **6** examines methodologies for indexing data on SSDs. It introduces novel data indexing algorithms, including the row-based FALSM-Tree (Flash Aware LSM-Tree) [2], which markedly boosts database performance during the insertion of multiple elements into an SSD-stored index. Experimental results demonstrate that the FALSM-Tree delivers six times faster performance and requires six times less data writing compared to the traditional LSM index. This chapter also showcases a new column-based indexing model, the CFT (Columned FD-Tree) [3]. Despite its columnar structure, the CFT index maintains a modification speed on par with that of the original row-based approach employing the FD tree, while significantly improving search query efficiency. Additionally, a novel partial indexing scheme, LAM (Lazy Adaptive Merging) [4], tailored to SSD characteristics, is presented. This method not only doubles the efficiency of the index creation compared to the AM algorithm but also accelerates query modifications by an average of 15

Chapter **7** focuses on the use of PCM for database indexing. It introduces the BB+-Tree (Buffered B+-Tree) and a novel partial indexing technique, PAM (PCM Adaptive Merging) [5], which is optimized for PCM storage. Experimental findings reveal that the newly devised system substantially outperforms the traditional Adaptive Merging algorithm. Specifically, the PAM method is capable of creating an index up to five times

faster and modifies five times less memory, thereby significantly extending the memory medium's lifespan.

Spis treści

1 Wstęp **1**

2 Indeksowanie **5**
2.1 Indeksowanie wierszowe . . . 7
2.2 Indeksowanie kolumnowe . . . 8
2.3 Indeksowanie częściowe . . . 11

3 Charakterystyka pamięci trwałych **15**
3.1 Zarządzanie dyskami z poziomu systemu operacyjnego Linux . . . 16
3.2 Dysk twardy (HDD) . . . 18
3.3 Pamięć typu flash . . . 19
3.3.1 Flash typu NOR . . . 20
3.3.2 Flash typu NAND . . . 21
3.3.3 FTL . . . 21
3.4 SSD . . . 23
3.5 PCM . . . 25
3.6 Podsumowanie . . . 28

4 Platforma testowa **29**
4.1 Symulator SIPS . . . 29
4.2 Zestawy kwerend . . . 35
4.2.1 Podstawowy zestaw kwerend . . . 37
4.2.2 Rozszerzony zestaw kwerend . . . 37
4.3 Testowanie indeksów częściowych . . . 39

5 Algorytmy indeksowania na pamięci flash **41**
5.1 Wykorzystywanie pamięci flash w urządzeniach wbudowanych . . . 41
5.2 Flash Aware Tree . . . 42
5.2.1 Struktura FA-Tree . . . 43
5.2.2 Procedury indeksu FA-Tree . . . 45
5.2.3 Opis algorytmów . . . 46
5.2.4 Analiza kosztu wstawiania rekordu . . . 47
5.2.5 Eksperymenty . . . 52

6 Algorytmy indeksowania na dyskach SSD **63**
6.1 Indeksowanie wierszowe . . . 63
6.2 Struktura LSM . . . 65
6.3 Flash Aware LSM-Tree . . . 66
6.3.1 Struktura FALSM . . . 66
6.3.2 Procedury indeksu FALSM . . . 69

6.3.3 Algorytm dodawanie zbiorczego . . . 73
6.3.4 Eksperymenty . . . 75
6.4 Indeksowanie kolumnowe . . . 85
6.5 Columned FD-Tree . . . 86
6.5.1 Struktura CF-Tree . . . 86
6.5.2 Procedury indeksu CF-Tree . . . 90
6.5.3 Opis algorytmów . . . 92
6.5.4 Dowód poprawności algorytmu scalania atrybutów . . . 93
6.5.5 Analiza kosztów algorytmów . . . 96
6.5.6 Eksperymenty . . . 101
6.6 Indeksowanie częściowe . . . 116
6.7 System Lazy Adaptive Merging . . . 117
6.7.1 Struktura LAM . . . 118
6.7.2 Procedury systemu LAM . . . 122
6.7.3 Opis algorytmów . . . 124
6.7.4 Wybór Indeksu dla systemu LAM . . . 126
6.7.5 Eksperymenty . . . 128

7 Algorytmy indeksowania na pamięci PCM 141
7.1 Indeksowanie wierszowe . . . 142
7.2 Indeksowanie kolumnowe . . . 145
7.3 Indeksowanie częściowe . . . 146
7.3.1 System PAM (PCM Adaptive Merging) . . . 147
7.3.2 Procedury systemu PAM . . . 150
7.3.3 Opis algorytmów . . . 151
7.3.4 Wybór Indeksu dla systemu PAM . . . 152
7.3.5 Nowy indeks BB+ (buffered B+-Tree) . . . 153
7.3.6 Eksperymenty . . . 157

8 Zakończenie 167
8.1 Podsumowanie . . . 167
8.2 Dalsze kierunki badań . . . 168

Bibliografia 171

Wstęp

Praca poświęcona jest indeksowaniu baz danych na nowoczesnych typach pamięci. Za nowoczesny model pamięci w tej pracy uznajemy: pojedyncze kości flash, dyski SSD oraz pamięć zmiennofazową PCM. Sposób przechowywania danych oraz zarządzania nimi podczas indeksowania, jak również przenoszenie, defragmentacja czy buforowanie, musi uwzględniać ograniczenia wynikające z funkcjonowania nośnika pamięci, na której zapisane są rekordy. Dotyczy to w szczególności ograniczeń liczby możliwych usunięć danych z komórek pamięci, a także asymetrii pomiędzy kosztami zapisu i odczytu. Efektywny sposób indeksowania rekordów nie tylko powinien minimalizować czas potrzebny na wykonanie kwerendy, ale także powinien minimalizować zużycie nowoczesnych modeli pamięci [6], [7]. Algorytm indeksowania musi być także bezpieczny. Oznacza to, że wszystkie dane, które są w nim zapisane, muszą zostać nienaruszone podczas awarii systemu. Do przechowywania baz danych zazwyczaj używa się nośników trwałych, takich jak dyski HDD, SSD czy PCM. Gdy odłączymy zasilanie, dane nie ulegają degradacji. Jednak algorytmy indeksujące, bardzo często, aby przyspieszyć operacje wykonywane na strukturze danych, używają różnych technik buforowania, zbierania statystyk i potrzebnych metadanych [8]. Informacje te zapisywane są w ulotnej pamięci RAM, a więc w chwili awarii systemu, dane te są tracone. Zatem bardzo ważnym aspektem takich algorytmów jest zdolność przywrócenia stanu przed awarią (ang. *crash recovery*), co zazwyczaj realizowane jest przez odtwarzanie wszelkich utraconych informacji na podstawie innych informacji zapisanych na dysku.

W hurtowniach danych z setkami tabel i tysiącami kolumn istnieje wiele sposobów na indeksowanie bazy danych. Zbyt mała liczba indeksów powoduje kosztowne skany nieposortowanych partii danych za każdym razem, zaś zbyt duża ich liczba powoduje czasowy narzut na aktualizacje podczas dodawania i usuwania rekordów. Ciężko jest idealnie zaprojektować bazę danych, znajdując idealną kombinację indeksów, ponieważ nie jesteśmy w stanie przewidzieć wszystkich potrzeb użytkownika [9]. Obecnie stosuje się 3 główne podejścia do indeksowania rekordów: wierszowe, kolumnowe i częściowe. Wybór techniki indeksowania zależy od wielu czynników: pamięci, na której przechowywane są dane, liczby kolumn w rekordzie, wielkości bazy danych oraz dominującego wzorca kwerend [10], [11], [12]. Wierszowy sposób indeksowania zapisuje rekordy obok siebie, jeden po drugim. Ten sposób zapisu wykorzystywany jest, gdy w użyciu bazy danych przeważają modyfikacje tabeli. Każdy zapis wykonuje pojedynczą operację na dysku, ponieważ cały rekord przechowywany jest w ciągłym obszarze pamięci.

Kolumnowe podejście stosuje się wtedy, gdy rekord składa się z wielu kolumn, ale tylko kilka z nich jest używanych w jednej kwerendzie. W takim przypadku, pojedynczy rekord jest zapisany w wielu miejscach, a kolumny kolejnych rekordów przechowywane są w ciągłych obszarach pamięci. Tak więc, jeśli chcemy wczytać wybrane kolumny dla wielu kluczy, to odczytujemy tylko potrzebne segmenty dysku. Niestety, gdy chcemy zapisać nowy rekord, zamiast pojedynczego zapisu, mamy tyle zapisów, ile kolumn w rekordzie,

ponieważ każda kolumna to osobny obszar fizycznej pamięci. Zatem ten sposób przechowywania danych używa się wtedy, gdy odczyty są dominującą operacją wykonywaną na tabeli. Trzeci sposób, indeksowanie częściowe, jest najmłodszym sposobem porządkowania danych. Polega on na indeksowaniu tylko tej części rekordów, która jest potrzebna lub będzie potrzebna w najbliższym czasie. Idealnie sprawdza się w ogromnych bazach danych, w których na co dzień korzysta się z niewielkiego podzbioru rekordów. Aby zminimalizować czasowy narzut wynikający z utrzymania indeksu, rekordy dodawane i usuwane są z indeksu automatycznie, w zależności od ich przydatności. Zazwyczaj nowe dane są wstawiane natychmiastowo do indeksu, a dane, o które poprosił użytkownik w kwerendzie, gdy nie były w indeksie, są kopiowane do niego, aby ich ponowny odczyt był o wiele szybszy. Cały mechanizm częściowego indeksowania można porównać do buforowania danych w pamięci podręcznej komputera (ang. *cache memory*).

Celem pracy jest analiza dotychczasowych algorytmów i struktur danych wykorzystywanych do indeksowania relacyjnych baz danych, opracowanie nowych metod indeksowania oraz implementacja zaproponowanych struktur danych. W pracy zaproponowano kilka nowych algorytmów i systemów porządkowania danych realizujących indeksowanie rekordów.

Struktura pracy jest następująca. W rozdziale **2** przeanalizujemy dokładnie różne sposoby indeksowania baz danych, ich wady i zalety, a także spróbujemy sformułować problemy do rozwiązania wynikające z przechowywania różnych typów indeksów na nowoczesnych modelach pamięci trwałej.

W rozdziale **3** omówimy funkcjonowanie pamięci flash, dysków HDD, SSD oraz PCM, a także sposoby zarządzania tymi pamięciami dostępne z poziomu systemu operacyjnego Linux. W tym rozdziale również przeprowadzimy dogłębną analizę charakterystyk każdej z poszczególnych pamięci oraz jej wpływ na funkcjonowanie indeksów pracujących na tych pamięciach.

W rozdziale **4** omówimy całą platformę testową, która została zaimplementowana z myślą o wprowadzeniu jednolitego, deterministycznego środowiska do przeprowadzenia wszystkich potrzebnych eksperymentów umieszczonych w tej pracy. W skład platformy testowej wchodzi nowatorski symulator SIPS (ang. *Storage and Index Performance Simulator*), który nie tylko jest odpowiedzialny za symulację modeli pamięci, ale także integruje algorytmy indeksujące bazę danych z symulowanym modelem pamięci. Dzięki temu program potrafi monitorować stan dysków, indeksów oraz kwerend, a co za tym idzie, dostarczać wszelkie niezbędne dane do przeprowadzenia analizy każdego z przedstawionych w tej pracy algorytmów. Platforma testowa zawiera także 3 zestawy kwerend przygotowane na podstawie najbardziej popularnych i rzetelnych zestawów eksperymentalnych, jak TPC-C [13] i TPC-H [14]. Wszystkie kwerendy testowe zostały dostosowane do warunków symulatora oraz implementacji algorytmów indeksujących, które nie są zintegrowane z silnikiem baz danych, ponieważ celem eksperymentów jest sprawdzenie wydajności samego sposobu indeksowania, a nie wpływu optymalizacji silnika baz danych na efektywność wykonywania kwerend.

W rozdziale **5** omówimy algorytmy indeksujące dane przechowywane na pojedynczych kościach flash. Najczęściej takie bazy danych stosowane są w urządzeniach wbudowanych (ang. *embedded devices*) i w tzw. urządzeniach internetu rzeczy (ang. *IoT - Internet of Things*), które ze względu na koszty produkcji używają kości flash zamiast dysków SSD. W tym samym rozdziale przedstawimy nowy algorytm indeksowania na

pamięci flash FA-Tree (ang. *Flash Aware Tree*) [1], przeanalizujemy jego działanie oraz omówimy wyniki eksperymentów przeprowadzonych z użyciem platformy testowej. Zaproponowana struktura danych FA-Tree osiągnęła nawet 20-krotnie lepszy czas obsługi kwerend zorientowanych na modyfikacje bazy od klasycznego indeksu opartego na drzewie B+. Jednocześnie indeks FA-Tree zużył 50-krotnie mniej pamięci od drzewa B+. Nowa struktura została również porównana z popularnym indeksem LSM-Tree, który ze względu na duże zużycie pamięci operacyjnej nie jest często wykorzystywany w urządzeniach wbudowanych z ograniczonymi zasobami sprzętowymi (pamięć operacyjna, moc obliczeniowa).

W rozdziale **6** omówimy sposoby indeksowania danych zapisanych na dyskach SSD. Przedstawimy nowe algorytmy indeksowania danych, takie jak wierszowy indeks FALSM-Tree (ang. *Flash Aware LSM-Tree*) [2], czyli modyfikację drzewa LSM, w pełni dostosowaną do dysków SSD oraz wspierającą ważną w ostatnich czasach operację dodawania zbiorczego rekordów (ang. *bulkload*). Dzięki wprowadzeniu nowej metody dodawania rekordów, czas obsługi takiej kwerendy został zredukowany aż 6-krotnie względem oryginalnego indeksu LSM. Warto również wspomnieć, że testy na zestawach TPC-C wykazały, że nowy algorytm nadpisuje nawet 6-krotnie mniej pamięci, a więc znacząco wydłuża czas życia dysków SSD. W tym samym rozdziale omówimy także całkiem nowy kolumnowy indeks CF-Tree (ang. *Columned Flash Tree*) [3]. Indeks ten jest zbiorem struktur danych typu FD-Tree, połączonych ze sobą specjalnie zaprojektowanymi metadanymi. Dzięki zaproponowanemu algorytmowi scalania atrybutów w rekord, indeks CFT w czasie $O(\log n)$ jest w stanie dla danego atrybutu zwrócić odpowiadający mu inny atrybut lub cały rekord. Tak szybki algorytm scalający kolumny jest niezbędny, aby uznać nową metodę indeksowania za przydatną na obecnym rynku baz danych. W rozdziale **6** przedstawiono pełny dowód oraz analizę złożoności obliczeniowej algorytmu scalającego. Dodatkowo przeprowadzono liczne eksperymenty pokazujące realną przydatność nowej metody. Mimo kolumnowego ułożenia, indeks CFT osiąga czas modyfikacji struktury mocno zbliżony do czasu wykonania modyfikacji przez oryginalne wierszowe podejście z wykorzystaniem drzewa FD. Maksymalne odchylenie na niekorzyść kolumnowego indeksu wynosiło 6%. Oczywistym faktem jest, iż kolumnowe podejście znacznie szybciej obsługiwało kwerendy wyszukujące zakres kluczy, gdy użytkownik nie potrzebował wszystkich kolumn. Czas obsługi takiej kwerendy przez strukturę CFT malał liniowo wraz z malejącą liczbą bajtów, które musiał wczytać, by wykonać zapytanie od użytkownika. W tym samym rozdziale przedstawimy nowy mechanizm indeksowania częściowego LAM (ang. *Lazy Adaptive Merging*) [4]. Mimo, że nowy algorytm korzysta z idei tworzenia indeksu podobnej do oryginalnego Adaptive Merging [15], to jest to całkiem nowy system, w pełni przystosowany do charakterystyki dysków SSD. Zaproponowany system LAM buduje indeks 2 razy szybciej niż oryginalny algorytm AM. Dodatkowo obsługuje on o 15% szybciej wszelkie kwerendy modyfikujące tabelę, takie jak dodawanie lub usuwanie rekordów.

W rozdziale **7** omówimy indeksowanie baz danych używających pamięci zmiennofazowej PCM (ang. *Phase Change Memory*) do przechowywania danych. Przedstawimy także nową strukturę danych BB+-Tree (ang. *Buffered B+-Tree*) oraz nowy sposób częściowego indeksowania dostosowanego do pamięci PCM - PAM (ang. *PCM Adaptive Merging*) [5]. Tak jak we wcześniej wymienionych rozdziałach, przeanalizujemy także eksperymenty przeprowadzone na nowych metodach indeksowania. Wyniki pokazują ogromną przewagę nowego przedstawionego systemu nad oryginalnym algorytmem Adaptive Merging. Algorytm PAM tworzy indeks nawet 5-krotnie szybciej, modyfikując także 5-krotnie mniej

pamięci, co znacząco wydłuży żywotność nośnika danych. W ostatnim rozdziale 8 podsumujemy całą pracę oraz przedstawimy możliwe dalsze kierunki badań.

Indeksowanie

W tym rozdziale omówimy kilka sposobów indeksowania, przedstawimy wady i zalety każdego z podejść oraz spróbujemy przeanalizować ich działanie w kontekście nowoczesnych modeli pamięci.

Indeks to uporządkowana struktura danych, która umożliwia szybki dostęp do rekordu o wybranym kluczu. Indeksy są zakładane na pojedynczych atrybutach lub zbiorze atrybutów. Wybór leży po stronie administratora baz danych i zależny jest od przewidywanego wzorca kwerend. Tabela, która nie jest posortowana po atrybucie znajdującym się w kwerendzie, musi zostać wczytana w całości (ang. *scan*). Taka operacja ma liniową złożoność obliczeniową, a jej koszt, używając notacji asymptotycznej, zapisujemy jako $\mathrm{O}(n)$, gdzie n to liczba rekordów w tabeli. Aby przyspieszyć ten proces wykorzystuje się indeksowanie. Na zbiorze rekordów stosuje się porządek liniowy, a więc zapisuje się je w taki sposób, aby szybciej znaleźć rekord o wybranym kluczu. Gdy w kwerendzie użytkownik poda atrybut, po którym posortowana jest tabela, zamiast pełnego skanowania, wystarczy użyć struktury danych indeksu i w odpowiedni sposób znaleźć potrzebny rekord (ang. *seek*). Indeksy najczęściej realizowane są jako struktury drzewiaste, a złożoność obliczeniowa takiego wyszukiwania wynosi $\mathrm{O}(\log n)$. Wynika to z faktu, że aby znaleźć szukany rekord należy przejść po drzewie od korzenia do liści [16].

Indeksy dzielą się na kilka grup [17]. Z punktu widzenia charakterystyki atrybutu indeksowego wyróżnia się indeks podstawowy (ang. *primary index*) oraz indeks wtórny (ang. *secondary index*). Indeks podstawowy jest założony na atrybucie, który jest kluczem tabeli. Taki atrybut musi przyjmować wartości unikalne w obrębie wszystkich wartości danej tabeli. Tabela może posiadać tylko jeden indeks podstawowy, ponieważ istnieje tylko jeden klucz. Indeks wtórny założony jest na dowolnym atrybucie tabeli, który nie jest kluczem głównym. W przeciwieństwie do indeksu podstawowego, wartości w indeksie wtórnym mogą się powtarzać. Tabela może posiadać wiele indeksów wtórnych. Należy jednak pamiętać, że każdy indeks powiększa koszt manipulacji rekordów [18]. Wstawianie oraz usuwanie danych z tabeli wydłuża się wraz z każdym posiadanym indeksem, ponieważ zawartość każdego indeksu musi odzwierciedlać nowy stan tabeli.

Biorąc pod uwagę liczbę kluczy w indeksie względem wszystkich rekordów w tabeli, indeksy dzielimy na gęste (ang. *dense index*) i rzadkie (ang. *sparse index*). Rysunek 2.1 ilustruje różnicę między tymi typami indeksów. Indeks gęsty zawiera w swojej strukturze klucz do każdego rekordu w tabeli, podczas gdy indeks rzadki obejmuje tylko wybrane klucze. Dzięki posiadaniu wszystkich kluczy, indeks gęsty umożliwia szybsze wyszukiwanie niż indeks rzadki, ponieważ umożliwia on dokładne określenie pozycji szukanego rekordu. Zwykle indeks zapisuje klucz oraz wskaźnik do lokalizacji rekordu na dysku, co sprawia, że przeszukiwanie indeksu jest znacznie szybsze niż przeglądanie fizycznych rekordów. W przypadku indeksu rzadkiego, w celu oszczędności pamięci przeznaczonej na dodatkowy indeks, rekordy są grupowane w wirtualne bloki o określonej wielkości (na załączonym

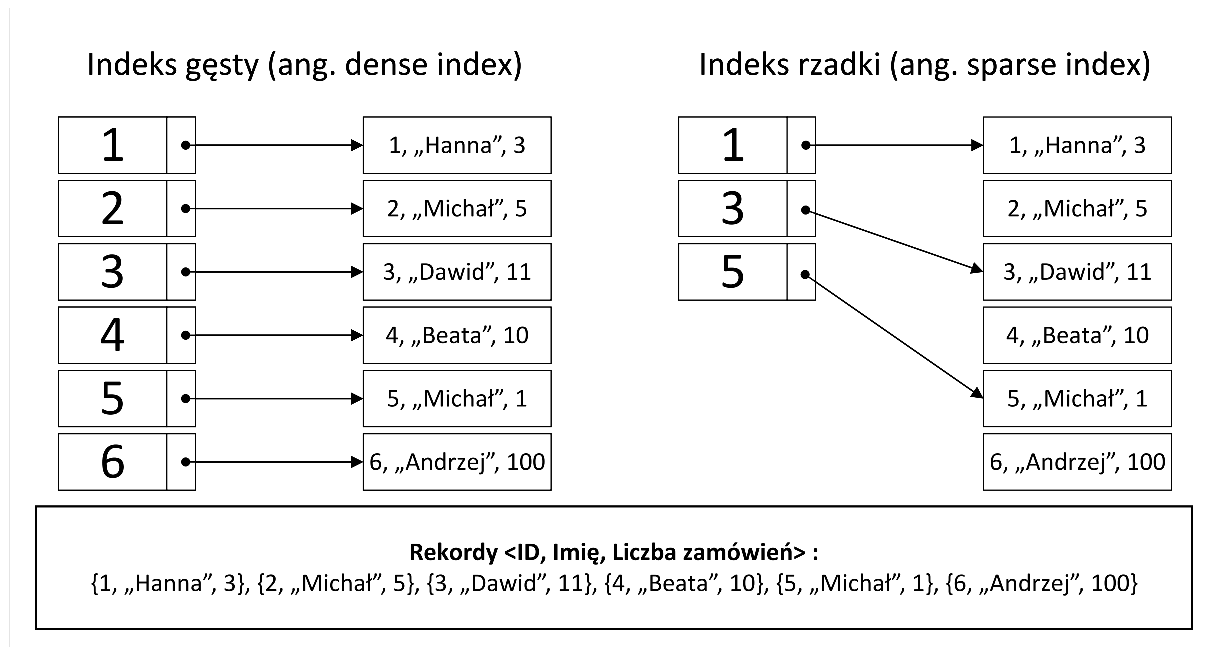

Rysunek 2.1: Indeksy gęste i rzadkie

rysunku wirtualny blok ma pojemność dwóch rekordów), a do indeksu dodawany jest pierwszy klucz z każdego bloku. Aby znaleźć rekord za pomocą takiego indeksu, najpierw lokalizujemy odpowiedni blok, a następnie wczytujemy cały wirtualny blok z dysku. Proces wyszukiwania w indeksie rzadkim jest wolniejszy niż w gęstym. Jednocześnie indeks rzadki zużywa mniej pamięci i wymaga mniej czasu na aktualizacje podczas wstawiania lub usuwania danych, ponieważ często wystarcza modyfikacja samego wirtualnego bloku, nie wprowadzając zmian w strukturze indeksu.

Ze względu na położenie rekordów w pamięci wyróżniamy indeksy zgrupowane (ang. *clustered index*) oraz niezgrupowane (ang. *nonclustered index*). Rysunek 2.2 przedstawia oba wymienione typy indeksów. Indeks zgrupowany zapisuje rekordy w strukturze indeksu, a więc może istnieć tylko jeden taki indeks dla tabeli. Jeśli chcemy stworzyć kolejny indeks zgrupowany, musimy skopiować tabelę i dopiero na kopii ułożyć rekordy fizycznie według innego porządku. Zaletą takiego indeksu jest bardzo szybki dostęp do wyszukiwanych danych, gdyż nie musimy wykonywać dwóch operacji na dysku, a więc odczytu strony, na której znajduje się klucz oraz odczytu fizycznego rekordu znajdującego się w miejscu wskazywanym przez wskaźnik zapisany obok klucza. Tak zapisany indeks jest o wiele większy niż normalny, ponieważ zawiera w sobie całą tabelę. Pamiętajmy jednak, że koszty operacji wykonywanych na indeksie skalują się wraz z liczbą rekordów w indeksie a nie wielkością indeksu. W związku z tym taki zapis nie wpływa negatywnie na pracę indeksu. Indeks niezgrupowany obok klucza zapisuje tylko wskaźnik do adresu, gdzie fizycznie zapisany jest rekord. Takich indeksów można mieć kilka dla danej tabeli w zależności od potrzeb. Indeksy te charakteryzują się nieco wolniejszym czasem dostępu do rekordu, mniejszym kosztem aktualizacji struktury oraz mniejszym zużyciem pamięci od indeksów zgrupowanych.

W tej pracy najbardziej skupimy się na typach indeksowania podzielonych ze względu na sposób ułożenia danych w pamięci. Rozważane będzie ułożenie rekordów wierszowo i kolumnowo. W pracy poruszymy także nowy sposób indeksowania - indeksowanie częściowe,

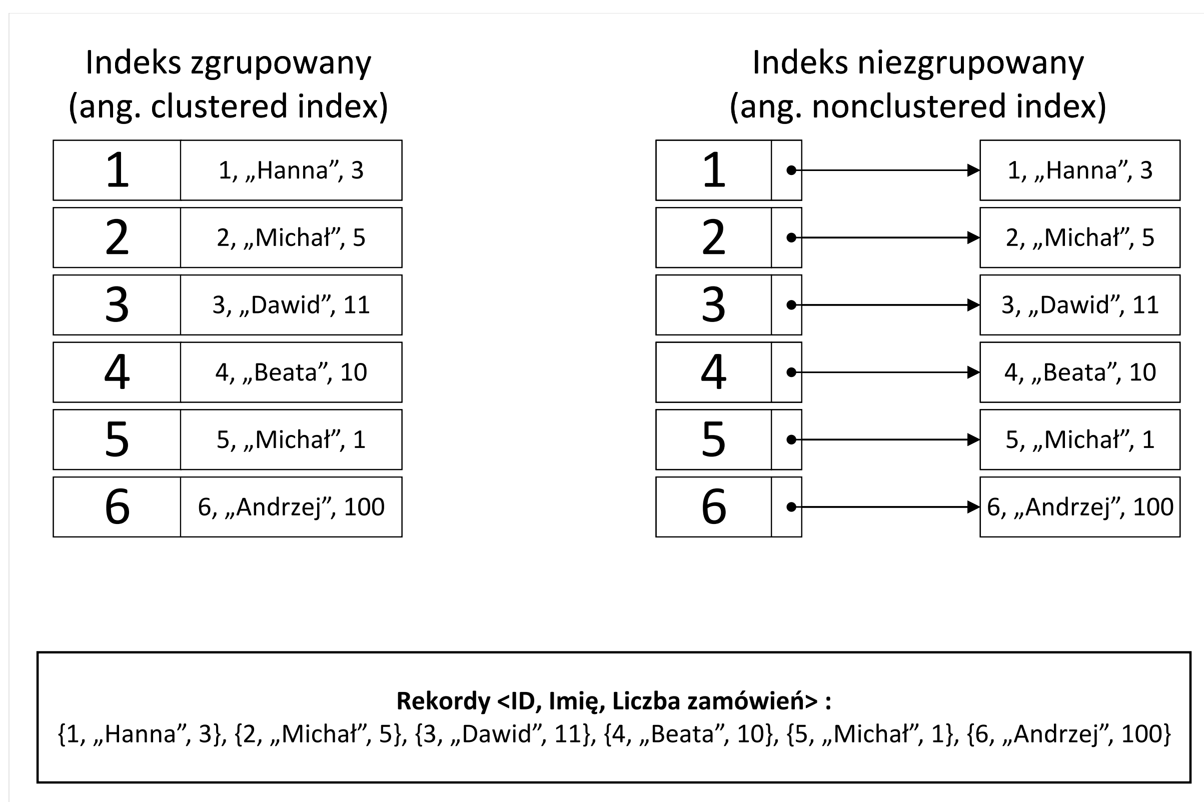

Rysunek 2.2: Indeksy zgrupowane i niezgrupowane

jako pewien pomysł automatyzacji wyboru danych do uporządkowania. Wymienione powyżej trzy typy indeksów, ich sposób działania oraz ich wady i zalety, przedstawimy w dalszej części tego rozdziału.

2.1 Indeksowanie wierszowe

Indeksy zapisujące rekordy wierszowo to najstarszy rodzaj omawianych w tej pracy indeksów. Zaletą tego typu indeksów jest prostota implementacji (o wiele łatwiej stworzyć indeks wierszowy niż kolumnowy) oraz szybkość utrzymania porządku na takim indeksie. Cały rekord zapisany jest w ciągłym obszarze pamięci. Tak więc, dodawanie nowego rekordu, usuwanie starego, jak i modyfikacje, wykonują pojedyncze operacje na dysku. Z drugiej strony, taki rodzaj indeksowania posiada kilka wad. Po pierwsze, wierszowe ułożenie rekordów nie sprzyja kompresji. Im mniejsza dziedzina, tym łatwiej zastosować kompresję danych. Zatem, idealnym ułożeniem byłaby agregacja podobnych wartości z tych samych kolumn. Dodatkowo, zazwyczaj tabela składa się z kilku lub nawet kilkunastu atrybutów. Większość kwerend nie będzie potrzebowała ich wszystkich. Mimo to, ze względu na ułożenie w pamięci, musimy wczytać cały rekord, niezależnie od zapytania.

Za najprostszą formę indeksu wierszowego możemy uznać posortowaną tablicę. Koszt wyszukiwania w takiej tablicy jest równy $O(\log n)$, ponieważ można użyć wyszukiwania binarnego. Największą wadą takiego podejścia jest koszt wstawiania i usuwania danych, który jest równy $O(n)$. Taka forma indeksu jest bardzo nieefektywna, dlatego nie używa się jej w bazach danych. Pierwszym nietrywialnym indeksem był ISAM [19] (ang. *Indexed Sequential Access Method*). ISAM to dwupoziomowy indeks statyczny używany do prze-

chowywania rekordów na dyskach HDD. Poziom pierwszy indeksuje cylindry. Dane na tym poziomie zawierają poszukiwany klucz i adres do ścieżki dyskowej. Poziom drugi indeksuje ścieżki. ISAM jest indeksem statycznym, co oznacza, że nie posiada mechanizmów modyfikowania struktury. Usunięcie rekordu powoduje powstanie pustego miejsca na dysku, a nowe rekordy są dodawane do bloków przepełnienia (nowych miejsc w pamięci). W konsekwencji, struktura jest bardzo nieefektywna pamięciowo oraz może być stosowana właściwie tylko do dysków HDD. W [20] opracowano wirtualną maszynę współpracującą ze strukturą ISAM - VSAM, dzięki czemu indeks ISAM można zaaplikować na dowolny sprzęt i dysk. VSAM niestety nie rozwiązał reszty problemów oryginalnego pomysłu. Dopiero wprowadzenie indeksów opartych na drzewach B+ [21] przyspieszyło wszystkie operacje wykonywane na indeksach. Drzewo B+ to samoorganizujące się drzewo posiadające ustaloną liczbę węzłów potomnych, często nazywanych potocznie dziećmi węzła. Taka struktura zapewnia logarytmiczny czas dostępu do dowolnego klucza oraz logarytmiczne dodawanie i usuwanie rekordów. Drzewo B+ jest najpopularniejszym indeksem baz danych zapisanych na dysku HDD. Jego strukturę można łatwo dopasować do parametrów dysku. Ustalając rozmiar węzła drzewa na rozmiar sektora dysku HDD osiągamy bardzo dobrą wydajność spowodowaną precyzyjnym buforowaniem obszarów dysku w pamięci RAM komputera. Kolejną strukturą danych, która jest bardzo często wykorzystywana, to Filtr Bloom'a [22]. Filtr Bloom'a jest probabilistyczną strukturą danych, która jest bardzo efektywna pamięciowo i w czasie stałym potrafi określić przynależność rekordu do zbioru. Wadą jest prawdopodobieństwo pojawienia się fałszywie błędnej odpowiedzi pozytywnej. Oznacza to, że jeśli filtr określi obecność elementu w zbiorze, informacja ta może być nieprawdziwa. Jednak gdy filtr stwierdzi, że elementu w zbiorze nie ma, to mamy pewność, że tak jest. Struktura ta wykorzystywana jest do redukcji zapytań do indeksu, które są kosztowne, ponieważ wczytują dane prosto z dysku.

Ze względu na odmienną charakterystykę każdej z pamięci, obecnie używa się wielu struktur danych indeksujących rekordy wierszowo. Gdy tabela zapisana jest w pamięci operacyjnej RAM, używa się drzewa czerwono czarnego [23], drzewa AVL [24] lub drzewa TRIE [25] [26]. Do popularnych indeksów działających efektywnie na pamięci flash i dyskach SSD należą między innymi FD [27] i LA [28]. Każde z nich w inny sposób redukuje liczbę zapisów oraz wymazań na dyskach SSD, co czyni je o wiele lepszym wyborem od drzewa B+ w kontekście pracy na pamięci flash. Z kolei do pracy na pamięci PCM często wybiera się jedną z modyfikacji drzewa B+ ([29], [30], [31]), które kosztem dodatkowych odczytów, redukują liczbę wolnych zapisów.

2.2 Indeksowanie kolumnowe

W ostatnich latach kolumnowe przechowywanie danych w bazie stało się coraz bardziej popularne. Wynika to z faktu, że większość zapytań do baz danych nie potrzebuje danych ze wszystkich kolumn. Zatem, w wierszowej implementacji marnujemy odczyty z dysku na wczytanie całego wiersza i wydobycie tylko potrzebnych atrybutów. W podejściu kolumnowym na jednej stronie w pamięci przetrzymywane są wartości pojedynczej kolumny dla kilku rekordów, dzięki czemu podczas wyszukiwania wczytujemy tylko potrzebne informacje. Niestety, kolumnowe podejście jest wolniejsze podczas zapisywania nowych rekordów, ponieważ musimy zapisać podzielony rekord na kolumny w kilku miejscach na dysku [10], [11], [12].

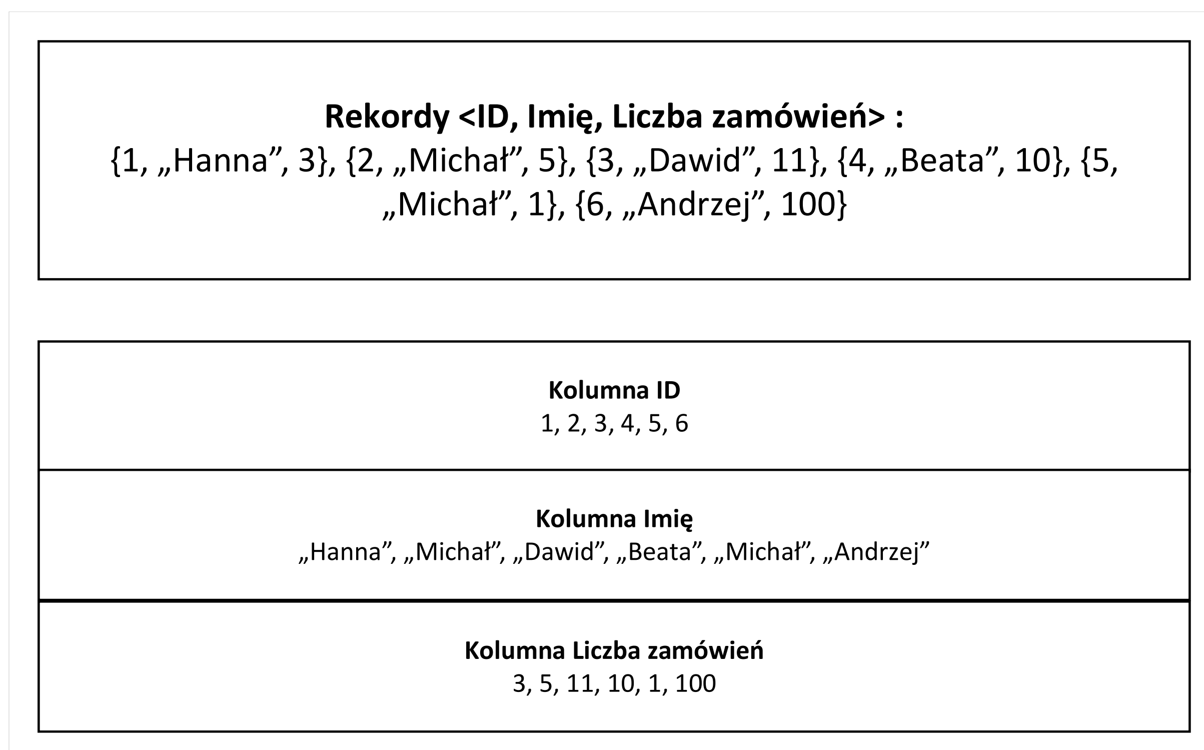

Rysunek 2.3: Kolumnowe ułożenie rekordów

Rysunek 2.3 przedstawia przykład kolumnowego ułożenia danych. Każda kolumna zapisana jest w osobnym miejscu w pamięci. Gdy użytkownik poprosi w kwerendzie o zestaw liczby zamówień dla każdego klienta, chcąc zobaczyć tylko ich imiona, wtedy z dysku odczytamy tylko potrzebne strony. Sektor dysku, na którym zapisane są ID użytkowników, nie zostanie wczytany podczas tego procesu, co przyspieszy obsługę takiej kwerendy. Przechowywanie kolumnowe niesie ze sobą również trudność w scalaniu wszystkich atrybutów w rekord. Dlatego struktura danych indeksu musi, prócz standardowych operacji, zawierać także operacje scalania, która dla danego atrybutu (niekoniecznie klucza) zwróci cały rekord. Jest to najtrudniejsza operacja do zaprojektowania ze względu na nietrywialne struktury danych użyte do indeksowania, np. drzewo B+. Sytuacja na rysunku jest o wiele prostsza. Atrybut danego rekordu jest na tym samym indeksie tablicy. Zatem, znając pozycję jednego atrybutu, możemy określić położenie innych atrybutów należących do danego rekordu i scalić je ze sobą. Taki algorytm został opracowany w jednej z pierwszych struktur zaprojektowanych do kolumnowego ułożenia tabeli DSM [32] (ang. *Decomposition Storage Model*). Struktura DSM ma jednak wiele wad. Przede wszystkim jest nieposortowana. Tak więc, gdy chcemy dodać kolejny rekord do DSM, musimy pobrać z niego wszystkie wartości atrybutów, a następnie każdą z nich dodać na koniec listy związanej z odpowiednią kolumną. Dzięki temu zawsze mamy pewność, że atrybuty tego samego rekordu są umieszczane na tej samej pozycji listy. Niestety, z tego powodu każda kwerenda musi wykonać pełen skan potrzebnych kolumn.

Za pierwszy silnik w pełni wspierający kolumnowy zapis tabeli uznaje się C-Store [33]. Silnik ten zapisywał tabelę w dwóch osobnych sekcjach: sekcji zorientowanej na szybkie odczyty, która była zapisana kolumnowo, oraz sekcji zoptymalizowanej pod częste zapisy i aktualizacje danych. Druga sekcja zapisana była wierszowo, aby umożliwić szybkie wsta-

wianie i usuwanie rekordów. C-Store sam decydował, kiedy przenieść dane z jednej sekcji do drugiej. Od tamtego czasu zaproponowano wiele nowych technik usprawniających algorytmy stworzone w C-Store [34], [35], [36], [37]. Dodano także wiele nowych usprawnień, między innymi takie, które skupiają się na równoległym odczycie kilku kolumn [38], [39], [40] oraz na kompresji danych w obrębie każdej z nich [41], [42], [43], [44], [45], [46]. Obecnie, ze względu na wiele zastosowań i możliwych optymalizacji, ułożenie kolumnowe tabeli jest bardzo popularne. Większość nowoczesnych silników baz danych wspiera ten sposób zapisu tabeli. Należą do nich między innymi: MonetDB [47], PostgreSQL [48], VectorWise [49], Druid [50] i eXtremeDB [51].

Najpopularniejszą strukturą danych używaną obecnie do indeksowania rekordów zapisanych kolumnowo jest PDT [52] (ang. *Positional Delta Tree*). Indeks ten wykorzystywany jest w bazach danych zapisanych w pamięci operacyjnej komputera (ang. *in-memory database*) oraz na dyskach twardych HDD. PDT zapisuje różnice pomiędzy starymi wartościami a nowymi, dodatkowo zapisując pozycję, na której należy zaaplikować tę zmianę. Dzięki temu, że w strukturze zapisujemy nie tylko dane, ale także pozycje wszystkich danych dla każdego z atrybutów, możemy w łatwy sposób scalić je w cały rekord. Dodatkowo, technika zapisywania samych zmian służy do agregowania wielu z nich w jedną dużą zmianę (ang. *batch*).

Kolumnowy zapis baz danych używa się najczęściej w sytuacjach, w których dominują odczyty. Zapis ten przyspiesza odczyt danych poprzez lepszą kompresję oraz skanowanie tylko potrzebnych kolumn, a co za tym idzie zmniejsza się liczba bajtów, jaką trzeba odczytać z dysku. Z drugiej strony, zapis nowego rekordu jest wolniejszy, ponieważ jeden rekord trzeba zapisać w kilku miejscach. Gdy baza danych zapisana jest w pamięci operacyjnej komputera lub na dysku HDD, zysk z odczytu przewyższa niewielką stratę na zapisie. Jednak nowoczesne pamięci takie jak flash, SSD czy PCM posiadają odmienną charakterystykę. Zapis na tych pamięciach jest kilkukrotnie wolniejszy niż odczyt, a więc klasyczne struktury danych nie osiągają dobrych rezultatów w ułożeniu kolumnowym. Algorytm musi nie tylko spełniać wszystkie wymogi kolumnowego zapisu, takie jak posiadanie szybkiej operacji scalania, ale musi także wykorzystywać techniki przyspieszające zapis danych adekwatne do używanych pamięci. Dobrymi przykładami jest system PAX [53], który polega na wirtualnym podziale strony dysku SSD na mini strony. Każda mini strona zawiera tylko dane jednej kolumny. Mamy zatem ułożenie kolumnowe kilku rekordów w obrębie jednej fizycznej strony. Taki mechanizm nie zmniejsza liczby bajtów wczytywanych z dysku, gdyż najmniejszą jednostką, na której pracujemy, jest strona, ale przyspiesza pracę procesora ze względu na lepsze wykorzystanie pamięci procesora (ang. *cache memory*). Kolejnym przykładem jest struktura FBDSM [54] (ang. *Flash-based Decomposition Storage Model*), która dostosowała oryginalny pomysł DSM [32] do pamięci flash. Zamiast jednej tabeli, są dwie. Pierwsza to tabela główna PT, w której zapisywane są dane dodane do tabeli, które nie zostały usunięte ani zmienione. Druga tabela to tabela LT, która zawiera wszystkie zmiany na tabeli PT, a więc: usunięcia rekordów oraz zmianę wartości. Dzięki temu nadpisywanie danych jest odroczone w czasie oraz realizowane później za pomocą paczek danych, co jest o wiele szybsze w przypadku pamięci flash. Struktura ta jednak nie rozwiązuje głównego problemu, czyli braku relacji porządku. Ponadto tabela nie jest posortowana po kluczu, a po czasie, aby zachować pozycje atrybutów dla danego rekordu, co umożliwia szybkie scalanie kolumn w jeden pełny rekord.

2.3 Indeksowanie częściowe

Stworzenie idealnego zbioru indeksów, zawierającego wszystkie potrzebne indeksy o wszystkich potrzebnych atrybutach do obsługi każdej z kwerend, to bardzo trudne zadanie, przed którym stają administratorzy baz danych. Nie da się przewidzieć wszystkich możliwych kwerend, jakie użytkownik końcowy będzie chciał wykonać na tabelach. Z tego więc powodu dąży się do automatyzacji procesu tworzenia indeksów [55], [56], [57]. Stosuje się podejścia, które próbują dostosowywać porządek bazy danych i kolejne indeksy wraz ze zmianą kwerend. Kolumny, po których musimy sortować dane podczas zapytania, są monitorowane i analizowane. Dzięki temu silnik bazy stwierdza, czy potrzebny jest nowy indeks lub czy istniejący przestał być już używany. Wtedy następuje reorganizacja, tzn. dodawany jest nowy indeks poprzez kopiowanie tabeli i sortowanie jej po innym kluczu lub usuwany jest stary indeks. Takie podejście ma kilka wad. Po pierwsze, czas potrzebny na analizę może być zbyt długi. Gdy silnik zacznie tworzyć indeks, wzorzec kwerendy może ulec zmianie, przez co nie zostanie on użyty, a czas na jego tworzenie zostanie zmarnowany. Po drugie, sam czas tworzenia indeksu jest ogromny, ponieważ trzeba posortować całą tabelę, często niemieszczącą się w pamięci RAM.

W przeciągu kilku ostatnich lat pojawiło się kolejne podejście do automatyzacji procesu indeksowania. Tym razem nie skupiano się na doborze atrybutów, jakie powinny być uporządkowane, ale wybraniu podzbioru tabeli, która jest na tyle często używana, że opłaca się uporządkować ten podzbiór i stworzyć na nim częściowy indeks. W [58], [59] zaproponowano *Indeks Cracking* jako nową metodę automatycznego, iteracyjnego tworzenia indeksu. W wyniku działania kwerendy, część tabeli jest reorganizowana, aby dostosować się do wzorca obecnego zapytania. Proces ten próbuje zamortyzować koszt tworzenia indeksu, dzieląc go na wiele części. Z początku czas będzie większy niż zwykły skan, ponieważ musimy dodać kilka operacji potrzebnych na powiększenie posortowanego zbioru. Jednak z czasem będzie się on zmniejszał, ponieważ będziemy mogli korzystać z częściowego indeksu. Gdy cały proces się zakończy, otrzymamy w pełni posortowaną tabelę. *Indeks Cracking* używa metody podziału danych na partycje (ang. *partition*) względem elementów z zakresu zapytania i działa podobnie do sortowania szybkiego (ang. *quicksort*) [60]. Za każdym razem partycja, która zawiera klucze z zakresu zapytania, dzielona jest na kolejne tak, aby jedna z nich zawierała tylko elementy mniejsze od zakresu kwerendy, druga wartości z danego zakresu, a trzecia dane o kluczach większych niż zakres. Zatem w większości przypadków stworzone zostaną dwie nowe partycje.

Rysunek 2.4 przedstawia trzy etapy tego procesu. Każda litera obrazuje wartość nowego klucza rekordu, który może się powtarzać, ponieważ indeksy częściowe są zazwyczaj indeksami wtórnymi. Górny prostokąt pokazuje układ danych przy inicjalizacji procesu zaraz po skopiowaniu. Środkowy prostokąt pokazuje partycje powstałe w wyniku zapytania od d do g. Elementami podziału są zatem wartości d i g. Pierwsza partycja zawiera wartości mniejsze od d, środkowa partycja zawiera elementy, które należało wczytać, czyli pomiędzy d i g, a ostatnia partycja zawiera pozostałe rekordy, czyli te z kluczami większymi niż g. Warto zwrócić uwagę, że partycje nie są posortowane wewnętrznie, a kolejność elementów dodawana do partycji jest taka sama jak ich wczytania. Ponieważ stan początkowy zawierał (idąc od lewej strony) rekordy $\{b, c, a, a\}$, to właśnie w takiej kolejności zostały umieszczone w partycji pierwszej. Ostatni stan przedstawia sytuację stworzoną przez kwerendę po zakresie i - j. Pierwsze dwie partycje są rozłączne z nowym zakresem wyszukiwania, a więc nie zostały zmienione podczas wyszukiwania. Ostatnia partycja zo-

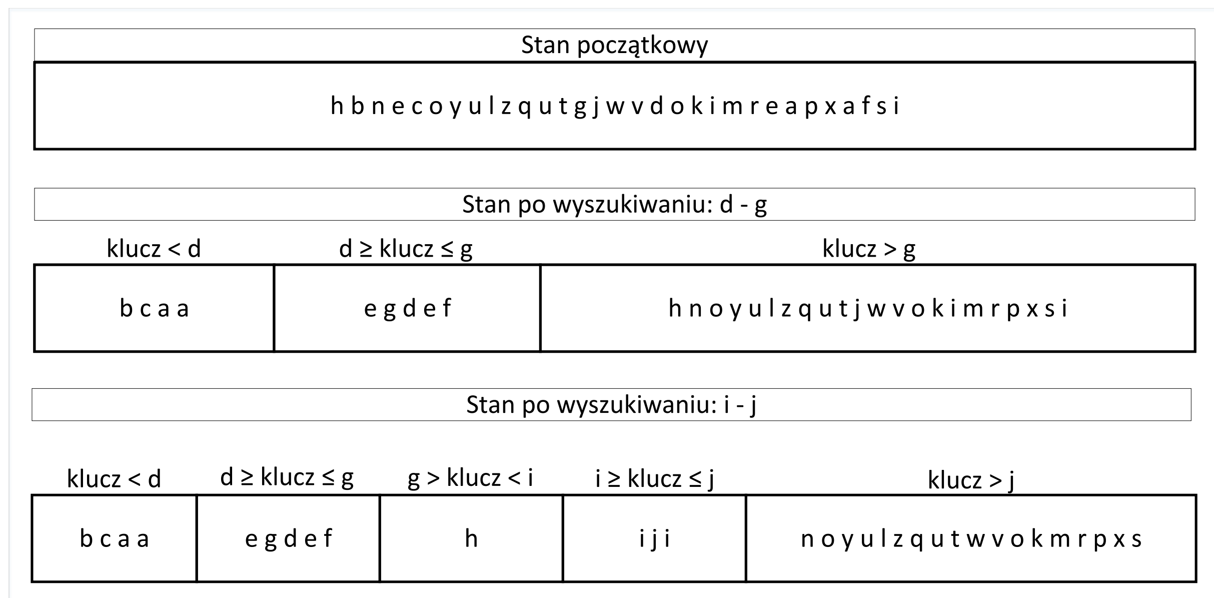

Rysunek 2.4: Indeks Cracking

stała podzielona na tych samych zasadach co poprzednio, czyli na zbiory o elementach mniejszych od i, elementach pomiędzy i a j oraz na elementy większe niż j.

Chociaż Indeks Cracking jest bardzo dobrym podejściem, gdy z góry nie znamy wszystkich potrzebnych kluczy, to jednak metoda ta ma kilka wad. Przede wszystkim częste reorganizacje na małych częściach tabeli są stosunkowo wolne w przypadku, gdy używamy pamięci blokowej takiej jak dyski HDD lub SSD. Po drugie, szybkość tworzenia indeksu zależna jest od wzorca kwerend. Tak jak w sortowaniu szybkim, złożoność obliczeniowa zależna jest od wyboru elementu rozdzielającego partycję (ang. *pivot*). I chociaż istnieją algorytmy wyboru, to jednak nie możemy ich tutaj zastosować, ponieważ punkt podziału jest ustalony przez użytkownika (krańce zakresu kwerendy). Trzecią wadą jest dość długi czas potrzebny na osiągnięcie takich samych efektów jak pełny indeks. Niestety, w najgorszym przypadku, gdy nigdy nie będziemy mogli skorzystać z partycji (gdy element rozdzielający partycję był zawsze najmniejszym lub największym elementem tabeli), metoda ta będzie gorsza niż zwykły skan. Dodatkowo ciężko jest dodać nowe dane do indeksu, który już jest częściowo posortowany, tak aby nie zaburzyć partycji. Wiele optymalizacji zostało zaproponowanych, aby zwiększyć przydatność algorytmu Indeks Cracking. W [61] dostosowano metodę do czysto-kolumnowego zapisu tabeli. W [62] wprowadzono lepszy algorytm wyboru elementu rozdzielającego, który nie zależy tylko i wyłącznie od kluczy wyszukiwania, dzięki czemu zmniejszona została liczba niepotrzebnych reorganizacji. W [63] dodano algorytmy wstawiania, aktualizacji oraz usuwania danych podczas reorganizacji partycji.

Kolejna metoda automatycznego tworzenia indeksu podczas kwerend została zaproponowana w [15]. Adaptive Merging, w przeciwieństwie do Indeks Cracking, korzysta z algorytmu scalania posortowanych list, tak jak sortowanie przez scalanie (ang. *mergesort*) [64]. Gdy po raz pierwszy musimy wyszukać elementy, biorąc pod uwagę wartości z danej kolumny, kopiujemy tabelę, sortujemy, wczytując tyle danych na raz, ile mieści się w buforze. Następnie sortujemy wartości w obrębie danej partycji. W kolejnych zapytaniach będziemy usuwać dane z posortowanych partycji oraz ze zbioru wczytanych danych tworzyć nowe partycje. W ten sposób uzyskamy po pewnym czasie zbiór partycji, które nie

tylko są posortowane wewnętrznie, ale także tworzą posortowany ciąg. W takim momencie możemy scalić je w jedną partycję, otrzymując pełny indeks. Partycje mogą być przetrzymywane w strukturze Partition B+-Tree [65]. W takim przypadku operacje na partycjach wykonywane są podobnie do zwykłego B drzewa [21]. Właśnie dlatego, podczas całego procesu, mamy wymierne korzyści z posiadania partycji. Podczas zapytania możemy równolegle odczytywać miejsca zapisu partycji, a w niej, za pomocą wyszukiwania binarnego (ang. *binary search*), znaleźć potrzebne dane.

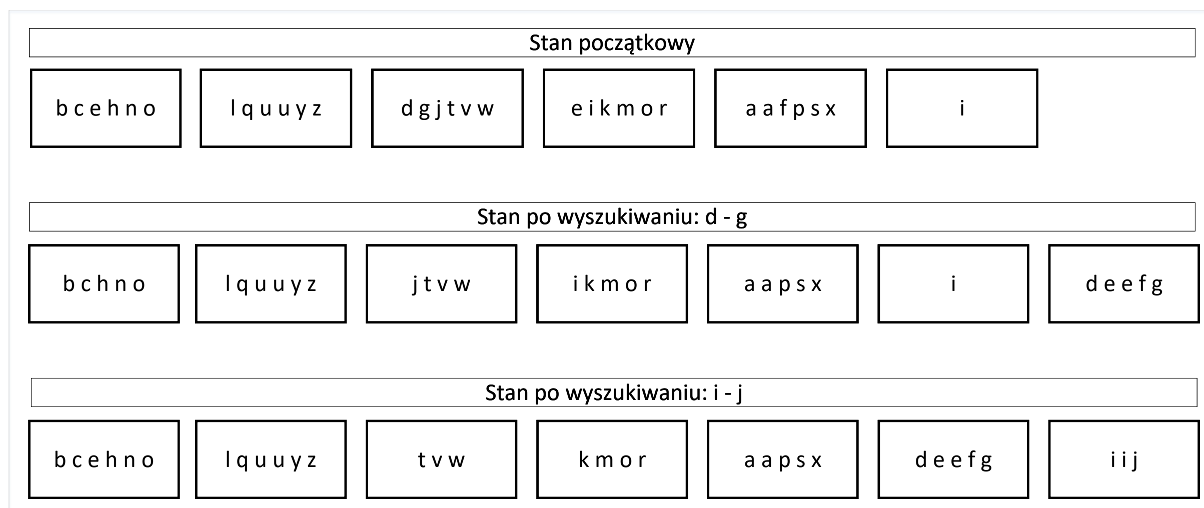

Rysunek 2.5: Adaptive Merging

Rysunek 2.5 przedstawia trzy kroki tego procesu. Aby zobrazować różnice pomiędzy tym podejściem a Indeks Cracking, dane oraz kwerendy pozostały takie same jak w poprzednim przykładzie. Zatem górny prostokąt pokazuje układ danych przy inicjalizacji procesu zaraz po skopiowaniu i sortowaniu paczek danych. Każda partycja posiada swoją maksymalną pojemność (ang. *capacity*) wynikającą wprost z rozmiaru bufora, w którym można posortować dane. W naszym przykładzie pojemność partycji została ustawiona na 6 rekordów. Zatem podczas inicjalizacji dane są kopiowane, dzielone na 6-elementowe zbiory, sortowane, a następnie zapisywane do nowych partycji. Drugi stan obrazuje sytuację powstałą w wyniku zapytania *d - g*. Każda partycja, która może zawierać dane potrzebne do wyniku kwerendy, jest skanowana, następnie rekordy z kluczami o wartościach z przedziału *d - g* są usuwane z poszczególnych partycji, sortowane w buforze, a następnie zapisane do całkiem nowej partycji. Ostatni stan powstał w wyniku kwerendy *f - j*. System powtórzył wszystkie kroki wymienione wcześniej, usunął potrzebne dane, posortował je i zapisał do nowej partycji. Warto zwrócić uwagę, że do bufora trafił ostatni rekord z partycji numer 6, która zawierała tylko jeden element - *i*. Ponieważ w wyniku tej kwerendy partycja stała się pusta, została usunięta z systemu. Metoda ta dostosowana jest do pamięci blokowej: nie dzielimy partycji na wiele nowych, każde zapytanie tworzy jedną dodatkową partycję, która zapisywana jest sekwencyjnie. Łatwo zauważyć, że im większy bufor, tym mniej będzie partycji oraz szybciej stworzymy pełny indeks. Dlatego podczas pierwszego kroku można posortować większe zbiory używając sortowania dostosowanego do pamięci zewnętrznej [66]. W [67] przedstawiono zrównoleglone wersje algorytmu sortowania, scalania i odczytu danych z partycji. W [68], [69] połączono metodę z pewnymi procedurami wykonywanymi w Indeks Cracking. Niestety wymienione optymalizacje skupiają się na zapisie całej tabeli w pamięci RAM, przez co są nieoptymalne dla nowoczesnych typów pamięci takich jak flash, SSD czy PCM.

Charakterystyka pamięci trwałych

W tym rozdziale zajmiemy się analizą charakterystyk poszczególnych pamięci wykorzystywanych w dalszej części pracy. Bardzo istotną kwestią jest to, aby przy wyborze struktury do indeksowania bazy danych brać pod uwagę cechy pamięci, na której ta baza jest zapisana. Często występuje sytuacja, gdy struktura indeksu, który dobrze działa na klasycznych dyskach twardych HDD, nie będzie dobrym wyborem dla nowszych modeli dysków SSD. W takim przypadku wydajność indeksu wynika z braku wykorzystania pełnego potencjału używanej pamięci. Dobrym przykładem jest popularne drzewo B+ [70]. Jest to podstawowa struktura danych używana do przechowywania danych w sposób uporządkowany na dyskach HDD. Jednak ze względu na odmienne właściwości pamięci flash, drzewo B+ nie jest dobrym wyborem, gdy baza danych zapisana jest na dyskach SSD [71]. Różne pamięci posiadają różny czas dostępu do danych (ang. *latency*) oraz szybkość przetwarzania danych (ang. *bandwidth*) (zobacz tabelkę 3.1). Rysunek 3.1 przedstawia hierarchię pamięci - im pamięć jest wyżej w hierarchii, tym jest szybsza, ale jednocześnie droższa i o mniejszej pojemności.

Pamięć podręczna procesora (ang. *cache*) zbudowana jest często z SRAM (ang. *Static Random Access Memory*), która charakteryzuje się bardzo szybkim czasem dostępu. Procesor, zanim zacznie pracować na danych, musi wczytać potrzebne fragmenty pamięci (czy to RAM czy to PCM) do swojej pamięci podręcznej. Tak samo jak pamięć główna komputera, pamięć podręczna jest typem pamięci ulotnej. Dane zapisane w tych pamięciach ulegają degradacji przy wyłączeniu zasilania. Obie te pamięci są bajtowo adresowalne. Możemy odczytywać i zapisywać pojedyncze bajty. W celu optymalizacji, system dzieli pamięć podręczną na bloki (ang. *cache line*) zwykle wielkości 64 B, a pamięć RAM na strony o wielkości 4 KB. Pamięci te cechują się bardzo szybkim czasem dostępu i dużą przepustowością danych. Pamięć zmiennofazowa PCM (ang. *Phase Change Memory*) to nowy rodzaj pamięci trwałej. Dane umieszczone na niej nie ulegają zniszczeniu po odłączeniu zasilania, a więc nadaje się do przechowywania dużych ilości danych. PCM, tak samo jak pamięć RAM, jest bajtowo adresowalna. Cechuje się szybkim czasem dostępu i dużą asymetrią pomiędzy szybkością odczytu i zapisu. Pozostałe rodzaje pamięci przedstawione na rysunku (dyski SSD) to trwałe pamięci blokowe. Praca zarówno z dyskami

Pamięć	Czas dostępu (ns)	Szybkość odczytu (GB/s)	Szybkość zapisu (GB/s)
L1 CACHE	1,2	105	58
RAM	20	20	12
PCM	350	8,1	5,6
SSD M2 Gen 3.0	5000	3,5	3,2
SSD SATA	$3{,}6 * 10^5$	0,55	0,5
HDD	$4{,}17 * 10^6$	0,16	0,15

Tabela 3.1: Porównanie szybkości pamięci komputerowych

SSD, jak i dyskami HDD, jest trudniejsza niż w przypadku pamięci bajtowo adresowalnych, ponieważ najmniejszą jednostką dostępną dla użytkownika jest strona, w przypadku dysku SSD, oraz sektor w przypadku dysków HDD. Wielkość stron to zazwyczaj od 2 KB do 8 KB, a wielkość sektora to 512 B - 4096 B. Takie ograniczenie zmusza użytkownika do własnego buforowania danych i agregacji kilku operacji w jedną.

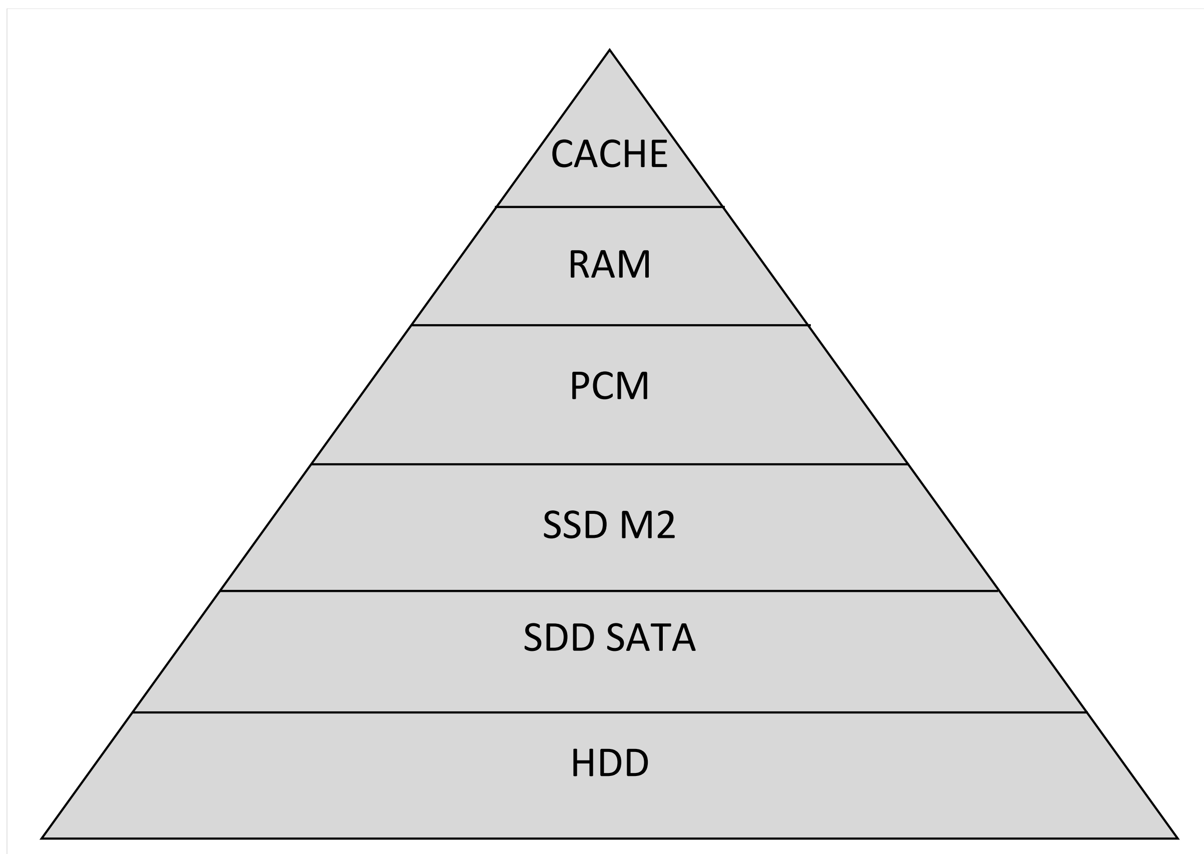

Rysunek 3.1: Hierarchia pamięci (względem szybkości)

3.1 Zarządzanie dyskami z poziomu systemu operacyjnego Linux

Aby w pełni zrozumieć wpływ charakterystyki pamięci na algorytmy indeksowania, musimy najpierw przeanalizować, jak system operacyjny zarządza dyskami oraz wykonuje na nich operacje. Wszystkie eksperymenty przedstawione w dalszej części tej pracy zostały przeprowadzone na systemie operacyjnym Linux. Dlatego też omówimy sobie działanie tego systemu. Linux jest systemem otwartym (ang. *open source*), oznacza to, że każdy z nas może obejrzeć i przeanalizować kod źródłowy jądra tego systemu [72].

System operacyjny Linux dostarcza nam kilkanaście dostępnych operacji na plikach [73], które bezpośrednio przekładają się na pracę z dyskami. Możemy je podzielić na następujące kategorie:

- **systemowe operacje WE/WY (ang. syscalls)**: open, write, read, flush, close
- **standardowe operacje WE/WY (ang. standard IO)**: fopen, fwrite, fread, fflush, fclose

- **wektorowe operacje WE/WY (ang. vectored IO)**: writev, readv,
- **operacje mapowania do pamięci (ang. memory-mapped IO)**: mmap, msync, munmap

Warto wspomnieć, że system operacyjny nie może wykonać operacji na pliku w inny sposób niż poprzez systemowe operacje, które wykonają odpowiedni kod jądra systemu operacyjnego. Wszystkie pozostałe operacje takie jak standardowe operacje wejścia/wyjścia, wektorowe operacje czy operacje mapowania wykonują pośrednio operacje systemowe z wykorzystaniem dodatkowego buforowania danych na poziomie aplikacji (biblioteki).

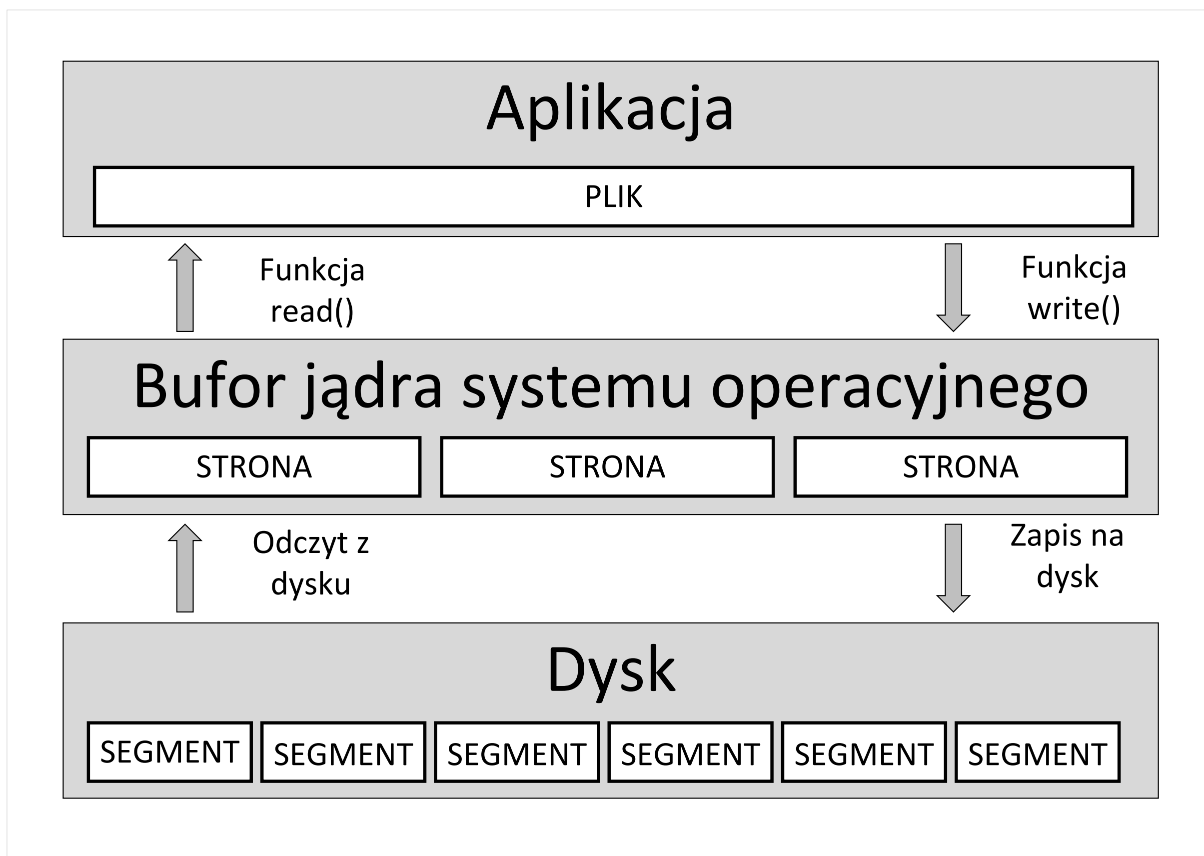

Rysunek 3.2: Operacje systemowe WE/WY

Jądro systemu operacyjnego, które przyjmuje operacje systemowe, nie wykonuje operacji `read()` i `write()` bezpośrednio na pliku (o ile nie dodamy takiej opcji). Zamiast tego dokonuje wewnętrznego buforowania danych (patrz rysunek 3.2). Bufor ten nazywamy *Page Cache*. Gdy chcemy wykonać operację na pliku lub jego fragmencie, jądro systemu sprawdza, czy sektor nie znajduje się w buforze. Gdy wykonujemy funkcję `read()`, najpierw sprawdzany jest bufor danych *Page Cache*. Jeśli dane znajdują się w buforze, potrzebne strony są od razu kopiowane do adresu podanego przez użytkownika aplikacji. Jednak gdy potrzebny sektor nie został znaleziony, system zgłasza *Page Fault*. W takim przypadku dane są wczytywane bezpośrednio z dysku, trafiają do bufora *Page Cache* i zostają skopiowane do aplikacji. Analogicznie postępujemy w przypadku funkcji `write()`. Dane od użytkownika trafiają do *Page Cache*. Niezależnie, czy segment znajdował się buforze czy też nie, operacja `write()` wpisuje zmienione dane fragmentu pliku jako strony *Page Cache*. Taka strona jest oznaczona jako *dirty* i oczekuje na wpisanie do dysku. Ope-

rację tę możemy wykonać manualnie za pomocą funkcji `flush()` lub `close()`. Możemy także czekać, aż system operacyjny sam podejmie decyzję o wyrzuceniu strony z bufora *Page Cache* i wpisaniu zmian w sektorach fizycznie na dysk.

Operacja `flush()` zostanie wywołana, gdy wolne miejsce w buforze *Page Cache* się skończy. Wtedy system operacyjny musi podjąć decyzję, które strony należy wyrzucić z bufora, a które zostawić. Istnieje kilka podejść do tego problemu. Najbardziej popularne to FIFO (ang. *First In First Out*), MRU (ang. *Most Recently Used*) i LRU (ang. *Last Recently Used*) [74]. Dodatkowo, gdy użytkownik aplikacji wie, w jaki sposób będzie pracować z plikiem, może ustawić odpowiednią strategię za pomocą funkcji `fadvise()`. Najczęściej używa się trzech opcji: *FADV_SEQUENTIAL*, *FADV_RANDOM* oraz *FADV_WILLNEED*. Pierwsza opcja sugeruje, że fragmenty plików będą odczytywane sekwencyjnie, jeden po drugim. W takiej sytuacji system może przygotować się na kolejne operacje i odczytywać segmenty dysku wcześniej (ang. *prefetch*). Druga opcja jest całkowitym przeciwieństwem pierwszej. Ponieważ wiemy, że zawsze będziemy odczytywać pojedyncze sektory dysku umieszczone w różnych miejscach, nie powinniśmy wykonywać operacji `prefetch()` i odczytywać więcej sektorów jednocześnie. Trzecia opcja mówi systemowi, że fragment pliku będzie potrzebny w najbliższej przyszłości i nie należy usuwać strony z *Page Cache*.

Pamiętajmy jednak, że jeśli niepoprawnie ustawimy strategię, czyli niezgodnie z faktycznym użyciem pliku, to możemy spowolnić działanie systemu. Dlatego należy korzystać z funkcji `fadvise()` tylko wtedy, gdy wiemy, w jaki sposób będziemy pracować na pliku. Dobrym przykładem wykorzystania funkcji `fadvise()` jest baza danych RocksDB. Dzięki komunikacji z jądrem systemu Linux, operacje na tej bazie zostały przyspieszone o kilkanaście procent [75].

Kolejną bardzo ważną opcją jest *O_DIRECT*. Możemy użyć tego parametru przy otwieraniu pliku za pomocą funkcji `open()`. Opcja ta wyłącza używanie bufora *Page Cache*. Oznacza to, że wszystkie operacje będą wykonywane bezpośrednio na dysku. Funkcja ta przydatna jest wtedy, gdy chcemy sami buforować dane z poziomu aplikacji. Metodę operacji na plikach z pominięciem struktury *Page Cache* wykorzystują MySQL [76] w silniku InnoDB [77] oraz PostgreSQL [48].

3.2 Dysk twardy (HDD)

Dysk twardy HDD (ang. *Hard Disk Drive*) to jeden z najbardziej popularnych rodzajów pamięci masowej wykorzystywanych na przełomie XX i XXI wieku. Podstawowym elementem twardego dysku jest znajdujący się w obudowie wirujący talerz lub zespół talerzy w przypadku nowoczesnych modeli. Konstrukcja dysku wykonana jest zazwyczaj z aluminium, a jego wnętrze pokrywa miękka warstwa zabezpieczająca, która zapobiega uszkodzeniom urządzenia oraz odpowiada za częściowe tłumienie hałasu. Talerz zamocowany jest na osi napędzanej silnikiem elektrycznym. Zapis i odczyt danych zapewniają głowice. Na każdą powierzchnię talerza przypada po jednej głowicy dla odczytu i dla zapisu. Umieszczone są one na elastycznych ramionach (tzw. pozycjonerach), które ustawiają głowice w odpowiedniej pozycji względem obracających się talerzy. Napęd ramion głowic realizowany jest najczęściej cewkami wzorowanymi na układach magnetodynamicznych stosowanych m.in. w głośnikach. Takie rozwiązanie umożliwia szybkie i precyzyjne umieszczanie głowic w zadanej pozycji, co skutkuje czasami dostępu do danych na pozio-

	512 B sektor	4 KB sektor
Dane użytkownika	512 B	4096 B
Kod korekcyjny (ECC)	50 B	100 B
Sumaryczna wielkość bloku	577 B	4211 B
Efektywność kodów korekcyjnych	0,887	0.973

Tabela 3.2: Porównanie formatów dysku HDD

mie kilkudziesięciu milisekund.

Razem z mechaniczną częścią dysku twardego znajduje się układ sterujący pracą dysku i przetwarzający dane. W skład układu wchodzą pamięć ROM (ang. *Read-only Memory*) zawierająca oprogramowanie proceduralne, interfejs SATA (ang. *Serial Advanced Technology Attachment*) oraz bufor danych zrealizowany za pomocą pamięci RAM.

Dysk twardy ze względu na swoją budowę jest urządzeniem blokowym. Oznacza to, że system operacyjny może odczytać lub zapisać jeden lub więcej sektorów. Sektor dzieli się na dwie części. Pierwsza część przechowuje dane i jest dostępna dla użytkownika. Druga część przechowuje kod korekcyjny ECC (ang. *Error Correcting Code*) i jest dostępna tylko z poziomu oprogramowania samego dysku. Wykorzystywana jest po to, aby korygować błędy podczas odczytu. W starszych modelach wielkość sektora wynosiła 512 B. Nowsze modele ze względu na większą pojemność dysku oraz na zwiększoną efektywność kodów korekcyjnych posiadają format AF [78] (ang. *Advanced Format*) cechujący się sektorami o wielkości 4 KB. Tabela 3.2 opisuje różnice pomiędzy formatami sektorów. Dyski HDD charakteryzują się o wiele wolniejszym odczytem i zapisem losowym niż sekwencyjnym. Wynika to z faktu, że zanim przeprowadzimy operację na sektorze danych, musimy poczekać, aż głowica przesunie się w odpowiednie miejsce i zacznie właściwą pracę. Zatem o wiele szybciej zapiszemy duży plik o wielkości 1 MB niż 10 plików o wielkości 100 KB. Mimo, że minimalną jednostką zapisu jest sektor, to podczas nadpisywania danych kontroler dysku sprawdzi bieżący stan i nadpisze tylko te bajty, które się zmieniły.

Podsumowując, dyski twarde HDD cechują się dużą pojemnością i stosunkowo niską ceną. Jednak ze względu na ich budowę (obrotowe talerze i głowice) jest to niezwykle delikatne i wrażliwe urządzenie. Podczas pracy z dyskami HDD należy zwrócić szczególną uwagę na tryb zapisu i odczytu. Sekwencyjne operacje są o wiele szybsze od losowych. Warto jednak nadmienić, że w przeciwieństwie do nowoczesnych dysków SSD, nadpisywanie danych można wykonać w miejscu (bez potrzeby usuwania bieżących danych w sektorze). Dzięki temu operacja ta jest tak samo szybka jak zwykły zapis. Właściwości tego nośnika pamięci masowej bardzo dobrze wykorzystuje drzewo B+ [79], które przeanalizujemy w kolejnych rozdziałach.

3.3 Pamięć typu flash

Pamięci typu flash są popularną odmianą pamięci nieulotnych EEPROM (ang. *Electrically Erasable Programmable Read-Only Memory*). Są obecne w niemal każdym urządzeniu elektronicznym – od kilkukilobajtowych pamięci przechowujących oprogramowanie sterowników (ang. *firmware*) przez kilkumegabajtowe magazyny w systemach wbudowanych, aż do dużych kart pamięci i dysków SSD (ang. *ang. Solid State Drive*) o pojemnościach dochodzących do kilkunastu terabajtów. Pamięć Flash została opracowana w labo-

	NOR	NAND
Maksymalna pojemność	niska	wysoka
Cena za bit	wysoka	niska
Niezawodność	bardzo wysoka	wysoka
Liczba błędów spowodowana degradacją	niska	średnia
Pobór energii w czasie pracy	duży	mały
Pobór energii w stanie spoczynku	mały	duży
Odczyt losowy	szybki	wolny
Zapis losowy	wolny	szybki
Kasowanie	bardzo wolne	wolne
Preferowane użycie	pamięć programu	pamięć masowa

Tabela 3.3: Porównanie typów pamięci flash NOR i NAND

ratoriach Toshiby przez Dr. Fujio Masuoka na początku lat '80 ubiegłego wieku. Zasada działania opiera się na przechowywaniu informacji w tranzystorach polowych MOSFET [80].

Flash jest pamięcią blokową. Operacje odczytu i zapisu można wykonać tylko na dużych ciągłych obszarach pamięci – stronach. Zazwyczaj strona ma pojemność 2 KB - 8 KB. Flash posiada również inne ograniczenia wynikające z architektury pamięci. Nie można zmienić wartości bitu z '0' na '1'. Aby nadpisać stronę należy wykonać operację usuwania (ang. *erase*). Operacja ta musi zostać wykonana na całym bloku. Blok zawiera od 32 do 128 stron. Z tego ograniczenia wynika ogromna asymetria pomiędzy szybkością losowego odczytu a losowego zapisu [81]. W przeciwieństwie do dysków twardych, pamięć flash nie posiada żadnych ruchomych części. Tak więc dostęp do dowolnego miejsca w pamięci jest tak samo szybki. Jednak operacja zapisu może wywołać kosztowne wymazanie całego bloku, które jest stosunkowo wolne. Z tego powodu wiele metod optymalizacji zostało zaproponowanych dla pamięci flash. Niektóre z nich skupiają się na częściowej zmianie architektury komórek pamięci [82], [83], [84]. Innym nurtem optymalizacji jest implementacja dodatkowego buforowania w warstwie sterowników [85], [86]. Ze względu na tak duże asymetrie pomiędzy szybkością odczytu i zapisu oraz odmienną od klasycznych dysków HDD charakterystykę, wiele klasycznych algorytmów i struktur danych zostało dostosowanych do tego rodzaju pamięci [87], [88], [89].

3.3.1 Flash typu NOR

Pamięć flash ze względu na wykorzystywaną architekturę bramek dzieli się na pamięć NAND i NOR. Tabelka 3.3 przedstawia główne różnice pomiędzy tymi typami. Pamięć NOR jest starszym typem pamięci flash. W konfiguracji obwodu wewnętrznego pamięci NOR, poszczególne komórki pamięci są połączone równolegle. W związku z tym dostęp do danych można uzyskać w losowej kolejności. Architektura pamięci NOR zapewnia wystarczającą liczbę linii adresowych do zmapowania całego zakresu pamięci. Daje to zaletę w postaci szybkiego losowego dostępu i krótkich czasów odczytu, co czyni ją idealną do zapisywania wykonywanego kodu dla niewielkich urządzeń wbudowanych. Główną wadą pamięci NOR jest większy rozmiar komórki pamięci, co skutkuje wyższym kosztem produkcji oraz niższymi prędkościami zapisu i usuwania danych z pamięci.

3.3.2 Flash typu NAND

W architekturze NAND bloki są połączone sekwencyjnie. Rozmiary bloków wynoszą od 8 KB do 32 KB i są mniejsze od bloków w architekturze NOR, które wynoszą 64 KB - 256 KB. To pozwala na zwiększenie prędkości odczytu, zapisu i usuwania. Ponadto urządzenia NAND są połączone za pomocą skomplikowanego szeregowo połączonego interfejsu, który może się różnić w zależności od producenta. Strukturalnie architektura NAND została zaprojektowana z myślą o zoptymalizowanej litografii o wysokiej gęstości, jako kompromis między możliwością dostępu swobodnego do mniejszych rozmiarów bloków. To sprawia, że pamięć NAND jest tańsza pod względem kosztu na wolumin. Teoretycznie gęstość bitów na komórkę pamięci NAND jest dwukrotnie większa niż w pamięci NOR.

Pamięć ta ma znacznie mniejszy rozmiar komórki i znacznie wyższe prędkości zapisu i usuwania danych w porównaniu do pamięci NOR. Do wad należy zaliczyć niższą prędkość odczytu oraz konieczność implementacji interfejsu pośredniczącego z uwagi na konieczność odwzorowania operacji wejścia/wyjścia. Interfejs ten nie pozwala na losowy dostęp do pamięci, co nieznacznie utrudnia jej obsługę. Należy zauważyć, że wykonanie kodu z pamięci NAND realizuje się poprzez kopiowanie zawartości pamięci do RAM. Jest to więc zasadnicza różnica w stosunku do pamięci NOR, gdzie kod wykonuje się bezpośrednio. Kolejną poważną wadą jest obecność uszkodzonych bloków. NAND zazwyczaj ma tylko 98% dobrych bitów, gdy jest dostarczany w stanie fabrycznym. Dodatkowo, w całym czasie eksploatacji modelu powstają dodatkowe uszkodzenia w blokach pamięci. Dlatego też konieczne jest wykorzystanie funkcji korekcji błędów (ECC) w urządzeniu, a także dedykowanego kontrolera, który eliminuje uszkodzone bloki z dalszej eksploatacji. Tabelka 3.4 przedstawia różnicę pomiędzy typami pamięci NAND: SLC (ang. *Single-Level Cell*), MLC (ang. *Multi-Level Cell*), TLC (ang. *Triple-Level Cell*) i QLC (ang. *Quad-Level Cell*).

Pamięć NAND z komórkami jednopoziomowymi (SLC) przechowuje tylko po 1 bicie informacji na komórkę. W efekcie komórka przechowuje wartość 0 lub 1, co pozwala szybciej zapisywać i odczytywać dane. Pamięć typu SLC zapewnia najlepszą wydajność i najwyższą wytrzymałość rzędu 10^5 cykli usuwania, przez co może służyć dłużej niż inne rodzaje pamięci NAND. Jednak niska gęstość zapisu danych sprawia, że SLC jest najdroższym rodzajem pamięci NAND i dlatego nie jest często stosowana w urządzeniach powszechnego użytku. Zwykle wykorzystuje się ją w serwerach i innych zastosowaniach przemysłowych, które wymagają szybkości i wytrzymałości. Pamięci wielopoziomowe typu MLC, TLC i QLC potrafią przechowywać odpowiednio 2, 3 i 4 bity w pojedynczej komórce. Większa gęstość danych utrudnia ich zapis i odczyt oraz zwiększa wrażliwość na błędy podczas zapisu. Z drugiej strony, takie wykorzystanie komórek pamięci zwiększa pojemność nośnika danych przy niewielkim koszcie. Pamięci wielopoziomowe ze względu na cenę stosuje się głównie w urządzeniach powszechnego użytku, w których wytrzymałość nośnika danych nie jest kluczowa.

3.3.3 FTL

Każda komórka pamięci flash ma ograniczoną żywotność. Operacja usuwania jest głównym czynnikiem powodującym niszczenie pamięci. Każdy blok może wytrzymać określoną liczbę cykli usuwania. Wytrzymałość pamięci zależy od jej typu. Pamięć SLC potrafi wytrzymać nawet 100 tys. usuwań, a pamięć QLC tylko tysiąc. System operacyjny posiada program (logger) do zapisywania wszystkich ważnych informacji z pamięci ulotnej

	SLC	MLC	TLC	QLC
Liczba cykli kasowania	>100000	>30000	<5000	1000
Czas przechowywania danych	>20lat	>10lat	<3lata	<1rok
Niezawodność	bardzo wysoka	wysoka	niska	niska
Degradacja danych	niska	średnia	wysoka	wysoka
Cena za 1 GB	wysoka	średnia	niska	niska
Pojemność	niska	średnia	wysoka	bardzo wysoka

Tabela 3.4: Porównanie typów pamięci flash NAND

RAM do pliku znajdującego się na pamięci masowej, np. flash. Dzięki temu w razie awarii systemu lub braku zasilania, informacje nie zostaną utracone. Gdyby wyłączyć wszystkie mechanizmy maksymalizujące żywotność pamięci flash w systemie operacyjnym, w ciągu sekundy niszczylibyśmy kilka bloków, zmniejszając tym samym pojemność naszej pamięci. Aby uniknąć takiej sytuacji wprowadzono mechanizm wirtualizacji pamięci flash. FTL (ang. *Flash Translation Layer*) jako mechanizm równomiernego rozłożenia pracy na całej pamięci flash został opatentowany w USA w 1995 [90]. Jego działanie opierało się na prostej wirtualizacji pamięci fizycznej.

Wyróżniamy dwa główne rodzaje systemów FTL. Pierwszy to mapowanie stronicowe. Każda fizyczna strona posiada swój odpowiednik logiczny w systemie FTL. Takie mapowanie zużywa sporo pamięci RAM (około 6MB RAM na każdy 1GB pamięci flash) [91]. Zaletą tego sposobu jest wręcz idealne rozłożenie pracy na całą pamięć flash, ponieważ posługujemy się w wirtualizacji minimalną jednostką dostępu do tej pamięci. Ze względu na duże zużycie pamięci RAM, co jest problemem w przypadku urządzeń wbudowanych, opracowano drugi sposób wirtualizacji – wirtualizację blokową [92]. FTL blokowy mapuje całe bloki fizyczne na sektory logiczne pamięci wirtualnej. Tablica mapująca jest stosunkowo mała (około 0.2MB RAM na każdy 1GB pamięci flash) [91]. Z drugiej strony wydajność tego systemu jest niższa od FTL stronicowego. Ze względu na wady i zalety każdej metody wprowadzono również metody hybrydowe [93], [94], [95], które wykorzystywane są w dużych skomplikowanych systemach operacyjnych jak Windows czy Linux.

Rysunek 3.3 przedstawia działanie prostego mechanizmu FTL stronicowego. Każda strona fizyczna (FS) posiada swój odpowiednik logiczny (LS) w tablicy mapowania FTL. Jeśli strona fizyczna jest uszkodzona (FS5 oraz FS9 zaznaczone ciemnym kolorem), zostaje przesunięta na koniec w tablicy mapowania i jest wyłączona z użytku. Dzięki temu dostępna pamięć ma ciągłe adresy logiczne. Gdy pracujemy na pliku, wykorzystujemy adresy logiczne zamiast fizycznych. Wydawać by się mogło, że plik jest zapisany w ciągłym miejscu pamięci, jednak zazwyczaj nie jest to prawdą. W rzeczywistości plik może być fizycznie rozmieszczony w kilku miejscach. Gdy nadpiszemy fragment pliku, wtedy FTL pod logiczny adres strony podstawi pierwszy wolny adres strony fizycznej. Wolna strona to fragment pamięci flash, która nie posiada żadnych danych użytkownika, a więc została w przeszłości skasowana i nie zapisana ponownie. Dzięki temu mapowanie FTL drastycznie zmniejsza liczbę wykonywanych operacji kasowania.

Gdybyśmy pisali po fragmencie LS1 10 razy, to musielibyśmy wywołać 10 razy operację kasowania na FS1 (ponieważ LS1=FS1) oraz wszystkich stronach znajdujących się w tym samym bloku. Ponieważ za każdym razem bierzemy nową stronę, która jest pusta, wykonujemy kasowanie tylko wtedy, gdy skończą nam się puste strony. Po każdym usuwa-

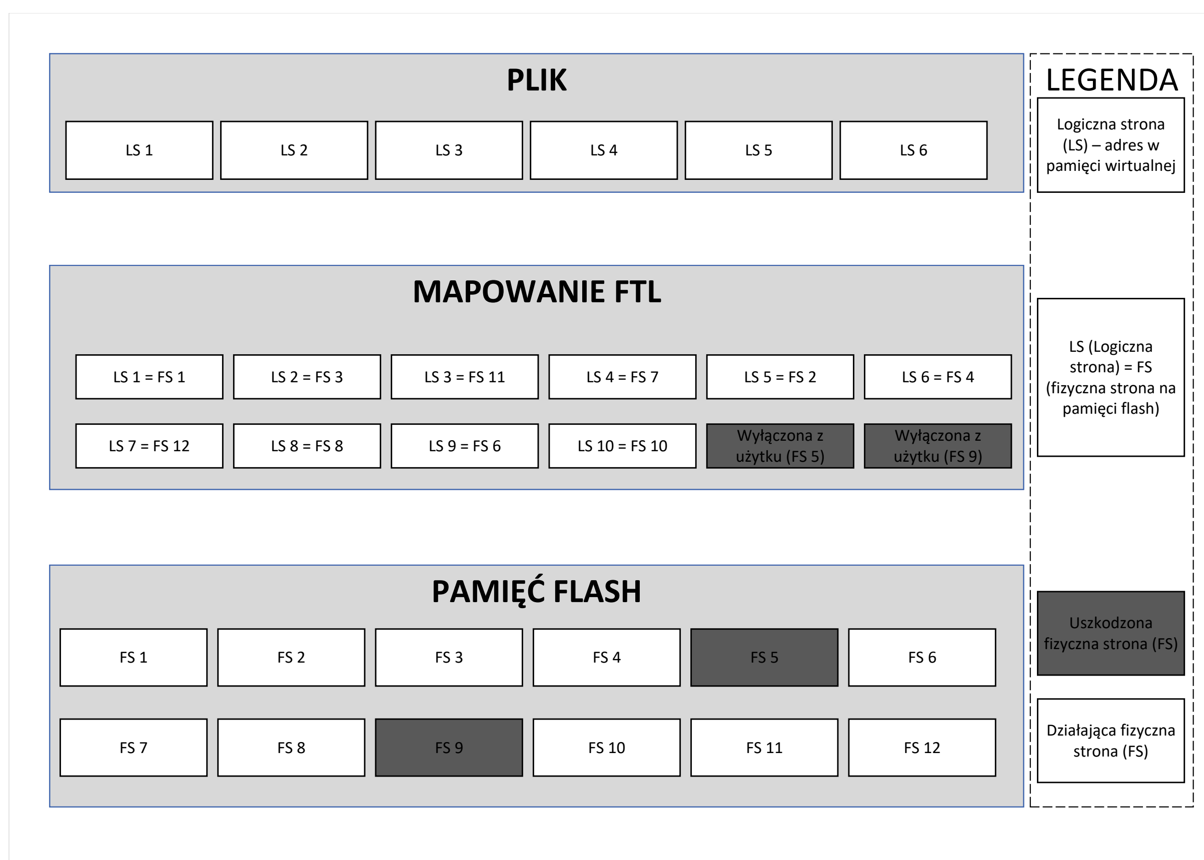

Rysunek 3.3: Działanie FTL

niu do puli pustych stron dodajemy nawet 32-64 nowe strony (czyli wszystkie skasowane strony należące do bloku), ponieważ tyle zazwyczaj znajduje się w pojedynczym bloku. W naszym przykładzie, zamiast 10 operacji wymazania, przeprowadzilibyśmy tylko jedną. Zatem taki prosty mechanizm wirtualizacji pamięci pozwala na przeprowadzenie nawet o 64 usunięć mniej.

Oprócz powyższej funkcjonalności, FTL musi równomiernie rozkładać strony do usuwania (ang. *wear-leveling*), tak aby nie zniszczyć szybko pamięci. Gdy mapowanie wybiera pustą stronę, bierze stronę znajdującą się w bloku o najmniejszym liczniku kasowań EC (ang. *erase counter*). Używanie licznika EC jest klasycznym podejściem, które jest wykorzystywane w większości implementacji FTL ze względu na jego dokładność [96], [97], [98], [99]. Alternatywą do przechowywania wartości EC na każdym bloku jest używanie estymowanych liczników [100], [101], które nie wymagają przechowywania fizycznie w bloku. Jednak wadą tego podejścia jest o wiele mniejsza dokładność, co dyskredytuje je do zastosowań komercyjnych.

3.4 SSD

Dyski SSD (ang. *Solid State Drive*) posiadają kompletnie odmienną charakterystykę od tradycyjnych dysków twardych (HDD) [102], [103]. Nie zawierają żadnych ruchomych części, co eliminuje konieczność oczekiwania na przesunięcie głowicy dysku na odpowiednie miejsce, jak to ma miejsce w przypadku dysków HDD. Dzięki temu czas odczytu i zapisu jest znacznie szybszy.

SSD zyskały na popularności głównie ze względu na szybko rosnącą pojemność (obecnie sięgającą kilku terabajtów), spadek kosztów produkcji, dobrą odporność na czynniki fizyczne, mały pobór mocy oraz bardzo dużą szybkość odczytu i zapisu.

Dyski SSD mogą zapisywać dane z wykorzystaniem wszystkich rodzajów pamięci typu NAND. Wybór pamięci zależy od zastosowań dysku. Pamięć SLC jest używana w drogich modelach przeznaczonych do użytku profesjonalnego, jak serwery czy hurtownie danych, gdzie szybkość wykonywanych operacji oraz bezpieczeństwo danych są bardzo ważne. Z kolei pamięć MLC jest powszechnie stosowana w dyskach przeznaczonych do laptopów czy komputerów osobistych. Ponieważ dyski SSD używają pamięci flash, ich charakterystyka oraz ograniczenia są identyczne jak w przypadku pamięci NAND.

Obecnie dyski używają dwóch typów interfejsów: wolniejszego SATA (ang. *Serial Advanced Technology Attachment*) [104], [105] o przepustowości maksymalnej 750 MB/s oraz szybszego M.2 (ang. *Next Generation Form Factor*) [106] wykorzystującego złącza PCIe (ang. *Peripheral Component Interconnect Express*) o maksymalnej przepustowości wynoszącej aż 4 GB/s. Szybszy interfejs M.2 może być użyty w protokole NVMe (*ang. Non-Volatile Memory Express*) [107], [108], który jest obecnie najpopularniejszym protokołem do komunikacji pomiędzy SSD a głównym procesorem. Dyski SSD mają wbudowany procesor oraz bufor danych, aby maksymalnie wykorzystać przepustowość używanego interfejsu.

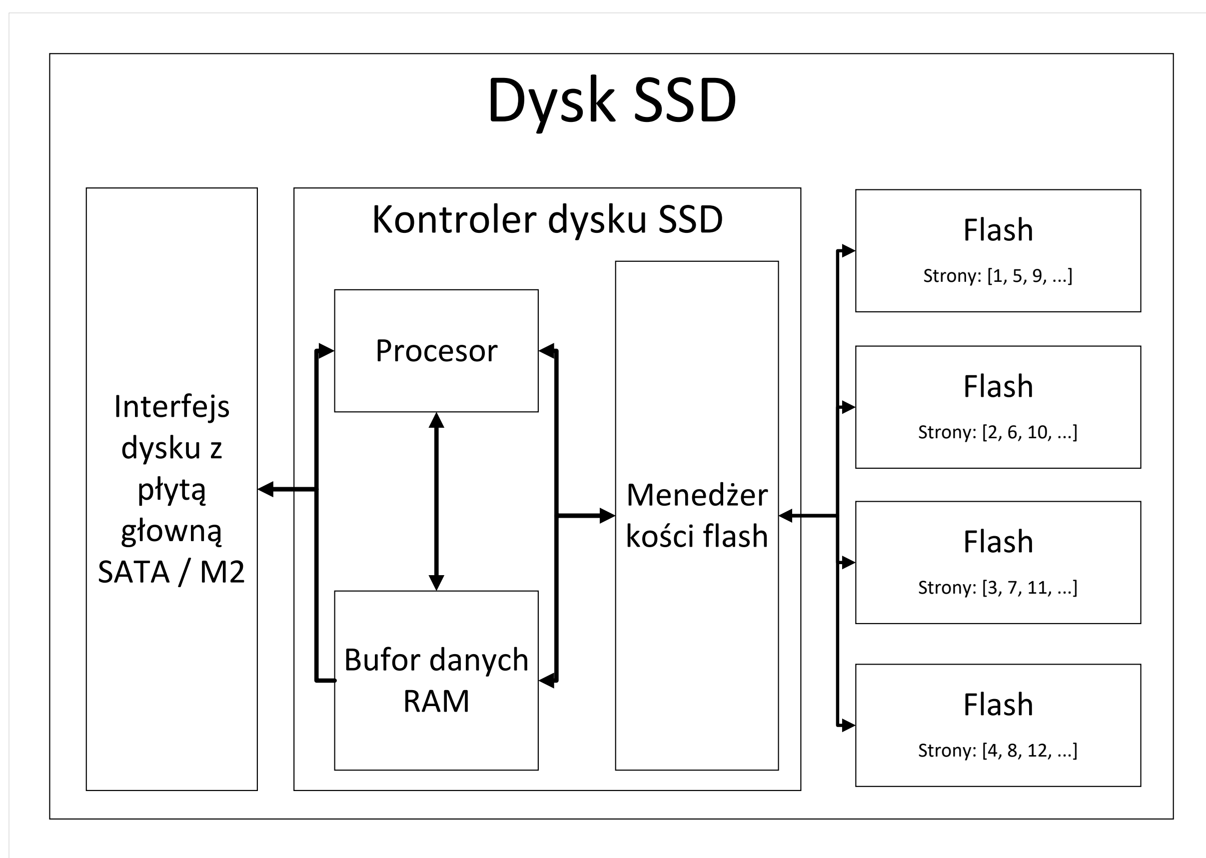

Rysunek 3.4: Budowa dysków SSD

Rysunek 3.4 przedstawia uproszczony model dysku SSD. Przykładowy dysk ma wbudowane 4 kości flash typu NAND. Menedżer pamięci flash często ma wbudowany algorytm FTL [109], który rozwiązuje problem szybkiego zużywania się pamięci (ang. *wear-leveling*).

Aby w pełni wykorzystać potencjał używanych kości pamięci, menedżer mapuje strony równolegle, umożliwiając jednoczesną pracę na wielu kościach. W naszym przykładzie, strony logiczne 1, 5, 9 ... wskazują na kolejne strony kości pierwszej, strony 2, 6, 10 ... na strony kości drugiej. Analogiczne mapowanie przeprowadzone jest dla pozostałych kości. Dzięki takiemu ułożeniu pamięci wirtualnej, możliwe jest równoległe wczytywanie lub zapisywanie danych, gdy użytkownik z góry zna zakres adresów, na których pracuje. Ponieważ układ ten w pamięci wirtualnej, widzianej przez użytkownika końcowego, jest sekwencyjny (fizycznie równoległy), tryb pracy kontrolera, umożliwiający jednoczesny odczyt lub zapis na wielu kościach, nazywamy trybem sekwencyjnym. Praca na ciągłym obszarze pamięci jest wydajniejsza właśnie dzięki użyciu trybu sekwencyjnego przez kontroler [110]. Efektywne algorytmy, projektowane z myślą o pracy na dyskach SSD, maksymalizują użycie tego trybu, jednocześnie minimalizując liczbę losowych dostępów [111], [112]. Aby przyspieszyć tryb losowy, kontroler dysku posiada także swój własny bufor RAM. Za jego pomocą implementowany jest podobny mechanizm buforowania, jak w przypadku pamięci podręcznej procesora (ang. *cache*) [113]. Gdy użytkownik prosi o dane z podanego adresu, procesor wbudowany w dysk SSD przegląda cały bufor danych w poszukiwaniu potrzebnych stron. Jedynie strony, które nie znalazły się w buforze, są wczytywane z pamięci flash [114]. Cały mechanizm jest bardzo podobny do omawianego wcześniej mechanizmu *Page Cache*.

Kolejnym ważnym mechanizmem przyspieszającym działanie dysków SSD jest automatyczne usuwanie bloków (ang. *garbage collection*) [115] w momencie, gdy dysk nie jest używany przez użytkownika lub jest używany minimalnie. Algorytm FTL dzieli strony na dwa podzbiory: strony puste – usunięte wcześniej, gotowe do ponownego użytku, oraz strony brudne (ang. *dirty*), które nie są już używane i oczekują na usunięcie. Ponieważ operacja zapisu jest najszybsza, gdy strona jest pusta i gotowa do użytku, procesor wbudowany w kontroler dysku SSD usuwa zużyte strony, gdy tylko jest taka możliwość (znikome wykorzystanie dysku). Algorytm odśmiecania pamięci jest bardzo ważnym elementem dysków SSD. Zaproponowano wiele różnych implementacji tego algorytmu, jak i wiele optymalizacji skupiających się głównie na dostosowaniu się do sposobu używania dysków, tak aby operacja usuwania bloków nie odbywała się podczas pełnego obciążenia nośnika pamięci [116], [117], [118], [119], [120]. Gdy dysk jest pełny (wszystkie strony mają zapisane dane od użytkownika), szybkość działania dysku drastycznie maleje [121], ponieważ nie ma pustych stron. Przed każdym zapisem musimy czekać na operację kasowania bloku. Z tego powodu producenci dysków SSD zalecają zapis danych do maksymalnie 80% pojemności SSD. Nowe systemy operacyjne wspierają także operacje TRIM, czyli manualne odśmiecanie pamięci. System operacyjny, mając więcej informacji o obłożeniu całego komputera [122], [123], [124], często potrafi lepiej zdecydować, kiedy warto włączyć kasowanie zużytych stron. Gdy podejmie taką decyzję, wysyła komendę `TRIM()` do dysku SSD, a ten, niezależnie od używanego algorytmu odśmiecania, zaczyna usuwać niepotrzebne już bloki.

3.5 PCM

Pamięć zmiennofazowa PCM (ang. *Phase Change Memory*) [125], [126] jest pamięcią nieulotną, opartą na nośniku krystalicznym. Autorem koncepcji i prototypów pamięci zmiennofazowej jest firma Ovonyx, od której pochodzi nazwa tej pamięci: *ovonic unified memory* (OUM) [127]. Obecnie rozwojem pamięci PCM zajmuje się firma Intel [128].

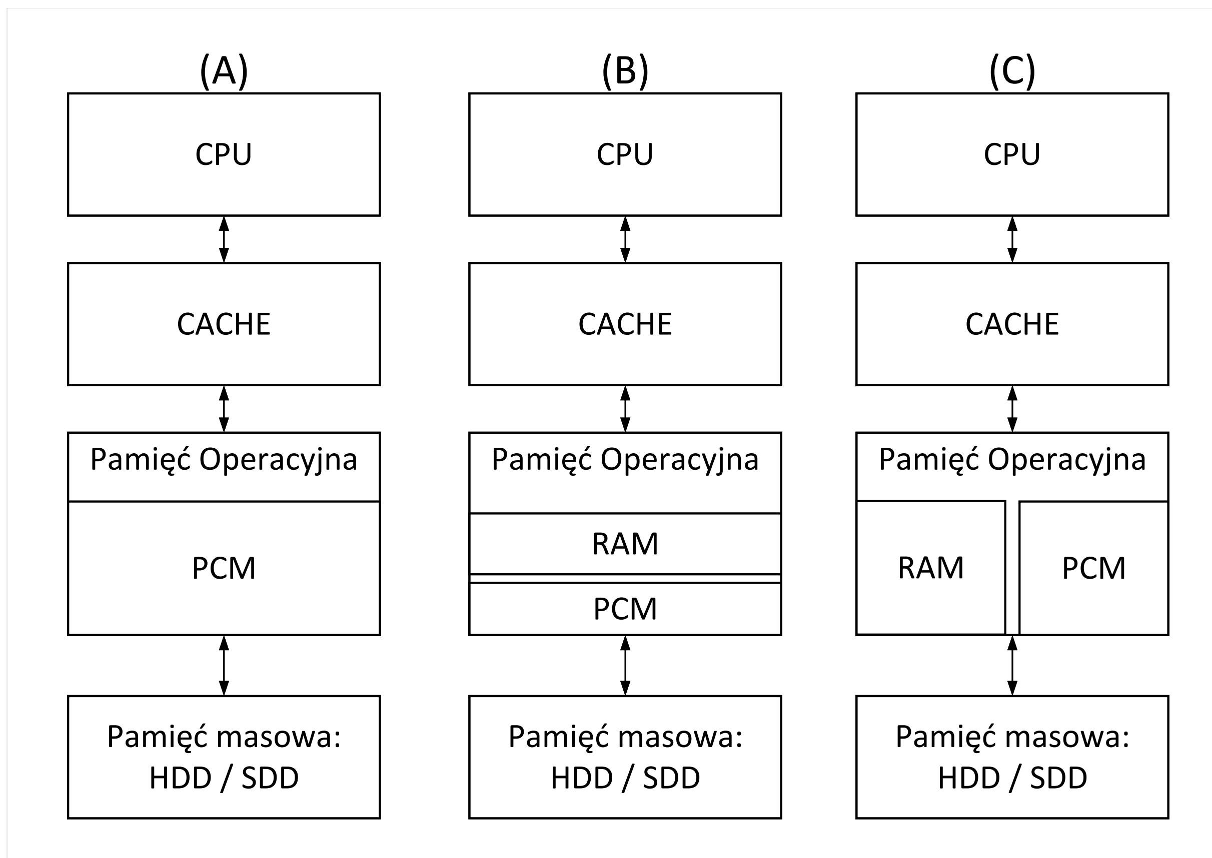

Rysunek 3.5: Możliwe zastosowania pamięci PCM

Podobnie jak pamięć flash, PCM nie traci danych po odłączeniu zasilania. Pamięć ta jest dużo bardziej wydajna od dysków HDD i SSD. Wartości dotyczące szybkości zapisu i odczytu bitów informacji szacuje się średnio na poziomie kilkadziesiąt razy wyższym niż w przypadku NAND. Dokładne informacje na temat szybkości pamięci przedstawia tabelka 3.1. Podczas zapisu danych nie istnieje konieczność wymazywania całego bloku komórek. Dlatego pamięć ta może zostać wykorzystana nie tylko jako pamięć masowa, ale także jako pamięć operacyjna komputera [129], [130], [131].

Rysunek 3.5 przedstawia możliwe zastosowania pamięci PCM zaproponowane w [132], [133], [134]. W propozycji *(A)* pamięć operacyjna jest w pełni realizowana za pomocą PCM. Pamięć zmiennofazowa jest wolniejsza od pamięci RAM, jednak pojedyncza kość pamięci jest pojemniejsza. Obecnie kości Intel Optane DC posiadają pojemność od 64 GB aż do 25 6GB. Dlatego gdy potrzebujemy pamięci operacyjnej o dużej pojemności, warto wybrać PCM jako pamięć główną komputera. W [132] zaproponowano algorytm wykorzystujący charakterystykę pamięci PCM, który posiada czas wykonania zestawu operacji tylko o 20% większy od operacji przeprowadzanych na klasycznej pamięci RAM DDR4.

Propozycje *(B)* i *(C)* dzielą pamięć operacyjną na dwie warstwy. W warstwie RAM, przechowywane są dane często używane lub niedawno użyte. Tak więc pamięć RAM odgrywa rolę bufora pomiędzy pamięcią podręczną procesora a pamięcią PCM. W zaproponowanej architekturze *(B)* użytkownik nie ma możliwości ręcznego buforowania danych. System operacyjny sam podejmuje decyzję, które dane będą znajdować się w buforze. W propozycji *(C)* użytkownik jest odpowiedzialny za buforowanie swoich danych, a system

operacyjny zapisuje wszystkie dane do PCM, jako głównej pamięci operacyjnej. Inną zaletą pamięci PCM jest jej trwałość. Komórki pamięci PCM mogą działać znacznie dłużej niż komórki pamięci flash. Zanim ulegną zdegradowaniu są w stanie wytrzymać około 100 milionów cykli. Dodatkowo komórki PCM też są bardziej stabilne od komórek flash, a informacja na nich zapisana nie ulega degradacji wraz z upływem czasu. Szacuje się, iż podczas pracy w normalnej temperaturze (85 stopni C) komórki przechowają informację przez około 300 lat [135].

Pamięć PCM oparta jest na nośniku krystalicznym. Do przechowywania danych wykorzystuje się proces zmiany stanu nośnika, który w temperaturze pokojowej może istnieć w postaci amorficznej (*logiczne 0*) lub krystalicznej (*logiczne 1*). Zmiana stanu następuje w wyniku podgrzania nośnika przez wyemitowaną wiązkę elektronów. Odczyt przeprowadzany jest także w wyniku działania strumienia elektronów, w oparciu o pomiar rezystancji nośnika, która jest inna dla różnych jego faz. Bardzo ważną cechą tego rodzaju pamięci jest możliwość przechowywania stanów pośrednich. Dzięki temu, możemy w jednej komórce zapisać kilka bitów informacji.

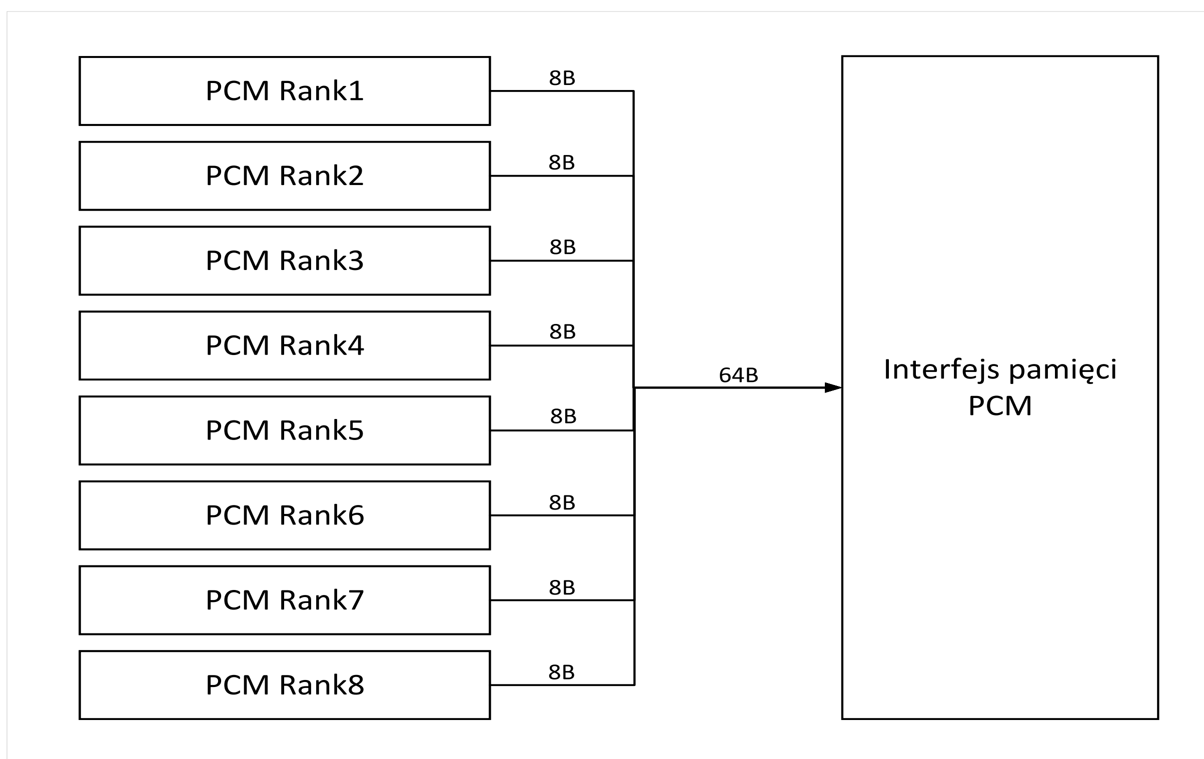

Rysunek 3.6: Pamięć PCM

Tak jak jest to w przypadku pamięci RAM, pamięć PCM jest również bajtowo adresowalna. Jednak ze względu na jej budowę oraz lepszą współpracę z pamięcią podręczną procesora (ang. *cache*), została podzielona na strony o wielkości 64 B. Rysunek 3.6 przedstawia uproszczoną budowę pojedynczej kości PCM. Pamięć zmiennofazowa, podobnie jak pamięć RAM, podzielona jest na równolegle połączone ze sobą banki pamięci (ang. *memory ranks*). Zazwyczaj kość zbudowana jest z 4 lub 8 banków pamięci. Obecnie wykorzystuje się głównie 8 banków, ponieważ w czasie jednego odczytu możemy wczytać całą stronę pamięci PCM (64 B), odczytując z każdego banku pojedyncze słowo maszynowe architektury 64-bitowej (8 B), która jest obecnie najbardziej popularna. Jest to idealne wykorzystanie nie tylko pamięci PCM, ale także pamięci podręcznej procesora, ponieważ

strona tej pamięci (*cache line*) zazwyczaj posiada również wielkość 64 B. Zatem podczas jednej operacji odczytu lub zapisu pracujemy na całej linii pamięci podręcznej, co prowadzi do maksymalizacji przepustowości i minimalizacji latencji pomiędzy pamięciami i procesorem. Ze względu na asymetrię pomiędzy czasem odczytu a zapisu oraz odmienną charakterystykę pamięci PCM od klasycznych dysków HDD jak i nowych dysków SSD, klasyczne struktury danych muszą być dostosowane do tego rodzaju pamięci. W [136] przedstawiono implementację drzewa B+, które kosztem większej liczby odczytów minimalizuje liczbę potrzebnych zapisów, zwiększając wydajność indeksu B+ o 30%.

3.6 Podsumowanie

Różne pamięci posiadają różne cechy. Unikalność wielu z nich wymusza zmianę klasycznego podejścia do problemu indeksowania i potrzebę dostosowania struktur danych do charakterystyki pamięci. Stare dyski twarde HDD, ze względu na ich małą przepustowość (około 150 MB/s) oraz dużą latencję (4.17 ms), są stopniowo zastępowane przez nowe rodzaje pamięci masowej, takie jak flash i PCM. Flash typu NAND, wykorzystywana w dyskach SSD, które nie posiadają ruchomych części, co przekłada się na szybki czas dostępu do dowolnej komórki pamięci (0.36 ms dla SATA, 0.005 ms dla M2). Ich mała latencja, duża przepustowość oraz malejące koszty produkcji przyczyniły się do coraz szerszego wykorzystywania dysków SSD w serwerach jak i hurtowniach danych. Algorytmy działające na tych dyskach powinny maksymalizować użycie sekwencyjnego trybu kontrolera oraz minimalizować niepotrzebne usuwanie bloków, co jest nie tylko wolną operacją, ale także skracającą żywotność pamięci flash. Kolejnym rodzajem pamięci nieulotnej jest pamięć zmiennofazowa PCM. W przeciwieństwie do dysków HDD i SSD, jest bajtowo adresowalna. Posiada bardzo dużą wytrzymałość oraz o wiele krótszy czas dostępu od dysków HDD czy SSD (350 ns). Z tego powodu wykorzystywana jest nie tylko jako pamięć masowa, ale także jako pamięć operacyjna komputera w sytuacjach wymagających dużej pojemności pamięci głównej. Zarówno PCM, jak i pamięć flash cechują się asymetrią pomiędzy czasem odczytu i zapisu. Dlatego też algorytmy pracujące na tej pamięci powinny dążyć do minimalizacji niepotrzebnych zapisów.

Platforma testowa

W tym rozdziale omówimy platformę testową: symulator pamięci trwałej, podstawowy zestaw kwerend oparty na zestawach zaproponowanych w [137], [138], rozszerzony zestaw oparty o zbiór operacji testowych TPC-C [13] i TPC-H [14] oraz nowy sposób testowania indeksów częściowych zaproponowany w [139].

Celem platformy testowej jest ujednolicenie eksperymentów przeprowadzanych na indeksach. Każdy indeks powinien zostać przetestowany w tych samych deterministycznych warunkach, przy użyciu tego samego modelu pamięci oraz tych samych operacji. Ponieważ nowoczesne typy pamięci trwałej jak PCM Intel Optane i Intel Optane SSD 3D Xpoint są drogie oraz zawierają wiele technik optymalizacji, które są niedeterministyczne, do przeprowadzenia testów użyto nowatorskiego symulatora pamięci trwałej SIPS (ang. *Storage and Index Performance Simulator*) stworzonego na potrzeby tej pracy. Wszystkie eksperymenty zostały napisane w języku C++ (standard 17), skompilowane narzędziem g++ w wersji 9.4.0 z najwyższą możliwą optymalizacją (O3). Programy zostały uruchomione na systemie operacyjnym Ubuntu 20.04. Komputer, na którym przeprowadzono eksperymenty, wyposażony jest w ośmiordzeniowy procesor Intel i7-9700F, każdy rdzeń o taktowaniu maksymalnym 4700 MHz. Pamięć podręczna procesora poziomu pierwszego (L1 cache) ma pojemność 2 MB, pamięć podręczna współdzielona pomiędzy wszystkie rdzenie (L3 cache) ma pojemność 12 MB. Pamięć operacyjna RAM o sumarycznej pojemności 32 GB, składa się z dwóch kości 16 GB połączonych ze sobą w trybie dual-channel, pracujące z częstotliwością 2666 MHz.

4.1 Symulator SIPS

Obecny postęp technologiczny sprawił, że przeprowadzenie rzetelnych eksperymentów jest bardzo trudne. Producenci dysków nie udostępniają pełnej specyfikacji sprzętu wraz z mechanizmami działającymi w tle na ich dyskach, rozmiarem bufora, modelem procesora i algorytmem buforującym przesyłane dane. Bardzo prawdopodobne jest, że algorytm będzie działał sprawniej na dyskach jednego producenta niż na dyskach drugiego, ponieważ implementacja indeksu będzie nieświadomie i pośrednio wykorzystywać wbudowaną optymalizację. Przykładowo, indeks może korzystać z dysku w taki sposób, że potrzebne dane będą znajdować się często w buforze wbudowanym, ponieważ bufor zarządza danymi w podobny sposób co wzorzec odczytów wykorzystywany przez indeks. Dobrym przykładem jest algorytm *MRU* (ang. *Most Recently Used*) buforowania danych, który przechowuje w buforze najczęściej wczytywane dane. W tym przypadku górne fragmenty indeksu B+ będą znajdować się w buforze i nie będzie potrzeby fizycznego odczytu z pamięci. Gdyby ten algorytm zmienić na *LRU* (ang. *Least Recently Used*), który przetrzymuje ostatnio żądane fragmenty dysku, wówczas górny fragment drzewa B+ byłby poza buforem, ponieważ ścieżka z korzenia do kluczy nie jest zawsze taka sama, ale zmienia się w zależności od klucza. W takim przypadku dysk musiałby wykonać więcej operacji

odczytu, co spowolniłoby pracę na indeksie. Widać zatem, że sposób implementacji algorytmów wbudowanych w dysk jak i dodatkowe mechanizmy wpływające na efektywność pracy na pamięci zaburzają wyniki eksperymentów.

Obecnie każdy dysk SSD i PCM posiada własny procesor. Wykonuje on wiele operacji w tle, nie informując o tym użytkownika. Dlatego wynik testu zależy od stanu dysku. Przykładowo, jeśli dysk SSD miałby wszystkie wolne strony skasowane, zapis nowych danych mógłby się odbyć natychmiastowo. Jednak gdy proces *garbage collector* nie zdążyłby wyczyścić potrzebnych stron, wtedy operacja zapisu musiałaby poczekać, aż proces skończy swoją pracę. Ponieważ nowoczesne dyski posiadają kilkuprocentowy bufor (np. użytkownik kupując dysk 1 TB, ma do dyspozycji tylko 920 GB - 950 GB), bardzo ciężko jest powtórzyć test i trafić na ten sam stan dysku co poprzednio. Kolejnym aspektem, który należy wziąć pod uwagę, jest cena. Ze względu na wcześniej wymienione optymalizacje, należy przeprowadzić testy na kilku dyskach różnych producentów. Komputer wspierający pamięci PCM Intel Optane w chwili pisania tej pracy kosztuje ponad 30 tys. złotych, a nowoczesny dysk SSD kosztuje ponad 2000 złotych. Ze względu na tak duży koszt jak i niedeterministyczne zachowanie realnych pamięci, do przeprowadzenia eksperymentów napisano symulator *SIPS* (ang. *Storage and Index Performance Simulator*).

Dyski SSD i pamięć flash zyskały na popularności. W związku z tym, wiele symulatorów zostało stworzonych, aby umożliwić testowanie zaproponowanych algorytmów. Symulatory możemy podzielić na dwie główne kategorie: sprzętowe (ang. *hardware simulators*) i programowe (ang. *software simulators*). Symulatory sprzętowe [140], [141], [142], [143] działają na urządzeniach FPGA (ang. *Field Programmable Gate Array*), które próbują symulować kontroler dysków w czasie rzeczywistym. Oznacza to, że jeśli zapis na dysku powinien trwać 2 minuty, urządzenie zgłosi koniec operacji dopiero po 2 minutach, chociaż symulacja zakończyła się w kilka sekund. Taki rodzaj urządzeń jest trudno dostosować do swoich potrzeb, a konfiguracja parametrów dla kilku dysków jak i połączenie ich ze środowiskiem głównego komputera to również trudne zadanie. Dodatkowo, sama symulacja zajmuje tyle czasu, co prawdziwa operacja, co nie jest efektywne podczas testowania wielu algorytmów indeksowania dla dużych baz danych na kilku rodzajach pamięci flash.

Programy symulujące dyski SSD mogą działać osobno jako aplikacja lub jako komponent w większym emulatorze całego sprzętu QEMU [144], [145]. FEMU [146], VSSIM [147] i SimpleSSD [148] to najpopularniejsze programy działające w środowisku emulatora QEMU. Mają one za zadanie symulować głównie funkcjonalność dysku, mechanizmy działające wewnątrz kontrolera oraz zużycie samego dysku. Zatem te symulatory nie powinny być stosowane do testowania algorytmów pod kątem ich efektywności. Ostatnia kategoria to programy działające jako osobne aplikacje. Wystawiają one API dla użytkowników. Aby z nich korzystać, należy dostosować implementacje algorytmów tak, aby zamiast prawdziwych operacji na systemie plików, używać operacji zdefiniowanych w symulatorze. Do najpopularniejszych z nich należą: MQSim [149], SSDModel [150], DiskSim [151], DiskSimExt [152], CPPSim [153], FlashSim [154], FlexSim [155], NandFlashSim [156], WiscSim [157] i SSDSim [158].

W [149] porównano najpopularniejsze symulatory dysków SSD w kontekście czterech dysków z interfejsem SATA III. Najmniejszy błąd względny wykazuje symulator MQSim, oscylujący w granicach 10-20% w zależności od modelu dysku. Pozostałe symulatory charakteryzują się błędem sięgającym nawet 300% w stosunku do rzeczywistego

Symulator	Liczba linii kodu	Błąd względny			
		SSD A	SSD B	SSD C	SSD D
MQSim	13 tys.	8%	6%	18%	14%
SSDModel	1 tys.	91%	155%	196%	136%
FlashSim	8 tys.	99%	259%	310%	138%
SSDSim	5 tys.	70%	68%	74%	85%
WicSim	7 tys.	95%	277%	324%	135%
FEMU	7 tys.	-	-	-	-
VSSim	6 tys.	-	-	-	-
SimpleSSD	7 tys.	-	-	-	-

Tabela 4.1: Porównanie symulatorów SSD [149]

czasu operacji. Takie różnice bezpośrednio wynikają z liczby komponentów, które symulator jest w stanie zamodelować: im bardziej kompleksowy model, tym wyniki bardziej dokładne. Ponadto, nowoczesne dyski SSD są zdolne do obsługi wielu zapytań jednocześnie, co czyni istotnym, aby symulator również oferował taką funkcjonalność [159]. Biorąc pod uwagę, iż niniejsza praca nie koncentruje się wyłącznie na dyskach SSD, lecz także na pamięci flash oraz PCM, użycie wyżej wymienionych symulatorów nie jest możliwe. Celem zaproponowanych eksperymentów, jak i platformy testowej, jest przeprowadzenie testów efektywności algorytmów indeksowania w jednolitym środowisku. Oznacza to konieczność integracji symulatora dysków SSD z symulatorem pojedynczej kości flash ([146]) oraz pamięci PCM ([160], [161], [162]).

Zamiast dążyć do zintegrowania wielu niekompatybilnych narzędzi, podjęto decyzję o opracowaniu nowego symulatora. Aby zapewnić ujednolicone środowisko testowe dla wszystkich rodzajów pamięci i indeksów omawianych w tej pracy, zaimplementowano symulator SIPS. Symulator ten nawiązuje do systemu Amber [163], który oprócz symulacji peryferii dysku, modeluje także warstwy systemu operacyjnego odpowiedzialne za transfer danych pomiędzy dyskiem a pamięcią RAM, a także buforowanie danych za pomocą komponentu *Page Cache*. Rysunek 4.1 prezentuje schemat klas symulatora SIPS. Zaczynając od najniższych komponentów w hierarchii, mamy `MemoryModel`, odpowiedzialny za symulację niskopoziomowego układu pamięci, bez buforów, wirtualizacji pamięci oraz innych mechanizmów minimalizujących zużycie pamięci. Nad kośćiami pamięci działa `MemoryController`, który zajmuje się wirtualizacją pamięci i równomiernym rozłożeniem jej zużycia (ang. *wear-leveling*). Wykorzystuje do tego celu algorytm FTL oraz jego odpowiednik dla pamięci PCM - PTL [164], odpowiadając również za podstawowe buforowanie i agregację zapytań do pamięci. Kontroler jest świadomy charakterystyki obsługiwanej pamięci, wiedząc o jej podziale na segmenty, co pozwala mu optymalizować operacje odczytu i zapisu. `MemoryDisk` to komponent symulujący dysk w całości, integrujący większość mechanizmów fizycznie umieszczonych na procesorze wbudowanym w dyski HDD, SSD, czy PCM.

Każdy dysk komunikuje się z płytą główną przez dedykowany interfejs, którego implementacja jest niezbędna, aby wiernie odwzorować wpływ na szybkość przesyłu danych. Dodatkowo, nowoczesne dyski wyposażone są w obszerne bufory RAM, które umożliwiają minimalizację fizycznego dostępu do pamięci dzięki zastosowaniu technik buforowania, np. LRU (ang. *Last Recently Used*) czy MRU (ang. *Most Recently Used*). Symulator SIPS, podobnie jak systemy Amber czy MQSim, funkcjonuje jako niezależna aplikacja i nie wymaga

Rysunek 4.1: Schemat symulatora SIPS

współpracy z żadnym emulatorem czy systemem operacyjnym. Implementując algorytm indeksowania, użytkownik musi skorzystać z API systemu plików dostarczanego przez symulator. Rozszerzenie symulatora o implementacje indeksów pozwala na to, by SIPS był nie tylko symulatorem różnorodnych pamięci, ale również symulatorem wielu indeksów baz danych działających na tych pamięciach. Integracja modelu pamięci, kontrolera, dysku i indeksu w jednym programie przynosi liczne korzyści, takie jak prostota implementacji – eliminacja potrzeby łączenia wielu programów przez API. Dodatkowo, obecność komponentu `SystemObservability`, który gromadzi informacje o interesujących nas operacjach i kosztach tych operacji, jest nieoceniona. Tabela 4.2 ukazuje kluczowe statystyki zbierane przez symulator, w tym nie tylko całkowite czasy operacji, ale i ich liczbę, średni czas wykonania, a także czas każdej indywidualnej kwerendy. Dzięki kompleksowej integracji symulatora, uzyskujemy pełny wgląd w działanie algorytmów – od czasu potrzebnego na realizację poszczególnych operacji (dodawanie, usuwanie, wyszukiwanie), przez zużycie pamięci (ang. *wearout*), aż po wpływ buforowania danych na to zużycie (różnice pomiędzy `MEMORY_COUNTER_VIRTUAL_WEAROUT` a `MEMORY_COUNTER_PHYSICAL_WEAROUT`).

Budując symulator pamięci flash i dysku SSD, należy wziąć pod uwagę przynajmniej najważniejsze komponenty tych pamięci, wpływające na efektywność ich pracy [165], [166]. W symulatorze SIPS najpierw zaimplementowano dokładnie pojedynczą kość pamięci

Nazwa	Opis
INDEX_COUNTER_INSERT_TIME	Całkowity czas potrzebny na wstawienie rekordów do indeksu
INDEX_COUNTER_DELETE_TIME	Całkowity czas potrzebny na usunięcie rekordów z indeksu
INDEX_COUNTER_PSEARCH_TIME	Całkowity czas potrzebny na wyszukiwanie punktowe rekordów w indeksie
INDEX_COUNTER_RSEARCH_TIME	Całkowity czas potrzebny na wyszukiwanie zakresowe rekordów w indeksie
INDEX_COUNTER_TOTAL_TIME	Całkowity czas potrzebny na wszystkie operacje wykonywane na indeksie
MEMORY_COUNTER_READ_TIME	Całkowity czas potrzebny na wszystkie operacje odczytu danych wykonywane na modelu pamięci
MEMORY_COUNTER_WRITE_TIME	Całkowity czas potrzebny na wszystkie operacje zapisu danych wykonywane na modelu pamięci
MEMORY_COUNTER_OVERWRITE_TIME	Całkowity czas potrzebny na wszystkie operacje nadpisania danych wykonywane na modelu pamięci
MEMORY_COUNTER_TOTAL_TIME	Całkowity czas potrzebny na wszystkie operacje wykonywane na modelu pamięci
MEMORY_COUNTER_VIRTUAL_WEAROUT	Całkowita liczba bajtów zgłoszona do zmiany w warstwie kontrolera (bajty zmienione wirtualnie w buforze też są liczone)
MEMORY_COUNTER_PHYSICAL_WEAROUT	Całkowita liczba bajtów zgłoszona do zmiany w warstwie modelu pamięci (bajty zmienione wirtualnie w buforze są pomijane)

Tabela 4.2: Najważniejsze statystyki zbierane przez symulator SIPS

	Pojemność		Prędkość		
Model	Strony	Bloku	Odczytu	Zapisu	Kasowania
Samsung K9F1G08U0D	2 KB	64 KB	58 MB/s	8 MB/s	1 MB/s
Micron MT29F32G08ABAAA	8 KB	1 MB	234 MB/s	23 MB/s	5 MB/s
Micron MT29F32G08CBEDBL83A3WC1	4 KB	512 KB	81 MB/s	4,5 MB/s	1,1 MB/s

Tabela 4.3: Wybrane modele pamięci flash

		Pojemność		Prędkość losowego		Prędkość sekwencyjnego	
Model	Interfejs	Strony	Bloku	Odczytu	Zapisu	Odczytu	Zapisu
Samsung 840	SATA	8 KB	512 KB	390 MB/s	182 MB/s	585 MB/s	535 MB/s
Toshiba VX500	SATA	4 KB	256 KB	379 MB/s	267 MB/s	568 MB/s	525 MB/s
Intel DCP4511	NVMe	4 KB	256 KB	1,2 GB/s	240 MB/s	2GB /s	1.47 GB/s

Tabela 4.4: Wybrane modele dysków SSD

flash wraz z algorytmami FTL: blokowym i stronicowym, wbudowanymi w kontroler tej pamięci. Algorytm FTL można wybrać z puli dostępnych algorytmów lub go wyłączyć, aby zobaczyć wpływ jego działania na efektywność indeksów i zużycie pamięci. Tabela 4.3 przedstawia charakterystykę wybranych modeli pamięci flash.

Prawdziwe dyski SSD posiadają kilka kości flash. Tak więc implementacja klasy dysków SSD korzysta z klasy implementującej działanie kości flash. Symulator SSD automatycznie buforuje operacje wykonywane na dysku za pomocą algorytmu MRU, dzięki czemu sam przełącza kontroler pamięci flash w tryb sekwencyjny lub punktowy. Ponieważ zależy nam na deterministycznym środowisku testowym, proces kasujący stare dane i czyszczący strony (ang. *garbage collector*) został zaimplementowany jako funkcja zamiast jako proces w tle. Oznacza to, że zawsze trzeba czekać, aż proces skończy swoją pracę, jeśli zabrakło nowych stron do zapisu. Dodatkowo, symulator posiada funkcję resetowania stanu dysku do ustawień fabrycznych, dzięki czemu każdy eksperyment może zostać przeprowadzony od tego samego punktu startowego. Tabela 4.4 przedstawia charakterystykę wybranych dysków SSD. Dwa dyski: Samsung 840 i Toshiba VX500 posiadają interfejs SATA, charakteryzują się podobnymi czasami odczytu i zapisu sekwencyjnego oraz dużo wolniejszymi operacjami losowymi. Dysk Intel DXP4511 posiada interfejs NVMe, który dzięki buforowaniu danych w kontrolerze, osiąga rewelacyjne prędkości odczytu jak i zapisu dla trybu sekwencyjnego przy jednocześnie bardzo wolnym zapisie losowym.

Część programu odpowiedzialna za symulację pamięci PCM była wzorowana na symulatorze zaproponowanym w [136]. Ponieważ PCM to pamięć bajtowo adresowalna, często używana jako pamięć główna, zastosowano te same mechanizmy co w przypadku pamięci RAM. Pamięć podzielona jest na banki, których jest domyślnie 8. Operacje zapisu jak i odczytu są wyrównane do linii pamięci podręcznej procesora, która najczęściej ma wielkość 64 B. Oznacza to, że zapis 1 B, 8 , jak i 64 B zajmuje tyle samo czasu. Do rozkładu zużycia pamięci oraz jej wirtualizacji zastosowano podstawowy algorytm PTL

Model	Pojemność strony	Szybkość odczytu	Szybkość zapisu
Testowy Model PCM	64 B	6,4 GB/s	1,6 GB/s

Tabela 4.5: Parametry testowego modelu pamięci PCM [167]

opracowany w [164]. Działa on podobnie jak stronicowy algorytm FTL, dzieląc pamięć na strony o wielkości od 2 KB do 4 KB. Wielkość strony domyślnie jest ustawiona na rozmiar strony RAM, czyli 4 KB. Ponieważ pamięć zmiennofazowa charakteryzuje się asymetrią pomiędzy czasem zapisu i odczytu, kontroler tej pamięci ma wbudowany mechanizm wykrywania faktycznych zmian i nadpisywania tylko tych bajtów, które różnią się od danych w kolejce do zapisu. Tabela 4.5 przedstawia parametry pamięci PCM, wzorowane na [167], gdzie sprawdzano szybkość zapisu i odczytu pierwszej edycji pamięci Intel Optane DC w różnych trybach pracy.

Każdy z dysków posiada także interfejs z płytą główną (w naszym przypadku z systemem plików), który ze względu na prostotę rozwiązania został zaimplementowany jako sekwencyjny. Oznacza to, że symulator nie wspiera równoległych dostępów do dysku, np. za pomocą interfejsu SATA. Takie uproszczenie zostało wprowadzone bez straty na rzetelności wyników, ponieważ celem jest testowanie efektywności indeksów na pojedynczych tabelach. Nie symulujemy silnika baz danych, który potrafi zrównoleglić zapytania do pamięci w celu ich przyspieszenia. Jako dodatkowy komponent zaimplementowano także algorytm buforujący *Page Cache*, który obecny jest w jądrze systemów operacyjnych. Algorytm ten można w każdej chwili włączyć. Domyślnie jest on wyłączony, ponieważ większość silników baz danych z niego nie korzysta.

4.2 Zestawy kwerend

Testowe zestawy kwerend wraz ze schematami relacyjnych baz danych TPC-C [13] oraz TPC-H [14] zostały wprowadzone, aby przetestować algorytmy indeksowania w warunkach zbliżonych do rzeczywistych. W [168] porównano i scharakteryzowano oba zestawy kwerend. TPC-C jest klasycznym zestawem, działającym na tabelach sklepowych. Znajdziemy tam, m.in., tabele klientów, zamówień i listę towarów na magazynie. Schemat relacji, zaproponowaną liczbę relacji i liczbę rekordów dla każdej tabeli pokazuje rysunek 4.2. Zestaw ten mocno obciąża dysk [169] za pomocą losowych wyszukiwań po kluczu oraz wyszukiwań skanujących całą tabelę. TPC-H jest podobny do TPC-C, lecz skupia się głównie na wielowątkowych dostępach do bazy oraz na sprawdzaniu wydajności algorytmów łączących rekordy z kilku tabel (operacja `join`) [170]. Ponieważ algorytmy i struktury danych przedstawione w tej pracy skupiają się na indeksowaniu tabeli, zestaw TPC-C został wybrany jako główny schemat testowania indeksów. Dodatkowo w eksperymentach zrezygnowano z testowania relacji pomiędzy tabelami. Dostosowano wszystkie kwerendy tak, aby pracowały tylko na jednej tabeli. Oprócz tego zredukowano zapytania SQL do prostych operacji na strukturze danych, takich jak: dodawanie nowego rekordu, usuwanie starego rekordu, wyszukiwanie kolumn po kluczu, skanowanie tabeli w celu znalezienia wartości kolumny, która kluczem nie jest, oraz aktualizacja wartości rekordu jak i klucza rekordu. Taka redukcja nie wpływa znacząco na rzetelność testów, ponieważ celem eksperymentów jest zmierzenie efektywności obsługi podstawowych operacji, podanych wcześniej, na różnych tabelach oraz modelach pamięci, a nie efektywności silnika bazy danych w połączeniu z indeksem. Zatem operacje łączenia tabel w zapytaniu poprzez

polecenia `join`, `where` itd. można pominąć.

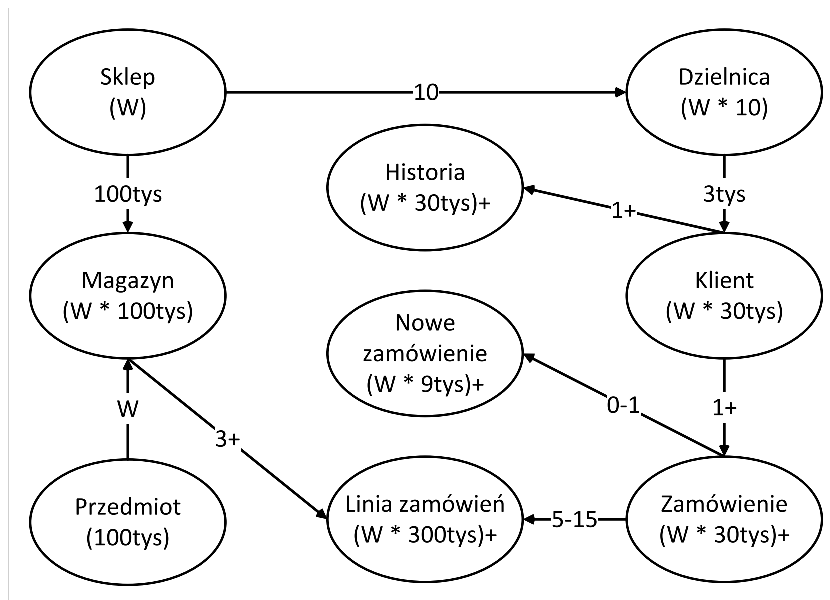

Rysunek 4.2: Schemat bazy danych TPC-C

Tabela 4.6 przedstawia schemat bazy danych TPC-C, zawierającą liczbę kolumn składających się na rekord oraz rozmiar rekordu, czyli sumę rozmiarów wszystkich kolumn. Rozmiar rekordu jest istotny podczas testowania struktur danych, które opierają się na zapisie całymi wierszami. Analogicznie, liczba kolumn jest głównym czynnikiem wpływającym na wydajność indeksów kolumnowych. Ze względu na te dwa czynniki, do eksperymentów zostały wybrane trzy tabele o różnej charakterystyce. Tabela *Sklep* (4.8) jest uznawana za podstawową tabelę testową. Jej liczba kolumn, wynosząca 9, jest medianą pod względem liczby kolumn, a rozmiar rekordu, 113 B, jest bliski zarówno średniej (177 B), jak i medianie (90 B) rozmiarów wszystkich kolumn. W związku z tym, tabelę *Sklep* można uznać za reprezentatywną dla bazy TPC-C. Kolejne wybrane tabele to *Nowe zamówienie* (4.9), która jest najmniejszą tabelą (20 B) w bazie danych, oraz tabela *Klient* (4.7), największą tabelą w bazie TPC-C (719 B).

Tabela	Liczba kolumn	Rozmiar rekordu
Sklep	9	113B
Magazyn	17	322B
Przedmiot	5	90B
Dzielnica	11	125B
Klient	21	719B
Historia	8	76B
Nowe zamówienie	3	20B
Zamówienie	8	47B
Linia zamówień	10	86B

Tabela 4.6: Baza danych TPC-C

4.2.1 Podstawowy zestaw kwerend

Operacje na indeksach dzielimy na dwie kategorie: punktowe oraz zakresowe. Operacje punktowe dotyczą pojedynczych danych i obejmują wstawianie pojedynczego rekordu, usuwanie jednego rekordu oraz wyszukiwanie punktowe (ang. *point search*). Operacje zakresowe działają na całym zakresie danych i obejmują komendy wstawiania wielu rekordów (ang. *bulkload*) oraz wyszukiwanie w zakresie kluczy (ang. *range search*). Indeks powinien wspierać wszystkie te operacje niezależnie od sposobu przechowywania danych (wierszowo lub kolumnowo). Operacje punktowe są typowo wykorzystywane w aplikacjach dostępnych dla szerokiego grona użytkowników. Przykładem może być strona internetowa sklepu, gdzie za każdym razem, gdy klient chce kupić produkt, system musi sprawdzić dostępność konkretnego produktu poprzez operację wyszukiwania punktowego. Właściciel sklepu, dodając lub usuwając pojedyncze produkty, również korzysta z operacji punktowych. Zatem operacje punktowe są istotne w zestawie testowych kwerend, ponieważ ich wydajność wpływa na doświadczenia użytkowników wielu aplikacji.

Podczas tworzenia zestawu testowego konieczne jest również uwzględnienie różnych sposobów użycia bazy danych. Niektórzy użytkownicy będą częściej wpisywać i usuwać dane, inni będą przeważnie odczytywać dane i na nich pracować, a jeszcze inni będą dążyć do zbalansowania liczby zapisów i odczytów. Z tego powodu powstały trzy różne podstawowe zestawy kwerend: ZP_{zapis}, ZP_{odczyt} i ZP_{balans}. W każdym z zestawów operacje są podzielone na X serii, gdzie liczba serii jest ustalana przez użytkownika. Domyślnie jest ich 10. W każdej serii najpierw wykonywane są operacje dodawania rekordów, następnie wyszukiwania po kluczu, a na końcu operacje usuwania rekordów. Proporcja zapisu do bazy została podzielona na wstawiania i usuwania w relacji 3:1.

1. ZP_{zapis} - 60% operacji wstawiania pojedynczego rekordu, 20% operacji wyszukiwania pojedynczego rekordu z użyciem klucza, 20% operacji usuwania pojedynczego rekordu.

2. ZP_{odczyt} - 15% operacji wstawiania pojedynczego rekordu, 80% operacji wyszukiwania pojedynczego rekordu z użyciem klucza, 5% operacji usuwania pojedynczego rekordu.

3. ZP_{balans} - 37.5% operacji wstawiania pojedynczego rekordu, 50% operacji wyszukiwania pojedynczego rekordu z użyciem klucza, 12.5% operacji usuwania pojedynczego rekordu.

Podstawowy zestaw kwerend sprawdza się dobrze zarówno na gotowych tabelach, jak i na tabelach pustych, nie zawierających żadnych rekordów. Operacje wyszukiwania pojedynczego rekordu jak i wstawiania jednego rekordu mają dla większości indeksów tę samą złożoność obliczeniową. Ich czas wykonania różni się głównie w zależności od charakterystyki pamięci, na której testowana jest baza danych. Przykładowo, na pamięci flash dodawanie rekordu będzie znacznie wolniejsze niż wyszukiwanie, ponieważ zapis wymaga kosztownej operacji usuwania całego bloku.

4.2.2 Rozszerzony zestaw kwerend

Zestaw rozszerzony został oparty na kwerendach z TPC-C. Celem tego zestawu jest symulacja hurtowni danych, gdzie operacje są buforowane i wykonywane na wielu rekordach jednocześnie. W odróżnieniu od zestawu podstawowego, tutaj stosuje się wstawianie

Nazwa kolumny	Rozmiar kolumny
C_ID	4 B
C_D_ID	4 B
C_W_ID	8 B
C_FIRST	16 B
C_MIDDLE	2 B
C_LAST	16 B
C_STREET_1	20 B
C_STREET_2	20 B
C_CITY	20 B
C_STATE	2 B
C_ZIP	9 B
C_PHONE	16 B
C_SINCE	16 B
C_CREDIT	2 B
C_CREDIT_LIM	16 B
C_DISCOUNT	8 B
C_BALANCE	16 B
C_YTD_PAYMENT	16 B
C_PAYMENT_CNT	4 B
C_DELIVERY_CNT	4 B
C_DATA	500 B

Tabela 4.7: Klient TPC-C

Nazwa kolumny	Rozmiar kolumny
W_ID	8 B
W_NAME	10 B
W_STREET_1	20 B
W_STREET_2	20 B
W_CITY	20 B
W_STATE	2 B
W_ZIP	9 B
W_TAX	8 B
W_YTD	16 B

Tabela 4.8: Sklep TPC-C

Nazwa kolumny	Rozmiar kolumny
NO_O_ID	8 B
NO_D_ID	4 B
NO_W_ID	8 B

Tabela 4.9: Nowe Zamówienie TPC-C

wielu danych jednocześnie (ang. *bulkload*), o ile dana operacja jest wspierana przez indeks. W przeciwnym wypadku, wstawianie realizowane jest klasycznie, jeden rekord po drugim. Wyszukiwanie całego zakresu kluczy jest parametryzowane przez selektywność zapytania, najczęściej używając selektywności na poziomie od 1% do 5%. Domyślnie, ten parametr ustawiony jest na 1%. Podobnie jak w zestawie podstawowym, rozszerzony zestaw podzielony jest na serie, w których najpierw realizowane jest dodawanie rekordów, następnie wyszukiwanie, a na końcu usuwanie rekordów. Biorąc pod uwagę charakterystykę wielu kwerend TPC-C oraz ich redukcję do podstawowych operacji na indeksach tylko na jednej tabeli, przygotowano cztery różne zestawy kwerend:

1. ZR_{A} - 100 serii, każda seria zawiera operacje dodawania 5 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 5 rekordów,
2. ZR_{B} - 5 serii, każda seria zawiera operacje dodawania 100 000 rekordów, 5 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 100 000 rekordów,
3. ZR_{C} - 10 serii, każda seria zawiera operacje dodawania 10 000 000 rekordów, 20 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 1 000 000 rekordów,
4. ZR_{D} - 10 serii, każda seria zawiera operacje dodawania 1 000 000 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 10 000 rekordów.

Rozszerzony zestaw kwerend okazuje się być znacznie bardziej efektywny w przypadku tabel zawierających już jakieś rekordy. Czas potrzebny na wyszukiwanie danych

jest proporcjonalny do wielkości bazy, co jest zależne od selektywności zapytań. W odróżnieniu od zestawu podstawowego, na pustej bazie danych, zestaw rozszerzony może wykazać się lepszym czasem działania, ponieważ wyszukiwania będą mniej czasochłonne. Rekomendowana wielkość bazy danych do testów to 10 milionów rekordów.

4.3 Testowanie indeksów częściowych

Ciężko jest porównać ze sobą algorytmy tworzące indeksy częściowe takie jak Indeks Cracking [58] czy też Adaptive Merging [15]. Sumaryczny czas może nie wystarczyć, aby w pełni dostrzec różnice i charakterystykę algorytmów. Oprócz czasu należy patrzeć na ilość pamięci potrzebnej na metadane, amortyzację kosztów tworzenia indeksu oraz czas potrzebny na ukończenie procesu. W [139] pokazano całkiem nowy sposób na analizę procesu tworzenia częściowego indeksu. Polega na obserwacji każdego zapytania przez pewien okres, dopóki indeks nie zostanie w pełni stworzony. Zatem te eksperymenty polegają na stworzeniu całego indeksu od podstaw za pomocą tylko kwerend wyszukujących, które dodają odczytane rekordy do indeksu. Na podstawie takiej obserwacji można dokładniej ocenić algorytm nie tylko biorąc pod uwagę czas tworzenia indeksu, ale także parametry ważne dla użytkownika końcowego np. maksymalny i średni czas obsługi zapytania w każdej fazie tworzenia indeksu. Autorzy wyznaczyli 4 takie fazy, które można wyróżnić w każdym algorytmie indeksowania.

1. **Sadzenie (ang. *planting*)** - Pierwsza faza sadzenia polega na inicjalizacji całego procesu. Początkowo trzeba skopiować tabele, wykonując przy tym pewne operacje potrzebne do rozpoczęcia procesu. Pierwsze kroki tego typu algorytmów zazwyczaj potrzebują więcej czasu niż prosty skan całej tabeli. Indeks zawiera na tyle mało elementów, że prawdopodobieństwo jego użycia jest niewielkie. Dlatego musimy wykonać drogie skanowanie oraz dodać kilka operacji potrzebnych na powiększenie indeksu. Podsumowując, pierwsza faza trwa dopóki czas obsługi kwerendy jest większy niż czas wykonania zwykłego, prostego skanu tabeli.

2. **Pielęgnacja (ang. *nursing*)** - Druga faza zaczyna się, gdy czas obsługi kwerendy jest mniejszy niż czas potrzebny na prosty skan, ale nadal większy niż w przypadku użycia pełnego indeksowania. W tej fazie zaczynamy korzystać z posortowanych partii danych, jednocześnie obniżając koszty dodatkowych operacji, ponieważ dodajemy coraz mniej danych do indeksu.

3. **Wzrastanie (ang. *growing*)** - Trzecia faza rozpoczyna się, gdy natrafiamy na zapytanie, które możemy obsłużyć w minimalnym czasie, czyli takim samym jak przy użyciu pełnego indeksu. W tym okresie indeks jest na tyle duży, że prawdopodobieństwo jego przydatności jest wysokie. W prawie każdej kwerendzie częściowo z niego korzystamy, jednak poza pojedynczymi przypadkami nie jesteśmy w stanie dorównać wyszukiwaniu w posortowanym zbiorze danych.

4. **Zbiory (ang. *harvesting*)** - Ostatnia faza zbiorów zaczyna się, gdy indeks jest w pełni stworzony, a zatem nie mamy już czasowych narzutów na jego tworzenie. Czas na obsługę zapytania jest taki sam jak przy użyciu pełnego indeksu.

W [171] ustalono, że powyższa analiza powinna być przeprowadzona na różnych wzorcach zapytań. Zazwyczaj używa się wzorca losowego. Minimalny klucz zapytania losowany jest z rozkładu jednostajnego, a maksymalny klucz zapytania zależy od selektywności i jest usta-

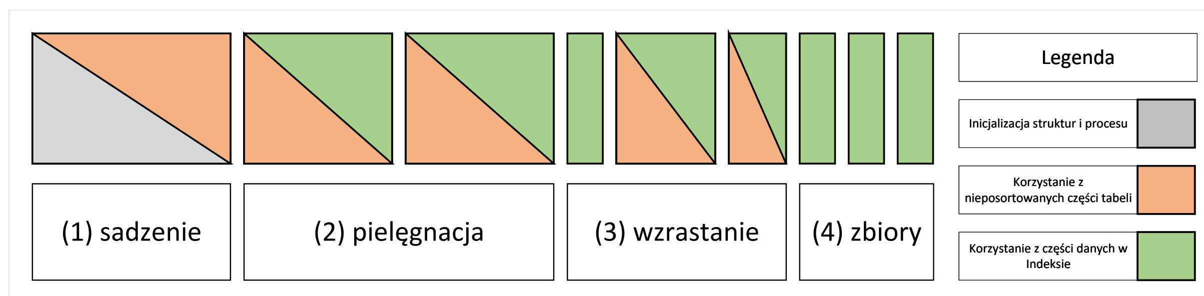

Rysunek 4.3: Fazy częściowego indeksowania

lany tak, aby podczas kwerendy odpowiednia liczba danych została wczytana i zwrócona przez silnik baz danych. Zwykle selektywność ustawia się na 1%–5%. W tym wzorcu prawdopodobieństwo przydatności indeksu zależy od liczby danych już posortowanych. Drugi wzorzec, sekwencyjny, symuluje sytuacje, w których poprzedni wynik zapytania wpływa na kolejny, np. raporty miesięczne i korekty tych raportów. Implementując wzorzec sekwencyjny, wybieramy minimalny klucz z tabeli wybranej do indeksowania. Następnie minimalny klucz żądany przez następne kwerendy jest przesuwany o połowę liczby danych wczytanych w poprzedniej kwerendzie, zależnie od selektywności, tak samo jak w przypadku wzorca losowego. Zatem w pierwszym zapytaniu wczytamy tylko dane z części nieposortowanej, a w każdej kolejnej połowę danych z nieposortowanego sektora tabeli i połowę z indeksu. Oczywiście, gdy indeks będzie gotowy, będziemy czytali już tylko z w pełni stworzonego indeksu. Trzecim wzorcem jest wzorzec nowych kluczy, gdzie każda kwerenda prosi o dane spoza indeksu. Zaczniemy go wykorzystywać dopiero gdy zostanie w pełni stworzony, co teoretycznie jest najgorszym przypadkiem dla algorytmów częściowego indeksowania, ponieważ nie korzystamy z indeksu podczas jego tworzenia. Dobrą praktyką jest przeprowadzenie testów dla wszystkich wymienionych wzorców, ponieważ różne zestawy kwerend testują różne aspekty algorytmu. Przyjęło się jednak, że domyślnie używa się wzorca losowego, który najlepiej symuluje użycie bazy danych w systemie rozproszonym z wieloma użytkownikami, gdzie kwerendy od różnych użytkowników trafiające do systemu w tym samym czasie wyglądają na losowe.

Algorytmy indeksowania na pamięci flash

W tym rozdziale omówimy sposoby indeksowania danych, popularne algorytmy i struktury danych służące do indeksowania na pamięci flash oraz przedstawimy nowy algorytm zaproponowany w [1].

Pamięć flash została dokładnie omówiona w rozdziale **3**. Przypomnijmy sobie jednak główne cechy tej pamięci. Flash dzieli się na dwa rodzaje: NOR i NAND. NOR charakteryzuje się bardzo szybkim odczytem, dzięki połączeniu równoległemu, ale ma wolny zapis i jego pojemność jest bardzo ograniczona. Zwykle pojemność kości NOR nie przekracza kilku MB i jest głównie wykorzystywany do zapisywania kodu oprogramowania na urządzeniach wbudowanych. Dla przechowywania danych używa się pamięci NAND, która charakteryzuje się szybszym zapisem i wolniejszym odczytem, ale co ważniejsze, posiada znacznie większą pojemność, sięgającą nawet kilkuset GB.

W tym rozdziale skupimy się wyłącznie na pamięci NAND. Pamiętajmy, że pamięć flash to pamięć blokowa, podzielona jest na strony o wielkości 2 KB - 8 KB i na bloki o wielkości 64 KB - 512 KB. Strona jest minimalną jednostką odczytu i zapisu, co oznacza, że nawet jeśli chcemy wykonać operację wejścia/wyjścia na 100 bajtach, musimy ją wykonać na całej stronie. Dodatkowo, pamięć flash posiada pewne ograniczenia zmiany wartości bitu. Ze względu na architekturę pamięci nie można zmienić wartości bitu z "0"na "1". Aby nadpisać stronę, musimy najpierw wykonać kosztowną operację kasowania danych (ang. *erase*), zmieniającą wartość całego bloku na ciąg samych "1". Dopiero po operacji kasowania możemy wpisać żądaną wartość, poprzez zmianę "1"na "0". Proces ten powoduje ogromną asymetrię pomiędzy szybkością zapisu i odczytu danych [81]. Należy także pamiętać, że każda komórka pamięci posiada skończony cykl życia zapisu. Każda operacja zapisu jak i kasowania zmniejsza żywotność pamięci. Zatem algorytm pracujący na tej pamięci powinien nie tylko minimalizować liczbę zapisów, aby skrócić czas wykonywania się operacji, ale także powinien minimalizować liczbę operacji kasowania, aby maksymalnie wydłużyć okres życia pamięci flash.

5.1 Wykorzystywanie pamięci flash w urządzeniach wbudowanych

Obecnie komputery osobiste, serwery jak i hurtownie danych korzystają głównie z dysków SSD, które zbudowane są z kości flash NAND. Dyski te, oprócz samych kości, zawierają szereg dodatkowych elementów oraz specjalne oprogramowanie zwiększające wydajność dysku. W urządzeniach wbudowanych, które z reguły są znacznie mniejsze od komputerów osobistych, brak jest przestrzeni na pełnowymiarowe dyski SSD. Dla-

tego w urządzeniach typu IoT (ang. *Internet of Things*), takich jak telefony komórkowe, inteligentne zegarki, pralki czy nawet systemy pomiarowe do rowerów, wykorzystuje się pojedyncze kości flash NAND do przechowywania danych, a kości flash NOR do zapisu oprogramowania.

Urządzenia wbudowane dysponują ograniczonymi zasobami obliczeniowymi, dedykowanymi głównie do realizacji podstawowych funkcji urządzenia. Oznacza to brak wolnych mocy obliczeniowych na działanie relacyjnej bazy danych w tle. Zamiast skomplikowanych struktur z kilkoma tabelami i relacjami między nimi, dane są zazwyczaj przechowywane w prostszych strukturach danych, takich jak drzewo B+ [21] lub drzewo LSM [172]. Drzewo LSM jest rzadziej stosowane ze względu na jego znaczne zapotrzebowanie na pamięć RAM do przechowywania mapowania struktury wewnętrznej $SSTableMap$. Operacje na tych strukturach danych nie są realizowane za pomocą języka SQL, jak w przypadku relacyjnych baz danych wyposażonych w silnik baz danych i interpreter poleceń. Zamiast tego, struktura danych oferuje użytkownikowi proste API, zwykle obejmujące podstawowe polecenia, takie jak dodanie nowego elementu, wyszukanie elementu po kluczu i usunięcie elementu. Korzystając z tego API, aplikacja działająca na urządzeniu może zarządzać wszystkimi niezbędnymi danymi. Jeśli taka architektura nie wystarcza do zbudowania aplikacji, częstym rozwiązaniem jest skorzystanie z zewnętrznego serwera, czyli wydajnego komputera z szybkimi dyskami SSD. Ten serwer, korzystając z prostego API dostępnego na każdym z urządzeń, odbiera dane i wstawia je do relacyjnej bazy danych. Umożliwia to użytkownikowi końcowemu pracę na zgromadzonych danych za pomocą języka SQL, ponieważ zapytania są przetwarzane na serwerze, interpretowane i wykonywane na wcześniej zgromadzonych danych zapisanych jako relacyjna baza. Sama struktura danych, takich jak np. drzewo B+, nie jest wystarczająca do efektywnego przechowywania danych na pamięci flash. Jak wspomniano w rozdziale **3**, bez wirtualizacji pamięci kość flash mogłaby szybko stracić żywotność. Dlatego, niezależnie od tego, czy urządzenie posiada system operacyjny, np. Linux, czy też nie, implementuje się system wirtualizacji bloków [91] lub stron pamięci flash [92] w celu wydłużenia żywotności kości NAND. Do najpopularniejszych systemów wirtualizacji pamięci należą algorytm FTL [90], BFTL [173] oraz UBI [174].

5.2 Flash Aware Tree

W [1] zaproponowaliśmy innowacyjną strukturę danych do przechowywania rekordów na pamięci flash typu NAND, nazwaną FA-Tree. Kluczową cechą tej nowej struktury jest jej zdolność do funkcjonowania w trybie relacyjnych baz danych jako indeks zgrupowany, co oznacza, że działa ona jako struktura danych przechowująca dowolne rekordy i oferuje proste API. Ponadto, FA-Tree stosuje własną metodę wirtualizacji pamięci jako naturalny efekt swojej działalności, co umożliwia uruchomienie indeksu bez konieczności korzystania z zewnętrznego systemu wirtualizacji, takiego jak FTL.

Charakterystyczną cechą FA-Tree jest szybkie wyszukiwanie, wynikające z drzewiastego ułożenia danych, wymagające $\mathrm{O}(\log n)$ odczytów z pamięci flash. W odróżnieniu od popularnego drzewa B+, zaproponowany indeks minimalizuje liczbę zapisów poprzez leniwą reorganizację danych. Eksperymenty przeprowadzone z użyciem platformy testowej SIPS, opisanej szczegółowo w rozdziale **4**, wykazały, że nowa struktura FA-Tree ma trzydziestokrotną przewagę nad tradycyjnym drzewem B+ oraz około 35% przewagę nad

drzewem LSM.

5.2.1 Struktura FA-Tree

Nasza nowa struktura FA-Tree składa się z kilku poziomów. Na samym szczycie, na poziomie 0 (L_0), znajduje się bardzo małe drzewo B+, które ze względu na niewielki rozmiar łatwo mieści się w pamięci RAM nawet urządzeń wbudowanych. Ten poziom służy do buforowania danych przed ich przesłaniem do kolejnych poziomów (L_i, $i > 0$), zapisanych na kości flash. W celu utworzenia struktury drzewa, liście w drzewie B+ zawierają wskaźniki do L_1, czyli pierwszego poziomu zapisanego na pamięci nieulotnej, a każdy kolejny poziom zawiera zbiór wskaźników do odpowiednich stron pamięci poziomu niższego. Taka struktura umożliwia łatwe przeszukiwanie drzewa od góry do dołu w celu odnalezienia rekordu o określonym kluczu.Każdy z poziomów posiada określoną maksymalną pojemność, wyrażoną w liczbie bloków kości flash, dzięki czemu struktura nie traci czasu na usuwanie częściowo zapisanych bloków. Każda operacja alokacji pamięci realizowana jest poprzez alokację całego bloku, przy czym równocześnie odbywa się mapowanie analogiczne do algorytmu FTL. Mapowanie to jest niezależne od systemów takich jak FTL czy UBI, co oznacza, że nasza struktura może współpracować z nimi jako dodatkowa warstwa oprogramowania i zapobiegać przedwczesnemu zużyciu bloków kości NAND. W celu zminimalizowania kosztów reorganizacji struktury, podobnie jak w przypadku drzew B+ czy LSM, wprowadziliśmy współczynnik K. Każdy kolejny poziom zawiera K razy więcej bloków ($|L_{i+1}| = |L_i| \cdot K$). Eksperymenty pokazały, że współczynnik K powinien być odpowiednio dostosowany do rodzaju kwerend. Im większe K, tym drzewo jest niższe, a zatem koszt wyszukiwania jest mniejszy, lecz koszt reorganizacji wzrasta. Dlatego wartość K powinna być dopasowana do specyfiki kwerend lub ustalona na neutralny poziom. Z przeprowadzonych testów wynika, że neutralne wartości K mieszczą się w przedziale $< 4; 10 >$.

W naszej nowej strukturze wyróżniamy cztery rodzaje danych:

1. **Normalna dana** (ang. *normal entry*) - to zwykły rekord zawierający klucz, po którym rekord jest wyszukiwany i wstawiany, oraz dowolne dane, które użytkownik chciał zapisać.
2. **Usunięta dana** (ang. *deleted entry*) - aby zminimalizować liczbę zapisów i operacji usuwania na pamięci flash, wprowadziliśmy leniwy mechanizm usuwania. Zamiast usuwać rekord natychmiastowo, co wymagałoby reorganizacji drzewa, wstawiamy nowy rekord oznaczony jako d_{key} z takim samym kluczem, jak rekord do usunięcia. Gdy takie rekordy spotkają się podczas migracji poziomów w dół, są usuwane ze struktury. Operacja ta jest dokładniej opisana w kolejnych sekcjach tego rozdziału.
3. **Zewnętrzny wskaźnik** (ang. *external fence*) - ten element struktury zawiera dwie wartości: identyfikator strony, na którą wskazuje (PID), z poziomu niżej oraz wartość pierwszego klucza (czyli najmniejszego) strony, na którą wskazuje. Podczas operacji scalania poziomów dla każdej strony poziomu L_{i+1} tworzony jest nowy wskaźnik do tej strony, który umieszczany jest na poziomie nad nim, czyli w L_i. Dzięki temu zachowana jest struktura drzewa po każdej reorganizacji.
4. **Wewnętrzny wskaźnik** (ang. *internal fence*) - podobnie jak zewnętrzny wskaźnik, zawiera dwie wartości: identyfikator strony, na którą wskazuje (PID), oraz klucz. Jednak tym razem klucz nie odnosi się do strony, na którą wskazuje, lecz

jest najmniejszym kluczem na poziomie, na którym znajduje się wewnętrzny wskaźnik. Każda strona po reorganizacji poziomów musi na pierwszym miejscu posiadać wskaźnik. Jeśli strona nie zawiera zewnętrznego wskaźnika, tworzony jest wewnętrzny wskaźnik wskazujący na tę samą stronę, co poprzedni wskaźnik danego poziomu.

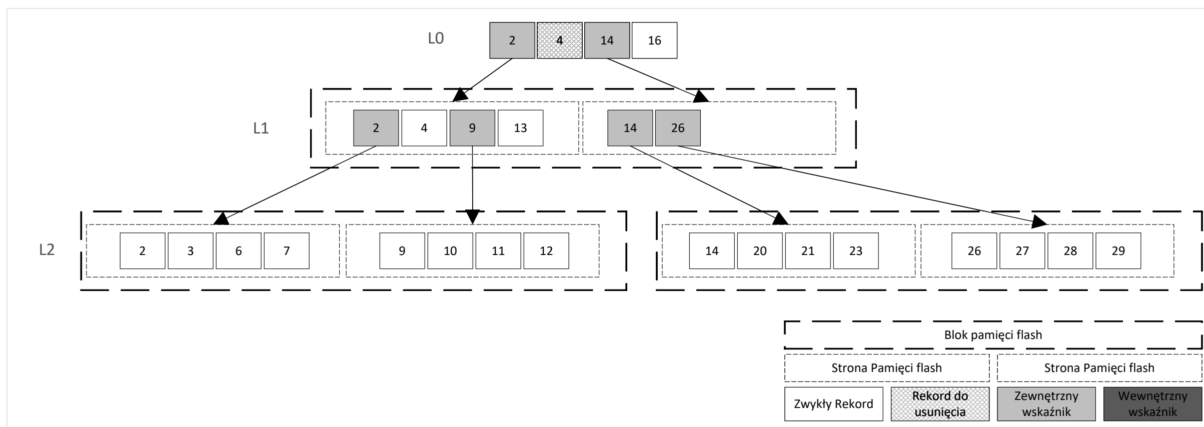

Rysunek 5.1: Przykładowa struktura FA-Tree

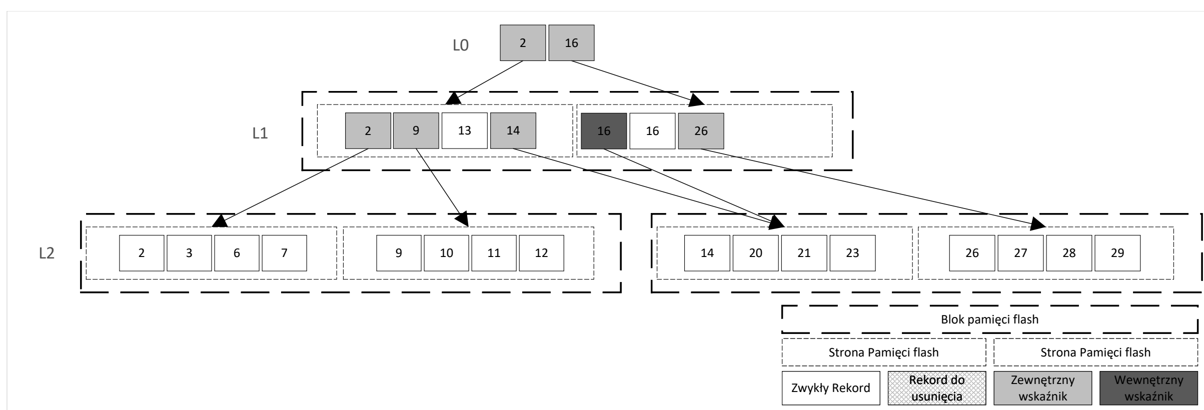

Rysunek 5.2: FA-Tree, zaraz po scalaniu poziomów L_0 i L_1

Rysunek 5.1 obrazuje przykładowy układ struktury FA-Tree. Na samym szczycie znajduje się małe drzewo B+, które ma maksymalnie rozmiar jednego bloku. W tym przykładzie jeden blok składa się z dwóch stron, a każda strona może pomieścić maksymalnie cztery rekordy. Poziom L_0, przechowywany w RAM, zawiera dwa wskaźniki do poziomu niżej, rekord do usunięcia z kluczem *4* oraz zwykły rekord z kluczem o wartości *16*. Ponieważ na poziomach L_0 oraz L_1 pierwszym elementem strony jest zawsze zewnętrzny wskaźnik, struktura nie zawiera żadnego wewnętrznego wskaźnika. Jak widać, taka organizacja struktury umożliwia bardzo szybki odczyt rekordu o podanym kluczu. Załóżmy, że chcemy znaleźć rekord z kluczem *20*. Rozpoczynając od poziomu L_0, szukamy wskaźnika (niezależnie od tego, czy jest to wskaźnik wewnętrzny czy zewnętrzny) o wartości najbliższej, lecz nie większej niż szukany klucz. Skoro szukamy wartości *20*, wskaźnikiem tym na poziomie L_0 będzie *14*. Następnie odczytujemy drugą stronę poziomu L_1, otrzymując dwa wskaźniki: *14* i *26*. Ponownie wybieramy *14*, co prowadzi nas do strony zawierającej dane *14, 20, 21, 23*. Teraz wystarczy już tylko odczytać rekord z kluczem *20* i zwrócić go użytkownikowi jako wynik zapytania.

Rysunek 5.2 ilustruje układ struktury FA-Tree bezpośrednio po połączeniu poziomów L_0 i L_1, omawianych w przykładzie na rysunku 5.1. Wcześniej, na poziomie L_0 znajdował się rekord oznaczony do usunięcia o wartości 4, który czekał na usunięcie odpowiadającego mu rzeczywistego rekordu na poziomie L_1. W trakcie scalenia tych dwóch poziomów zignorowaliśmy oba te rekordy i nie zapisaliśmy ich do nowych poziomów. Jako że poziom L_2 pozostał niezmieniony, wszystkie zewnętrzne wskaźniki ze starego poziomu L_1 zachowano bez zmian. Należy zauważyć, że rekord z kluczem *16*, pierwotnie znajdujący się na poziomie L_0, został przeniesiony do L_1. Gdybyśmy go bezpośrednio przekopiowali, stałby się on pierwszym elementem na drugiej stronie nowego poziomu L_1. Aby umożliwić dalsze prawidłowe wyszukiwanie w strukturze, dodaliśmy wewnętrzny wskaźnik do ostatniego wskaźnika na poziomie L_1, czyli wskaźnika *14*, który wskazuje na tę samą stronę. Wartość tego wewnętrznego wskaźnika jest równa wartości pierwszego normalnego rekordu na tej stronie, czyli *16*.

5.2.2 Procedury indeksu FA-Tree

Wstawianie

Aby dodać nowy rekord do drzewa FA-Tree, początkowo rekord jest wstawiany do niewielkiego drzewa B+ znajdującego się w pamięci RAM. Pozwala to uniknąć kosztownych operacji zapisu na pamięci flash przy każdym dodawaniu rekordu, buforując tym samym wszystkie dane w szybkiej pamięci RAM. Gdy drzewo B+ osiąga swoją maksymalną pojemność, jego zawartość jest przesyłana do pamięci flash, co wiąże się z koniecznością reorganizacji poziomów L_0 i L_1. Każdy poziom ma określoną maksymalną pojemność, co oznacza, że reorganizacja poziomów L_0 i L_1 może spowodować przepełnienie poziomu L_1. W takiej sytuacji poziomy L_1 i L_2 są scalane, a proces jest powtarzany rekurencyjnie dla kolejnych poziomów, aż do momentu, gdy poziom, który ma otrzymać dane, dysponuje wolną przestrzenią.

Wyszukiwanie

Struktura FA-Tree umożliwia wyszukiwanie punktowe określonego klucza oraz wyszukiwanie rekordów w określonym zakresie kluczy. W przypadku wyszukiwania punktowego, przechodzimy przez drzewo od góry do dołu, aż do odnalezienia poszukiwanego rekordu. Dzięki temu, że każda strona na danym poziomie zawiera przynajmniej jeden wskaźnik do strony poziomu niższego, możemy przeszukiwać drzewo, wczytując tylko jedną stronę z każdego poziomu. Kierujemy się do strony o największym kluczu spośród tych, które są mniejsze lub równe poszukiwanemu kluczowi, pamiętając, by pomijać rekordy oznaczone jako *Usunięta dana*. Ponieważ nowy rekord oznaczony do usunięcia jest zawsze dodawany na poziomie wyższym niż oryginalny rekord, w przypadku napotkania *Usuniętej danej* o poszukiwanym kluczu, możemy zakończyć wyszukiwanie i poinformować użytkownika, że rekord o danym kluczu został usunięty.

Wyszukiwanie zakresowe przeprowadzane jest w bardzo podobny sposób. Jako klucz wiodący używamy minimalnego klucza z zakresu. To właśnie na jego podstawie przechodzimy przez drzewo. Dodatkowo, na każdym poziomie wczytujemy rekordy znajdujące się na prawo od odwiedzonego rekordu, aż do momentu, gdy napotkamy rekord z kluczem przekraczającym maksymalny klucz zakresu. Postępowanie z danymi oznaczonymi do usunięcia jest takie samo, jak przy wyszukiwaniu punktowym.

Usuwanie

Usuwanie rekordu o określonym kluczu w strukturze FA-Tree nie odbywa się natychmiast, jak to ma miejsce w przypadku drzew B+. Zamiast tego, wstawiamy nowy rekord z kluczem, który zamierzamy usunąć, oznaczając go jako *Usunięta dana*. W trakcie reorganizacji poziomów, gdy napotkamy na oba rekordy: oryginalny i rekord oznaczony do usunięcia, usuwamy je oba. Operacja ta jest realizowana poprzez pominięcie tych rekordów podczas przenoszenia danych ze starych zbiorów do nowego zbioru.

Reorganizacja drzewa

Reorganizacja drzewa inicjowana jest, gdy któryś z poziomów nie dysponuje wolnym miejscem dla nowych elementów. W takiej sytuacji uruchamiany jest proces scalania dwóch poziomów: aktualnego i bezpośrednio znajdującego się poniżej. Jeśli poziom niżej nie istnieje, tworzony jest nowy z odpowiednio dużą pojemnością, K razy większą niż poprzedni poziom. Scalanie poziomów L_i z L_{i+1} przebiega analogicznie do scalania posortowanych list. Tworzymy nowy poziom L'_{i+1} i za każdym razem przenosimy do niego rekordy, wybierając mniejsze z dwóch scalanych poziomów, kontynuując proces aż do pełnego scalenia obu poziomów w jeden. Następnie, usuwane są stare poziomy L_i i L_{i+1}, tworzony jest nowy poziom wyżej L'_i, do którego dodajemy wskaźniki na strony z nowo utworzonego poziomu niższego L'_{i+1}. Podczas reorganizacji uwzględniamy, że jeżeli na poziomie L_i znajduje się rekord z takim samym kluczem, jak rekord na poziomie L_{i+1}, ale oznaczony jako rekord do usunięcia, to pomijamy oba rekordy, nie włączając żadnego z nich do nowego poziomu L'_{i+1}. Może się zdarzyć, że nowy poziom L'_{i+1} również nie będzie dysponował wystarczającą przestrzenią, by pomieścić wszystkie dane. Wówczas proces scalania jest powtarzany dla poziomów L'_{i+1} i L_{i+2}, aż do osiągnięcia poziomu, który jest w stanie pomieścić wszystkie rekordy.

5.2.3 Opis algorytmów

Algorytm scalania poziomów

Algorytm scalania poziomów, przedstawiony w 5.1, stanowi kluczowy element całej struktury. Wprowadzenie leniwego usuwania i buforowania danych umożliwiło minimalizację liczby reorganizacji struktury oraz zapisów na kości flash. Gdy dany poziom jest pełny, wykonujemy scalanie z poziomem znajdującym się poniżej. Linie 1-4 przygotowują strukturę do algorytmu. Ważne jest, aby pamiętać, że każdy poziom składa się z określonej liczby bloków, a nie stron, co różni się od drzew B+ czy LSM. Dzięki temu, podczas tworzenia poziomów, możemy skorzystać z wbudowanego systemu wirtualizacji blokowej pamięci flash. Dodatkowo, usuwając stare poziomy (linie 36-37), w pełni wykorzystujemy operację kasowania, ponieważ nie usuwamy zbędnych stron, które nie należały do naszego poziomu i które wymagałyby przeniesienia w inne miejsce. Cały proces scalania jest bardzo podobny do scalania posortowanych list, dlatego algorytm działa dopóki oba poziomy nie zostaną opróżnione (linie 8-35). Ponieważ niższy poziom L_{i+1} zostanie usunięty i zastąpiony nowym poziomem L'_{i+1}, wszystkie wskaźniki na poziomie L_i staną się nieaktualne. Dlatego w linii 9 pomijamy wszystkie wskaźniki, zarówno zewnętrzne, jak i wewnętrzne. Poziom L_{i+2} pozostaje bez zmian (chyba że rekurencyjnie wywołamy algorytm z linii 35), więc nie możemy usunąć wskaźników zewnętrznych z poziomu L_{i+1}, aby nie utracić dostępu do poziomu L_{i+2}. Wskaźniki wewnętrzne na poziomie L_{i+1} nie

są już potrzebne, ponieważ zostały stworzone tylko, aby spełnić warunek struktury mówiący, że pierwszy rekord na stronie musi być wskaźnikiem. Zmiana układu poziomu L_{i+1}, który zostanie przepisany do L'_{i+1}, spowoduje również zmianę wskaźników wewnętrznych. Jak wspomniano wcześniej, usuwanie elementów nie odbywa się natychmiastowo. Zamiast tego, wstawiamy rekord o tym samym kluczu, oznaczony jako rekord do usunięcia. Gdy podczas scalania poziomów (linie 12-13) napotkamy na parę takich rekordów, usuwamy je, pomijając oba rekordy w algorytmie, co oznacza, że żaden z nich nie zostanie wpisany do nowego poziomu L'_{i+1}. Linie 15-22 są odpowiedzialne za wybór minimalnego klucza z obu poziomów oraz przesunięcie wskaźnika na kolejny rekord. W przypadku poziomu L_{i+1}, musimy także zapamiętać ostatni wskaźnik zewnętrzny. Będzie on niezbędny do stworzenia nowego wskaźnika wewnętrznego na poziomie L'_{i+1} (linie 29-32). Przed wstawieniem nowego rekordu do poziomu L'_{i+1} (linia 33), musimy upewnić się, czy nasza struktura jest prawidłowa. W związku z tym, jeśli zamierzamy wstawić rekord do nowej, pustej strony, musimy najpierw dodać wskaźnik do tej strony do poziomu L'_i, aby umożliwić dostęp do poziomu L'_{i+1}.

5.2.4 Analiza kosztu wstawiania rekordu

W tej sekcji skupimy się na analizie algorytmu wstawiania nowego rekordu do drzewa FA oraz porównaniu go do złożoności obliczeniowej dodawania rekordu do drzewa B+. Nie będziemy analizować procesu wyszukiwania, ponieważ jest on realizowany w obu strukturach w podobny sposób, wynikający z ich architektury. W każdym z drzew odczyt jednej strony na poziomie jest wystarczający, co sprawia, że koszt wyszukiwania w obu przypadkach ma charakter logarytmiczny. Tabela 5.1 przedstawia asymptotyczną złożoność operacji wyszukiwania i wstawiania dla struktur drzewa FA i drzewa B+. Jak można zauważyć, wszystkie operacje mają złożoność logarytmiczną.

Twierdzenie 5.1 *Niech T oznacza amortyzowany czas wstawiania elementu do drzewa FA wynosi, wtedy:*

$$T = \mathrm{O}\left(\frac{K}{P_{cap} - K} \cdot \log n\right),$$

gdzie
K - współczynnik pojemności 2 poziomów ($K = \frac{|L_{i+1}|}{|L_i|}$),
$P_{cap} = \left\lceil \frac{P_{size}}{R_{size}} \right\rceil$ - liczba rekordów możliwych do zapisania na stronie

Dowód. Zanim przejdziemy do pełnej analizy złożoności obliczeniowej wstawiania rekordów do struktur FA-Tree, ustalmy pewne oznaczenia

- n - liczba wstawianych danych (rekordów)
- R_{size} - rozmiar rekordu wyrażony w bajtach
- P_{size} - rozmiar strony wyrażony w bajtach
- $P_{cap} = \left\lceil \frac{P_{size}}{R_{size}} \right\rceil$ - liczba rekordów możliwych do zapisania na stronie
- L_i^j - liczba danych na poziomie i zaraz po skończeniu scalania j
- W_{cost} - koszt zapisu pojedynczej strony
- R_{cost} - koszt odczytu pojedynczej strony

Pseudokod 5.1: faLevelMerge(L_i, L_{i+1})

```
1  if L_{i+1} nie istnieje then
2      Stwórz pusty poziom L_{i+1} z pojemnością L_i.capacity · K
3  Stwórz pusty poziom L'_i z pojemnością L_i.capacity
4  Stwórz pusty poziom L'_{i+1} z pojemnością L_{i+1}.capacity
5
6  Niech r_i będzie pierwszym rekordem z poziomu L_i
7  Niech r_{i+1} będzie pierwszym rekordem z poziomu L_{i+1}
8  while L_i AND L_{i+1} są niepuste do
       // Poziom L_{i+1} będzie tworzony na nowo, możemy pominąć wszystkie wskaźniki
9      Pomiń wszystkie zewnętrzne i wewnętrzne wskaźniki w L_i
       // Poziom L_{i+2} zostaje, zatem zewnętrzne wskaźniki również muszą pozostać
10     Pomiń wszystkie wewnętrzne wskaźniki w L_{i+1}
11
       // Usuń rekordy do usunięcia
12     while r_i.type = RECORD_TO_DELETE AND r_{i+1}.type =
        RECORD_NORMAL AND r_i.key = r_{i+1}.key do
13         Pomiń oba rekordy r_i oraz r_{i+1}
14
       // Weź minimum z obu poziomów
15     if r_i.key < r_{i+1}.key then
16         recordToInsert := r_i
17         Niech r_i będzie następnym rekordem z poziomu L_i
18     else
19         recordToInsert := r_{i+1}
20         if r_{i+1}.type = RECORD_EXTERNAL_FENCE then
21             lastFence := r_{i+1}
22         Niech r_{i+1} będzie następnym rekordem z poziomu L_{i+1}
23
24     if Obecna strona P poziomu L'_{i+1} jest pusta then
           // Każda nowa strona musi być wskazywana przez jakiś wskaźnik wyżej
25         external.pid := P
26         external.key := recordToInsert.key
27         Wpisz external do L'_i
28
           // Pierwszy rekord na stronie, musi być wskaźnikiem
29         if recordToInsert.type <> RECORD_EXTERNAL_FENCE then
30             internal.pid := lastFence.pid
31             internal.key := recordToInsert.key
32             Wpisz internal do L'_{i+1}
33     Wpisz recordToInsert do poziomu L'_{i+1}
34     if L'_{i+1} nie ma już wolnego miejsca then
35         faLevelMerge(L'_{i+1}, L_{i+2})
36 Zamień stary poziom L_i na nowy poziom L'_i
37 Zamień stary poziom L_{i+1} na nowy poziom L'_{i+1}
```

	Koszt wyszukiwania	**Koszt wstawiania**	
Struktura danych	**Odczyt**	**Odczyt**	**Zapis**
FA-Tree	$O(\log n)$	$O\left(\frac{K}{P_{cap}-K} \cdot \log n\right)$	$O\left(\frac{K}{P_{cap}-K} \cdot \log n\right)$
B+-Tree	$O(\log n)$	$O(\log n)$	$O(\log n)$

Tabela 5.1: Koszt operacji WE/WY

- FA_{height} - liczba poziomów drzewa FA
- K - współczynnik pojemności 2 poziomów ($K = \frac{|L_{i+1}|}{|L_i|}$)
- m_i - liczba wywołań algorytmu scalania po n danych dla poziomu i
- N_i^{write} - sumaryczna liczba danych do zapisania podczas m_i scaleń dla poziomu i
- N_i^{read} - sumaryczna liczba danych do wczytania podczas m_i scaleń dla poziomu i
- t_{insert} - czas potrzebny na dodanie n element i przeprowadzenie m_i scaleń dla każdego poziomu i

Zacznijmy od rzeczy prostych. Wiemy że wskaźników wewnętrznych jest maksymalnie tyle ile stron na danym poziomie.

$$|internal_i| = \left\lceil \frac{|L_i|}{P_{cap}} \right\rceil$$

Analogicznie, wskaźników zewnętrznych jest dokładnie tyle ile stron na niższym poziomie.

$$|external_i| = \left\lceil \frac{|L_{i+1}|}{P_{cap}} \right\rceil$$

Wiemy, że zaraz po wykonaniu algorytmu scalania nowy poziom wyższy ma tylko wskaźniki zewnętrzne, stąd:

$$|L_{i-1}^j| = |external_{i-1}| \qquad j > 0$$

$$|L_{i-1}^j| = \left\lceil \frac{|L_i|}{P_{cap}} \right\rceil \qquad j > 0$$

Spróbujmy oszacować koszt zapisu dla poziomu i. Scalanie przepisuje dane z obu poziomów do nowych poziomów. Zatem, koszt scalania to sumaryczny koszt zapisów danych dla obu poziomów zaraz po zakończeniu scalania.

$$N_i^{write} = \sum_{j=1}^{m_i} (|L_i|^j + |L_{i-1}^j|)$$

Wiemy, że poziom L_{i-1} zawiera tylko wskaźniki zewnętrzne. Na podstawie ich liczby możemy oszacować ile było danych poniżej.

$$|L_i^j| = |external_{i-1}| \cdot P_{cap}$$

Zatem mamy:

$$N_i^{write} = \sum_{j=1}^{m_i} (|external_{i-1}| \cdot P_{cap} + |L_{i-1}^j|)$$

$$N_i^{write} = \sum_{j=1}^{m_i} (|L_{i-1}^j| \cdot P_{cap} + |L_{i-1}^j|)$$

$$N_i^{write} = \sum_{j=1}^{m_i} ((1 + P_{cap}) \cdot |L_{i-1}^j|)$$

$$N_i^{write} = (1 + P_{cap}) \cdot \sum_{j=1}^{m_i} |L_{i-1}^j| \tag{5.1}$$

Załóżmy teraz, że wszystkie rekordy n zostały scalone do najniższego poziomu. Musiały zatem zostać skopiowane do poziomu L_{i-1}, a później do L_i gdy poziom L_{i-1} był pełen.

$$n = \sum_{j=1}^{m_i} (|L_{i-1}| - |external_{i-1}^j|)$$

$$n = \sum_{j=1}^{m_i} (|L_{i-1}| - |L_{i-1}^j|)$$

$$n = m_i \cdot |L_{i-1}| - \sum_{j=1}^{m_i} |L_{i-1}^j|$$

$$n = m_i \cdot |L_{i-1}| - \sum_{j=1}^{m_i} \left\lceil \frac{|L_i^j|}{P_{cap}} \right\rceil$$

$$\sum_{j=1}^{m_i} |L_{i-1}^j| = (m_i \cdot |L_{i-1}| - n) \tag{5.2}$$

Łącząc ze sobą 5.1 z 5.2 dostajemy:

$$N_i^{write} = (1 + P_{cap}) \cdot (m_i \cdot |L_{i-1}| - n) \tag{5.3}$$

Spróbujmy przeprowadzić podobne rozumowanie dla liczby odczytów podczas scalania obu poziomów. Aby przeprowadzić scalanie musimy odczytać oba poziomu, mają one tyle danych ile wpisaliśmy po zakończeniu poprzedniego scalania, stąd:

$$N_i^{read} = \sum_{j=1}^{m_i} (|L_{i-1}^{j-1}| + |L_i^{j-1}|)$$

Spróbujmy teraz wyrazić N_i^{read} za pomocą N_i^{write}. Skorzystajmy z faktu, że możemy założyć, iż liczba danych na poziomie i po scaleniu j jest równa sumie 2 poziomów utworzonych po poprzednim scaleniu

$$|L_{i-1}^{j}| = |L_{i-1}^{j-1}| + |L_{i}^{j-1}|$$

Dzięki temu, możemy łatwo wyrazić N_i^{read} za pomocą N_i^{write}.

$$N_i^{write} = \sum_{j=1}^{m_i} (|L_{i-1}^{j}| + |L_i^{j}|)$$

$$N_i^{write} = \sum_{j=1}^{m_i} (|L_{i-1}^{j-1}| + |L_i^{j-1}| + |L_i^{j}|) \tag{5.4}$$

$$N_i^{read} = N_i^{write} - \sum_{j=1}^{m_i} |L_{i-1}^{j}|$$

$$N_i^{read} = N_i^{write} - \frac{n}{P_{cap}} \tag{5.5}$$

Jak widać odczytujemy mniej danych, ponieważ nie musimy odczytywać nowych wskaźników zewnętrznych na poziomie L_{i-1}^{j}.

Możemy teraz oszacować czas potrzebny na scalanie wszystkich poziomów. Zanim to zrobimy, warto znać górne ograniczenie na liczbę scaleń. Wiemy, że scaleń było tyle ile stosunek wszystkich wstawianych danych n do liczby rekordów, jakie może pomieścić dany poziom. Biorąc pod uwagę, że nie wszystkie rekordy to dane użytkownika dostajemy:

$$m_i < \frac{n}{|L_{i-1}| - \frac{|L_{i-1}|}{P_{cap}} - -\frac{|L_i|}{P_{cap}}}$$

$$m_i < \frac{P_{cap}}{P_{cap} - K - 1} \cdot \frac{n}{|L_{i-1}|}$$

Teraz w końcu jesteśmy gotowi aby oszacować czas potrzebny na wstawianie wszystkich elementów n oraz wszystkich reorganizacji poziomów. Użyjemy do tego czasy amortyzowanego:

$$t_{insert} = \frac{1}{n} \cdot \sum_{i=1}^{FA_{height}-1} (\frac{R_{size} \cdot N_i^{write}}{W_{cost}} + \frac{R_{size} \cdot N_i^{read}}{R_{cost}})$$

$$t_{insert} < \frac{W_{cost} + R_{cost}}{W_{cost} \cdot R_{cost}} \cdot P_{size} \sum_{i=1}^{FA_{height}-1} (\frac{m_i \cdot |L_{i-1}|}{n} - 1)$$

$$t_{insert} < \frac{W_{cost} + R_{cost}}{W_{cost} \cdot R_{cost}} \cdot P_{size} \sum_{i=1}^{FA_{height}-1} (\frac{P_{cap}}{P_{cap} - K - 1} - 1) \tag{5.6}$$

	Pojemność		Prędkość		
Model	Strony	Bloku	Odczytu	Zapisu	Kasowania
Samsung K9F1G08U0D	2 KB	64 KB	58 MB/s	8 MB/s	1 MB/s
Micron MT29F32G08ABAAA	8 KB	1 MB	234 MB/s	23 MB/s	5 MB/s
Micron MT29F32G08CBEDBL83A3WC1	4 KB	512 KB	81 MB/s	4,5 MB/s	1,1 MB/s

Tabela 5.2: Wybrane modele pamięci flash

Wiemy, że wysokość trzeba FA_{height} jest logarytmiczna, uzależniona od współczynnika K oraz wielkości drzewa B+ w RAM czyli poziomu L_0. Wynosi więc ona:

$$FA_{height} = \left\lceil \frac{\log_K n}{|L_0|} \right\rceil$$

Możemy zatem przepisać nierówność 5.6, używając powyższej nierówności. Dostajemy:

$$t_{insert} < \frac{W_{cost} + R_{cost}}{W_{cost} \cdot R_{cost}} \cdot \frac{K+1}{P_{cap} - K - 1} \cdot 1) \cdot P_{size} \cdot \left\lceil \frac{\log_K n}{|L_0|} \right\rceil$$

$$t_{insert} = \mathrm{O}\left(\frac{K}{P_{cap} - K} \cdot \log n \right) \tag{5.7}$$

♦

5.2.5 Eksperymenty

W tej części rozdziału przedstawimy i przeanalizujemy eksperymenty wykonane za pomocą symulatora SIPS, opisanego dokładnie w rozdziale 4. Do eksperymentów wybrano trzy kości flash typu NAND o różnych charakterystykach. Tabela 5.2 zawiera szczegółowe parametry wybranych modeli. Kość Samsung K9F1G08U0D wyróżnia się niską pojemnością strony (2 KB) i bloku (64 KB) oraz stosunkowo małą prędkością odczytu (58 MB/s). Micron MT29F32G08CBEDBL83A3WC1 charakteryzuje się większą pojemnością strony (4 KB) i bloku (512 KB), jednak prędkość usuwania bloku jest porównywalna z kością Samsunga. Pomimo szybkiego odczytu (81 MB/s), ten model pamięci odznacza się bardzo wolnym zapisem, wynoszącym zaledwie 4,5 MB/s, co podkreśla typową dla kości flash asymetrię między szybkościami zapisu i odczytu. Wybrano również kość Micron MT29F32G08ABAAA, która cechuje się znakomitymi parametrami. Wysokie prędkości odczytu i zapisu to nie jedyne atuty tego modelu. Pomimo dużego bloku o pojemności 1 MB, prędkość kasowania jest pięciokrotnie wyższa niż u pozostałych modeli z zestawienia i wynosi 5 MB/s. Eksperymenty przeprowadzono na dwóch tabelach z popularnego zestawu kwerend TPC-C [13], który został szczegółowo opisany w rozdziale 4.

Podstawowy zestaw kwerend

Podstawowy zestaw kwerend imituje proste wykorzystanie bazy danych, podobne do zastosowań typowych struktur danych. Takie wzorce kwerend są często używane przez

Nazwa kolumny	Rozmiar kolumny
W_ID	8 B
W_NAME	10 B
W_STREET_1	20 B
W_STREET_2	20 B
W_CITY	20 B
W_STATE	2 B
W_ZIP	9 B
W_TAX	8 B
W_YTD	16 B

Tabela 5.3: Sklep TPC-C

Nazwa kolumny	Rozmiar kolumny
NO_O_ID	8 B
NO_D_ID	4 B
NO_W_ID	8 B

Tabela 5.4: Nowe Zamówienie TPC-C

użytkowników urządzeń wbudowanych, gdzie indeks funkcjonuje jako pojedyncza instancja struktury danych, oferując prosty interfejs użytkownika, bez obecności silnika bazy danych. W zestawach rozróżniamy trzy typy operacji: wstawianie, wyszukiwanie i usuwanie, z każdą operacją przeprowadzaną na pojedynczym rekordzie. Tym samym, wyszukiwanie nie obejmuje selektywności jako parametru i jest to wyszukiwanie punktowe, które dla podanego klucza zwraca rekord zapisany w indeksie lub informację o błędzie, gdy rekord nie zostanie znaleziony. Podstawowy zestaw kwerend zawiera trzy wzorce o różnej charakterystyce:

1. ZP_{zapis} - 60% operacji wstawiania pojedynczego rekordu, 20% operacji wyszukiwania pojedynczego rekordu za pomocą klucza, 20% operacji usuwania pojedynczego rekordu,
2. ZP_{odczyt} - 15% operacji wstawiania pojedynczego rekordu, 80% operacji wyszukiwania pojedynczego rekordu za pomocą klucza, 5% operacji usuwania pojedynczego rekordu,
3. ZP_{balans} - 37.5% operacji wstawiania pojedynczego rekordu, 50% operacji wyszukiwania pojedynczego rekordu za pomocą klucza, 12.5% operacji usuwania pojedynczego rekordu.

W serii eksperymentów skoncentrowaliśmy się na tabeli *Sklep* (5.3), która charakteryzuje się wielkością rekordu wynoszącą 113 B. Analizie poddaliśmy indeksy: drzewo B+, drzewo LSM oraz naszą nową propozycję - indeks FA. Przy czym warto zauważyć, że drzewo B+ jest najczęściej stosowanym indeksem. Struktura LSM, wymagająca dodatkowej przestrzeni w pamięci RAM do przechowywania danych, rzadziej znajduje zastosowanie w urządzeniach wbudowanych. Indeks FA wykorzystywał bufor w pamięci RAM do przechowywania danych poziomu L_0, których wielkość odpowiadała pojemności jednego bloku flash. Analogicznie, indeks LSM również korzystał z bufora tej samej wielkości dla tymczasowego przechowywania danych przed ich przesłaniem do poziomu L_1. Ponadto, wykorzystano dodatkowy bufor o pojemności 1MB przeznaczony na $SSTableMap$. Kwerendy w ramach zestawów zostały przeprowadzone przy użyciu 100 tys. operacji. Dla zestawuZP_{zapis} wykonano 60 tys. operacji wstawiania, 20 tys. punktowych wyszukiwań pojedynczego rekordu, a następnie 20 tys. operacji usuwania losowych rekordów z tabeli. Stan początkowy tabeli był pusty.

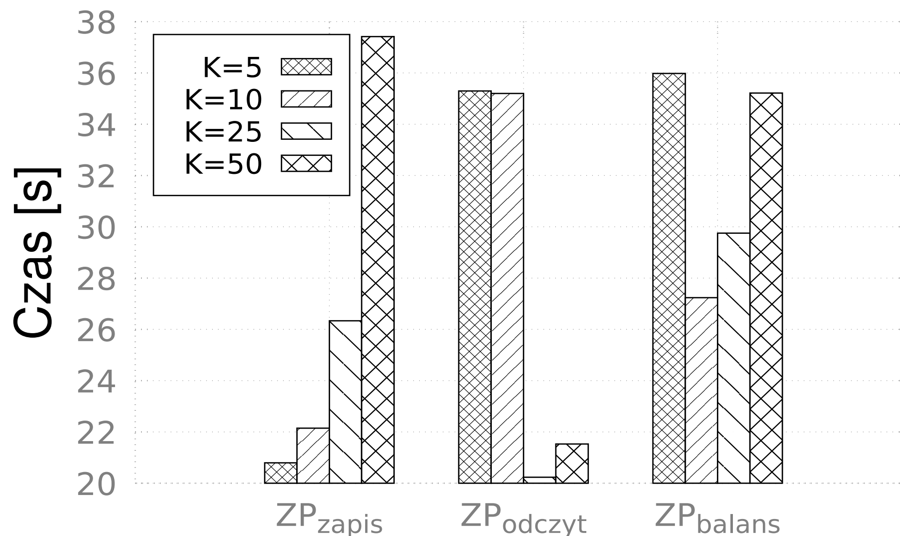

Rysunek 5.3: Czas wykonania 100 tys. operacji dla różnych parametrów drzewa FA
Flash: Samsung K9F1G08U0D
Tabela: Sklep (113 B)

Przed omówieniem porównania indeksu FA z indeksami B+ oraz LSM, skupimy się na wpływie kluczowego parametru systemu FA, czyli parametru K. Ten współczynnik określa stosunek pojemności między kolejnymi poziomami. Dla przykładu, gdy K jest równy 5, każdy następny poziom ma 5 razy większą pojemność niż poprzedni. Konfiguracja systemu bezpośrednio wpływa na szybkość wykonywania operacji. Na podstawie rysunku 5.4 można stwierdzić, że im wyższe K, tym wolniejsze są operacje wstawiania, lecz szybsze wyszukiwanie. Jest to spowodowane bezpośrednim wpływem K na wysokość drzewa. Większe K skutkuje niższym drzewem, co oznacza mniej poziomów do przeszukania w celu znalezienia rekordu. W efekcie, mniejsze K prowadzi do wyższego drzewa i wolniejszego wyszukiwania. Podczas wstawiania obserwujemy sytuację odwrotną; niższe drzewo oznacza mniej, lecz większe poziomy, co zwiększa czas potrzebny na pojedynczą reorganizację. Należy zauważyć, że K nie wpływa na rozmiar bufora (poziomu L_0), więc jeśli poziom L_1 jest duży, każde scalenie L_0 z L_1 wymaga przepisania dużej liczby rekordów, co wydłuża czas wstawiania. Warto również zwrócić uwagę, że parametr K wpływa na topologię drzewa. W trakcie eksperymentów wykonujemy stałą liczbę operacji, co może prowadzić do różnej liczby reorganizacji w zależności od struktury drzewa. Dlatego w zestawie ZP_{balans} trend rosnący jest widoczny dopiero od wartości $K = 10$. Otrzymując podobne wyniki dla wszystkich trzech modeli pamięci, pomimo ich różnorodnych charakterystyk, w pracy przedstawiono jedynie wyniki dla modelu Samsung K9F1G08U0D, opisane na rysunku 5.4. Oznacza to, że parametry takie jak wielkość strony, bloku oraz czasy zapisu i odczytu nie wpływają na obserwowaną zmianę zachowania spowodowaną modyfikacją parametru K. Dzięki temu, indeks można dostosować do przewidywanego zestawu kwerend, a nie do specyfikacji modelu pamięci. W sytuacji, gdy dominują operacje zapisu, zaleca się ustawienie K na niską wartość, natomiast w przypadku przewagi odczytów, K powinno być ustalone na wyższym poziomie (np. 25). Biorąc pod uwagę, że zapis w pamięci flash jest relatywnie wolny, należy skoncentrować się na optymalizacji tej operacji. Z tego powodu, w dalszych eksperymentach, parametr K został ustalony na wartość 5.

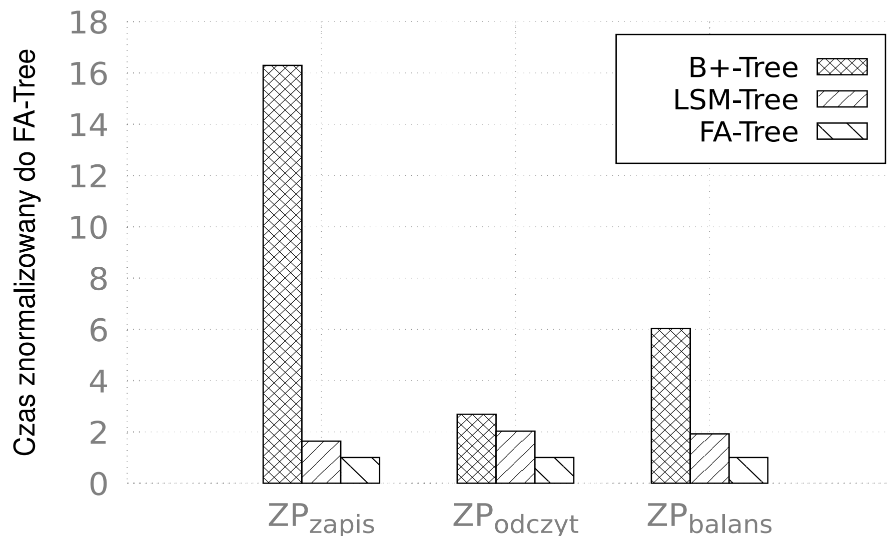

Rysunek 5.4: Znormalizowany czas dla 100 tys. operacji
Flash: Samsung K9F1G08U0D
Tabela: Sklep (113 B)

Zestaw	B+-Tree	LSM-Tree	FA-Tree
ZP_{zapis}	338,86 s	34,09 s	20,79 s
ZP_{odczyt}	94,93 s	71,7 s	35,29 s
ZP_{balans}	216,9 s	68,23 s	35,98 s

Tabela 5.5: Czas wykonania 100 tys. operacji
Flash: Samsung K9F1G08U0D
Tabela: Sklep (113 B)

Zestaw	B+-Tree	LSM-Tree	FA-Tree
ZP_{zapis}	644,26 s	29,61 s	23,6 s
ZP_{odczyt}	171,19 s	49,01 s	37,01 s
ZP_{balans}	409,31 s	61,03 s	46,03 s

Tabela 5.6: Czas wykonania 100 tys. operacji
Flash: Micron MT29F32G08CBEDBL83A3WC1
Tabela: Sklep (113 B)

Zestaw	B+-Tree	LSM-Tree	FA-Tree
ZP_{zapis}	271,06 s	15,76 s	12,96 s
ZP_{odczyt}	75,54 s	30,9 s	25,31 s
ZP_{balans}	173,39 s	19,88 s	16,38 s

Tabela 5.7: Czas wykonania 100 tys. operacji
Flash: Micron MT29F32G08ABAAA
Tabela: Sklep (113 B)

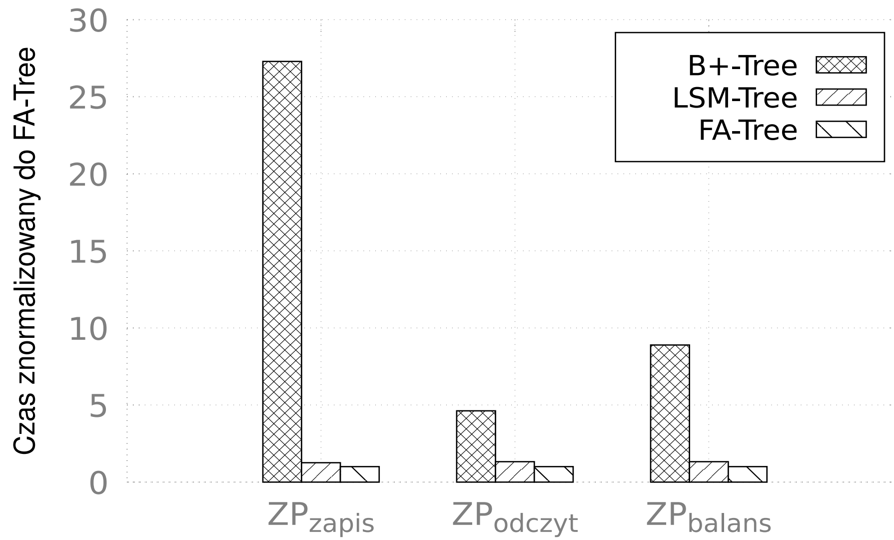

Rysunek 5.5: Znormalizowany czas dla 100 tys. operacji
Flash: Micron MT29F32G08CBEDBL83A3WC1
Tabela: Sklep (113 B)

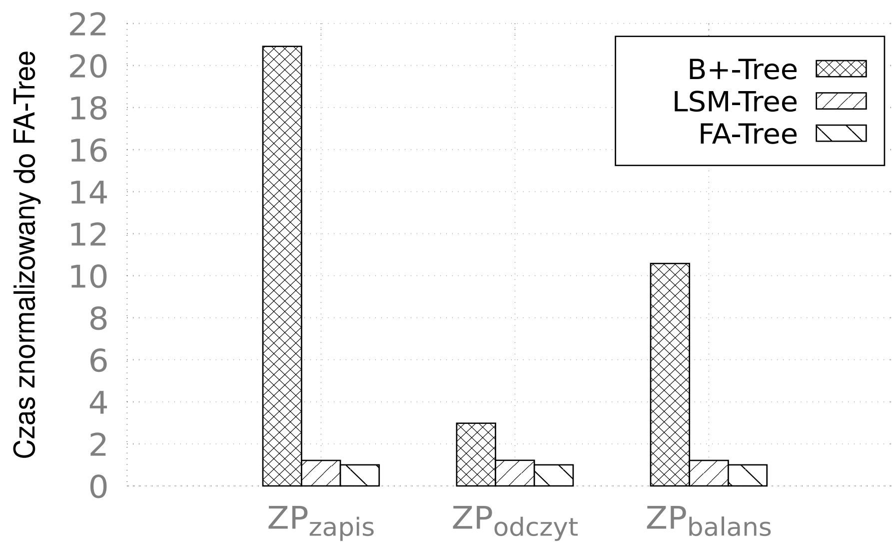

Rysunek 5.6: Znormalizowany czas dla 100 tys. operacji
Flash: Micron MT29F32G08ABAAA
Tabela: Sklep (113 B)

Zestaw	B+-Tree	LSM-Tree	FA-Tree
ZP_{zapis}	301 MB	59 MB	59 MB
ZP_{odczyt}	75 MB	12 MB	12 MB
ZP_{balans}	188 MB	32 MB	32 MB

Tabela 5.8: Zużycie pamięci po 100 tys. operacji
Flash: Samsung K9F1G08U0D
Tabela: Sklep (113 B)

Tabele 5.5, 5.6, i 5.7 prezentują szczegółowe wyniki czasowe osiągnięte przez indeksy podczas realizacji zestawu kwerend, odpowiednio dla kości Samsung K9F1G08U0D, Micron MT29F32G08CBEDBL83A3WC1 i Micron MT29F32G08ABAAA. Obserwując te wyniki, zauważamy, że chociaż parametry techniczne kości flash wpływają na czas realizacji kwerend, nie zmieniają one ogólnego trendu obserwowanego w wynikach. W każdym przypadku indeks B+ był najwolniejszy, za nim uplasował się LSM, a najwyższą wydajność prezentował indeks FA. Rysunki 5.4, 5.5, i 5.6 pokazują wyniki tych samych eksperymentów co odpowiadające im tabele, lecz zamiast bezwzględnych wartości czasowych, prezentują czas znormalizowany względem wyników uzyskanych przez indeks FA (wartość dla indeksu FA jest zawsze równa 1). Takie porównanie pozwala łatwo ocenić, jak nowa struktura FA wypada na tle innych analizowanych struktur danych.

Analizując tę serię eksperymentów, dochodzimy do wniosku, że drzewo B+ nie jest dostosowane do pamięci blokowej charakteryzującej się asymetrią kosztów zapisu i odczytu. W zestawach ZP_{zapis} i ZP_{balans} czas realizacji zapytań okazuje się najdłuższy. Jest to spowodowane tym, że choć drzewo B+ cechuje się efektywnym czasem wyszukiwania, czas potrzebny na zapis nowych rekordów jest znacząco wydłużony. Każdy nowy rekord wymaga potencjalnej reorganizacji węzła, a nieraz również wyższych poziomów drzewa. Taka reorganizacja wiąże się z koniecznością kasowania i ponownego zapisywania bloków danych, co sprawia, że wstawianie pojedynczych rekordów nie jest efektywne dla tego typu pamięci. Na kości flash Micron MT29F32G08CBEDBL83A3WC1, charakteryzującej się najwolniejszym zapisem w naszej analizie, drzewo B+ było aż 28 razy wolniejsze od indeksu FA. Podobnie, korzystając z najszybszej kości Micron MT29F32G08ABAAA, drzewo B+ realizowało zestaw kwerend ZP_{zapis} 17 razy wolniej w porównaniu do drzewa FA. Struktura LSM, choć dostosowana do pamięci blokowych jak dyski HDD, kości flash, czy dyski SSD, ze względu na swoją wewnętrzną topologię, zoptymalizowana jest przede wszystkim pod kątem efektywnego wstawiania, usuwania rekordów oraz wyszukiwania zakresowego. W niniejszej serii eksperymentów do wyszukiwania wykorzystano operację punktowego wyszukiwania, która jest efektywnie realizowana przez indeksy B+ i FA, ale nie przez LSM. Dlatego, pomimo efektywnego wstawiania rekordów, indeks LSM jest wolniejszy od struktury FA we wszystkich modelach flash. Na przykład, na kości Micron MT29F32G08CBEDBL83A3WC1 zestaw ZP_{zapis} został zrealizowany o 25% wolniej niż przez FA, zestaw ZP_{balans} o 32% wolniej, a zestaw ZP_{odczyt} nawet o 35% wolniej.

Poza czasem wykonania kwerend ważne jest również zwrócenie uwagi na zużycie pamięci. Sposób, w jaki algorytm wykorzystuje pamięć, bezpośrednio wpływa na trwałość kości flash. Mniejsza liczba operacji zapisu i kasowania przekłada się na mniejsze zużycie pamięci i dłuższą żywotność. Symulator SIPS dostarcza nam przybliżone informacje na temat zużycia kości flash. Tabele 5.8, 5.9, 5.10 prezentują przybliżoną ilość megabajtów, jaką indeksy zapisywały lub nadpisywały na modelach flash: Samsung K9F1G08U0D,

Zestaw	B+-Tree	LSM-Tree	FA-Tree
ZP_{zapis}	588 MB	28 MB	28 MB
ZP_{odczyt}	147 MB	4 MB	4 MB
ZP_{balans}	367 MB	15 MB	15 MB

Tabela 5.9: Zużycie pamięci po 100 tys. operacji
Flash: Micron MT29F32G08CBEDBL83A3WC1
Tabela: Sklep (113 B)

Zestaw	B+-Tree	LSM-Tree	FA-Tree
ZP_{zapis}	1161 MB	23 MB	23 MB
ZP_{odczyt}	290 MB	2 MB	2 MB
ZP_{balans}	726 MB	13 MB	13 MB

Tabela 5.10: Zużycie pamięci po 100 tys. operacji
Flash: Micron MT29F32G08ABAAA
Tabela: Sklep (113 B)

Micron MT29F32G08CBEDBL83A3WC1, Micron MT29F32G08ABAAA. Zauważamy, że drzewo B+ nadpisuje nawet do 50 razy więcej pamięci niż drzewa LSM i FA, co wynika z algorytmu wstawiania. Drzewo B+ dodaje rekordy pojedynczo, co każdym razem wymaga reorganizacji całego węzła. Drzewa LSM i FA korzystają z małego bufora i dzięki algorytmowi scalania poziomów, wprowadzają wiele rekordów jednocześnie, minimalizując liczbę zużytej pamięci. Porównując wyniki, możemy zauważyć, że podobne strategie dodawania i usuwania rekordów w indeksach LSM i FA dają bardzo zbliżone rezultaty, różniące się nie więcej niż o 1%. Ponadto, im większe bloki i strony, tym wyraźniejsza przewaga drzewa FA nad B+. Na modelu Micron MT29F32G08ABAAA z rozmiarem strony 8 KB, B+ nadpisuje 50 razy więcej pamięci niż FA. Natomiast na modelu Samsung K9F1G08U0D o rozmiarze strony 2 KB, indeks B+ nadpisał tylko 6 razy więcej bajtów niż indeks FA. Wynika to z adaptacji indeksów do modeli pamięci. Drzewo B+ ma rozmiar węzła równy rozmiarowi strony lub bloku (w zależności od konfiguracji, w eksperymentach był to rozmiar strony), co oznacza, że większa strona wymaga przepisania większej ilości bajtów podczas wstawiania rekordu. W przypadku indeksów FA i LSM, ich struktura wymaga, aby bufor (poziom L_0) miał przynajmniej wielkość bloku kości flash, co oznacza, że większy blok prowadzi do większego bufora i mniej częstych reorganizacji poziomów. Na przykład, na modelu Samsung K9F1G08U0D drzewo FA nadpisało 59 MB w zestawie ZP_{zapis}, a na modelu Micron MT29F32G08ABAAA tylko 23 MB w tym samym zestawie.

Rozszerzony zestaw kwerend

Zestaw rozszerzony, opracowany na bazie kwerend z TPC-C, ma za zadanie symulować operacje typowe dla hurtowni danych, gdzie akcje są buforowane i realizowane na licznych rekordach. W odróżnieniu od zestawu podstawowego, w tym przypadku stosujemy operację masowego wstawiania danych (ang. *bulkload*), jeśli dana struktura indeksu na to pozwala. Jeżeli nie, wstawianie odbywa się metodą pojedynczych wpisów. Indeksy FA oraz LSM w pewnym sensie obsługują operację `bulkload` dzięki wbudowanemu buforowi, co umożliwia dodawanie wielu rekordów w sposób równie efektywny, jak dodawanie pojedynczych wpisów. Jest to znacząca przewaga tych struktur. Z kolei drzewo B+ nie oferuje tej funkcjonalności, gdy struktura nie jest pusta, co wymusza stosowanie standar-

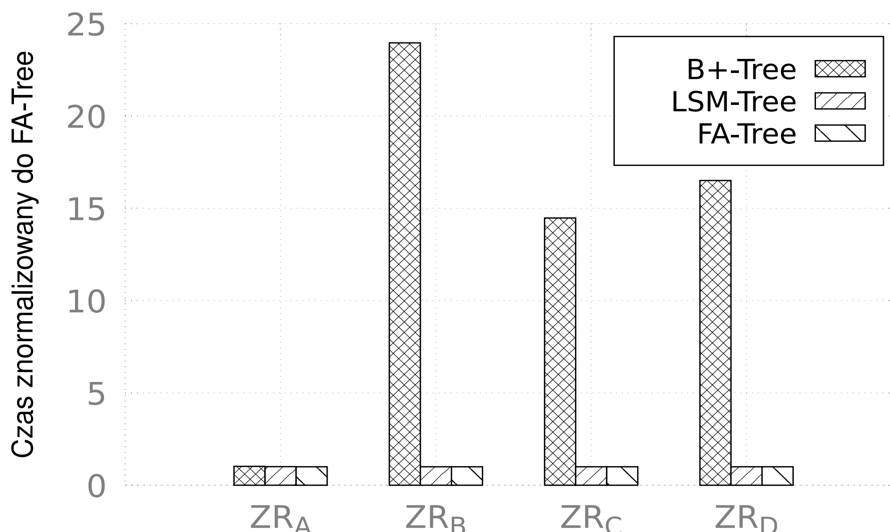

Rysunek 5.7: Znormalizowany czas
Flash: Samsung K9F1G08U0D
Tabela: Sklep (113 B)

dowego sposobu wstawiania. W odróżnieniu od zestawu podstawowego, tutaj stosujemy wyszukiwanie zakresowe zamiast punktowego. Selekcja każdego zapytania ustawiona jest na 1% całości tabeli, co oznacza, że zakres kluczy dobierany jest w taki sposób, aby wynik wyszukiwania stanowił w przybliżeniu 1% wszystkich rekordów. Podobnie jak zestaw podstawowy, także i rozszerzony podzielony jest na serie operacji. Każda seria rozpoczyna się od dodawania rekordów, po czym następuje wyszukiwanie, a na końcu usuwanie wpisów. Analizując charakterystykę szerokiego zakresu kwerend TPC-C oraz ich uproszczenie do kluczowych operacji na indeksach na pojedynczej tabeli, opracowano cztery różne zestawy kwerend, szczegółowo omówione w rozdziale 4.

1. ZR_{A} - 100 serii, każda seria zawiera operacje dodawania 5 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 5 rekordów,
2. ZR_{B} - 5 serii, każda seria zawiera operacje dodawania 100 000 rekordów, 5 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 100 000 rekordów,
3. ZR_{C} - 10 serii, każda seria zawiera operacje dodawania 10 000 000 rekordów, 20 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 1 000 000 rekordów,
4. ZR_{D} - 10 serii, każda seria zawiera operacje dodawania 1 000 000 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 10 000 rekordów.

Rozszerzony zestaw kwerend sprawdza się o wiele lepiej na tabelach zawierających już rekordy. Dlatego też początkowo indeksy będą zawierać 10 mln rekordów.

Tabele 5.11, 5.12 oraz 5.13 prezentują szczegółowe wyniki czasowe uzyskane przez indeksy w trakcie realizacji zestawu rozszerzonego kwerend na kościach flash Samsung K9F1G08U0D, Micron MT29F32G08CBEDBL83A3WC1 oraz Micron MT29F32G08ABAAA. Można zauważyć, że niezależnie od modelu pamięci, czas wykonania operacji na indeksach LSM i FA jest bardzo zbliżony, różnica wynosi mniej niż 1%. Jest to efekt podobieństwa w strukturze i mechanizmach działania obu indeksów, które prze-

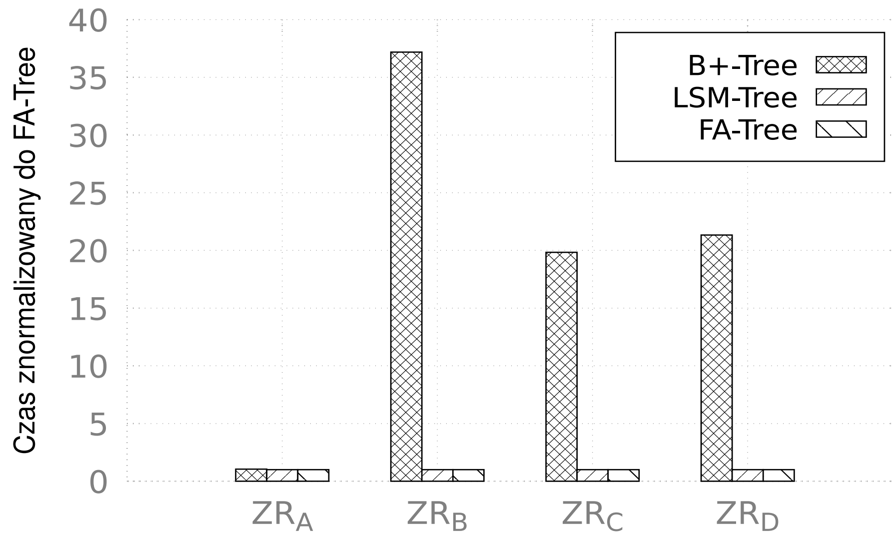

Rysunek 5.8: Znormalizowany czas
Flash: Micron MT29F32G08CBEDBL83A3WC1
Tabela: Sklep (113 B)

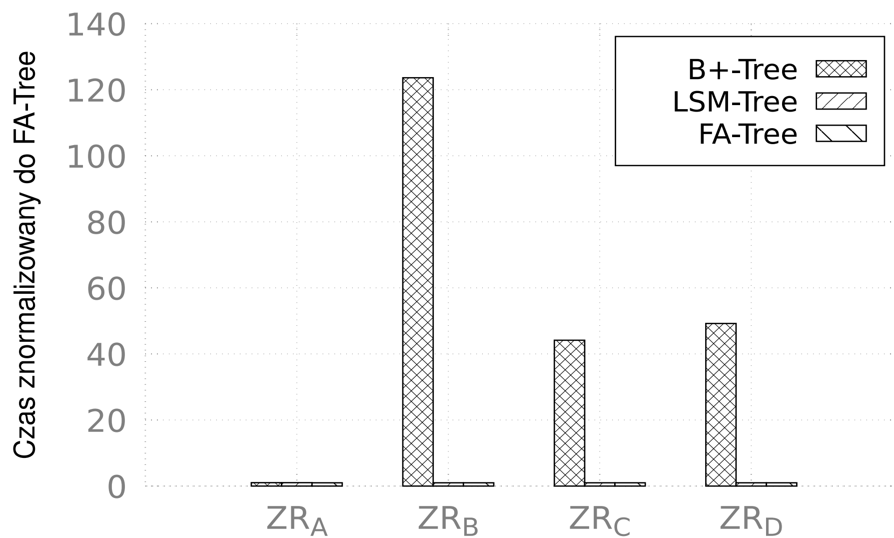

Rysunek 5.9: Znormalizowany czas
Flash: Micron MT29F32G08ABAAA

Zestaw	**B+-Tree**	**LSM-Tree**	**FA-Tree**
$\boldsymbol{ZR_A}$	198 s	195 s	194 s
$\boldsymbol{ZR_B}$	1 h	153 s	153 s
$\boldsymbol{ZR_C}$	140 h	9,7 h	9,7 h
$\boldsymbol{ZR_D}$	13,4 h	0,8 h	0,8 h

Tabela 5.11: Czas wykonania
Flash: Samsung K9F1G08U0D
Tabela: Sklep (113 B)

Zestaw	B+-Tree	LSM-Tree	FA-Tree
$\boldsymbol{ZR_A}$	145 s	140 s	139 s
$\boldsymbol{ZR_B}$	2 h	186 s	186 s
$\boldsymbol{ZR_C}$	268 h	13,5 h	13,5 h
$\boldsymbol{ZR_D}$	25,5 h	1,2 h	1,2 h

Tabela 5.12: Czas wykonania
Flash: Micron MT29F32G08CBEDBL83A3WC1
Tabela: Sklep (113 B)

Zestaw	B+-Tree	LSM-Tree	FA-Tree
$\boldsymbol{ZR_A}$	51 s	49 s	49 s
$\boldsymbol{ZR_B}$	0,8 h	23 s	23 s
$\boldsymbol{ZR_C}$	112 h	2,5 h	2,5 h
$\boldsymbol{ZR_D}$	10,8 h	0,2 h	0,2 h

Tabela 5.13: Czas wykonania
Flash: Micron MT29F32G08ABAAA
Tabela: Sklep (113 B)

kładają się na analogiczne czasy operacji dodawania i usuwania rekordów. Różnice w czasie wykonania są widoczne głównie przy wyszukiwaniu punktowym, co zostało zweryfikowane w zestawie podstawowym. W przypadku rozszerzonego zestawu kwerend, skupiamy się na wyszukiwaniu zakresowym. Wszystkie testowane indeksy zapewniają wsparcie dla tego typu wyszukiwania, co sprawia, że czas potrzebny na znalezienie pierwszego klucza w zakresie nie odgrywa znaczącej roli. Kluczowe jest tutaj odczytywanie danych znajdujących się w bezpośrednim sąsiedztwie. Dzięki podobnej metodzie przetwarzania danych przez wybrane indeksy, osiągane są zbliżone czasy operacji. W efekcie, indeksy LSM i FA uzyskują porównywalne wyniki w zakresie operacji dodawania, usuwania i wyszukiwania zakresowego. Warto jednak podkreślić, że indeks FA wykazuje istotną przewagę nad LSM podczas realizacji wyszukiwań punktowych. Wsparcie dla wyszukiwania zakresowego skutkuje podobnymi czasami realizacji zestawu ZR_A na indeksach B+, LSM i FA. Potwierdza to nasze założenie o wysokiej efektywności drzewa B+ w zakresie wyszukiwań, zarówno punktowych, jak i zakresowych. Jednakże, drzewo B+ charakteryzuje się znacznie dłuższym czasem operacji dodawania i usuwania na kościach flash, co jest wyraźnie widoczne podczas porównywania czasów wykonania różnych zestawów kwerend. Wyniki przedstawione na rysunkach 5.7, 5.8, 5.9 pokazują te same eksperymenty co tabele, ale z zastosowaniem normalizacji czasu do wyników uzyskanych przez indeks FA (indeks FA ma zawsze wartość 1). Analiza pozwala stwierdzić, że większy udział operacji dodawania i usuwania rekordów w zestawie kwerend zwiększa przewagę drzewa FA nad indeksem B+. Na przykład, zestaw ZR_B na kości Micron MT29F32G08ABAAA był realizowany przez indeks B+ w ciągu 0,8h, podczas gdy z użyciem drzewa FA zajmował jedynie 23 s, co oznacza 125-krotnie szybsze wykonanie. Możemy również zaobserwować, że większe rozmiary stron i bloków w pamięci flash pogarszają wydajność drzewa B+ w porównaniu do drzewa FA. Zestaw ZR_B na kości Samsung K9F1G08U0D (strona 2 KB) był realizowany 24 razy dłużej na indeksie B+ niż na indeksie FA, natomiast na kościach Micron MT29F32G08CBEDBL83A3WC1 (strona 4 KB) i Micron MT29F32G08ABAAA (strona 8 KB) różnice te wynosiły odpowiednio 37 i 125 razy.

Zestaw	Nowe zamówienie (20B)	Sklep (113B)	Klient (719B)
$\boldsymbol{ZR_A}$	1,08:1	1,02:1	1,01:1
$\boldsymbol{ZR_B}$	190:1	24:1	8:1
$\boldsymbol{ZR_C}$	95,3:1	14,5:1	6,2:1
$\boldsymbol{ZR_D}$	105,9:1	16,5:1	7,7:1

Tabela 5.14: Stosunek czasu wykonania zestawów B+Tree do FA-Tree
Flash Samsung K9F1G08U0D

Oprócz analizy wpływu wielkości strony na czas wykonania kwerend, zbadaliśmy również, jak wielkość rekordów wpływa na efektywność przetwarzania. Wybór padł na model Samsung, który jest najbardziej reprezentatywny wśród rozpatrywanych przez nas kości flash. W tabeli 5.14 przedstawiono stosunek czasu wykonania kwerend na drzewie B+ w porównaniu do drzewa FA. Obserwujemy, że mniejsza wielkość rekordu sprawia, iż indeks B+ wypada znacznie gorzej w relacji do indeksu FA. Zjawisko to wynika z konieczności reorganizacji węzła przy każdym zapisie, niezależnie od rozmiaru zapisywanego rekordu, oraz z faktu, że konieczne jest zapisanie całej strony, nawet jeśli zmiany dotyczą mniejszego fragmentu. Drzewo FA, buforując rekordy i operując na całych blokach, nie jest podatne na wpływ ani wielkości bloku, ani wielkości rekordu na czas wykonania operacji. Jest to kolejna istotna przewaga tej struktury, która podkreśla jej uniwersalność i efektywność.

Podsumowując, indeks FA łączy w sobie zalety drzewa B+ oraz indeksu LSM. Charakteryzuje się efektywnym wyszukiwaniem punktowym oraz wyszukiwaniem rekordów z całego zakresu, podobnie jak drzewo B+. Jednocześnie jest przystosowany do pamięci blokowych, osiągając szybkość dodawania i usuwania rekordów na poziomie indeksu LSM. Co więcej, indeks FA korzysta z jednego niewielkiego bufora w poziomie L_0, który znacząco przyspiesza wykonanie kwerend, gdy jego wielkość odpowiada rozmiarowi bloku pamięci flash. W przeciwieństwie do struktury LSM, FA nie wykorzystuje dodatkowych buforów, co minimalizuje jego zapotrzebowanie na pamięć RAM. Ponadto, indeks FA integruje mechanizm logicznego mapowania bloków, oferując wbudowaną funkcjonalność podobną do algorytmu FTL-blokowego. Dzięki temu, stosowanie indeksu FA w urządzeniach wbudowanych jest niezwykle proste i nie wymaga zaawansowanego systemu operacyjnego ani wielowarstwowej architektury oprogramowania. Jego podstawowy sterownik zapewnia kompatybilność z różnymi modelami pamięci flash, a szybkość przetwarzania zapytań przez prosty interfejs API jest do 28 razy wyższa w porównaniu do tradycyjnych struktur danych, takich jak drzewo B+. Dodatkowo, mniejsze zużycie pamięci przez indeks FA, nawet do 21 razy w porównaniu do drzewa B+, wydłuża czas eksploatacji urządzeń, co jest kluczowe w systemach wbudowanych, gdzie wymiana komponentów może być problematyczna, np. przy aktualizacji infrastruktury sieci LTE. Analiza teoretyczna oraz praktyczne eksperymenty przeprowadzone przy użyciu symulatora SIPS wyraźnie wskazują na przewagę nowej struktury FA nad drzewem B+ i strukturą LSM w kontekście urządzeń wbudowanych.

Algorytmy indeksowania na dyskach SSD

W tym rozdziale omówimy metody indeksowania danych, popularne algorytmy i struktury danych służące do indeksowania na dyskach SSD, a także przedstawimy nowe podejścia do indeksowania: indeksowanie wierszowe za pomocą struktury FALSM-Tree [2], indeksowanie kolumnowe wykorzystujące indeks CF-Tree [3] oraz indeksowanie częściowe realizowane przy użyciu systemu LAM [4]. Koncepcję każdego z tych rodzajów indeksowania wprowadziliśmy już w rozdziale **2**. W dalszej części skoncentrujemy się na dostosowaniu przedstawionych algorytmów indeksujących do specyfiki działania dysków SSD.

Charakterystyka dysków SSD została szczegółowo przedstawiona w rozdziale **3**. Przyjrzyjmy się jednak kluczowym aspektom tych urządzeń. Dyski SSD (ang. *Solid State Drives*) różnią się podstawowo od tradycyjnych dysków twardych (HDD) [102], [103]. Brak ruchomych części eliminuje konieczność oczekiwania na pozycjonowanie głowicy, co jest typowe dla HDD. Dzięki temu dyski SSD oferują znacznie szybszy dostęp do danych. Popularność SSD wzrosła dzięki zwiększającej się pojemności (obecnie osiągającej kilka terabajtów), spadającym kosztom produkcji, wysokiej odporności na czynniki zewnętrzne, niskiemu poborowi energii oraz szybkiemu odczytowi i zapisowi danych. Te dyski składają się z wielu kości pamięci flash typu NAND, co oznacza, że operacje odczytu i zapisu wykonuje się na całych stronach. Nadpisywanie danych wymaga jednak procesu kasowania danych z bloków, co w przypadku SSD jest automatyzowane, eliminując konieczność ręcznego zarządzania blokami pamięci. Wykorzystanie wielu układów pamięci flash umożliwia równoczesny odczyt lub zapis danych na wszystkich kościach, maksymalizując potencjał dysku. Przy zapisie danych na większym zakresie, kontroler SSD automatycznie wchodzi w tryb sekwencyjny, który jest znacznie szybszy. Natomiast przy losowym dostępie do danych, kiedy nie jest znany pełny zakres, dysk pracuje wolniej, korzystając z trybu losowego. Skomplikowana charakterystyka dysków SSD, a zwłaszcza ograniczona przepustowość w trybie losowym, wymusza na algorytmach indeksujących maksymalizację wykorzystania trybu sekwencyjnego, co istotnie wpływa na skrócenie czasu obsługi zapytań.

6.1 Indeksowanie wierszowe

Indeksy wierszowe, jako najstarsze i najczęściej stosowane struktury w bazach danych, wyróżniają się swoją prostotą implementacji i efektywnością utrzymania porządku. W takim ułożeniu każdy rekord zapisywany jest w ciągłej sekwencji pamięci, co upraszcza operacje dodawania nowych rekordów, usuwania starych oraz modyfikacji, redukując je do pojedynczych operacji na dysku. Jednakże, to podejście ma również swoje wady. Wierszowe rozmieszczenie rekordów utrudnia kompresję danych i, biorąc pod uwagę, że

tabele często składają się z wielu atrybutów, większość zapytań nie wymaga dostępu do wszystkich z nich jednocześnie. Mimo to, struktura pamięci zmusza nas do wczytywania całego rekordu, co wpływa na zbędne wydłużenie czasu obsługi zapytania. Najczęściej stosowaną strukturą danych dla indeksów wierszowych jest drzewo B+ [21]. Niestety, ze względu na charakterystykę dysków SSD, znacząco różniącą się od RAM i dysków HDD, drzewo B+ nie jest optymalnym wyborem dla tego typu pamięci. Jak zaobserwowano w poprzednim rozdziale **5**, poświęconym indeksowaniu na pamięci flash, drzewo B+ nie tylko okazało się być znacznie wolniejsze w obsłudze kwerend (do 120 razy wolniejsze niż drzewo FA), ale również generowało dużo więcej operacji zapisu i kasowania, skracając żywotność pamięci nawet 23-krotnie w porównaniu z drzewem FA.

W związku z wymienionymi ograniczeniami, zaproponowano szereg nowych struktur, z których najbardziej znaczące to: drzewo FD [27], drzewo LA [28] oraz struktura LSM [172]. Drzewo FD charakteryzuje się podziałem na poziomy, gdzie każdy poziom jest kolekcją stron dysku SSD. Alokacja pamięci odbywa się od razu dla całego poziomu, co zapewnia ciągłość obszaru pamięci. Proces dodawania rekordu rozpoczyna się od umieszczenia go w niewielkim buforze. Gdy bufor osiąga swoją pojemność maksymalną, rekordy są przenoszone do pierwszego poziomu. Następnie, gdy pierwszy poziom zostanie zapełniony do swojej maksymalnej pojemności, dane są przenoszone na kolejny poziom. Kluczową zaletą drzewa FD jest możliwość wykorzystania sekwencyjnego trybu pracy kontrolera dysku SSD, ponieważ każdy poziom jest reprezentowany przez ciągły obszar pamięci. Co więcej, proces przenoszenia danych odbywa się pomiędzy pełnymi poziomami, co pozwala na precyzyjne określenie zakresu pamięci przeznaczonej do odczytu i ponownego zapisu. Dzięki temu dysk SSD może efektywnie przełączać się w tryb sekwencyjny.

Indeks LA wprowadza mechanizm leniwej reorganizacji struktury drzewa, gdzie operacje nie są realizowane natychmiast, ale zapisywane do dziennika zdarzeń. Rekordy tymczasowo przechowywane są w buforze, czekając na inkorporację do struktury. Kiedy dziennik osiąga swoją maksymalną pojemność, rozpoczyna się procedura aktualizacji struktury na podstawie zgromadzonych operacji. Taka metoda przynosi liczne korzyści. Przede wszystkim, możliwość agregacji operacji może doprowadzić do anulowania się niektórych z nich; na przykład, jeśli w dzienniku znajduje się operacja dodania rekordu, a później jego usunięcia, nie musimy przeprowadzać żadnej akcji. Co więcej, dodanie kilku rekordów do tego samego węzła może zostać zrealizowane w ramach pojedynczego zapisu, co znacząco zwiększa efektywność operacji na dyskach SSD. Niemniej, mechanizm ten ma także pewne ograniczenia, najistotniejszym jest spadek wydajności przy obsłudze zróżnicowanych zestawów kwerend. Na przykład, kombinacja operacji wstawiania, wyszukiwania i usuwania dotyczących różnych kluczy wymaga wykonania oddzielnych operacji w różnych częściach drzewa, co nie przynosi korzyści z agregacji. Dodatkowo, struktura oparta na idei podobnej do drzewa B+ sprawia, że dysk SSD pracuje głównie w trybie losowym. Implementacja tego mechanizmu wymaga również szczególnej uwagi, aby zapewnić pełne bezpieczeństwo danych w przypadku niespodziewanych przerw w zasilaniu czy innych awarii systemu.

Struktura LSM wyróżnia się spośród innych indeksów dzięki unikalnemu podejściu do organizacji danych. Podobnie jak drzewo FD, LSM również jest podzielone na poziomy, lecz zasadniczą różnicą jest brak bezpośrednich wskaźników między poszczególnymi poziomami, co oznacza, że nie można przemieszczać się przez strukturę LSM w taki sam sposób jak przez tradycyjne drzewo. Każdy poziom w LSM definiuje ciągły obszar pamięci o ustalonej wielkości, a dane w obrębie poziomu są zorganizowane w posortowane podzbiory (ang. *SSTable*), z zapisanymi w metadanych informacjami o lokalizacji w pa-

mięci, minimalnym oraz maksymalnym kluczu każdego podzbioru. Dzięki tym metadanym, dostępnym zwykle w pamięci RAM, szybki dostęp do danych jest zapewniony. Proces wstawiania rekordu do struktury LSM odbywa się poprzez tymczasowe umieszczenie go w buforze, a następnie, kiedy bufor się zapełni, przepisanie danych do kolejnego poziomu. Operacja ta jest powtarzana, aż do osiągnięcia poziomu zdolnego pomieścić wszystkie nowe dane. W przeciwieństwie do drzewa FD, LSM nie generuje wskaźników dla nowo tworzonych podzbiorów danych; zamiast tego, tworzone są wpisy w buforze metadanych, które opisują każdy nowy podzbiór, co pozwala na optymalne wykorzystanie przestrzeni dyskowej. Odszukanie klucza w strukturze LSM wymaga przeszukania metadanych, aby wyselekcjonować jedynie te podzbiory danych, które potencjalnie mogą zawierać poszukiwane wartości. Jest to możliwe dzięki szczegółowemu opisowi każdego podzbioru w metadanych. Korzystając ze struktury LSM, możliwe jest pełne wykorzystanie sekwencyjnego trybu pracy kontrolera dysku SSD, co jest kluczowe zarówno przy wstawianiu danych, jak i przy ich wyszukiwaniu. Ta unikalna cecha sprawia, że LSM znajduje zastosowanie nie tylko w relacyjnych bazach danych jako indeks, ale również jako system plików czy podstawowa struktura danych służąca do przechowywania par klucz-wartość.

6.2 Struktura LSM

Współczesne bazy danych często funkcjonują jako rozproszone systemy, gdzie pojedynczy serwer obsługuje dane pochodzące z wielu urządzeń. Te urządzenia, podłączone do serwera, mogą indywidualnie dodawać tylko kilka rekordów na raz, jednak łącznie serwer może otrzymywać tysiące nowych rekordów każdej sekundy. W związku z tym, techniki buforowania danych [175], [176] oraz metody minimalizujące zapisy na dyskach SSD [177] stają się coraz bardziej powszechne. Dzięki buforowaniu danych możliwe jest agregowanie rekordów do dodania do indeksu w jednej zbiorczej operacji, co jest znane jako dodawanie zbiorcze (ang. *bulkload*). Istnieje wiele algorytmów optymalizujących tę operację dla indeksów wspierających dodawanie zbiorcze [178], [179], [180]. Nie wszystkie indeksy jednak wspierają tę procedurę; na przykład, drzewo B+ umożliwia dodawanie zbiorcze wyłącznie w sytuacji, gdy drzewo jest puste. Indeksy takie jak FD, FA, czy LSM, wspierają dodawanie zbiorcze jedynie w ograniczonym zakresie. Jest to dla nich naturalna metoda dodawania rekordów, gdyż każdy z tych indeksów posiada niewielki bufor danych. Rekordy są dodawane do niższych poziomów dopiero po zapełnieniu bufora. Taka metoda zbiorczego dodawania nie jest jednak bez wad, szczególnie kiedy mamy do czynienia z ogromną ilością danych. W takich przypadkach dodawanie elementów „od góry”, nawet z wykorzystaniem buforowania, może nie być najefektywniejszym rozwiązaniem. W [181] zaproponowano nowy algorytm dodawania zbiorczego do indeksu LSM, który zamiast skupiać się wyłącznie na optymalizacji zapisów, dąży do równomiernego rozłożenia danych na wszystkie poziomy indeksu, aby symulować tradycyjne pojedyncze dodawanie.

Indeks LSM ze względu na swoje wszechstronne zastosowanie był przedmiotem wielu optymalizacji w ostatnich latach. Szczegółowy przegląd tych optymalizacji został przedstawiony w [182]. W pracy [183] przedstawiono nową metodę reorganizacji drzewa, która polega na scalaniu poziomu z niższym poziomem, który zawiera najmniej danych, zamiast klasycznego scalania kolejnych poziomów. Natomiast w [184] zaproponowano podział rekordów na oddzielne zbiory kluczy i wartości, przechowywane w różnych obszarach pamięci. Takie podejście ułatwia wyszukiwanie i zwiększa efektywność kompresji, ale jednocześnie wydłuża czas dodawania nowych rekordów i wymaga zastosowania algorytmu

łączącego klucz z odpowiadającym mu rekordem. Niestety, ze względu na różnicę w kosztach odczytu i zapisu, ten algorytm nie jest optymalny dla dysków SSD. Prace [185] i [186] skupiają się na optymalizacji indeksu LSM specjalnie pod kątem dysków SSD i pamięci flash, koncentrując się głównie na efektywnym alokowaniu pamięci, aby zmniejszyć liczbę używanych bloków, oraz na kompresji danych w blokach, by zmaksymalizować ilość danych zapisanych na jednostkę pamięci i zredukować liczbę operacji odczytu i zapisu. Dodatkowo, w [187] przedstawiono mechanizm dostosowujący rozmiar poziomów do przewidywanych przyszłych zapytań na podstawie analizy zapytań historycznych, co pozwala na obniżenie kosztów scalania poziomów w porównaniu do tradycyjnej metody wykorzystywanej w indeksie LSM. W [188] zrezygnowano z sortowania SSTable, czyli podzbiorów danych, z których składa się poziom tego indeksu. Optymalizacja ta nie ma wpływu na liczbę odczytów i zapisów podczas scalania poziomów. Ma niestety negatywny wpływ na wyszukiwanie zakresowe. Zamiast odczytać tylko potrzebne dane, musimy wczytać cały węzeł, który składa się często z kilku lub nawet kilkunastu stron. Tę optymalizację zastosowano do urządzeń wbudowanych o małym rozmiarze bufora, dzięki czemu sortowanie zewnętrzne podczas dodawania działa szybciej, kosztem wolniejszego wyszukiwania. Techniki tej nie powinno się stosować na serwerach, które posiadają dużą moc obliczeniową i spore zasoby pamięci operacyjnej RAM.

6.3 Flash Aware LSM-Tree

Ze względu na szerokie zastosowanie indeksu LSM oraz brak odpowiedniego algorytmu potrafiącego dostosować operacje dodawania zbiorczego do dysków SSD, w [2] zaproponowaliśmy nową wersję indeksu LSM nazwaną FA-LSM (ang. *Flash Aware LSM-Tree*). Struktura ta wprowadza nowy algorytm dodawania całego zbioru rekordów oraz zmienia układ poziomów. Poziom składa się z kilku ciągłych obszarów pamięci. Nie jest on jednak posortowany, co umożliwia dodanie rekordów do każdego poziomu bez zbędnego wywoływania algorytmu scalania. Oznacza to, że nie musimy dodawać nowych rekordów z góry na dół, tak jak to ma miejsce w przypadku klasycznego LSM. Możemy zamiast tego dodać zbiór rekordów do dowolnego poziomu. Eksperymenty na zbiorze kwerend rozszerzonych z użyciem symulatora SIPS wykazały pięciokrotnie lepszy czas względem zwykłego LSM oraz sześciokrotnie mniejsze wykorzystanie pamięci flash na dysku SSD, co przekłada się na dłuższe życie komórek pamięci oraz całego dysku.

6.3.1 Struktura FALSM

Nasza nowa struktura FALSM, tak samo jak zwykłe LSM, składa się z kilku poziomów. Poziom L_0 to bufor nowych danych, który znajduje się w szybkiej pamięci operacyjnej RAM. Jego wielkość jest ustalana indywidualnie dla każdego systemu i zazwyczaj wynosi od 2 MB do 16 MB. Każdy kolejny poziom L_i, $i > 0$ zapisany jest już na dysku SSD. Wielkość poszczególnych poziomów zależy od parametru k, który zazwyczaj przyjmuje wartości od *4* do *10*. Oznacza to, że jeśli L_0 ma wielkość 2 MB i k jest równe *4*, to L_1 ma pojemność 8 MB, L_2 32 MB, itd. FALSM również nie posiada wskaźników na poziomy niżej. Każdy poziom składa się z węzłów (SSTable), czyli ciągłych obszarów pamięci. Każdy taki podzbiór rekordów ma określony początkowy adres, wielkość oraz wartość minimalnego i maksymalnego klucza zapisanego w tym zbiorze rekordów. Te atrybuty nazywamy własnościami węzła, które są zapisane w dodatkowym buforze posiadającym wszystkie niezbędne metadane. Różnicą między strukturą FALSM a LSM

jest wprowadzenie dwóch rodzajów węzłów:

- **Normalny węzeł** (ang. *Normal SSTable*) - część poziomu, która, tak jak w przypadku zwykłego LSM, jest w pełni posortowana. Każdy taki węzeł posiada odpowiedni wpis o swoich własnościach w buforze. Na danym poziomie zakresy kluczy, stworzone z atrybutów minimalnej i maksymalnej wartości klucza dla każdego węzła, są zbiorami rozłącznymi,
- **Dopisany węzeł** (ang. *Overflow SSTable*) - część poziomu, która została dopisana podczas dodawania zbiorczego. Sam węzeł jest posortowany, jednak ze względu na to, że część poziomu została dopisana innym sposobem niż przy reorganizacji drzewa, występowanie dopisanego węzła oznacza, że poziom nie jest w pełni posortowany. Każdy dopisany węzeł również posiada wpis w buforze, specjalnie oznaczony, aby wskazać, że poziom nie jest już w pełni posortowany. Podczas reorganizacji poziomów sortujemy oba poziomy w nowy, w pełni posortowany poziom. Zatem podczas reorganizacji indeksu dopisane węzły zostają przekształcone w normalne węzły, a zakresy kluczy mogą mieć części wspólne z innymi węzłami, zarówno normalnymi, jak i dopisanymi.

Każdy z węzłów posiada określoną wielkość, która zazwyczaj równa jest rozmiarowi bufora (L_0). Maksymalna pojemność zarówno normalnego węzła, jak i dopisanego węzła jest taka sama. Podczas dodawania zbiorczego możliwe jest więc stworzenie kilku dopisanych węzłów. Ponieważ wprowadzenie dopisanego węzła sprawia, że poziom nie jest posortowany w całości (tylko węzły są posortowane wewnętrznie), wyszukiwanie również musi ulec zmianie. Normalnie, gdy szukamy klucza, wiemy, że może on występować tylko w jednym węźle na danym poziomie. W strukturze FALSM klucz może występować w jednym normalnym węźle i w każdym dopisanym węźle danego poziomu. Oczywiście, za wybór węzłów odpowiada bufor, który posiada atrybuty węzłów. Podczas wyszukiwania wybieramy tylko te węzły, które mogą zawierać szukany klucz, na podstawie minimalnego i maksymalnego klucza danego węzła.

Wprowadzenie dopisywania nowych węzłów podczas dodawania zbiorczego drastycznie zmniejszyło liczbę zapisów na dysku SSD. Załóżmy, że poziom L_0 może pomieścić 10 rekordów, a poziom L_1 40 rekordów. Podczas dodawania zbiorczego 10 rekordów, klasyczne LSM najpierw wstawiłoby 10 rekordów jeden po drugim do bufora, a następnie bufor zostałby przepisany do L_1, co oznacza zapis 10 rekordów na dysk SSD. Następnie wstawiamy kolejne 10 nowych danych pojedynczo do bufora i ponownie scalamy L_0 z L_1, co wiąże się z odczytem 10 rekordów i zapisem 20 rekordów. W efekcie, wstawianie 20 danych kosztuje nas łącznie odczyt 10 rekordów i zapis 30 rekordów. Struktura FALSM działa inaczej. Wybiera poziom, który jest w stanie zmieścić wszystkie rekordy, a jeśli takiego poziomu nie ma, tworzy nowy. W naszym przykładzie, poziom L_1 posiada odpowiednią pojemność dla 20 rekordów, więc wpisujemy od razu wszystkie 20 danych do poziomu L_1. Koszt takiego wstawiania to tylko zapis 20 rekordów, co jest znaczną poprawą w porównaniu do klasycznego algorytmu wstawiania do indeksu LSM. Im więcej poziomów może posiadać dopisanych węzłów, tym dłużej będzie trwało wyszukiwanie. Jednak szybciej będziemy w stanie dodawać kolejne elementy. Ponieważ liczba dopisanych węzłów wpływa na szybkość wykonywania kwerend, wprowadziliśmy parametr T, który określa, jak dużo nowych danych można dopisać za jednym razem do obecnego poziomu. Przykładowo, jeśli $T = 2$, to możemy za pomocą jednego dodawania zbiorczego dopisać rekordy o rozmiarze do 50% pojemności poziomu. W tej procedurze nie bierzemy pod uwagę obec-

nego stanu poziomu, lecz jego maksymalną pojemność. Oznacza to, że wybrany przez algorytm poziom może nie posiadać już miejsca na nowe dane. Wtedy najpierw scalamy wybrany poziom z niższym poziomem, a następnie wpisujemy nowe rekordy do wybranego poziomu.

$$liczbaWpisywanychDanych \leqslant \frac{maksymalnaLiczbaDanych}{T} \tag{6.1}$$

Wiedząc, jak będzie wyglądał zestaw kwerend, można odpowiednio skonfigurować strukturę FALSM za pomocą parametrów k i T, tak aby działała jak najlepiej. Zazwyczaj parametr k ustawiany jest na wartości pomiędzy 4 a 10, zaś parametr T pomiędzy 2 a 5.

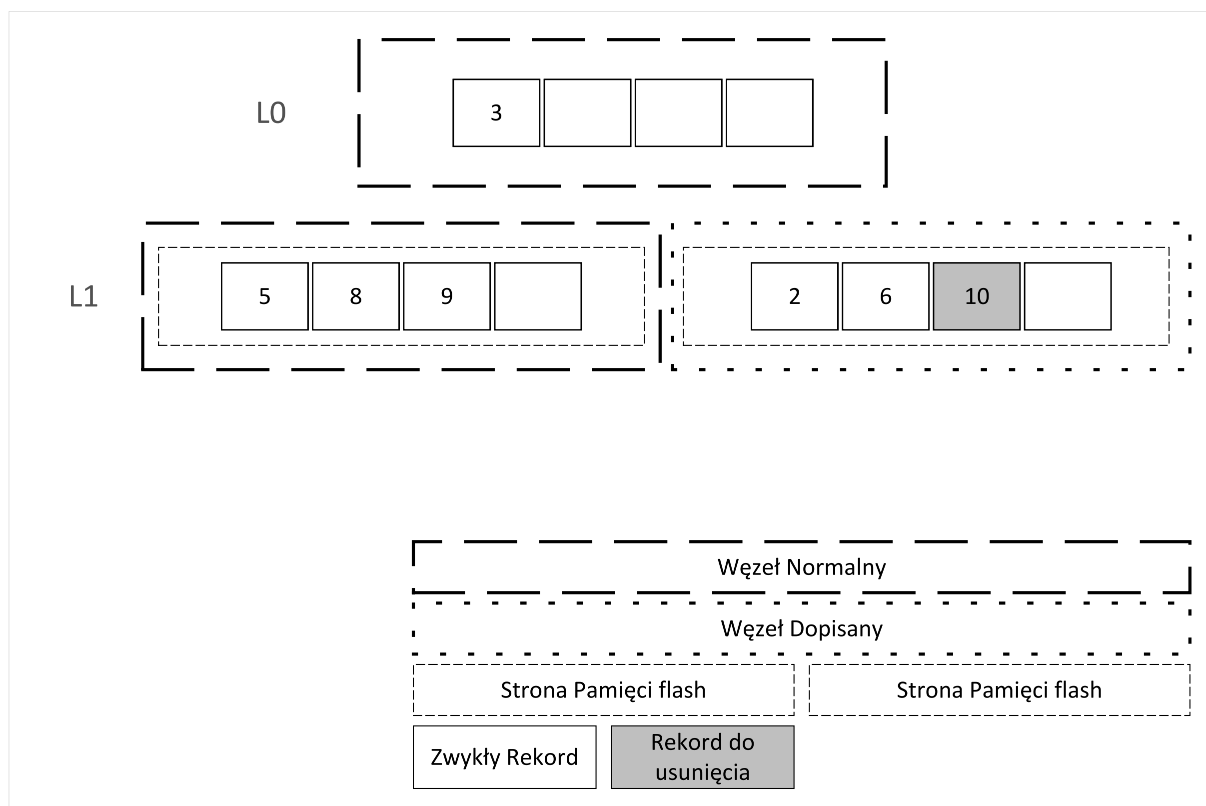

Rysunek 6.1: Przykładowa struktura FA-LSM

Rysunek 6.1 przedstawia przykładowy układ struktury FALSM. Zakładamy, że $k = 2$, $T = 2$ oraz że strona pamięci flash dysku SSD może pomieścić maksymalnie 4 rekordy. Na samej górze mamy poziom L_0, który nie jest zapisany na dysku, ale jest przetrzymywany w szybkiej pamięci RAM. Zawiera tylko jeden rekord o kluczu równym 3. Jak widać, z poziomu L_0 nie ma żadnego wskaźnika na poziom L_1, a więc nie da się przejść po drzewie z góry na dół. Poziom L_1 składa się z dwóch węzłów. Pierwszy z nich, po lewej, jest węzłem normalnym, czyli takim, który powstał poprzez scalenie poziomu L_0 z poprzednią wersją poziomu L_1. Zawiera on wartości 5, 8 i 9. Drugi węzeł to węzeł dopisany, stworzony został przez algorytm dodawania zbiorczego. Zawiera on trzy rekordy, z czego dwa są zwykłymi rekordami, a rekord z kluczem o wartości 10 to rekord do usunięcia. Aby zminimalizować liczbę zapisów, drzewa takie jak FA, FD czy właśnie LSM i FALSM, zamiast usuwać dane natychmiastowo, dodają nowy rekord o wartości klucza, który należy usunąć. Dzięki temu

usuwanie odraczane jest w czasie. Zwróćmy uwagę, że mimo iż klucze się nie powtarzają oraz rekordy są posortowane wewnątrz węzłów, to już zakres kluczy, powstały z atrybutów węzłów, nie jest unikatowy (rozłączny). Zakres węzła normalnego to $(5; 9)$, a zakres węzła dopisanego to $(2; 10)$. Zatem, jeśli będziemy chcieli wyszukiwać klucz o wartości 6, musimy przeszukać obydwa węzły, ponieważ mogą zawierać rekord o wskazanym kluczu.

6.3.2 Procedury indeksu FALSM

Wstawianie

Dodawanie nowego rekordu odbywa się dokładnie tak samo, jak z wykorzystaniem klasycznego indeksu LSM. Najpierw rekord wstawiany jest do bufora w pamięci RAM, dzięki czemu nie wykonujemy kosztownych operacji zapisu na dysku za każdym razem. Gdy bufor nie będzie w stanie pomieścić kolejnego rekordu, zrzucany jest na dysk. Wykonujemy wtedy reorganizację poziomów L_0 oraz L_1. Ponieważ każdy z poziomów zawiera ograniczoną pojemność, istnieje prawdopodobieństwo, że reorganizacja poziomów L_0 z L_1 przepełni poziom L_1. W takim przypadku rekurencyjnie scalamy poziomy L_1 z L_2 oraz wszystkie kolejne poziomy, gdy zajdzie taka potrzeba, dopóki poziom przyjmujący dane będzie miał wolne miejsce.

Wyszukiwanie

Ze względu na obecność dopisanych węzłów, wyszukiwanie wykonujemy inaczej niż na strukturze LSM. Pamiętajmy, że dla każdego węzła, czy to normalnego, czy to dopisanego, mamy wpis w buforze metadanych, zawierający jego właściwości. Zatem, gdy szukamy klucza, musimy wczytać wszystkie węzły, w których taki klucz może się znajdować. Gdy poziom nie zawiera żadnego dopisanego węzła, wiemy, że tylko jeden węzeł normalny może zawierać szukany klucz. Gdy poziom posiada węzły dopisane, należy odczytać wszystkie węzły na poziomie, które według atrybutów mogą zawierać szukany klucz. Należy również pamiętać, że jeśli napotkamy rekord do usunięcia, należy zakończyć procedurę wyszukiwania i jako wynik zgłosić użytkownikowi brak szukanego rekordu.

Usuwanie

Usuwanie rekordu o podanym kluczu wykonujemy dokładnie tak samo jak na indeksie LSM. Samo usuwanie nie jest wykonywane natychmiastowo, jak to ma miejsce w drzewach B+. Zamiast tego wstawiamy nowy rekord z kluczem, który mamy usunąć, i ustawiamy typ tego rekordu jako *Usunięta dana*. Gdy podczas reorganizacji poziomów natrafimy na oba rekordy: oryginalny oraz ten do usunięcia, wtedy usuwamy oba rekordy. Ta operacja realizowana jest jako brak zapisu poszczególnych rekordów ze starych zbiorów do nowego zbioru.

Scalanie poziomów

Reorganizacja drzewa przeprowadzana jest w przypadku, gdy któryś z poziomów nie ma wolnego miejsca na kolejne elementy. Wtedy uruchamiamy proces scalania dwóch poziomów: obecnego i kolejnego pod nim. Jeśli nie istnieje poziom niżej, wtedy jest on tworzony z odpowiednio dużą pojemnością (k razy większą od poprzedniego poziomu). W klasycznym drzewie LSM oba poziomy są posortowane, a zatem scalanie wykonujemy algorytmem łączenia dwóch posortowanych list. W przypadku struktury FALSM, mamy

podobną sytuację, z tą różnicą, że poziom może zawierać wiele posortowanych zbiorów. Każdy z takich zbiorów (węzłów) możemy traktować jako posortowaną listę. Zatem, aby scalić oba poziomy, wystarczy użyć algorytmu łączenia wielu list, realizowanego za pomocą kolejki priorytetowej, czyli struktury kopca. Początkowo do kopca dodajemy minimalny klucz z każdego węzła z obu poziomów. Za każdym razem wyciągamy z kopca rekord o minimalnym kluczu i dodajemy kolejny rekord z węzła. Dzięki temu, w wyniku scalania, otrzymamy nowy poziom w pełni posortowany. Oznacza to, że węzły dopisane połączą się z innymi węzłami dopisanymi oraz normalnymi, tworząc poziom zawierający tylko normalne węzły. Podczas reorganizacji pamiętamy, że jeśli poziom L_i będzie zawierał rekord o tym samym kluczu, co rekord na poziomie L_{i+1}, ale z odpowiednim znacznikiem do usunięcia, wtedy pomijamy oba rekordy i żadnego z nich nie wpisujemy do nowego poziomu L'_{i+1}. Możliwe jest, że podczas tego procesu poziom L'_{i+1} również nie będzie miał wystarczająco miejsca, aby pomieścić wszystkie dane. Wtedy wykonujemy scalanie poziomów L'_{i+1} z L_{i+2}. Proces ten powtarzamy rekurencyjnie do momentu uzyskania poziomu mieszczącego wszystkie rekordy.

Dodawanie zbiorcze

Wprowadzenie algorytmu dodawania zbiorczego jest główną cechą nowego indeksu FALSM. Aby dodać wiele rekordów jednocześnie, zamiast wstawiać je do bufora i czekać na reorganizację struktury, indeks FALSM dodaje nowe dane od razu do poziomu, który ma odpowiednią pojemność. Początkowo szukamy poziomu, który spełnia warunek 6.1. Wybieramy poziom o najmniejszym indeksie z tych, które spełniają podany warunek. Jeśli wybrany poziom pomieści wszystkie nowe rekordy, to tworzymy nowe węzły dopisane i dodajemy je do poziomu, co sprawia, że poziom przestaje być posortowany. Zauważmy, że bierzemy pod uwagę liczbę danych do dodania oraz maksymalną pojemność poziomów, a nie ich obecny rozmiar. Zatem wybrany poziom może nie posiadać już miejsca na nowe rekordy. W tym wypadku najpierw przeprowadzamy scalanie wybranego poziomu z poziomem następnym, a dopiero potem dodajemy nowe dane do wybranego poziomu. W tej sytuacji nowy poziom nie zawiera żadnych węzłów, więc dopisane węzły stają się węzłami normalnymi, a zatem wszystkie rekordy są posortowane. Możemy też mieć sytuację, w której żaden z istniejących poziomów nie spełnia warunku 6.1. Oznacza to, że liczba danych do wstawienia jest na tyle duża, że nie zmieści się w istniejącym drzewie FALSM. W takim przypadku tworzymy nowe poziomy, wypełniając je w całości aż do momentu wyczerpania nowych danych.

Rysunek 6.2 przedstawia przykładowy proces dodawania zbiorczego rekordów do struktury FALSM. Na potrzeby przykładu zakładamy, że $k = 2$, $T = 2$ oraz że węzeł składa się z jednej strony pamięci flash, a strona dysku może pomieścić 4 rekordy. Początkowo mamy jeden rekord w buforze (L_0) o wartości 3. Pozostałe rekordy mieszczą się w jednym normalnym węźle na poziomie L_1. Gdy wykonujemy wstawianie zbiorcze dodatkowych trzech elementów $\{2, 6, 10\}$, szukamy poziomu, który ma minimalnie pojemność 6 (ponieważ $T \cdot 3 = 6$). Takim poziomem jest L_1. Zatem tworzymy węzeł dopisany i dodajemy go do poziomu L_1. Od tego momentu każde wyszukiwanie na tym poziomie musi dostosować się do faktu, iż poziom nie jest w pełni posortowany. Kolejną kwerendą jest dodanie zbiorcze aż 7 nowych rekordów $\{7, 11, 12, 14, 20, 22, 24\}$.

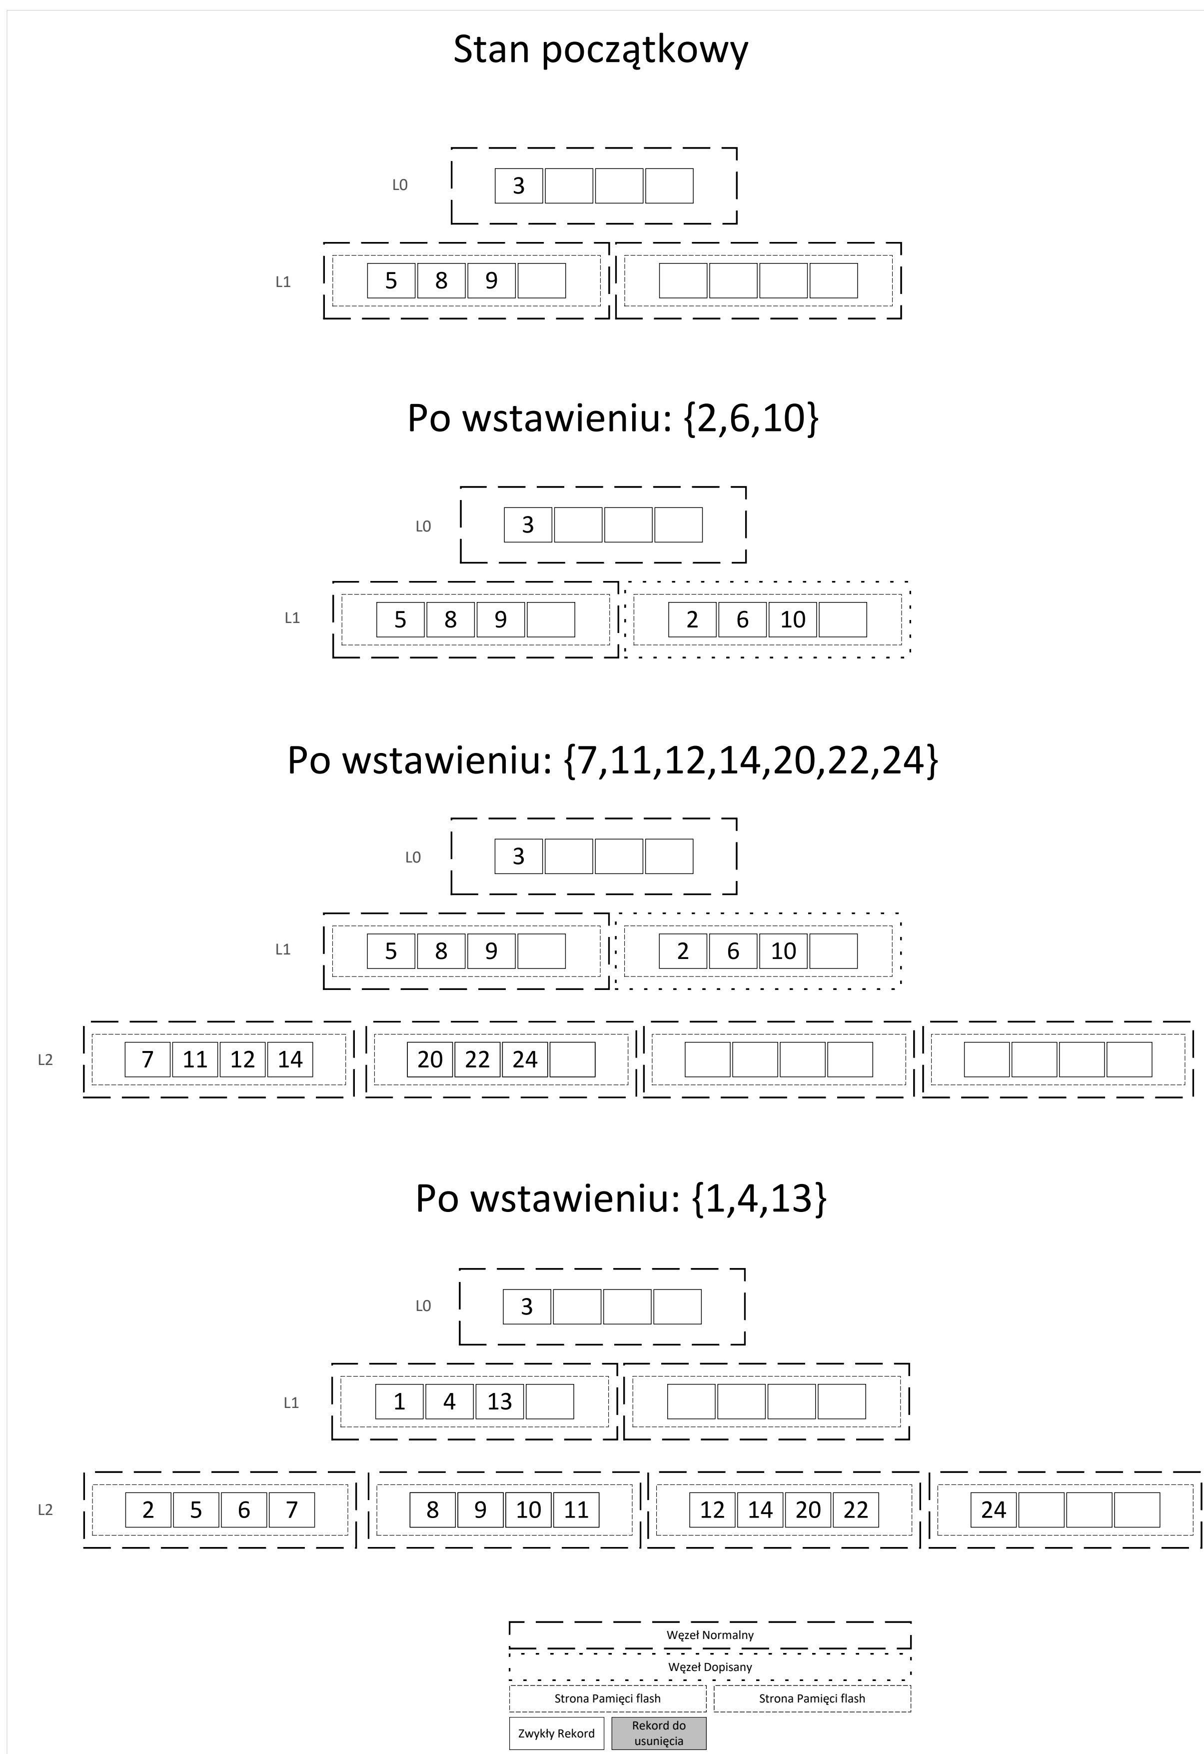

Rysunek 6.2: Przykład dodawania zbiorczego na strukturze FALSM

Zatem musimy znaleźć poziom o pojemności przynajmniej 14. Niestety, struktura FALSM nie posiada takiego poziomu. Zatem tworzymy nowy, który będzie miał pojemność 16, i wpisujemy nowe rekordy do tego poziomu. Warto zaznaczyć, że wpisujemy nowe elementy do normalnych węzłów, ponieważ poziom był pusty. Pozostałe poziomy są bez zmian, ponieważ dodawanie elementów odbyło się bezpośrednio na poziomie L_2. Ostatnią kwerendą w tym przykładzie jest dodanie trzech kolejnych rekordów $\{1, 4, 13\}$. Szukamy więc poziomu z pojemnością przynajmniej 6. Takim poziomem jest L_1. Jednak obecnie nie jest w stanie pomieścić aż tylu danych. Zatem zanim dodamy do niego nowe elementy, musimy przeprowadzić reorganizację struktury. Scalamy ze sobą L_1 z L_2. W wyniku tego powstaje nowy poziom L'_2, który zawiera wszystkie rekordy ze starych poziomów L_1 i L_2. Podczas tego scalania odbyła się całkowita reorganizacja poziomu L_2 na L'_2. Nowy poziom zawsze jest posortowany i składa się tylko z normalnych węzłów, które zawierają rekordy z poziomów L_1 oraz L_2. Oznacza to, że podczas reorganizacji przekształciliśmy wszystkie dopisane węzły z obu poziomów w węzły normalne dzięki ponownemu sortowaniu rekordów. Ostatnim etapem reorganizacji jest stworzenie nowego pustego poziomu L'_1. Ponieważ jego pojemność maksymalna jest dokładnie taka sama jak starego poziomu L_1, wiemy, że nie musimy ponownie szukać poziomu dla nowych rekordów. Wstawiamy zatem elementy $\{1, 4, 13\}$ do nowego poziomu L'_1 jako węzeł normalny, ponieważ podczas wstawiania poziom był pusty.

6.3.3 Algorytm dodawanie zbiorczego

Pseudokod 6.1: falsmBulkloading(Entry $entriesToInsert$)

```
1  Niech height będzie wysokością drzewa FA-LSM
2  Niech numEntries będzie rozmiarem zbioru wejściowego danych entriesToInsert
3  Niech maxEntry[i] będzie maksymalną liczbą danych jaką może pomieścić
     poziom i
4  Niech maxEntryInBuffer będzie maksymalną liczbą danych jaką może
     pomieścić bufor (L_0)
5
   // Jeśli bulkload się nie opłaca, dodaj dane do bufora
6  if numEntries < maxEntryInBuffer then
7  |  addToBuffer(entriesToInsert)
8  |  return
9
   // Znajdź odpowiednio duży poziom, uwzględniając parametr T
10 lvl := 1
11 while lvl <= height do
12 |  if numEntries < ⌈maxEntry[lvl] / T⌉ then
13 |  |  addToLevel(entriesToInsert, lvl)
14 |  |  return
15 |  lvl := lvl + 1
16
   // Poziom nie został znaleziony, musimy stworzyć nowe poziomy i wpisać tam dane
17 pos := 0
18 while numEntries > 0 do
19 |  createLevel(lvl)
20 |  n := min(maxEntry[lvl], numEntries)
21 |
   |  // Dodaj obecny podzbiór danych entriesToInsert do poziomu, wypełniając go w całości
22 |  Entry entriesToLoad[ ] := truncateEntrySet(entriesToInsert, pos, n)
23 |  addToLevel(entriesToLoad, lvl)
24 |
25 |  numEntries := numEntries - n
26 |  pos := pos + n
27 |  lvl:=lvl + 1
```

W tej sekcji dokładnie omówimy nowy algorytm dodawania zbiorczego do indeksu FALSM. Ze względu na dość duży poziom skomplikowania, pseudokod został podzielony na dwie części: funkcję `falsmBulkloading` (6.1), która jest główną funkcją interfejsu struktury oraz funkcję `addToLevel` (6.2), która jest funkcją pomocniczą odpowiedzialną za dodanie nowych elementów do wybranego poziomu.

Zacznijmy od omówienia funkcji głównej. Funkcja `falsmBulkloading` przyjmuje zbiór nowych rekordów jako argument wejściowy. W zależności od jego rozmiaru, możemy podjąć decyzję o wykonaniu klasycznego dodawania rekordów do bufora. Linie 6-8 są za to odpowiedzialne. Gdy liczba danych jest mniejsza niż rozmiar bufora, to oznacza, że jest

Pseudokod 6.2: addToLevel(Entry *entriesToInsert*, int lvl)

```
1  Niech numEntries będzie rozmiarem zbioru wejściowego danych entriesToInsert
2  Niech maxEntry[i] będzie maksymalną liczbą danych jaką może pomieścić
     poziom i
3  Niech numEntry[i] będzie obecną liczbą danych na poziomie i
4
   // Poziom nie pomieści więcej danych, musimy wykonać scalanie poziomów
5  if numEntry[lvl] + numEntriesToInsert > maxEntry[lvl] then
6      Entry entriesToMerge[]:= getEntries(lvl)
       // Poziom niżej istnieje, wczytaj zatem dane z poziomu lvl + 1
7      if exists lvl + 1 then
8          Entry entries[]:= getEntries(lvl + 1)
9          entriesToMerge:= entriesToMerge ∪ entries
10         removeEntries(lvl + 1)
11         removeLevel(lvl + 1)
12
       // Dane zostały wczytane, nawet jeśli poziom istniał, został on usunięty
13     createLevel(lvl + 1)
14     Entry sortedEntries[]:= sortEntries(entriesToMerge)
15
       // Wykonaj rekurencyjnie dodanie danych do pustego poziomu lvl + 1
16     addToLevel(sortedEntries, lvl + 1)
17
   // Jeśli poziom jest pusty, możemy stworzyć normalne węzły, w przeciwnym wypadku
       tworzymy węzły dopisane
18 if isEmpty(lvl) then
19     NormalSSTable tab[] := createNormalSSTables(lvl)
20     addToSSTables(tab, entriesToInsert)
21 else
22     OverflowSSTable tab[] := createOverflowSSTables(lvl)
23     addToSSTables(tab, entriesToInsert)
```

ich tak mało, że nie powinniśmy tworzyć dla tych danych węzła dopisanego, który zostanie dodany do jakiegoś poziomu. Spowodowałoby to zbyt dużą liczbę takich węzłów, zatem spowolniłoby to znacząco algorytm wyszukiwania danych za pomocą klucza. Gdy danych jest więcej niż rozmiar bufora, musimy znaleźć odpowiedni poziom, który nie tylko posiada odpowiednio dużą pojemność, ale także spełnia warunek (6.1) określony przez parametr T (linie 10-15). Gdy taki poziom znajdziemy (linie 12-14), możemy wykonać funkcję `addToLevel` i zakończyć algorytm dodawania zbiorczego. Istnieje jednak sytuacja, w której indeks FALSM nie posiada odpowiedniego poziomu. Wówczas taki poziom (lub wiele poziomów) należy stworzyć (linia 19), dodać go do struktury FALSM, a następnie wpisać do nich maksymalną liczbę nowych rekordów (linie 22 i 23).

Funkcja `addToLevel` służy do dodawania elementów do wybranego poziomu. Jako argumenty wejściowe przyjmuje zbiór rekordów do dodania oraz numer poziomu, do którego należy dodać ten zbiór. Możliwe jest, że dodane wartości nie zmieszczą się w wybranym

poziomie (linie 5-11). W takim przypadku musimy wykonać scalanie poziomów, czyli wczytać wszystkie elementy poziomu lvl oraz poziomu $lvl + 1$, jeśli taki istnieje (linie 7-11). Gdy w buforze znajdują się wszystkie elementy, tworzymy nowy poziom (linia 13), sortujemy otrzymane rekordy (linia 14), a następnie dodajemy je do nowego poziomu za pomocą tej samej funkcji (rekurencyjnie wołamy funkcję `addToLevel` w linii 16). Następnie, niezależnie od tego, czy musieliśmy przeprowadzić reorganizację, czy nie, możemy zapisać zbiór nowych rekordów do wybranego poziomu. Jeśli wybrany poziom jest pusty, możemy stworzyć normalne węzły i dodać je do poziomu (linie 18-20). W przeciwnym przypadku musimy stworzyć węzły dopisane i zapisać je na końcu obecnego poziomu (linie 21-23).

6.3.4 Eksperymenty

		Pojemność		Prędkość losowego		Prędkość sekwencyjnego	
Model	Interfejs	Strony	Bloku	Odczytu	Zapisu	Odczytu	Zapisu
Samsung 840	SATA	8 KB	512 KB	390 MB/s	182 MB/s	585 MB/s	535 MB/s
Toshiba VX500	SATA	4 KB	256 KB	379 MB/s	267 MB/s	568 MB/s	525 MB/s
Intel DCP4511	NVMe	4 KB	256 KB	1,2 GB/s	240 MB/s	2 GB/s	1,47 GB/s

Tabela 6.1: Wybrane modele dysków SSD

W tej części rozdziału przedstawimy i przeanalizujemy eksperymenty wykonane za pomocą symulatora SIPS, który został dokładnie opisany w rozdziale 4. Do eksperymentów wybrano trzy dyski SSD o odmiennej charakterystyce. Tabela 6.1 zawiera szczegółowe parametry wybranych modeli. Samsung 840 charakteryzuje się bardzo dużą pojemnością strony oraz bloku, odpowiednio 8 KB i 512 KB. Standardowo pojemność strony to 4 KB i taką właśnie posiadają modele Toshiba i Intel. Wybrany model Samsunga posiada bardzo szybki odczyt i zapis sekwencyjny, zbliżony do maksymalnej teoretycznej prędkości interfejsu SATA 3 (750 MB/s), która ze względu na dodatkowe dane i bity kontrolne wynosi w praktyce 590 MB/s. Mimo bardzo dobrej prędkości sekwencyjnej, to szybkość zapisu losowego jest bardzo wolna na poziomie 182 MB/s. Kolejnym wybranym dyskiem jest model Toshiba VX500. Jest to standardowy model dysku SSD z interfejsem SATA 3. Prędkości sekwencyjne zbliżone są do modelu Samsunga, jednak Toshiba posiada o wiele większą prędkość losowego zapisu (267 MB/s). Najlepszym dyskiem w tym zestawieniu jest Intel DCP 4511. Ten model charakteryzuje się ogromną prędkością sekwencyjnych operacji (ponad 1 GB/s) oraz bardzo szybkim odczytem losowym (1,2 GB/s). Największą wadą tego modelu jest bardzo wolny zapis losowy na poziomie tylko 240 MB/s. Większość eksperymentów została przeprowadzona na modelu Samsung 840 ponieważ jest to obecnie najpopularniejszy dysk SSD z interfejsem SATA 3. Eksperymenty zostały przeprowadzone na trzech charakterystycznych tabelach (Sklep, Nowe zamówienie i Klient) popularnego zestawu kwerend TPC-C [13], który został dokładnie opisany w rozdziale 4.

Parametr T

Najważniejszym parametrem indeksu FALSM jest parametr T, który jest kluczowym czynnikiem wyboru poziomu podczas procedury dodawania zbiorczego nowych elementów

do indeksu. W tej części eksperymentów zajmiemy się dokładnie obserwacją oraz analizą wpływu parametru T na szybkość wykonywania się kwerend. Symulator SIPS nie tylko mierzy sumaryczny czas wykonania kwerendy, ale także potrafi zmierzyć dokładnie, ile czasu indeks poświęcił na poszczególne operacje, takie jak wyszukiwanie rekordów czy ich dodawanie. Skorzystamy z tego, aby lepiej zrozumieć wpływ T na indeks FALSM. Nasza nowa struktura głównie różni się od klasycznego LSM wsparciem operacji dodawania zbiorczego. Samo dodawanie pojedynczych rekordów wykonywane jest dokładnie tak samo na obu indeksach. Z tego powodu zrezygnowaliśmy z przeprowadzania eksperymentów z użyciem podstawowego zestawu kwerend. W zamian za to, na potrzeby naszych obserwacji, stworzyliśmy cztery nowe zestawy, w których używamy tylko dodawania zbiorczego i wyszukiwania zakresu kluczy o selektywności 1%.

- T_{A} - Wstawiamy 10 mln rekordów za pomocą kolejnych zbiorów o losowym rozmiarze z przedziału 50 tys. do 100 tys. Po każdej procedurze wstawiania przeprowadzamy **20** wyszukiwań elementów z losowego zakresu o selektywności 1%. Zestaw kwerend jest wywoływany, dopóki wszystkie 10 mln rekordów nie zostaną dodane do indeksu.
- T_{B} - Wstawiamy 10 mln rekordów za pomocą kolejnych zbiorów o losowym rozmiarze z przedziału 50 tys. do 100 tys. Po każdej procedurze wstawiania przeprowadzamy **40** wyszukiwań elementów z losowego zakresu o selektywności 1%. Zestaw kwerend jest wywoływany, dopóki wszystkie 10 mln rekordów nie zostaną dodane do indeksu.
- T_{C} - Wstawiamy 10 mln rekordów za pomocą kolejnych zbiorów o losowym rozmiarze z przedziału 50 tys. do 100 tys. Po każdej procedurze wstawiania przeprowadzamy **100** wyszukiwań elementów z losowego zakresu o selektywności 1%. Zestaw kwerend jest wywoływany, dopóki wszystkie 10 mln rekordów nie zostaną dodane do indeksu.
- T_{D} - Wstawiamy 10 mln rekordów za pomocą kolejnych zbiorów o losowym rozmiarze z przedziału 50 tys. do 100 tys. Po każdej procedurze wstawiania przeprowadzamy **250** wyszukiwań elementów z losowego zakresu o selektywności 1%. Zestaw kwerend jest wywoływany, dopóki wszystkie 10 mln rekordów nie zostaną dodane do indeksu.

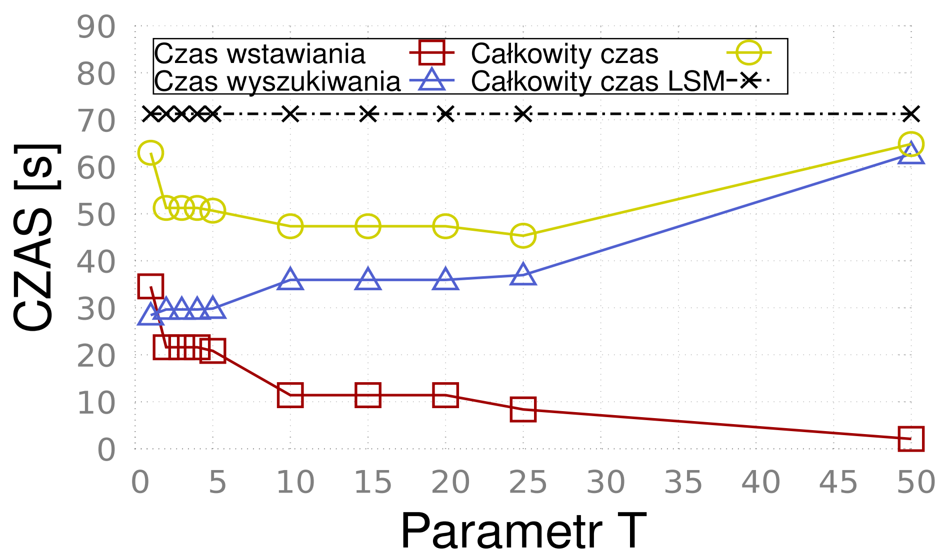

Rysunek 6.3: Czas wykonania zestawu kwerend T_A
Dysk: Samsung 840
Tabela: Sklep (113 B)

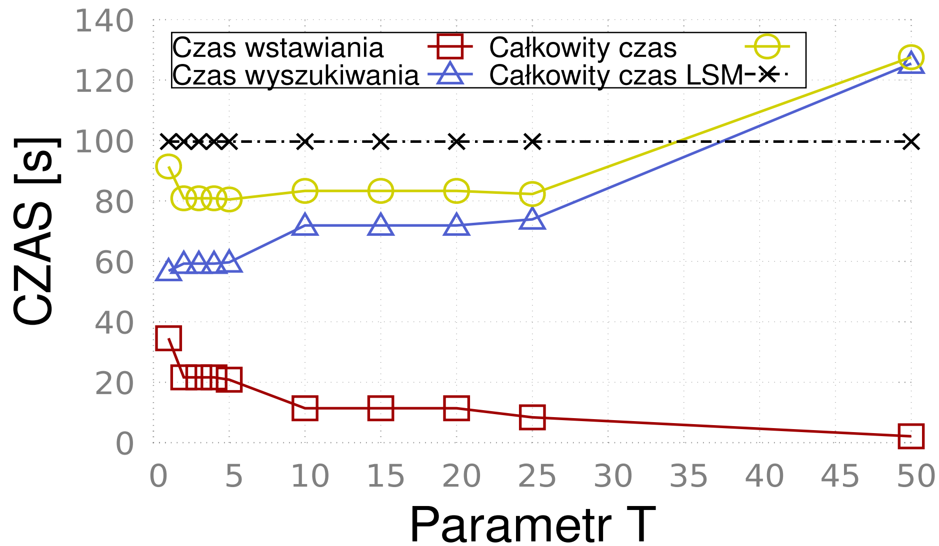

Rysunek 6.4: Czas wykonania zestawu kwerend T_B
Dysk: Samsung 840
Tabela: Sklep (113 B)

Rysunki: 6.3, 6.4, 6.5, 6.6 przedstawiają wyniki uzyskane na dysku Samsung 840 dla zestawów odpowiednio T_A, T_B, T_C, T_D przeprowadzonych na tabeli TPC-C Sklep o rozmiarze 113 B.

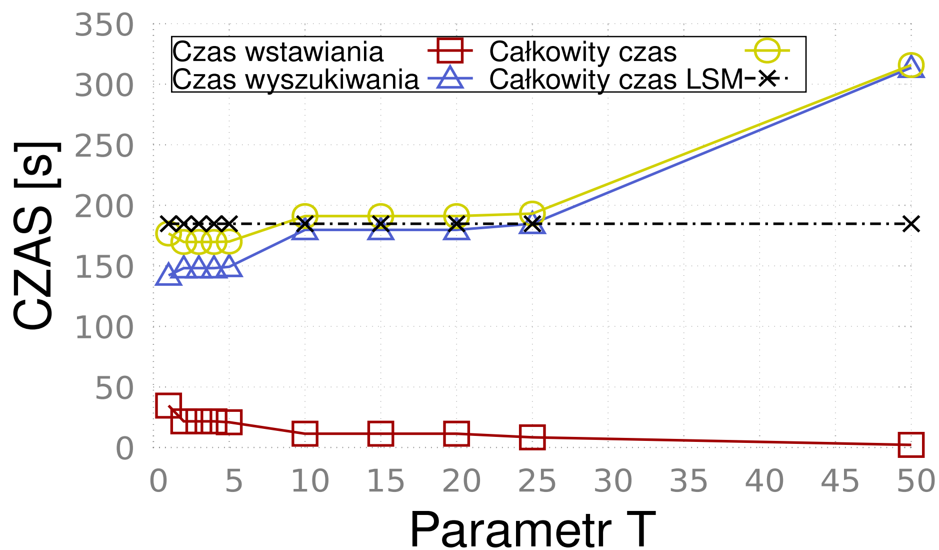

Rysunek 6.5: Czas wykonania zestawu kwerend T_C
Dysk: Samsung 840
Tabela: Sklep (113 B)

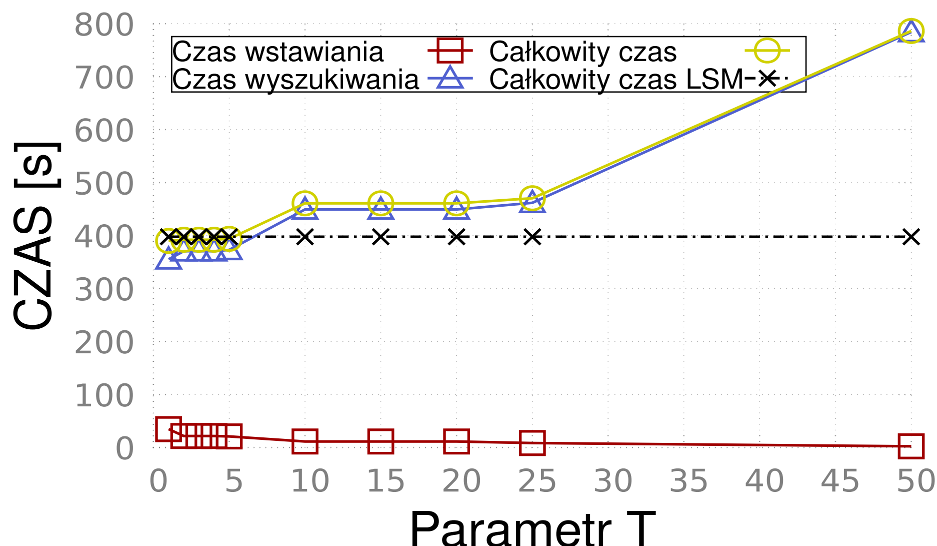

Rysunek 6.6: Czas wykonania zestawu kwerend T_D
Dysk: Samsung 840
Tabela: Sklep (113 B)

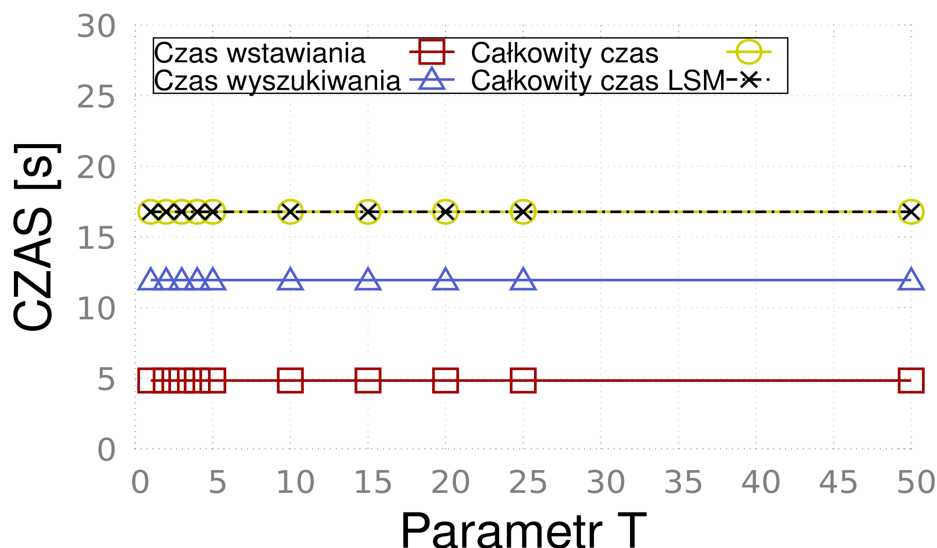

Rysunek 6.7: Czas wykonania zestawu kwerend T_B
Dysk: Samsung 840
Tabela: Nowe zamówienie (20 B)

Pierwszą obserwacją jest malejący czas dodawania rekordów oraz rosnący czas wyszukiwania wraz z rosnącym parametrem T. Wynika to ze zmian topologii drzewa FALSM. Im większe T, tym więcej poziomów posiada drzewo, a nowe zbiory danych często lądują w niższych poziomach. To z kolei wpływa na minimalizację liczby reorganizacji oraz zmniejszenie kosztów samej reorganizacji, ponieważ poziomy zawierają mniej danych. Niestety, wraz ze wzrostem poziomów, rośnie liczba węzłów, które musimy wczytać podczas wyszukiwania, co przekłada się na zwiększony koszt tej operacji.

Drugą obserwacją jest wpływ na całkowity czas wykonywania się zestawu kwerend. Gdy liczba wyszukiwań jest większa niż 20 (czyli zestawy T_B, T_C, T_D), to dla dużych wartości T struktura FALSM wykonuje kwerendy znacznie dłużej niż zwykła struktura LSM. Zbyt duża liczba poziomów zmniejszyła czas dodawania elementów, jednak drastycznie wydłużyła czas wyszukiwania, co w efekcie końcowym przełożyło się na gorszą efektywność niż w indeksie LSM.

Trzecią i najważniejszą obserwacją jest wybór optymalnego T. W przypadku zestawu T_A, najlepszy wynik FALSM osiągnął dla $T = 25$. Jednak już dla pozostałych zestawów, przy takiej wartości T, indeks okazał się gorszy od zwykłego LSM. Gdy liczba wyszukiwań jest dość duża, najlepiej ustawić T na wartości 3, 4 lub 5. Przy takich wartościach FALSM zawsze był bardziej efektywny od struktury LSM.

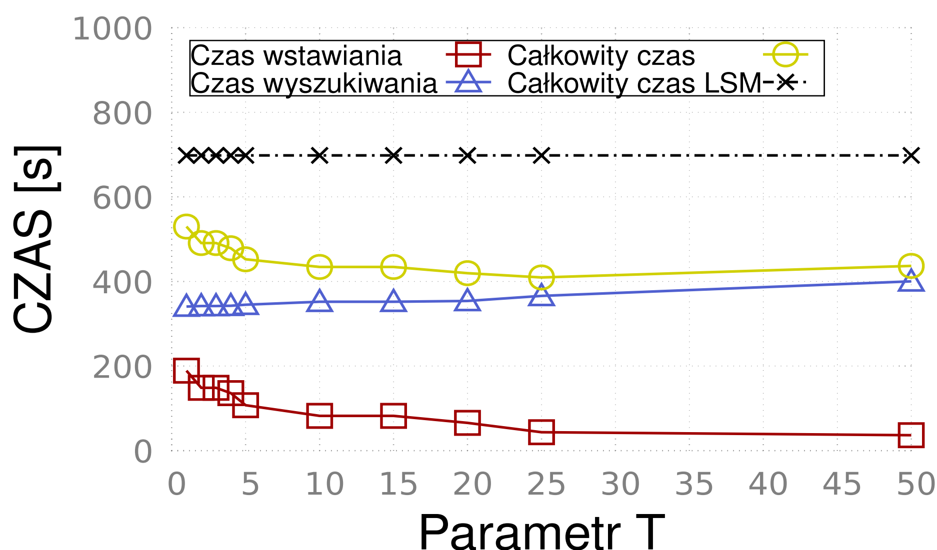

Rysunek 6.8: Czas wykonania zestawu kwerend T_B
Dysk: Samsung 840
Tabela: Klient (719 B)

W kolejnej serii eksperymentów sprawdziliśmy wpływ rozmiaru tabeli na wybór najlepszej wartości T. Eksperymenty zostały przeprowadzone na tabelach: Nowe Zamówienie (rysunek 6.7), Sklep (rysunek 6.4) oraz Klient (rysunek 6.8) przy użyciu dysku Samsung 840. Parametr T nie miał żadnego wpływu na czas wykonania się operacji dla małej tabeli Nowe zamówienie o rozmiarze 20 B. Wynika to z faktu, że większość danych trafiła do bufora i nie została przepisana na docelowy poziom (pamięć dysku SSD). Ponieważ bufor dla obu indeksów: FALSM i LSM, jest ustawiony na tę samą wielkość 4 MB, czas wykonania się kwerend dla tych indeksów był dokładnie taki sam. Analizując wyniki z eksperymentu przeprowadzonego na dużej tabeli Klient o rozmiarze 719 B, możemy stwierdzić, że im większy rozmiar rekordu, tym wybór parametru T jest ważniejszy. Wynika to z faktu, iż im większy rekord, tym więcej czasu kosztuje jego przepisanie podczas reorganizacji struktury. Zatem dobry wybór poziomu docelowego potrafi drastycznie obniżyć czas wstawiania danych. W tym przypadku najlepszy całkowity czas został osiągnięty dla $T = 25$. Wynik ten był o 8% lepszy od najlepszego poprzednio wybranego $T = 5$.

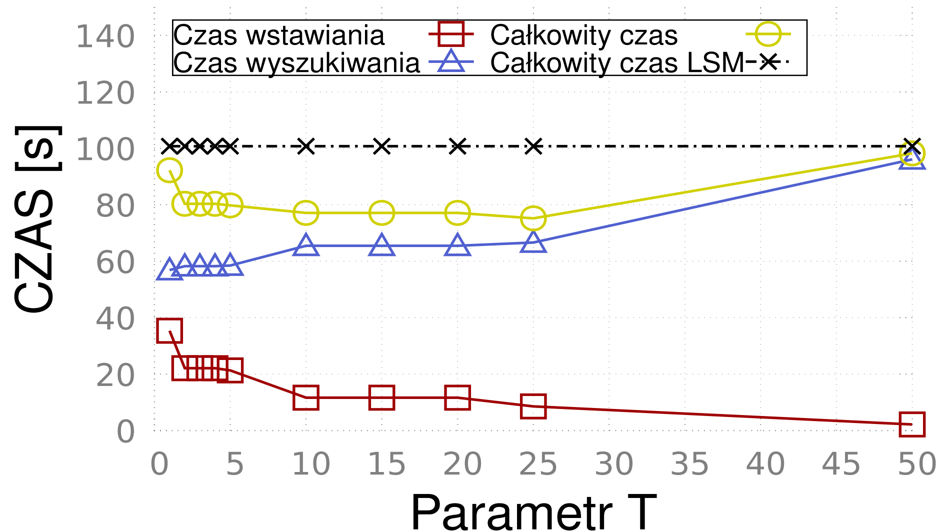

Rysunek 6.9: Czas wykonania zestawu kwerend T_B
Dysk: Toshiba VX500
Tabela: Sklep (113 B)

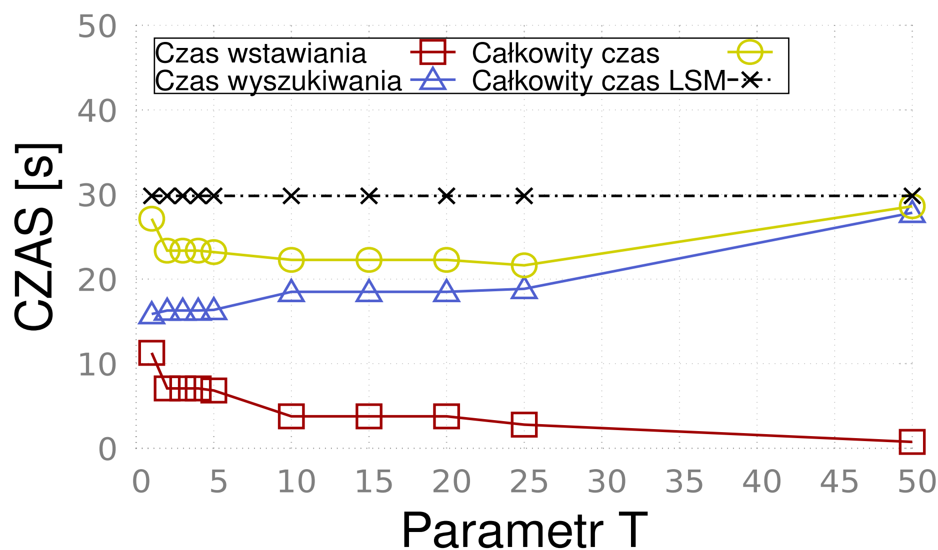

Rysunek 6.10: Czas wykonania zestawu kwerend T_B
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

W trzeciej serii eksperymentów zbadaliśmy wpływ charakterystyki dysków na efektywność struktury FALSM przy różnych parametrach T. Ponownie wybraliśmy standardową tabelę TPC-C Sklep. Jednak tym razem zamieściliśmy wyniki tylko dla zestawu T_B, ponieważ pozostałe zestawy uzyskały ten sam trend. Rysunki: 6.4, 6.9, 6.10 przedstawiają wyniki odpowiednio dla dysków Samsung, Toshiba i Intel. Porównując ze sobą wszystkie trzy dyski, widzimy, że szybkość odczytu jak i zapisu nie ma wpływu na wybór najlepszego parametru T. Okazało się, że głównie rozmiar strony i bloku ma wpływ na osiągi FALSM. Rozmiar strony, jak i parametr T, ma wpływ na topologię drzewa:

im mniejsza strona, tym więcej ich jest w jednym węźle. To oznacza, że musimy zapisać lub odczytać więcej stron podczas obsługi pojedynczego węzła. Z obserwacji wynika, że na dyskach o mniejszych stronach optymalne T znajduje się w okolicach wartości 20-25. Jednak warto zaznaczyć, że czas całkowity wykonania się kwerend nie odbiega więcej niż 3% od poprzedniej optymalnej wartości 5. Możemy zatem uznać, że $T = 5$ jest wartością, która sprawdza się bardzo dobrze dla dowolnego dysku, jak i dowolnego rozmiaru tabeli. Użyjemy tego faktu w kolejnych eksperymentach, w których ustawimy wartość T właśnie na 5.

Rozszerzony zestaw kwerend

Tak jak wspominaliśmy wcześniej, zestaw rozszerzony powstał na podstawie kwerend z TPC-C. Celem tego zestawu jest symulacja hurtowni danych, w której operacje są buforowane i wykonywane na wielu rekordach. Oznacza to, że każde dodawanie rekordów użyje dodawania zbiorczego na strukturze FALSM oraz zwykłego dodawania do bufora na strukturze LSM.

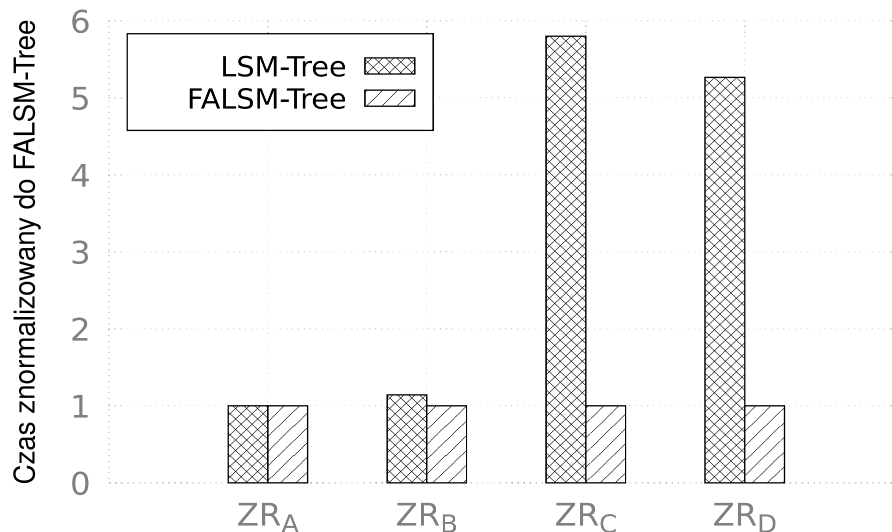

Rysunek 6.11: Znormalizowany czas
Dysk: Samsung 840
Tabela: Sklep (113 B)

W tym zestawie kwerend używamy wyszukiwania całego zakresu rekordów zamiast punktowego wyszukiwania. Każde wyszukiwanie ma ustawioną selektywność na poziomie 1% całej tabeli. W każdej serii zestawu kwerend najpierw wykonywane jest dodawanie rekordów, później wyszukiwanie, a na końcu usuwanie rekordów. Przygotowano cztery różne zestawy kwerend, które dokładnie opisano w rozdziale 4.

1. ZR_A - 100 serii, każda seria zawiera operacje dodawania 5 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 5 rekordów,
2. ZR_B - 5 serii, każda seria zawiera operacje dodawania 100 000 rekordów, 5 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 100 000 rekordów,
3. ZR_C - 10 serii, każda seria zawiera operacje dodawania 10 000 000 rekordów, 20

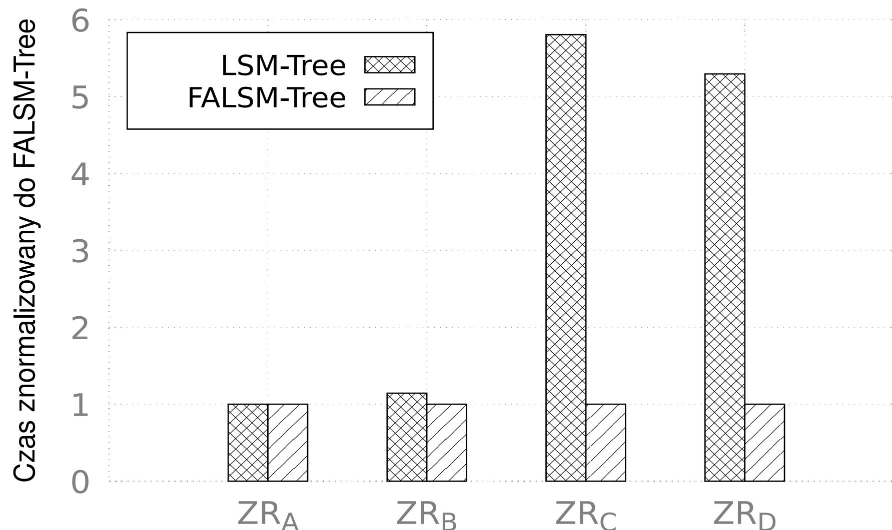

Rysunek 6.12: Znormalizowany czas
Dysk: Toshiba VX500
Tabela: Sklep (113 B)

wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 1 000 000 rekordów,

4. ZR_{D} - 10 serii, każda seria zawiera operacje dodawania 1 000 000 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 10 000 rekordów.

Zaproponowany zestaw kwerend wykonujemy na indeksie zawierającym już wiele danych. W naszym przypadku, najpierw wstawiliśmy do indeksów 10 mln danych, a następnie wykonaliśmy kwerendy i zmierzyliśmy czas jak i wykorzystanie pamięci dysku SSD za pomocą odpowiednich liczników dostarczanych przez symulator SIPS. Przypomnijmy, że w tych eksperymentach FALSM ma ustawiony parametr T na stałą wartość 5.

Analizując wyniki wszystkich eksperymentów przedstawionych na rysunkach: 6.11, 6.12, 6.13, 6.14, 6.15, możemy stwierdzić, że ani charakterystyka dysku ani rozmiar rekordu nie wpływa na trend i przewagę FALSM nad LSM. Niezależnie od modelu pamięci czy tabeli, LSM uzyskał taki sam czas jak FALSM dla zestawu ZR_A. To spowodowane jest bardzo małą liczbą nowych rekordów, które prawie w całości trafiły do bufora i nie zostały przepisane na dysk. Dla zestawu ZR_B drzewo FALSM uzyskało wynik o 12% lepszy od struktury LSM. Z kolei w przypadku zestawów ZR_C i ZR_D FALSM okazał się lepszy ponad 5-krotnie od klasycznego indeksu. Jak widać, gdy w zestawie kwerend występuje dużo zbiorczych dodawań, to mimo iż czas wyszukiwania jest zwiększony przez obecność węzłów dopisanych, całkowity czas zestawu jest o wiele lepszy na FALSM. Nasza nowa struktura uzyskuje lepszy czas poprzez minimalizację liczby zapisów na dysk, a więc całkowite zużycie pamięci (ang. wearout) też jest mniejsze. Tabela 6.2 przedstawia całkowitą liczbę zapisanych bajtów podczas przeprowadzania eksperymentów. Jak widać mamy dokładnie ten sam trend co na wykresach omawianych wcześniej. FALSM zapisuje nawet 5-krotnie mniej bajtów na dysku SSD niż indeks LSM.

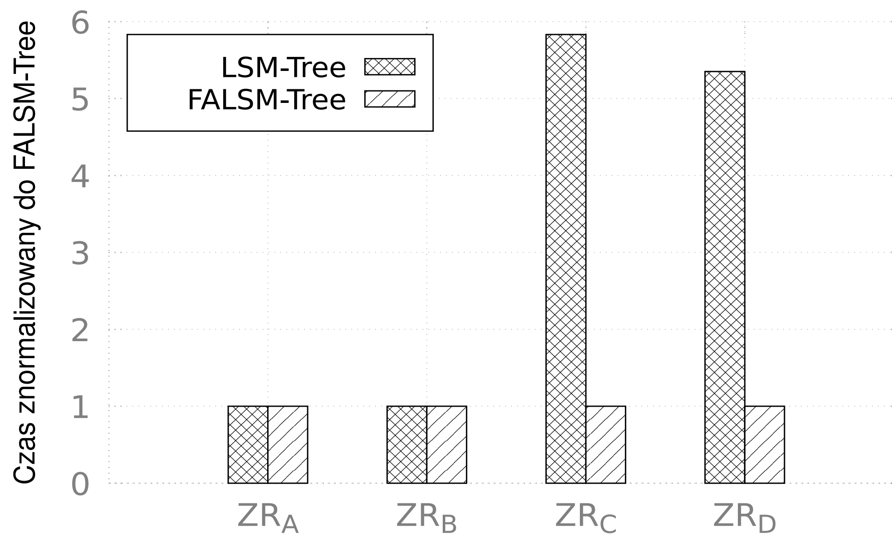

Rysunek 6.13: Znormalizowany czas
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

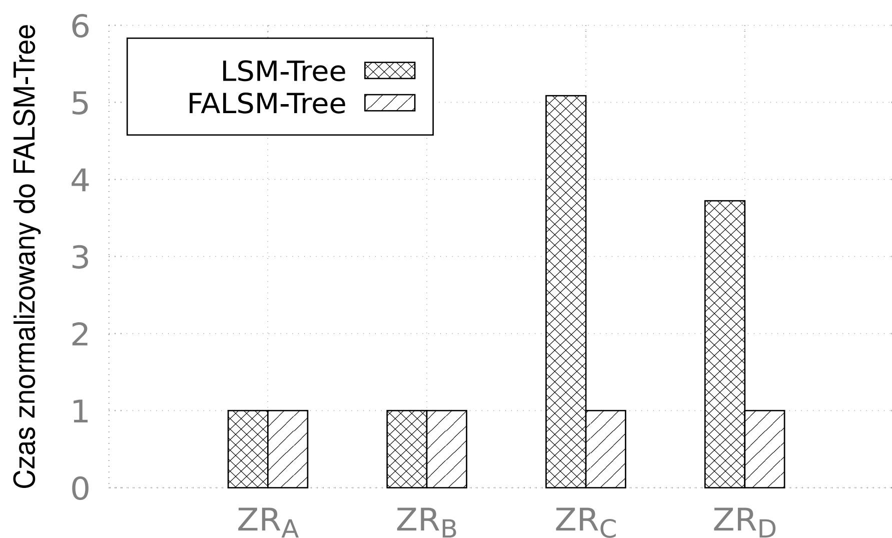

Rysunek 6.14: Znormalizowany czas
Dysk: Samsung 840
Tabela: Nowe zamówienie (20 B)

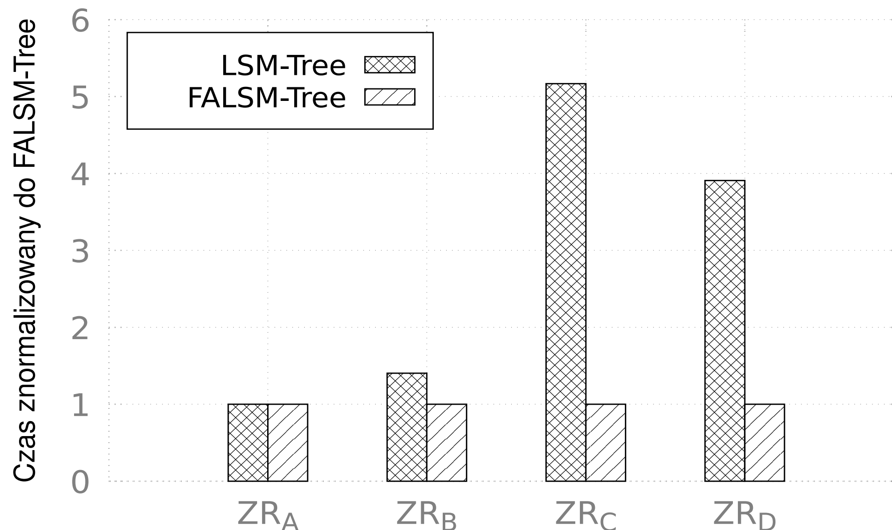

Rysunek 6.15: Znormalizowany czas
Dysk: Samsung 840
Tabela: Klient (719 B)

	Nowe zamówienie		Sklep		Klient	
Zestaw	**LSM**	**FALSM**	**LSM**	**FALSM**	**LSM**	**FALSM**
ZR_A	0	0	0	0	33 KB	33 KB
ZR_B	58 KB	58 KB	416 KB	349 KB	4,4 MB	2,9 MB
ZR_C	24 MB	4,4 MB	170 MB	28 MB	1,3 GB	250 MB
ZR_D	2 MB	500 KB	14,2 MB	2,4 MB	110 MB	27 MB

Tabela 6.2: Zużycie pamięci dysku SSD na różnych tabelach
Dysk: Samsung 840

	Nowe zamówienie		Sklep		Klient	
Zestaw	**LSM**	**FALSM**	**LSM**	**FALSM**	**LSM**	**FALSM**
ZR_A	3,9s	3,9 s	20 s	20 s	122 s	122 s
ZR_B	0,4 s	0,4 s	2 s	1,7 s	18 s	13 s
ZR_C	87 s	17 s	10 min	1,8 min	80 min	16 min
ZR_D	7,7 s	2 s	52 s	10 s	7 min	1,5 min

Tabela 6.3: Czas wykonania kwerend na różnych tabelach
Dysk: Samsung 840

W poprzednich eksperymentach, gdy sprawdzaliśmy wpływ parametru T na efektywność struktury FALSM, dowiedzieliśmy się, że rozmiar strony dysku SSD ma wpływ na wybór T. Analizując wyniki zestawu umieszczone w tabeli 6.4, widzimy, że przy ustalonym już T, rozmiar strony i bloku nie mają wpływu na czas wykonania się całego zestawu. Oczywiście, im lepsze parametry dysku, szybszy czas zapisu i odczytu, tym szybciej uda się obsłużyć wszystkie kwerendy. Stąd zawsze najmocniejszy dysk w naszym zestawieniu, Intel DCP4511, osiąga najlepsze czasy we wszystkich zestawach. Wynika to głównie z faktu, iż ani LSM ani FALSM nie używają losowych zapisów. Ich procedury dodawania nowych elementów działają w taki sposób, że zawsze kontroler dysku może działać

	Samsung 840		Toshiba VX500		Intel DCP4511	
Zestaw	**LSM**	**FALSM**	**LSM**	**FALSM**	**LSM**	**FALSM**
$\boldsymbol{ZR_A}$	20s	20 s	20,2 s	20,2 s	5,6 s	5,6 s
$\boldsymbol{ZR_B}$	2 s	1,7 s	2 s	1,7 s	0,2 s	0,2 s
$\boldsymbol{ZR_C}$	10 min	1,8 min	10,5 min	1,9 min	198 s	34 s
$\boldsymbol{ZR_D}$	52 s	10 s	53 s	10 s	16,8 s	3,2 s

Tabela 6.4: Czas wykonania kwerend na różnych dyskach SSD
Tabela: Sklep (113 B)

w trybie sekwencyjnym. Dlatego, mimo bardzo wolnego zapisu losowego, Intel uzyskuje najkrótszy czas wykonania kwerend.

Podobne wnioski uzyskujemy ze sprawdzenia efektywności indeksów na różnych tabelach. Mimo iż rozmiar rekordu wpływał na optymalne T, to przy ustalonym parametrze, nie ma on wpływu na różnice pomiędzy LSM a FALSM. Tak więc zostaje zachowany trend dokładnie taki sam, jak w przypadku poprzednich eksperymentów. Oznacza to, iż mimo że mniejsze rekordy potrzebują mniej czasu na ich zapisanie, to nadal FALSM jest 5-krotnie szybszy od indeksu LSM w zestawie ZR_C. Jedyna zmiana zaistniała w zestawie ZR_D. Przy użyciu tabeli Nowe zamówienie o rozmiarze 20 B, FALSM uzyskał wynik około 4 razy lepszy niż LSM, a na tabeli Sklep oraz Klient uzyskał wyniki około 5 razy lepsze od klasycznej struktury.

6.4 Indeksowanie kolumnowe

Chociaż indeksowanie wierszowe nadal jest domyślnym sposobem zapisu w wielu systemach baz danych, zapis kolumnowy w ostatnich latach znacząco zyskał na popularności. Wynika to z faktu, że większość zapytań do baz danych nie potrzebuje informacji ze wszystkich kolumn. W wierszowej implementacji marnujemy odczyty z dysku na wczytanie całego wiersza i wyłuskanie tylko potrzebnych atrybutów. W podejściu kolumnowym na jednej stronie w pamięci przetrzymywane są wartości pojedynczej kolumny dla kilku rekordów, co pozwala podczas wyszukiwania wczytywać tylko potrzebne informacje. Niestety, podejście kolumnowe jest wolniejsze podczas zapisywania nowych rekordów, ponieważ musimy zapisać podzielony rekord na kolumny w kilku miejscach na dysku [10], [11], [12].

Historycznie, za pierwszy silnik w pełni wspierający kolumnowy zapis tabeli uznaje się C-Store [33]. Opisany on został dokładnie w rozdziale 2. Przypomnijmy jednak najważniejsze aspekty tego systemu. C-Store zapisywał tabelę w dwóch osobnych sekcjach: sekcji zorientowanej na szybkie odczyty, która była zapisana kolumnowo, oraz sekcji zoptymalizowanej pod częste zapisy i aktualizacje danych. Druga sekcja zapisana była wierszowo, aby umożliwić szybkie wstawianie i usuwanie rekordów. C-Store sam decydował kiedy przenieść dane z jednej sekcji do drugiej.

Indeksowanie kolumnowe w ostatnich latach zyskało na popularności, dzięki czemu większość nowoczesnych silników baz danych wspiera ten sposób zapisu tabeli. Do takich systemów należą między innymi: MonetDB [47], PostgreSQL [48], VectorWise [49], Druid [50] oraz eXtremeDB [51]. Najpopularniejszą strukturą danych obecnie używaną do indeksowania rekordów zapisanych kolumnowo jest PDT [52] (ang. *Positional Delta Tree*). Ten

indeks jest stosowany w bazach danych zapisanych w pamięci operacyjnej komputera (ang. *in-memory database*) oraz na dyskach twardych HDD. Jednak ze względu na specyfikę działania, nie zaleca się stosowania tej struktury na dyskach SSD. Nowoczesne pamięci takie jak flash, SSD czy PCM charakteryzują się inną charakterystyką, gdzie zapis jest kilkukrotnie wolniejszy niż odczyt, co sprawia, że klasyczne struktury danych nie są efektywne w ułożeniu kolumnowym. Algorytm musi spełniać wymogi kolumnowego zapisu, jak szybka operacja scalania, ale również wykorzystywać techniki przyspieszające zapis danych odpowiednie dla używanych pamięci. Dobrymi przykładami są system PAX [53], który dzieli wirtualnie stronę dysku SSD na mini strony, z których każda zawiera dane tylko jednej kolumny, oraz struktura FBDSM [54] (ang. *Flash-based Decomposition Storage Model*), dostosowująca oryginalny pomysł DSM [32] do pamięci flash. FBDSM dzieli dane na dwie tabele: PT, zapisującą stałe dane, oraz LT, zawierającą wszelkie zmiany. Ta struktura umożliwia odroczone nadpisywanie danych oraz ich szybsze przetwarzanie dzięki operacjom pakietowym, co jest korzystne dla pamięci flash, jednak nie rozwiązuje problemu braku uporządkowania danych kluczowych i nie jest sortowana według klucza, lecz według czasu, co ułatwia scalanie kolumn w pełne rekordy.

6.5 Columned FD-Tree

Ponieważ żadna z wcześniej wymienionych struktur nie wspiera jednocześnie kolumnowego zapisu, szybkiego wyszukiwania po kluczu oraz wsparcia dla dysków SSD w pełni, zaproponowałem nową strukturę danych, która spełnia wszystkie te wymogi. Struktura CF-Tree (ang. *Columned FD-Tree*) [3], oparta na zbiorze drzew [27], składa się z drzewa KCF (ang. *Key Column FD Tree*), przechowującego atrybut klucza, oraz drzew NCF (ang. *Non-key Column FD Tree*), gdzie każde przechowuje jeden z atrybutów, które nie są kluczem. Za pomocą specjalnego algorytmu scalania atrybutów w rekord, stworzonego na potrzeby tej struktury, możemy w każdym momencie połączyć wszystkie kolumny i otrzymać pełny rekord. Struktura CF-Tree charakteryzuje się bardzo szybkim wstawianiem nowych elementów, porównywalnym do szybkości oryginalnego drzewa FD, które zapisywało dane wierszowo, szybkim wyszukiwaniem z zakresu oraz wolniejszym wyszukiwaniem punktowym. Szybkość wyszukiwania zależy od liczby kolumn, które użytkownik chce wczytać, oraz od wielkości samego atrybutu. Podczas eksperymentów zaobserwowano znaczącą przewagę struktury CF-Tree nad FBDSM w każdych warunkach, oraz przewagę nad wierszowym FD, gdy liczba wczytanych kolumn była mniejsza niż liczba atrybutów składających się na cały rekord.

6.5.1 Struktura CF-Tree

Nasza nowa struktura CF-Tree składa się z tylu drzew FD, ile atrybutów ma rekord w tabeli. Aby zapewnić szybki zapis i odczyt na dyskach SSD, pojedyncze drzewo w tej strukturze składa się z kilku poziomów. Na samej górze, na poziomie L_0, znajduje się bardzo małe drzewo B+ o wielkości zaledwie kilku stron dysku SSD. Każdy poziom według zasady 2 (opisanej później w tym rozdziale) musi posiadać tyle samo danych, co dotyczy również bufora. Z tego wynika, że rozmiary buforów dla różnych drzew w zbiorze CF-Tree nie muszą być równe; ich wielkości dostosowywane są w taki sposób, aby każde drzewo mogło pomieścić w buforze tyle samo danych co kolumna klucza na KCF. Ponieważ poziom L_0 jest bardzo mały, z łatwością zmieści się w pamięci RAM. Poziom L_0 służy do buforowania danych, zanim trafią one do dalszych poziomów (L_i, $i > 0$), które

są zapisane na dysku SSD. Aby uzyskać strukturę drzewa, liście w drzewie B+ zawierają wskaźniki do L_1, czyli pierwszego poziomu zapisanego na dysku. Ponadto, każdy kolejny poziom zawiera zbiór wskaźników do odpowiednich stron pamięci poziomu niżej. Dzięki takiej strukturze możemy w łatwy sposób przejść po naszym drzewie od góry do dołu, aby wyszukać rekord o wskazanym kluczu. Sama procedura wyszukiwania, ze względu na kolumnowe ułożenie danych, jest dość skomplikowana, ponieważ wymaga użycia nowego algorytmu scalania atrybutów w rekord. Procedura wyszukiwania szczegółowo opisana jest w dalszej części tego rozdziału.

Każdy z poziomów posiada swoją maksymalną pojemność wyrażoną w liczbie stron dysku SSD. Każda operacja alokacji pamięci odbywa się poprzez alokację pełnej strony. Aby zminimalizować koszty reorganizacji struktury, podobnie jak w przypadku drzewa B+ czy LSM, wprowadziliśmy współczynnik k. Każdy kolejny poziom zawiera k razy więcej bloków ($|L_{i+1}| = |L_i| \cdot k$). Podczas eksperymentów zauważyliśmy, że współczynnik k powinien być dobrany odpowiednio do rodzaju kwerendy. Im większe k, tym drzewo jest niższe, co oznacza, że koszt wyszukiwania jest mniejszy, ale koszt reorganizacji jest znacznie większy. Z tego względu należy dobierać ten współczynnik pod konkretny zestaw kwerend lub ustalić neutralną wartość. Z przeprowadzonych eksperymentów wynika, że neutralne wartości k mieszczą się w przedziale $5; 10$. W naszej nowej strukturze wyróżniamy 4 rodzaje danych:

1. **Normalna dana** (ang. *normal entry*) – jest to pojedynczy atrybut rekordu. Dla drzewa KCF będzie to klucz rekordu, dla pozostałych drzew NCF będą to zwykłe wartości danej kolumny, która nie jest kluczem.

2. **Usunięta dana** (ang. *deleted entry*) – aby zminimalizować liczbę zapisów na dysku SSD, skorzystaliśmy z leniwego mechanizmu usuwania dostępnego w drzewie FD. Zamiast usuwać rekord natychmiastowo, co doprowadziłoby do reorganizacji wszystkich drzew, wstawiamy nowy rekord oznaczony jako d_{key} o takim samym kluczu jak rekord, który chcemy usunąć. Dzielimy więc rekord na atrybuty i wstawiamy wartości poszczególnych atrybutów do odpowiadających im drzew, oznaczając przy tym wartość jako „do usunięcia”. Gdy dane podczas nieuniknionej migracji poziomów w dół spotkają się, są usuwane ze struktury. Operacja ta jest dokładnie opisana w kolejnych sekcjach tego rozdziału.

3. **Zewnętrzny wskaźnik** (ang. *external fence*) – ten element struktury zawiera trzy pola. Pierwszym z nich jest identyfikator strony, na którą wskazuje (PID) z poziomu niżej. Drugim polem jest wartość pierwszego (czyli najmniejszego) klucza strony, na którą wskazuje. Warto zwrócić uwagę, że wskaźnik zawiera wartość klucza na każdym drzewie KCF i NCF. Ponieważ operacja scalania poziomów wykonywana jest jednocześnie na wszystkich drzewach w obrębie CFT, istnieje możliwość skopiowania odpowiedniej wartości klucza z KCF podczas tworzenia wskaźnika w drzewach NCF. Ostatnim polem jest tablica $numEntriesBeforePageArray$, która zawiera wartości $numEntriesBeforePage$ kolejnych stron na ścieżce od obecnej strony do liścia w drzewie z kluczem (lub wartością innego atrybutu skorelowanego z kluczem) równym wartości klucza danego wskaźnika. Podczas operacji scalania poziomów, dla każdej strony poziomu L_{i+1} tworzony jest nowy wskaźnik do tej strony i umieszczany jest w poziomie nad nim, czyli w L_i. Dzięki temu struktura drzewa jest zachowana po każdej reorganizacji.

4. **Wewnętrzny wskaźnik** (ang. *internal fence*) – wskaźnik ten zawiera tylko dwa

pola. Pierwszym z nich jest wskaźnik na stronę z poziomu niższego (PID). Drugim polem jest wartość klucza. Tym razem nie jest to klucz strony, na którą wskazuje, ale klucz najmniejszego klucza na poziomie, na którym znajduje się wewnętrzny wskaźnik. Tak samo jak w przypadku zewnętrznego wskaźnika, wartość klucza brana jest z drzewa KCF niezależnie od tego, czy wskaźnik znajduje się w drzewie KCF czy NCF. Każda strona jako pierwszy element musi posiadać wskaźnik, aby utrzymać strukturę drzewa i wszystkie własności struktury FD jak i CFT. Jeśli strona nie zawiera zewnętrznego wskaźnika, wówczas tworzony jest wewnętrzny wskaźnik, który wskazuje na tę samą stronę, co poprzedni wskaźnik danego poziomu.

Struktura CFT posiada 7 głównych własności, które nie mogą zostać zaburzone podczas działania systemu.

1. Liczba danych w każdym FD-Tree jest taka sama.
2. Liczba danych w każdym FD-Tree na danym poziomie jest taka sama.
3. Liczba zewnętrznych wskaźników (ang. *external fences*) na poziomie L_i jest równa liczbie stron na poziomie L_{i+1}.
4. Jeśli poziom nie jest liściem, to pierwszą daną (ang. *entry*) na stronie musi być wskaźnik.
5. Wszystkie wskaźniki na każdym drzewie w zbiorze CF-Tree posiadają wartość pola *key* równą wartości klucza braną z KCF.
6. Każda strona dysku SSD p na każdym poziomie posiada pole $p.numEntriesBeforePage$, zawierające liczbę danych zapisanych na tym poziomie przed stroną p.
7. Każdy zewnętrzny wskaźnik ptr posiada tablicę $numEntriesBeforePageArray$, która składa się z $ptr.page.numEntriesBeforePage$, $ptr'.page.numEntriesBeforePage$, $ptr''.page.numEntriesBeforePage$, $\ldots$, gdzie ptr', ptr'', $\ldots$ to skrajnie lewe wskaźniki na drodze od strony, na której zapisany jest ptr, aż do liścia z wartością $ptr.key$.

Rysunek 6.16 przedstawia przykładową strukturę CF-Tree dla rekordu o 2 atrybutach. Pierwszym atrybutem jest liczba – klucz rekordu, drugim atrybutem jest pojedyncza litera. Dla uproszczenia przykładu zakładamy, że oba atrybuty mają taki sam rozmiar. Strona dysku SSD jest w stanie pomieścić 4 wartości. Parametr k jest ustawiony na wartość 2. Tak więc każdy kolejny poziom ma 2 razy większą pojemność. Ze względu na to, iż rekord składa się z tylko 2 atrybutów, CF-Tree zawiera 2 drzewa: KCF i jedno NCF. Warto zauważyć, że o ile wartości w drzewie KCF nie mogą się powtarzać, ponieważ klucz jest unikalny, to wartości w NCF mogą się powtarzać, ponieważ nie są kluczem rekordu.

Jak już wiemy, w drzewie wyróżniamy 4 rodzaje rekordów:

1. Normalne - dane, które użytkownik dodał do bazy (na rysunku np. $\langle 2, G\rangle$, $\langle K, 9\rangle$).
2. Do usunięcia - dane, które użytkownik chce usunąć, ale ze względu na system leniwego usuwania, zamiast przeprowadzać nadmiarową reorganizację drzewa, dodajemy rekord do usunięcia (na rysunku mamy $\langle 8, V\rangle$ na poziomie L_3, oraz $\langle 8, V\rangle$ do usunięcia na poziomie L_1).

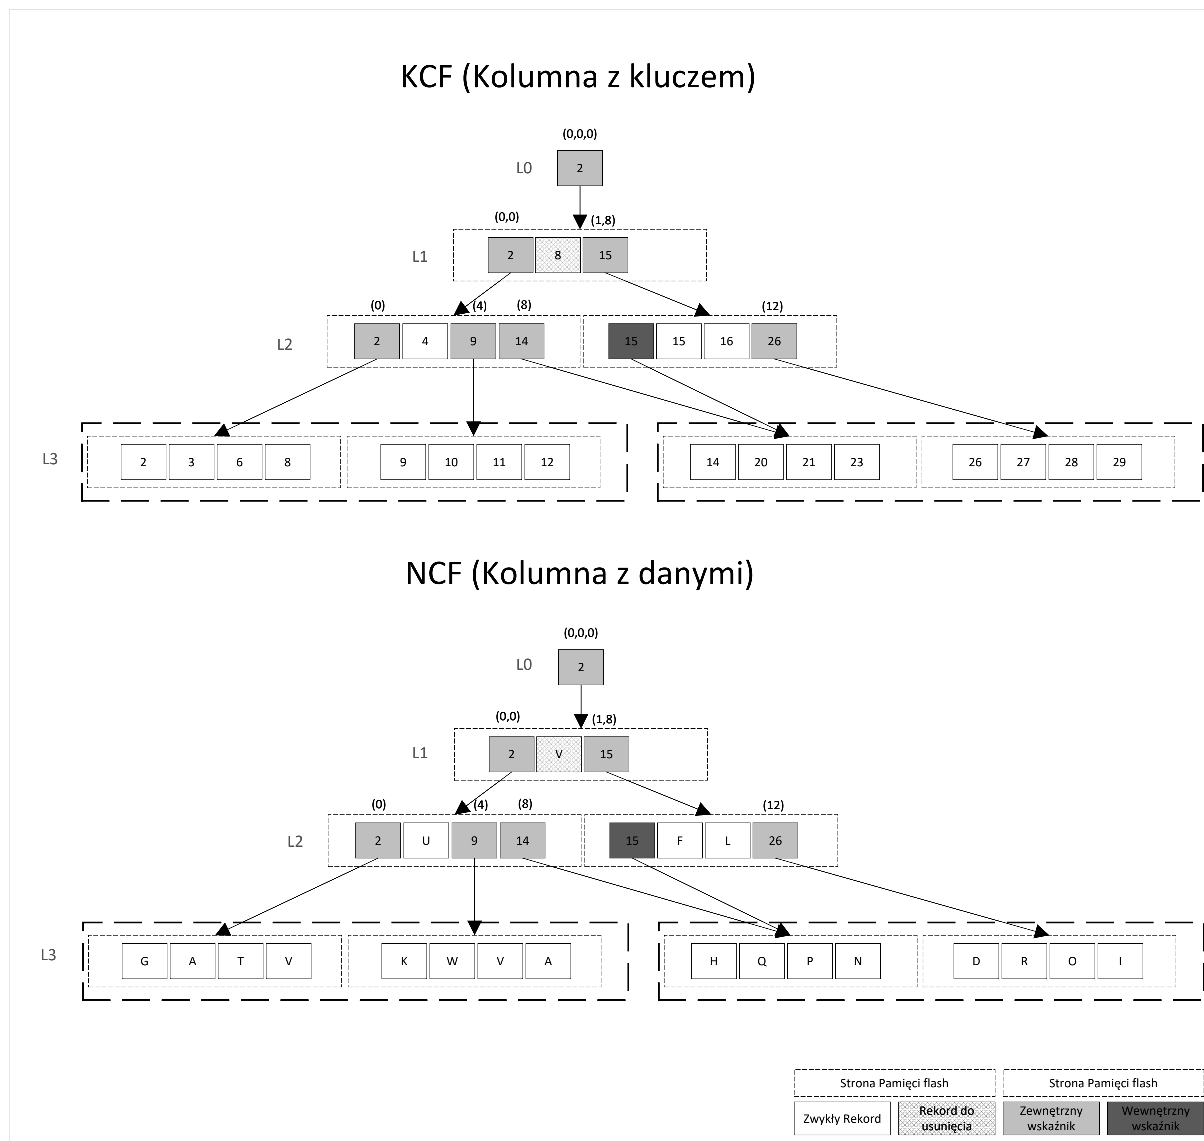

Rysunek 6.16: Przykładowa struktura CF-Tree

3. Wskaźnik wewnętrzny - na rysunku jest to $\langle 15 \rangle$ na poziomie L_2. Warto zauważyć, że wartość tego wskaźnika jest taka sama w drzewie KCF jak i NCF.

4. Wskaźnik zewnętrzny - wskaźnik na poziom niżej, który prócz wartości i wskaźnika na stronę zawiera także tablicę $numEntriesBeforePageArray$. Tablica ta zawiera liczbę danych zapisaną przed stronami na ścieżce od wskaźnika do liścia. Przykładowo, wskaźnik $\langle 15, (1{,}8) \rangle$ wskazuje na stronę $P2$ poziomu L_1. Przed tą stroną mamy tylko jedną normalną daną $\langle 4, U \rangle$, później nasza ścieżka prowadzi do $P3$ na poziomie L_2. Przed tą stroną mamy aż 8 normalnych wartości, a więc tablica ma wartości (1,8).

Taka struktura drzew pozwala nam w bardzo łatwy sposób znaleźć odpowiednie atrybuty i złożyć wszystkie kolumny w pełny rekord. Przykładowo chcemy znaleźć rekord o kluczu 10. Najpierw szukamy klucza 10 w drzewie KCF. Ta procedura nie różni się od zwykłego wyszukiwania w drzewie FD. Początkowo mamy w buforze tylko wskaźnik 2. Zatem odwiedzamy stronę $P1$. Tutaj szukamy wskaźnika o największej wartości mniejszej niż 10. Wskaźnik 2 spełnia ten warunek. Wczytujemy zatem kolejną stronę - $P1$.

Tym razem to wskaźnik o wartości 9 jest największym wskaźnikiem, zatem odczytujemy kolejną stronę i znajdujemy wartość 10. Wiemy zatem, że nasz rekord został zapisany na poziomie L_3, na stronie $P2$ na pozycji 6. Mając wszystkie informacje, możemy wykonać algorytm scalania atrybutów. Wykorzystując tablicę $numEntriesBeforePageArray$ musimy znaleźć atrybut na pozycji 6. Zatem odczytujemy bufor drzewa NCF. Mamy tutaj tylko 1 wskaźnik, a więc wczytujemy stronę $P1$. Teraz szukamy takiego wskaźnika, który ma ostatnią wartość tablicy maksymalną ale nie większą niż 6 (ostatnią wartość, ponieważ szukamy danej w ostatnim poziomie). Wskaźnik 2 spełnia ten warunek, ponieważ wartość $numEntriesBeforePageArray[2] = 0$, a dla kolejnego wskaźnika 15 wartość $numEntriesBeforePageArray[2] = 8$. Odczytujemy kolejną stronę zawierającą $(2, U, 9, 14)$. Kolejny raz musimy znaleźć odpowiedni wskaźnik na podstawie tablicy $numEntriesBeforePageArray$. Wskaźnik o wartości 9 spełnia nasz warunek wyszukiwania, a więc odczytujemy stronę $P2$. Wiemy, że ta strona ma przed sobą 4 wartości, zatem szukany atrybut znajduje się na pozycji 2 obecnej strony. Zwracamy zatem wartość W i kończymy algorytm.

6.5.2 Procedury indeksu CF-Tree

Wstawianie

Ponieważ CF-Tree to zbiór drzew FD, samo wstawianie odbywa się tak samo jak w drzewie FD, z tą różnicą, że rekord otrzymany od użytkownika dzielimy na pojedyncze atrybuty. Klucz rekordu wstawiamy do KCF-Tree, a pozostałe kolumny do NCF-Tree. Pamiętajmy, że każde z drzew FD w zbiorze posiada swój bufor w pamięci RAM oraz że każde drzewo musi posiadać tyle samo danych na każdym poziomie, również w buforze. Oznacza to, że rozmiary buforów są różne, dostosowane do rozmiaru atrybutu, który przechowują. Gdy bufor drzewa KCF jest pełen, następuje scalanie poziomu L_0 (bufora) z poziomem L_1. Scalanie wykonujemy równolegle na każdym drzewie, aby zachować wszystkie własności struktury CF.

Wyszukiwanie

Wyszukiwanie podzielone jest na dwie fazy. Pierwsza polega na znalezieniu poziomu i pozycji w tym poziomie dla szukanego klucza w KCF. Następnie trzeba znaleźć wszystkie wartości, które zażądał użytkownik w kwerendzie. Ponieważ mamy ułożenie kolumnowe, nie musimy łączyć wszystkich atrybutów w cały rekord. Wystarczy połączyć tylko te kolumny, które będą potrzebne w zapytaniu, co znacząco zmniejsza koszt wyszukiwania w porównaniu do ułożenia wierszowego, gdzie zawsze musimy wczytać cały rekord. Podczas wyszukiwania punktowego potrzebujemy tylko pojedynczego rekordu (lub jego fragmentu). Gdy już znamy pozycję i poziom klucza, możemy wykonać algorytm scalania atrybutów, aby znaleźć pozostałe wartości. Oznacza to, że za każdym razem musimy przeszukać logarytmicznie wiele drzew. Procedurę tę powtarzamy dla każdego zapytania. Ponieważ koszt odczytu kilku bajtów jest taki sam jak koszt odczytu całej strony na dysku SSD, wyszukiwanie punktowe jest wolniejsze na ułożeniu kolumnowym, ponieważ zamiast pojedynczego przejścia po drzewie, mamy tyle przejść, ile kolumn musimy zwrócić w zapytaniu. O wiele lepszą sytuację mamy podczas wyszukiwania całego zakresu. Za pierwszym razem, gdy musimy znaleźć pierwsze atrybuty i ich pozycje, używamy algorytmu scalania atrybutów. Później jednak, wiedząc, że z drzewa KCF musimy odczytać kolejno n wartości, te same n kolejnych wartości odczytujemy z pozostałych drzew bez

konieczności ponownego wyszukiwania ich pozycji w drzewie. Zatem ułożenie kolumnowe posiada bardzo szybkie wyszukiwanie zakresu kluczy, które jest tym szybsze od ułożenia wierszowego, im większa jest selektywność i mniejszy podzbiór wartości rekordu do wczytania.

Usuwanie

Usuwanie rekordu o podanym kluczu nie następuje natychmiastowo. Zamiast tego wstawiamy nowy rekord z kluczem, który mamy usunąć, i ustawiamy typ tego rekordu jako *Usunięta dana*. Gdy podczas reorganizacji poziomów natrafimy na oba rekordy: oryginalny oraz ten do usunięcia, wtedy usuwamy oba rekordy. Ta operacja realizowana jest jako brak zapisu poszczególnych rekordów ze starych zbiorów do nowego zbioru. Oczywiście, operacja usuwania, jak i dodawania rekordu do usunięcia, odbywa się na wszystkich drzewach KCF i NCF jednocześnie.

Scalanie poziomów

Reorganizacja drzewa przeprowadzana jest, gdy któryś z poziomów nie ma wolnego miejsca na kolejne elementy. Wtedy uruchamiamy proces scalania dwóch poziomów: obecnego i kolejnego poniżej niego. Jeśli nie istnieje poziom niżej, wtedy jest on tworzony z odpowiednio dużą pojemnością (k razy większą od poprzedniego poziomu). Każde z drzew zawiera tyle samo danych, a jego pojemność jest dostosowana tak, aby na każdym poziomie mogło pomieścić tyle samo danych, co w pozostałych drzewach. Dlatego gdy istnieje potrzeba wykonania reorganizacji na głównym drzewie KCF, to również wykonujemy ją na wszystkich pozostałych drzewach NCF. Scalanie poziomów odbywa się według porządku narzuconego przez wartości kluczy w drzewie KCF. Oznacza to, że jeśli w danym momencie powinniśmy przepisać wartość z poziomu L_i, bo wartość obecnego klucza na tym poziomie jest najmniejsza wśród wszystkich kluczy, to przepisujemy odpowiednie wartości (dane z odpowiednich pozycji i poziomów) ze wszystkich drzew w obrębie CFT. Dzięki temu zachowujemy wszystkie własności struktury. Podczas reorganizacji pamiętamy, że jeśli poziom L_{i-1} będzie zawierał rekord o tym samym kluczu co rekord na poziomie L_i ale z odpowiednim znacznikiem do usunięcia, wtedy pomijamy oba rekordy (czyli wszystkie dane na wszystkich drzewach) i żadnego z nich nie wpisujemy do nowego poziomu L'_i. Możliwe, że podczas tego procesu poziom L'_i również nie będzie miał wystarczająco miejsca, aby pomieścić wszystkie dane. Wtedy wykonujemy scalanie poziomów L'_i z L_{i+1}. Proces ten powtarzamy rekurencyjnie do momentu uzyskania poziomu mieszczącego wszystkie rekordy.

Scalanie atrybutów

Scalanie atrybutów w jeden rekord to najważniejszy i zarazem najtrudniejszy do zaprojektowania algorytm w kolumnowym układzie indeksu. Bez tego algorytmu nie bylibyśmy w stanie połączyć z powrotem atrybutów zapisanych w drzewach KCF i NCF w cały rekord, co oznaczałoby zerową przydatność struktury CFT. Algorytm scalania opiera się na założeniu, że każde drzewo posiada tyle samo danych na każdym z poziomów. Oznacza to, że jeśli znaleźliśmy atrybut na pozycji pos danego poziomu lvl, to należy go połączyć z innymi atrybutami na tej samej pozycji tego samego poziomu. Dokonać tego możemy dzięki tablicy $numEntriesBeforePageArray$, która zawiera liczbę danych zapisanych przed stronami na ścieżce od obecnego wskaźnika (również od korze-

nia) do liścia. Wiedząc, że każda strona musi zawierać przynajmniej jeden taki wskaźnik, mamy pewność, że w każdym momencie mamy dostęp do tej informacji. Za jej pomocą możemy jednoznacznie wyznaczyć stronę, która zawiera atrybut na szukanej pozycji *pos*. Sama procedura jest bardzo prosta i względnie szybka, ponieważ na każdym poziomie wystarczy odczytać tylko jedną stronę. Zatem koszt takiego scalenia jest logarytmiczny, podobnie jak wyszukiwanie punktowe w oryginalnym drzewie FD.

6.5.3 Opis algorytmów

Pseudokod 6.3 przedstawia dokładną listę kroków, jaką należy wykonać, aby scalić ze sobą oba poziomy w obrębie całego zbioru CFT. Sam algorytm jest bardzo podobny do scalania posortowanych list. Porządek reorganizacji ustalają klucze zapisane w drzewie KCF. Wiemy, że każdy poziom zawiera tyle samo danych oraz że każdy element poziomu na pozycji *pos* jest częścią tego samego rekordu. Zatem reorganizacja musi zostać wykonana na wszystkich drzewach KCF i NCF w taki sam sposób, aby nie zaburzyć własności drzew. Linia 5 jest odpowiedzialna za pominięcie, czyli usunięcie wszystkich wskaźników na poziomie L_{i-1}. Możemy tak postąpić, ponieważ poziom L_i będzie usuwany i nadpisany nowym poziomem L'_i. Zatem wszystkie wskaźniki na poziomie L_{i-1} staną się nieaktualne. Poziom L_{i+1} zostaje bez zmian (chyba że rekurencyjnie wywołamy algorytm z linii 40), więc nie możemy usunąć wskaźników zewnętrznych. Gdybyśmy to zrobili, stracilibyśmy bezpowrotnie dostęp do poziomu L_{i+1}. Z kolei wskaźniki wewnętrzne na poziomie L_i nie są już potrzebne. Zostały stworzone tylko dlatego, żeby był spełniony warunek mówiący o tym, że pierwszy rekord na stronie musi być wskaźnikiem. Ponieważ zmieni się układ poziomu L_i, który zostanie przepisany do L'_i, również zmienią się wskaźniki wewnętrzne. Zatem pominięcie wszystkich wskaźników wewnętrznych w linii 6 jest prawidłowe. Linie 7-8 są odpowiedzialne za usuwanie rekordów. Tak jak wspominaliśmy, usuwanie elementów nie odbywa się natychmiastowo. Zamiast tego wstawiany jest rekord o tym samym kluczu odpowiednio oznaczony jako rekord do usunięcia. Gdy podczas scalania poziomów napotkamy na parę takich rekordów, wówczas usuwamy je, pomijając oba rekordy w algorytmie. Oznacza to, że żaden z nich nie zostanie wpisany do nowego poziomu L'_i. Następnym krokiem algorytmu jest wybór poziomu, z którego musimy przepisać dane znajdujące się w pamięci wskazywanej przez obecne wskaźniki e_i i e_{i-1}. Oczywiście, przeprowadzając reorganizację, musimy zachować liniowy porządek w drzewie. Musimy zatem wybrać wskaźnik, który ma mniejszą wartość klucza. Jeśli wybrany zostanie poziom L_{i-1}, sytuacja jest bardzo prosta. Poziom ten zawiera tylko normalne dane, ponieważ wskaźniki zostały usunięte w linii 5, a rekordy do usunięcia w linii 8. Ponieważ klucze zapisane w drzewie KCF nadają porządek w całym zbiorze CFT, bierzemy dane ze wszystkich drzew jednocześnie, mając na uwadze, że musimy je wczytać z poziomu L_{i-1} (linie 9-12). Gdy wybierzemy poziom L_i, sytuacja jest trochę bardziej skomplikowana. Na tym poziomie, oprócz normalnych danych, są jeszcze zewnętrzne wskaźniki, które są potrzebne do budowania struktury $numEntriesBeforePageArray$, wykorzystywanej w algorytmie scalania atrybutów (6.4). Pamiętajmy, że gdy pierwsza dana na stronie dysku SSD nie jest wskaźnikiem zewnętrznym, to tworzony jest jego wewnętrzny odpowiednik, który przyjmuje wartość wskaźnika taką, jak ostatni zewnętrzny wskaźnik na tym poziomie. Z tego względu, gdy napotykamy wskaźniki na poziomie L_i, zapisujemy je w tymczasowych zmiennych, aby zawsze mieć do nich dostęp (linie 14-18). Ponieważ każdy atrybut może mieć różny rozmiar (wielkość wyrażoną w bajtach), dany poziom w obrębie drzew CFT może składać się z różnej liczby stron dysku SSD. Zatem może zawierać różną liczbę

wskaźników zewnętrznych. Przepisywanie normalnych danych musimy synchronizować pomiędzy wszystkie drzewa. W tym celu, w liniach 7-26, przechodzimy po drzewach NCF tak długo, aż nie napotkamy na normalną daną. Oczywiście, podczas przepisywania danych i wskaźników z L_i do nowego poziomu L_i' musimy pamiętać, aby odpowiednio zbudować nowy poziom oraz zachować strukturę drzewa poprzez odpowiednie połączenia z poziomu wyższego do nowego poziomu (linie 19-24). Gdy tworzymy nową stronę, musimy stworzyć odpowiedni wskaźnik na tę stronę. Zapisujemy do niego pierwszy klucz strony, wskaźnik na obecną stronę oraz tworzymy tablicę $numEntriesBeforePageArray$. Tablica ta zawiera liczbę danych zapisanych przed stroną, na którą wskazuje, oraz na kolejnych poziomach na ścieżce do liścia. Dlatego jako $numEntriesBeforePageArray[0]$ przypisujemy wartość $p.numEntriesBeforePage$, którą łatwo policzyć, ponieważ reorganizacja przeprowadzana jest na całym poziomie. Dzięki temu możemy w łatwy sposób śledzić liczbę zapisanych danych. Kolejne wartości tej tablicy są takie same jak ścieżki poniżej. Gdy mamy już wybrane dane (linie 10-12 lub 27-29), należy je wpisać do nowego poziomu L_i', uważając, aby nie zaburzyć struktury i własności drzewa. Po pierwsze, jeśli tworzymy nową stronę i obecnie wpisywaną daną nie jest wskaźnik zewnętrzny, to tworzymy nowy wewnętrzny wskaźnik o wartościach ostatniego zewnętrznego wskaźnika. Procedurę w liniach 30-38 wykonujemy dla KCF oraz wszystkich NCF. Tak samo jak poprzednio (linie 21-24), teraz również musimy pamiętać, aby wpisać nowy wskaźnik do poziomu wyżej, gdyż stworzyliśmy nową stronę. Również w tym przypadku krok ten wykonujemy dla KCF i wszystkich drzew NCF. Do ostatnich kroków algorytmu należą sprawdzenie, czy nowy poziom jest w stanie pomieścić wszystkie wpisane do niego wartości. Jeśli nie, to musimy rekurencyjnie wykonać nasz algorytm dla poziomów L_i' i L_{i+1}. Gdy skończymy przepisywać wszystkie rekordy, podmieniamy poziomy na nowe w naszej strukturze drzewa i kończymy proces reorganizacji.

Pseudokod 6.4 opisuje procedurę znajdowania wartości kolumny i dla danego rekordu e. Działanie algorytmu opiera się głównie na wartościach tablicy $numEntriesBeforePageArray$, która wypełniana jest podczas reorganizacji poziomów (6.3). Własność 2 mówi, że *Liczba danych w każdym FD-Tree na danym poziomie jest taka sama*. Z tego względu rekord możemy stworzyć łącząc ze sobą atrybuty zapisane w tym samym miejscu (na tej samej pozycji w danym poziomie) ze wszystkich drzew. Początkowo musimy przejść przez małe, buforowane w pamięci RAM drzewo B+ i znaleźć odpowiednią stronę drzewa FD. Drzewo B+ jak również wszystkie poziomy drzewa FD zawierają wskaźniki wraz z tablicą $numEntriesBeforePageArray$, która określa, jak wiele danych zostało zapisane przed stroną, na którą wskazuje wskaźnik. Wiemy zatem, że poszukiwania w drzewie FD musimy zacząć od strony, która miała największą wartość, ale mniejszą od $e.pos$ (linia 3). Posiadając taką stronę możemy zacząć poszukiwania. Na każdym poziomie drzewa FD również szukamy takiego wskaźnika, dla którego wartość $numEntriesBeforePageArray$ jest największa, ale mniejsza od $e.pos$ (linie 6-8). Warto zauważyć, że ta procedura wczytuje tylko jedną stronę na każdym poziomie. Gdy znajdujemy się na odpowiednim poziomie, musimy znaleźć wartość atrybutu na naszej stronie. Skoro znamy jego pozycję, wystarczy przesunąć się na odpowiednie miejsce (linie 12-15) i zwrócić szukaną wartość.

6.5.4 Dowód poprawności algorytmu scalania atrybutów

Teraz postaramy się udowodnić poprawność algorytmu $columnMerge$, to znaczy pokażemy, że potrafimy jednoznacznie dopasować wartość na każdej z kolumn.

Pseudokod 6.3: cftLevelMerge(L_{i-1}, L_i)

```
1  Niech KLvl_{i-1}, KLvl_i, NLvl_{i-1}, NLvl_i będą poziomami z KCF i NCF
2  Niech Ke_{i-1}, Ke_i będą pierwszymi danymi na poziomach KLvl_{i-1} i KLvl_i
3  Niech Ne_{i-1}, Ne_i będą pierwszymi danymi na poziomach NLvl_{i-1} i NLvl_i
4  while Ke_{i-1} ≠ NULL and Ke_i ≠ NULL do
5      Pomiń wszystkie wskaźniki na KLvl_{i-1} oraz na Nlvl_{i-1}
6      Pomiń wszystkie wewnętrzne wskaźniki na KLvl_i oraz na NLvl_i
7      while Ke_{i-1}.type = DELETED and Ke_i.type = NORMAL and
         Ke_{i-1}.key = Ke_i.key do
8          Pomiń obie dane na wszystkich drzewach CFT
9      if Ke_{i-1}.key < Ke_i.key then
10         KEntryToInsert := Ke_{i-1}
11         NEntryToInsert := Ne_{i-1}
12         Niech Ke_{i-1}, Ne_{i-1} będą następnymi danymi w KLvl_{i-1} i NLvl_{i-1}
13     else
14         if Ke_i.type = EXTERNAL_FENCE then
15             KLastFence := Ke_i
16         while Ne_i.type ≠ NORMAL do
17             if Ne_i.type = EXTERNAL_FENCE then
18                 NLastFence := Ne_i
19             if Obecna strona p na NLvl'_i jest pusta then
20                 External.key := Ne_i.key
21                 External.pid := p
22                 External.numEntriesBeforePageArray[0] =
                     p.numEntriesBeforePage
23                 Skopiuj NLastFence.numEntriesBeforePageArray do
                     External.numEntriesBeforePageArray[i], i > 0
24                 Zapisz External na NLvl'_{i-1}
25             Zapisz Ne_i na NLvl'_i
26             Niech Ne_i będzie następną daną na NLvl'_i
27         KEntryToInsert := Ke_i
28         NEntryToInsert := Ne_i
29         Niech Ke_i, Ne_i będą następnymi danymi w KLvl_i i NLvl_i
30     if Obecna strona p na KLvl'_i jest pusta then
31         if KEntryToInsert.type ≠ EXTERNAL_FENCE then
32             Internal.key := KEntryToInsert.key
33             Internal.pid := KLastFence.pid
34             Zapisz Internal na KLvl'_i
35         External.key := KEntryToInsert.key
36         Wykonaj linie [21-24] dla KCF
37     Zapisz KEntryToInsert na KLvl'_i
38     Wykonaj linie [30-37] dla NCF
39     if KLvl'_i jest przepełniony then
40         cftLevelMerge(L'_i, L_{i+1})
41 Zastąp KLvl_{i-1}, KLvl_i, NLvl_{i-1}, NLvl_i przez Klvl'_{i-1} KLvl'_i, NLvl'_{i-1}, Nlvl'_i
```

Pseudokod 6.4: cftColumnMerge(input: Entry e, Int i)

```
1  Niech e.lvl będzie poziomem entry e
2  Niech e.pos będzie pozycją entry e na poziomie e.lvl
3  Niech p będzie stroną wskazywaną przez Wskanik f pochodzącego z
     Buforowanego B+ z kolumny i, takiego że
     f.numEntriesBeforePageArray[e.lvl] ma największą wartość z mniejszych od
     e.pos
4  while f.lvl < e.lvl do
5  |   Niech f będzie pierwszym wskaźnikiem na stronie p
6  |   while f.numEntriesBeforePageArray[e.lvl − f.lvl] < e.pos do
7  |   |   ptr := f.pid
8  |   |   Niech f będzie następnym wskaźnikiem na stronie p
9  |   p := ptr
10 counter := p.numEntriesBeforePage
11 Niech e′ będzie pierwszą daną na stronie p
12 while counter < e.pos do
13 |   if e′.type = NORMAL then
14 |   |   counter := counter + 1
15 |   Niech e′ będzie następną daną na stronie p
16 return e′
```

Najpierw wprowadźmy niezbędne oznaczenia:

- Niech PTR_{L_i} będzie zbiorem wskaźników na poziomie L_i,
- Niech $PAGE_{L_i}$ będzie zbiorem stron na poziomie L_i,
- Niech $ptr'_{L_i} \prec ptr_{L_i}$ oznacza, że wskaźnik ptr'_{L_i} jest zapisany przed ptr_{L_i} na poziomie L_i naszego drzewa FD (niezależnie czy to KCF czy NCF),
- Niech $page'_{L_i} \prec page_{L_i}$ oznacza, że strona $page'_{L_i}$ jest zapisana przed stroną $page_{L_i}$ na poziomie L_i.
- Niech $PTR_{L_i,page}$ będzie zbiorem wskaźników zapisanych na stronie *page* poziomu L_i,
- Niech $PTR^n_{L_i,page}$ będzie podzbiorem $PTR_{L_i,page}$ zawierającym wszystkie te wskaźniki, które spełniają warunek $ptr.numEntriesBeforePageArray[lvl - i] < n$.
- Ponieważ wskaźniki mają zdefiniowany porządek, możemy wyłonić z nich element maksymalny ptr_{max}. Dokładniej mówiąc, ptr_{max} jest elementem maksymalnym w zbiorze PTR, jeśli dla każdego $ptr' \in PTR$ takiego, że $ptr' \neq ptr_{max}$ zachodzi $f' \prec ptr_{max}$.

Lemat 6.1 *Jeśli* $ptr'_{L_i} \prec ptr_{L_i}$ *to* $ptr'.pid'_{L_{i+1}} \prec ptr.pid_{L_{i+1}}$ *lub* $ptr'.pid_{L_{i+1}} = ptr.pid_{L_{i+1}}$

Dowód. Dowód jest bardzo prosty. Wystarczy, że spojrzymy na algorytm scalający poziomy. Wskaźniki zapisywane są dokładnie według wcześniej zdefiniowanego porządku,

zatem później zapisany wskaźnik nie może wskazywać na wcześniej zapisaną stronę. Mówiąc dokładniej będzie on wskazywał na tę samą stronę co poprzedni wskaźnik, jeśli jest to Wewnętrzny wskaźnik lub będzie wskazywał na kolejną stronę w przypadku, gdy jest to zewnętrzny wskaźnik. ⧫

Twierdzenie 6.1 *Algorytm znajduje poprawną ścieżkę ze strony* $page_{L_i}$ *do strony* $page_{L_j}$*, która zawiera szukaną daną na pozycji npos, jeśli algorytm ten na każdym poziomie* L_k *(*$i \leqslant k < j$*) wybierze maksymalnego* ptr_{max} *ze zbioru* $PTR^{npos}_{L_k,page}$ *i przejdzie do strony wskazywanej przez niego.*

Dowód. Udowodnimy to przez sprzeczność. Niech ptr' i ptr_{max} będą wskaźnikami ze zbioru $PTR^{npos}_{L_k,page}$ oraz niech ptr_{max} będzie elementem maksymalnym z tego zbioru. Załóżmy, że nasz algorytm nie wybiera maksymalnego elementu, czyli, że wybiera ptr' takie, że $ptr' \prec ptr_{max}$. Niech $PAGE'_{L_t,ptr'}$ i $PAGE_{L_t,ptr_{max}}$ zawierają strony z poziomu L_t dla poddrzew ukorzenionych odpowiednio w $ptr'.pid$ i w $ptr_{max}.pid$.

Przez $page_{min}$ oraz $page_{max}$ oznaczamy minimalne i maksymalne strony ze zbioru $PAGE_{L_t,ptr}$. Z definicji i własności CFT wynika, że

$$page'_{min}.numEntriesBeforePage = ptr'.numEntriesBeforePageArray[lvl - t]$$

oraz

$$page_{min}.numEntriesBeforePage = ptr_{max}.numEntriesBeforePageArray[lvl - t]$$

Z lematu 6.1, mamy:

$$page'_{max} \leqslant page_{min}$$

skąd

$$page'_{max}.numEntriesBeforePage \leqslant page_{min}.numEntriesBeforePage$$

Zatem, jeśli szukamy danej na pozycji $npos$, dla której

$$npos > ptr'.numEntriesBeforePageArray[lvl - t]$$

to

$$page'_{max}.numEntriesBeforePage \leqslant page_{min}.numEntriesBeforePage < n \quad (6.2)$$

Zatem, zaczynając od strony wskazywanej przez wskaźnik ptr' możemy dotrzeć do wszystkich stron $page'_{min} < page < page'_{max}$. W konsekwencji możemy znaleźć wszystkie dane na pozycji $p'_{min}.numEntriesBeforePage < npos < p'_{max}.numEntriesBeforePage$. Na mocy równania 6.2, wiemy że nie możemy w ten sposób dojść do danej na pozycji $npos$. Zatem zawsze musimy wybierać maksymalny element. ⧫

6.5.5 Analiza kosztów algorytmów

Zanim przeprowadzimy analizy kosztów algorytmów, wprowadźmy niezbędne oznaczenia.

- c - liczba kolumn (drzew) w zbiorze CFT

- n - liczba wstawianych danych
- R_{size} - rozmiar atrybutu wyrażony w bajtach
- P_{size} - rozmiar strony wyrażony w bajtach
- $P_{cap} = \left\lceil \frac{P_{size}}{R_{size}} \right\rceil$ - liczba atrybutów możliwych do zapisania na stronie
- L_i^j - liczba danych na poziomie i zaraz po skończeniu scalania j
- W_{cost} - koszt zapisu pojedynczej strony
- R_{cost} - koszt odczytu pojedynczej strony
- FD_{height} - liczba poziomów pojedynczego drzewa FD, pamiętajmy że każde drzewo w zbiorze CFT ma tyle samo poziomów.
- k - współczynnik pojemności 2 poziomów ($k = \frac{|L_{i+1}|}{|L_i|}$)
- m_i - liczba wywołań algorytmu scalania po n danych dla poziomu i
- N_i^{write} - sumaryczna liczba danych do zapisania podczas m_i scaleń dla poziomu i
- N_i^{read} - sumaryczna liczba danych do wczytania podczas m_i scaleń dla poziomu i
- t_{insert} - czas potrzebny na dodanie n elementów i przeprowadzenie m_i scaleń dla każdego poziomu i

Analiza kosztu algorytmu scalania atrybutów

Twierdzenie 6.2 *Niech T oznacza koszt scalania kolumn. Wtedy*

$$T = (c-1) \cdot \left\lceil \log_k \left(\frac{n}{|L_0|} \right) \right\rceil,$$

gdzie c oznacza liczbę kolumn (drzew) w zbiorze CFT, $k = \frac{|L_{i+1}|}{|L_i|}$ jest współczynnikiem pojemności 2 poziomów, n jest liczbą wstawianych danych oraz $|L_0|$ jest pojemnością bufora (poziomu 0).

Dowód. Podczas scalania atrybutów na każdym poziomie i czytamy wartości pól

$$numEntriesBeforePageArray[FD_{height} - i]$$

Strona może zawierać wiele wskaźników zewnętrznych, czyli może być wiele wartości $numEntriesBeforePageArray$. Wybieramy jednak taki wskaźnik, dla którego wartość

$$ptr.numEntriesBeforePageArray[FD_{height} - i]$$

jest największa z wartości mniejszych niż szukana pozycja $npos$. Następnie przechodzimy niżej na stronie $ptr.pid$ wybranego wskaźnika. Zatem na każdym poziomie odczytamy tylko pojedynczą stronę i od razu przejdziemy do poziomu niżej. Zatem koszt połączenia atrybutu z innym atrybutem jest równy:

$$t_{columnMerge} = h$$
$$t_{columnMerge} = \left\lceil \log_k \left(\frac{n}{|L_0|} \right) \right\rceil$$

Z tego wynika, że koszt stworzenia rekordu mając wybraną wartość dowolnej kolumny jest równy:

$$t_{columnMerge} = (c-1) \cdot \left\lceil \log_k \left(\frac{n}{|L_0|} \right) \right\rceil$$

Analiza kosztu wstawiania rekordu

Algorytm wstawiania dzieli się na dwie fazy. Pierwsza jest to podział rekordy na atrybuty i wstawienie poszczególnych wartości kolumn do odpowiednich drzew KCF i NCF. Początkowo wstawianie odbywa się do buforu zapisanego w pamięci RAM, ponieważ nasza analiza skupia się na operacjach WE/WY dysku SSD, koszt pierwszej fazy jest równy 0. Druga faza to reorganizacja poziomów. Ze względu na to, iż algorytm scalania wykonywany jest na wszystkich drzewach ze zbioru CFT bez dodatkowych kosztów scalania atrybutów, analizę możemy podzielić na dwie części: analizę scalania na pojedynczym drzewie FD oraz analizę pełnego scalania poziomów w obrębie całego zbioru CFT. Drzewo FD jest bardzo podobne do drzewa FA przedstawionego w poprzednim rozdziale 5.

Przytoczmy zatem kilka niezbędnych faktów, które udało nam się ustalić podczas analizy drzewa FA, a które nie różnią się na drzewie FD.

Wiemy że wskaźników wewnętrznych jest maksymalnie tyle ile stron na danym poziomie, czyli

$$|internal_i| = \left\lceil \frac{|L_i|}{P_{cap}} \right\rceil .$$

Podobnie, wskaźników zewnętrznych jest dokładnie tyle ile stron na niższym poziomie, czyli

$$|external_i| = \left\lceil \frac{|L_{i+1}|}{P_{cap}} \right\rceil .$$

Wiemy, że zaraz po wykonaniu algorytmu scalania nowy poziom wyższy ma tylko wskaźniki zewnętrzne, stąd

$$|L_{i-1}^j| = |external_{i-1}|, \quad j > 0$$

$$|L_{i-1}^j| = \left\lceil \frac{|L_i|}{P_{cap}} \right\rceil, \quad j > 0$$

Koszt scalania to sumaryczny koszt zapisów danych dla obu poziomów zaraz po zakończeniu scalania, czyli

$$N_i^{write} = \sum_{j=1}^{m_i} (|L_i|^j + |L_{i-1}^j|)$$

Wiemy, że poziom L_{i-1} zawiera tylko wskaźniki zewnętrzne. Na podstawie ich liczby możemy oszacować ile było danych poniżej.

$$|L_i^j| = |external_{i-1}| \cdot P_{cap}$$

Zatem mamy

$$N_i^{write} = \sum_{j=1}^{m_i} (|external_{i-1}| \cdot P_{cap} + |L_{i-1}^j|)$$

$$N_i^{write} = \sum_{j=1}^{m_i} (|L_{i-1}^j| \cdot P_{cap} + |L_{i-1}^j|)$$

$$N_i^{write} = \sum_{j=1}^{m_i} ((1 + P_{cap}) \cdot |L_{i-1}^j|)$$

$$N_i^{write} = (1 + P_{cap}) \cdot \sum_{j=1}^{m_i} |L_{i-1}^j| \tag{6.3}$$

Gdy założymy, że wszystkie rekordy n zostały scalone do najniższego poziomu, dostajemy

$$n = \sum_{j=1}^{m_i} (|L_{i-1}| - |external_{i-1}^j|)$$

$$n = \sum_{j=1}^{m_i} (|L_{i-1}| - |L_{i-1}^j|)$$

$$n = m_i \cdot |L_{i-1}| - \sum_{j=1}^{m_i} |L_{i-1}^j|$$

$$n = m_i \cdot |L_{i-1}| - \sum_{j=1}^{m_i} \left\lceil \frac{|L_i^j|}{P_{cap}} \right\rceil$$

$$\sum_{j=1}^{m_i} |L_{i-1}^j| = (m_i \cdot |L_{i-1}| - n) \tag{6.4}$$

Łącząc ze sobą 6.3 z 6.4 dostajemy

$$N_i^{write} = (1 + P_{cap}) \cdot (m_i \cdot |L_{i-1}| - n)\ . \tag{6.5}$$

Z rozdziału **5** pamiętamy, że aby przeprowadzić scalanie musimy odczytać oba poziomu, mają one tyle danych ile wpisaliśmy po zakończeniu poprzedniego scalania, stąd

$$N_i^{read} = \sum_{j=1}^{m_i} (|L_{i-1}^{j-1}| + |L_i^{j-1}|)\ .$$

Aby wyrazić N_i^{read} za pomocą N_i^{write} skorzystajmy z faktu, że możemy założyć, iż liczba danych na poziomie i po scaleniu j jest równa sumie 2 poziomów utworzonych po poprzednim scaleniu

$$|L_{i-1}^j| = |L_{i-1}^{j-1}| + |L_i^{j-1}|$$

Dzięki temu, możemy łatwo wyrazić N_i^{read} za pomocą N_i^{write}.

$$N_i^{write} = \sum_{j=1}^{m_i}(|L_{i-1}^j| + |L_i^j|)$$

$$N_i^{write} = \sum_{j=1}^{m_i}(|L_{i-1}^{j-1}| + |L_i^{j-1}| + |L_i^j|) \tag{6.6}$$

$$N_i^{read} = N_i^{write} - \sum_{j=1}^{m_i} |L_{i-1}^j|$$

$$N_i^{read} = N_i^{write} - \frac{n}{P_{cap}} \tag{6.7}$$

Jak widać odczytujemy mniej danych, ponieważ nie musimy odczytywać nowych wskaźników zewnętrznych na poziomie L_{i-1}^j.

Możemy teraz oszacować czas potrzebny na scalanie wszystkich poziomów. Zanim to zrobimy, warto przypomnieć sobie górne ograniczenie na liczbę scaleń.

$$m_i < \frac{n}{|L_{i-1}| - \frac{|L_{i-1}|}{P_{cap}} - -\frac{|L_i|}{P_{cap}}}$$

$$m_i < \frac{P_{cap}}{P_{cap} - k - 1} \cdot \frac{n}{|L_{i-1}|}$$

Teraz w końcu jesteśmy gotowi aby oszacować czas potrzebny na wstawianie wszystkich elementów n oraz wszystkich reorganizacji poziomów.

$$t_{insert} = \frac{1}{n} \cdot \sum_{i=1}^{FD_{height}-1} \left(\frac{R_{size} \cdot N_i^{write}}{W_{cost}} + \frac{R_{size} \cdot N_i^{read}}{R_{cost}} \right)$$

$$t_{insert} < \frac{W_{cost} + R_{cost}}{W_{cost} \cdot R_{cost}} \cdot P_{size} \cdot \sum_{i=1}^{FD_{height}-1} \left(\frac{m_i \cdot |L_{i-1}|}{n} - 1 \right)$$

$$t_{insert} < \frac{W_{cost} + R_{cost}}{W_{cost} \cdot R_{cost}} \cdot P_{size} \cdot \sum_{i=1}^{FD_{height}-1} \left(\frac{P_{cap}}{P_{cap} - k - 1} - 1 \right) \tag{6.8}$$

Wiemy, że wysokość trzeba FD_{height} jest logarytmiczna, uzależniona od współczynnika k oraz wielkości drzewa B+ w RAM czyli poziomu L_0. Wynosi więc ona:

$$FD_{height} = \left\lceil \frac{\log_k n}{|L_0|} \right\rceil$$

Możemy zatem przepisać nierówność 6.8, korzystając z powyższej równości. Dostajemy

$$t_{insert} < \frac{W_{cost} + R_{cost}}{W_{cost} \cdot R_{cost}} \cdot \frac{k+1}{P_{cap} - k - 1} \cdot P_{size} \cdot \left\lceil \frac{\log_k n}{|L_0|} \right\rceil$$

więc

$$t_{insert} = \mathrm{O}\left(\frac{k}{P_{cap} - k} \log n\right) \tag{6.9}$$

Zatem amortyzowany czas na wstawianie atrybutu do drzewa jest logarytmiczny ze względu na liczbę wstawianych elementów i wynosi

$$\mathrm{O}\left(\frac{k}{P_{cap} - k} \log n\right)$$

Twierdzenie 6.3 *Niech T oznacza amortyzowany czas wstawiania rekordu do indeksu CFT, wtedy*

$$T = \mathrm{O}\left(\frac{c \cdot k}{P_{cap} - k} \log n\right)$$

gdzie c jest liczbą kolumn (drzew) w zbiorze CFT, k jest współczynnikiem pojemności 2 poziomów, P_{cap} jest liczbą atrybutów możliwych do zapisania na stronie, zaś n jest liczbą wstawianych danych.

Dowód. Ponieważ wykonujemy c niezależnych reorganizacji poziomów, z których każda posiada tyle samo danych, możemy bardzo łatwo rozszerzyć analizę na wszystkie kolumny. Oczywiście parametry:

- R_{size} - rozmiar atrybutu wyrażony w bajtach
- $P_{cap} = \left\lceil \frac{P_{size}}{R_{size}} \right\rceil$ - liczba atrybutów możliwych do zapisania na stronie

mogą ulec zmianie, ponieważ każda kolumna może posiadać inny rozmiar, to jednak wpływa to tylko na liczbę użytych stron oraz liczbę wskaźników jakie trzeba zapisać. Powyższa analiza pokazała, że jest ich na tyle mało, że możemy pominąć koszt ich zapisu, zaś zmiana parametru P_{cap} nie jest asymptotyczna, różnice w wielkościach można wyrazić pewną stałą, a zatem nie wpłyną na koszt amortyzowany wyrażony notacją duże O. Zatem sumaryczny koszt dodawania całego rekordu do struktury CFT można zapisać jako

$$\mathrm{O}\left(\frac{c \cdot k}{P_{cap} - k} \cdot \log_k n\right) .$$

♦

6.5.6 Eksperymenty

W tej części rozdziału przedstawimy i omówimy eksperymenty wykonane za pomocą symulatora SIPS, który został dokładnie opisany w rozdziale 4. Do eksperymentów wybrano trzy dyski SSD o odmiennej charakterystyce. Tabela 6.5 zawiera szczegółowe parametry wybranych modeli. Zwykle eksperymenty są przeprowadzane na trzech tabelach: Sklep, Nowe zamówienie oraz Klient. Ponieważ tym razem przedmiotem eksperymentów jest kolumnowe indeksowanie baz danych, użyjemy tylko dwóch tabel, które posiadają dużą liczbę kolumn. Atrybuty wybranych tabel pokazane są w tabeli 6.9. Naszą domyślną tabelą będzie Klient, ponieważ ostatni atrybut jest znacznie większy od pozostałych. Oznacza to, że brak wczytywania tej kolumny podczas wyszukiwania znacząco poprawi wydajność obsługi tej kwerendy.

		Pojemność		Prędkość losowego		Prędkość sekwencyjnego	
Model	Interfejs	Strony	Bloku	Odczytu	Zapisu	Odczytu	Zapisu
Samsung 840	SATA	8 KB	512 KB	390 MB/s	182 MB/s	585 MB/s	535 MB/s
Toshiba VX500	SATA	4 KB	256 KB	379 MB/s	267 MB/s	568 MB/s	525 MB/s
Intel DCP4511	NVMe	4 KB	256 KB	1,2 GB/s	240 MB/s	2 GB/s	1,47 GB/s

Tabela 6.5: Wybrane modele dysków SSD

Podstawowy zestaw kwerend

Podstawowy zestaw kwerend służy do sprawdzenia wydajności testowanego indeksu w sytuacji, gdy używa się go podobnie do zwykłej struktury danych. Pierwotnie zestaw podstawowy, dokładnie opisany w rozdziale 4, składał się z trzech podstawowych operacji: wstawiania, wyszukiwania i usuwania. Każda z tych operacji była przeprowadzana na jednym rekordzie, a wyszukiwanie było punktowe i zwracało tylko jeden rekord. Ponieważ kolumnowe ułożenie danych optymalizuje głównie operacje wyszukiwania, do zestawu kwerend wprowadziliśmy również wyszukiwanie zakresu kluczy o podanej selektywności (1%, 5%, 10%). Z tego samego powodu zrezygnowaliśmy ze wzorców: ZP_{zapis}, ZP_{odczyt}, ZP_{balans}, skupiając się tylko na wzorcu ZP_{odczyt}. Ten wzorzec składa się z 15% operacji wstawiania pojedynczego rekordu, 80% operacji wyszukiwania punktowego lub zakresowego z użyciem klucza, oraz 5% operacji usuwania pojedynczego rekordu. Zestaw podstawowy określa tylko stosunek operacji modyfikacji indeksu do wyszukiwań rekordów, a liczba tych operacji jest dowolna, domyślnie jest to 100 tys. operacji. Ponieważ wybrane indeksowania opisane poniżej posiadają buforowanie, to 100 tys. operacji nie wystarczyły, aby uzyskać stabilne wyniki, dlatego testy przeprowadzono dla 1 mln operacji.

Każdy eksperyment został przeprowadzony z użyciem trzech rodzajów indeksowania. Pierwszy to klasyczne drzewo FD, gdzie rekordy zapisane są wierszowo, analogicznie do oryginalnego drzewa FD. Dodatkowo wybrano strukturę FBDSM [54], która jest zmodyfikowaną wersją struktury DSM [32], dostosowaną do charakterystyki pamięci flash i dysków SSD. Niestety, chociaż ta struktura zapisuje dane kolumnowo, to nie jest posortowana po kluczu, co oznacza, że operacje takie jak wyszukiwanie i usuwanie wymagają wczytania całego zbioru danych, aby znaleźć pozycję wybranego atrybutu, a następnie odczytać pozostałe atrybuty znajdujące się na tej samej pozycji, ale w innym obszarze pamięci. Dzięki zastosowanemu buforowaniu i podziałowi na dwie tabele: PT (tabelę główną) i LT (tabelę zmodyfikowanych wartości), znacząco poprawiono operacje dodawania rekordów oraz ich modyfikacji względem pierwotnego pomysłu DSM. Ostatnią strukturą danych jest zaproponowana struktura CF-Tree.

Zazwyczaj testujemy indeksy operujące na danych zapisanych wierszowo. W takim przypadku liczba atrybutów żądanych przez użytkownika w kwerendzie nie ma znaczenia, ponieważ i tak musimy odczytać cały rekord z dysku. Jednak tym razem testujemy bazy danych z kolumnowym ułożeniem, dlatego każdy z eksperymentów został przeprowadzony kilka razy. Za każdym razem kwerenda żądała więcej kolejnych atrybutów. Na przykład, podczas testowania indeksów używając danych z tabeli Sklep, kwerenda mogła prosić o wyszukiwanie wartości dla trzech kolumn (klucz zawsze mamy podany i jest zwracany w rekordzie), takich jak W_ID (klucz), W_NAME, W_STREET_1, i W_STREET_2. Dzięki

Nazwa kolumny	Rozmiar kolumny
C_ID	4 B
C_D_ID	4 B
C_W_ID	8 B
C_FIRST	16 B
C_MIDDLE	2 B
C_LAST	16 B
C_STREET_1	20 B
C_STREET_2	20 B
C_CITY	20 B
C_STATE	2 B
C_ZIP	9 B
C_PHONE	16 B
C_SINCE	16 B
C_CREDIT	2 B
C_CREDIT_LIM	16 B
C_DISCOUNT	8 B
C_BALANCE	16 B
C_YTD_PAYMENT	16 B
C_PAYMENT_CNT	4 B
C_DELIVERY_CNT	4 B
C_DATA	500 B

Tabela 6.6: Klient TPC-C

Nazwa kolumny	Rozmiar kolumny
W_ID	8 B
W_NAME	10 B
W_STREET_1	20 B
W_STREET_2	20 B
W_CITY	20 B
W_STATE	2 B
W_ZIP	9 B
W_TAX	8 B
W_YTD	16 B

Tabela 6.7: Sklep TPC-C

Nazwa kolumny	Rozmiar kolumny
NO_O_ID	8 B
NO_D_ID	4 B
NO_W_ID	8 B

Tabela 6.8: Nowe Zamówienie TPC-C

Tabela 6.9: Atrybuty wybranych tabel TPC-C

temu możemy zobaczyć, jak liczba zwracanych kolumn i liczba bajtów wpływa na wydajność kwerend, gdy baza danych jest zapisana na wybranych trzech indeksach.

Rysunki 6.17, 6.18 oraz 6.19 przedstawiają wyniki eksperymentów dla dysków Samsung 840, Toshiba VX 500 oraz Intel DCP4511 odpowiednio. Eksperymenty zostały przeprowadzone na tabeli Sklep, używając zestawu podstawowego ZP_{odczyt}, gdzie stosowano punktowe wyszukiwanie pojedynczego rekordu. Analizując wykresy, widzimy, że struktury zapisujące dane kolumnowo osiągają gorsze wyniki niż oryginalne drzewo FD, zapisane wierszowo. Struktura FBDSM nie jest dostosowana do obsługi kwerend wyszukujących, więc każda operacja wymaga pełnego skanu obszarów pamięci niezbędnych do stworzenia wyniku kwerendy. Z kolei w strukturze CF-Tree, im więcej kolumn użytkownik zażądał w zapytaniu, tym więcej obszarów pamięci musimy wczytać, a co za tym idzie, więcej razy musimy wykonać procedurę scalania atrybutów w trakcie ostatniej fazy wyszukiwania.

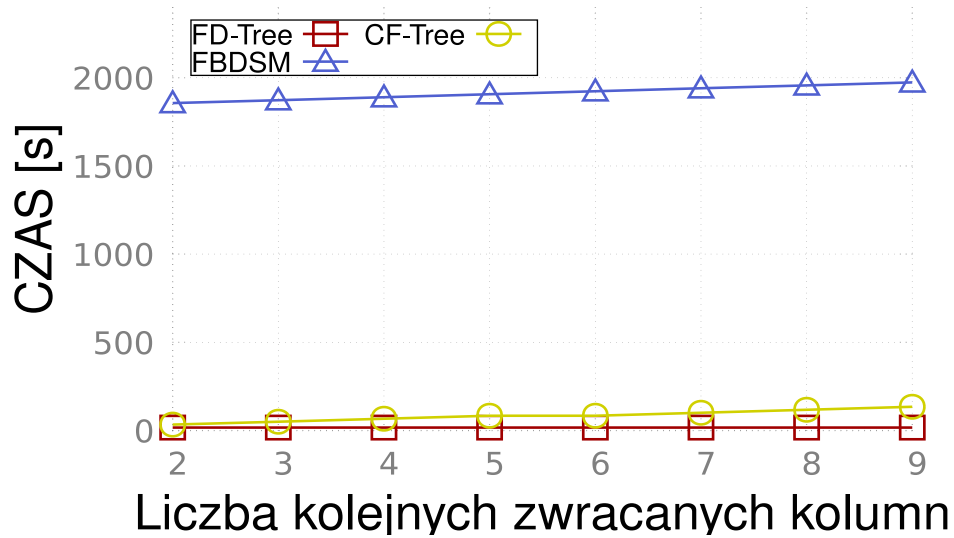

Rysunek 6.17: Czas wykonania zestawu kwerend ZP_{odczyt}
Dysk: Samsung 840
Tabela: Sklep (113 B)

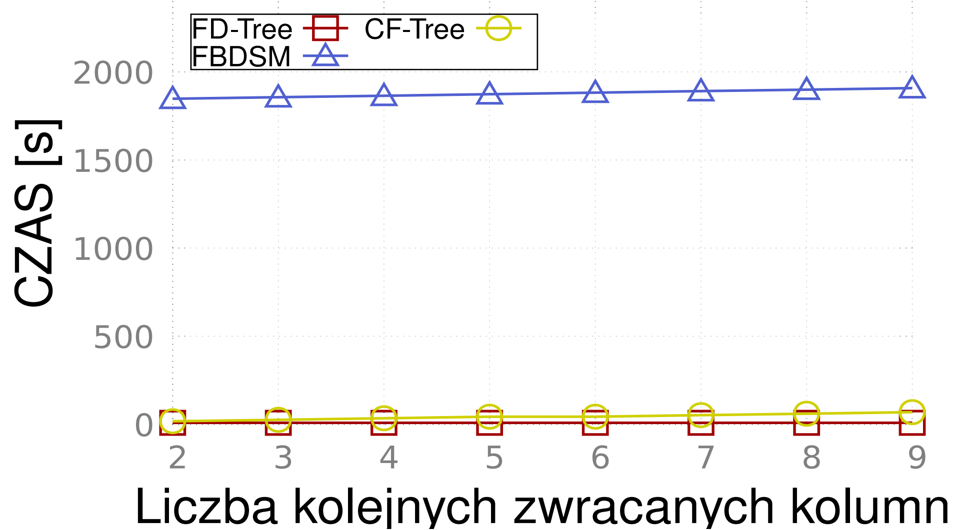

Rysunek 6.18: Czas wykonania zestawu kwerend ZP_{odczyt}
Dysk: Toshiba VX500
Tabela: Sklep (113 B)

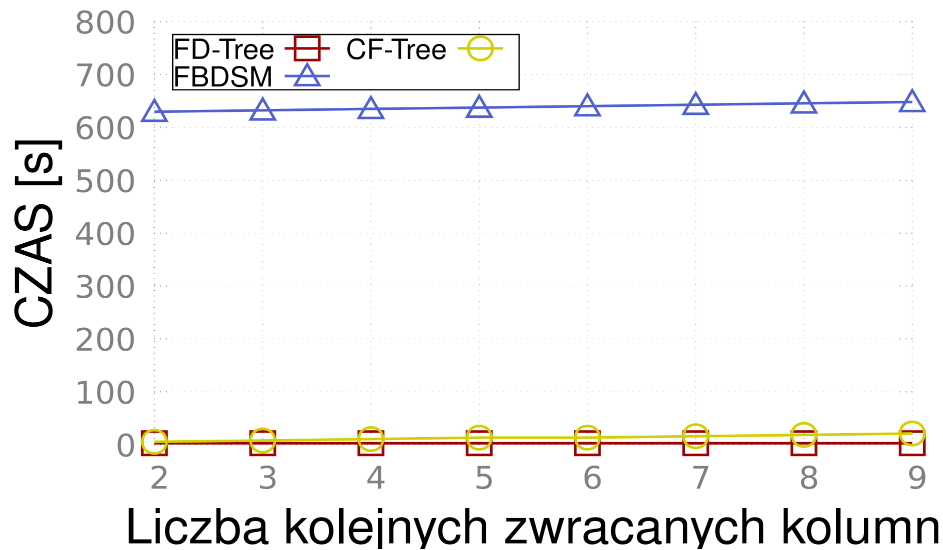

Rysunek 6.19: Czas wykonania zestawu kwerend ZP_{odczyt}
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

Koszt tej procedury jest bardzo niski (logarytmiczny) względem liczby danych w indeksie. Jednakże, biorąc pod uwagę, że wyszukiwanie w strukturach FD oraz CF-Tree również jest logarytmiczne, koszt scalania znacząco wpływa na całkowity koszt wyszukiwania punktowego. Wierszowa implementacja drzewa FD, podczas wyszukiwania podanego rekordu, przechodzi przez drzewo z góry na dół tylko raz, wczytując jedną stronę na każdym poziomie. Mimo że na końcu zamiast wczytywać tylko potrzebne atrybuty, wczytujemy cały rekord, to w przypadku tego wyszukiwania nie wpływa to negatywnie na czas wykonania kwerendy, ponieważ rekord mieści się na jednej stronie.

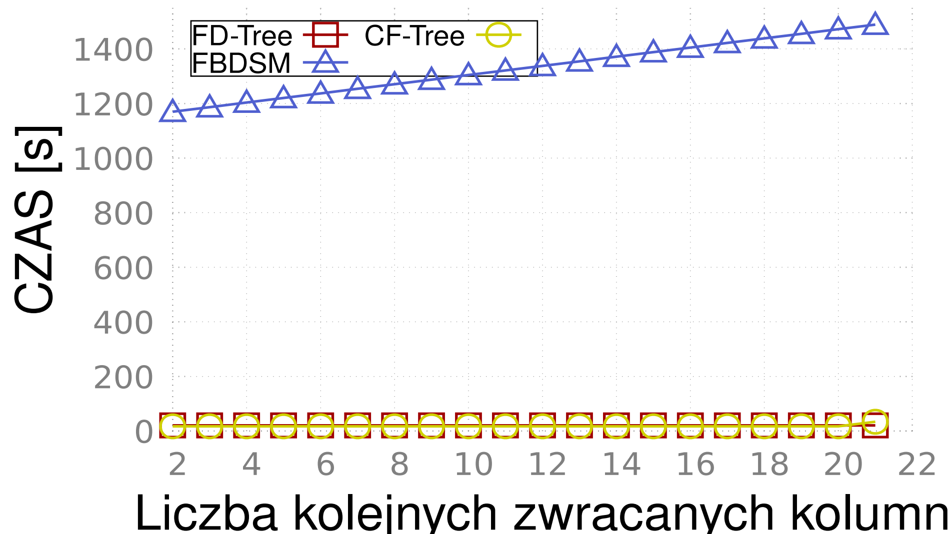

Rysunek 6.20: Czas wykonania zestawu kwerend ZP_{odczyt}
Dysk: Samsung 840
Tabela: Klient (719 B)

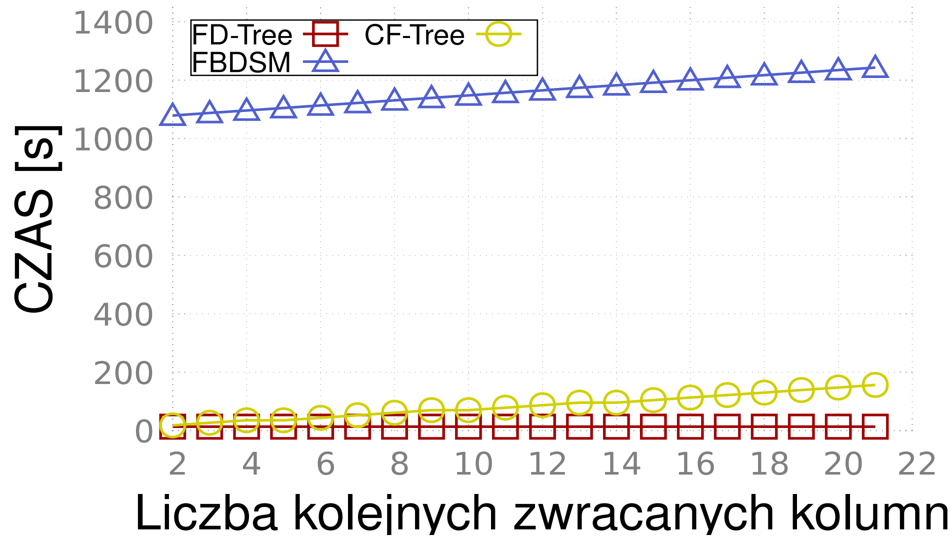

Rysunek 6.21: Czas wykonania zestawu kwerend ZP_{odczyt}
Dysk: Toshiba VX500
Tabela: Klient (719 B)

Pamiętajmy, że czas odczytu kilku bajtów jak i jednej całej strony jest taki sam na dyskach SSD, ponieważ operujemy na całych stronach. Mimo iż wybrane dyski posiadają różne charakterystyki, to na wszystkich wykresach obserwujemy ten sam trend.

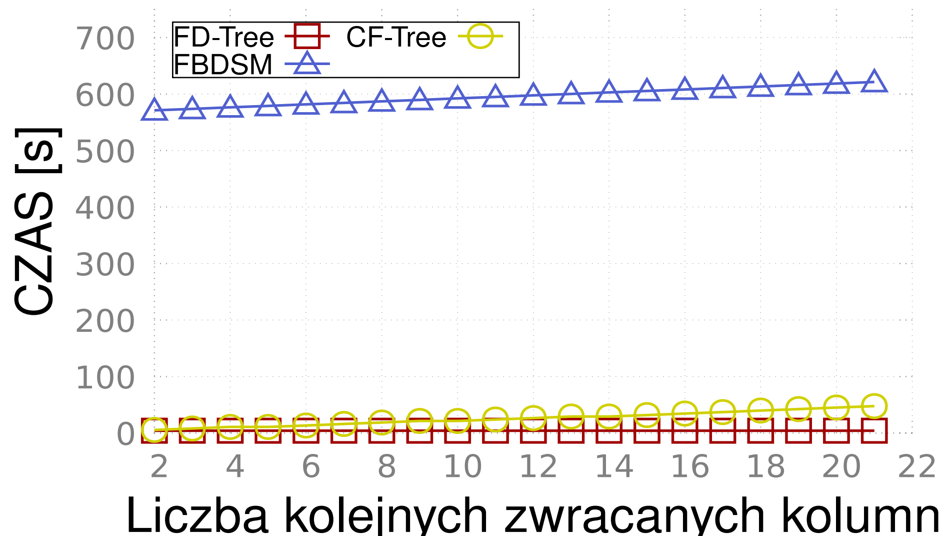

Rysunek 6.22: Czas wykonania zestawu kwerend ZP_{odczyt}
Dysk: Intel DCP4511
Tabela: Klient (719 B)

Rysunki 6.20, 6.21 oraz 6.22 przedstawiają wyniki eksperymentów dla odpowiednio dysków: Samsung 840, Toshiba VX 500 oraz Intel DCP4511, tym razem z użyciem tabeli Klient. W każdym z testów zastosowano wyszukiwanie punktowe. Pomimo że rekord tabeli Klient jest ponad 6 razy większy od rekordu tabeli Sklep, obserwujemy podobną sytuację. Wierszowa implementacja struktury FD konsekwentnie wykonuje zestaw kwerend

w najkrótszym czasie. Jest to spowodowane faktem, że podczas wyszukiwania punktowego wielkość rekordu nie wpływa na czas wyszukiwania, gdyż zawsze jest wymagany tylko jeden odczyt, niezależnie od ilości bajtów do wczytania. Warto zauważyć, że czas wyszukiwania w strukturze FBDSM, wraz ze wzrostem liczby zwracanych kolumn, rośnie teraz szybciej niż w poprzedniej serii eksperymentów. Wynika to z faktu, iż struktura FBDSM przeprowadza pełny skan obszarów pamięci; im większy atrybut, tym większy obszar pamięci musi być wczytany, co znacząco wydłuża czas wykonania kwerendy.

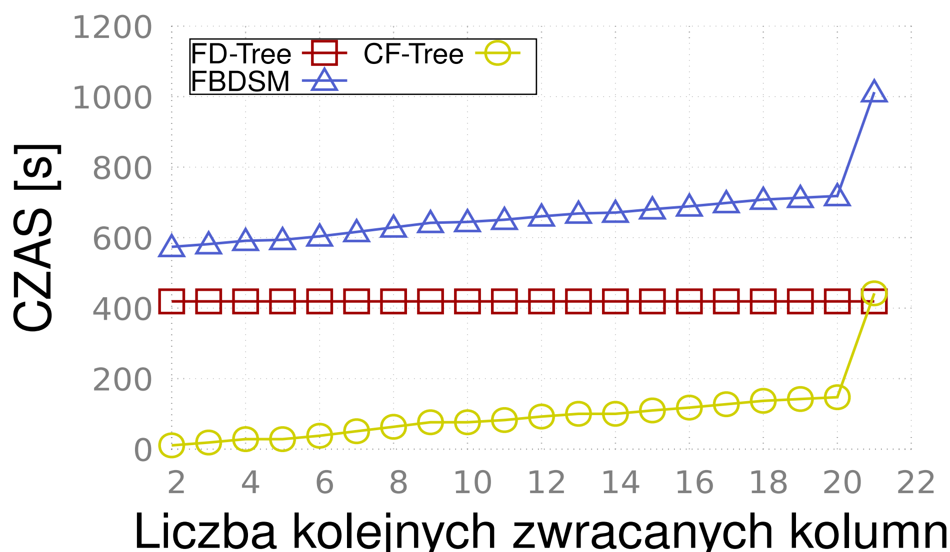

Rysunek 6.23: Czas wykonania zestawu kwerend ZP_{odczyt}
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

Z poprzednich dwóch serii eksperymentów wynika, że charakterystyka dysku wpływa na czas wykonania zestawu kwerend — szybszy odczyt strony skutkuje szybszym wyszukiwaniem. Jednakże, nie wpłynęło to na obserwowany trend: FBDSM zawsze osiągało najgorsze wyniki, a wierszowe ułożenie danych było najlepsze dla wyszukiwania punktowego. Dlatego w tej serii eksperymentów zdecydowaliśmy skupić się na wynikach dla najszybszego z wybranych dysków: Intel DCP4511. Dodatkowo ograniczyliśmy badania do tabeli Klient, ponieważ jej specyfika istotnie wpływa na szybkość wykonywania kwerend wyszukiwania. Tym razem zamiast wyszukiwania punktowego zastosowaliśmy wyszukiwanie kluczy z całego zakresu dla różnych selektywności. Rysunki 6.23, 6.24 i 6.25 przedstawiają wyniki eksperymentów dla zestawu ZP_{odczyt} z użyciem wyszukiwań dla selektywności odpowiednio 1%, 5% oraz 10%. Tabela 6.10 zawiera szczegółowe wyniki tych eksperymentów wraz z liczbą zwracanych bajtów przez kwerendy wyszukujące dla użytych selektywności 1%, 5% oraz 10%.

Dla selektywności 1% najgorsze wyniki osiągnęła ponownie struktura FBDSM. Przy tak małej selektywności korzyści płynące z odczytywania tylko niezbędnych fragmentów rekordu są niwelowane przez konieczność skanowania całego obszaru pamięci. Należy zauważyć, że chociaż podczas wyszukiwania punktowego struktura CF-Tree osiągała gorsze wyniki niż wierszowa implementacja FD-Tree, to w tym przypadku, nawet przy małej selektywności, zaproponowana kolumnowa struktura osiąga znacznie lepsze wyniki niż klasyczna implementacja indeksu. Tym razem procedura scalająca rekordy jest wywoływana

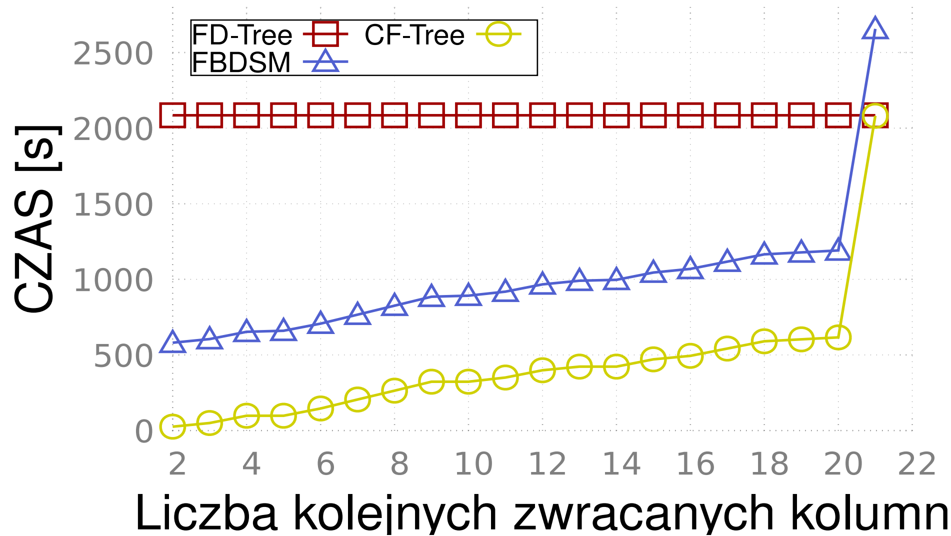

Rysunek 6.24: Czas wykonania zestawu kwerend ZP_{odczyt}
Selektywność 5%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

tylko raz podczas każdego wyszukiwania, gdy ma miejsce pierwsze scalanie atrybutów. Następnie wystarczy przesuwać się o tyle samo pozycji równolegle na każdym z drzew. Dzięki temu dodatkowy czas potrzebny na scalanie kolumn jest zminimalizowany, a efekt odczytu mniejszej liczby stron z dysku SSD znacząco wpływa na poprawę wydajności obsługi kwerendy. Im mniej kolumn musimy zwrócić użytkownikowi, tym mniej pamięci musimy odczytać z dysku. Dlatego czas wykonania kwerendy rośnie liniowo wraz ze wzrostem liczby odczytanych bajtów niezbędnych do wykonania zapytania. Dodatkowo warto zauważyć, że nawet w przypadku zwracania całego rekordu, kolumnowy indeks CF-Tree wykonuje kwerendę w czasie porównywalnym do wierszowej implementacji drzewa FD.

Wyniki dla selektywności 5% i 10% są bardzo podobne. Przy tak dużej selektywności skanowanie pełnego obszaru pamięci dla pewnych atrybutów osiąga lepsze wyniki niż wierszowe indeksowanie. Jednak struktura FBDSM wykonuje kwerendę dłużej niż wierszowe drzewo FD, szczególnie gdy obsługuje kwerendę dla całego rekordu. Z kolei nowa struktura CF-Tree radzi sobie świetnie, osiągając za każdym razem krótszy czas wykonania zestawu kwerend, nie tylko w porównaniu do indeksu FD-Tree, ale także w porównaniu do struktury FBDSM. Analizując podstawowy zestaw kwerend, możemy zauważyć, że struktura CF-Tree zawsze osiąga gorsze wyniki od wierszowego indeksu przy wyszukiwaniu punktowym, ale zawsze lepsze wyniki przy wyszukiwaniu z zakresu kluczy. Dodatkowo, CF-Tree zawsze wykonuje kwerendy szybciej niż struktura FBDSM, ponieważ nie tylko zawiera kolumnowe ułożenie danych, ale także jest w pełni posortowana. Procedury modyfikacji indeksu są równie szybkie co w strukturze FBDSM, a samo wyszukiwanie, nie wymagając skanowania części tabeli, jest znacząco szybsze w porównaniu do implementacji w FBDSM.

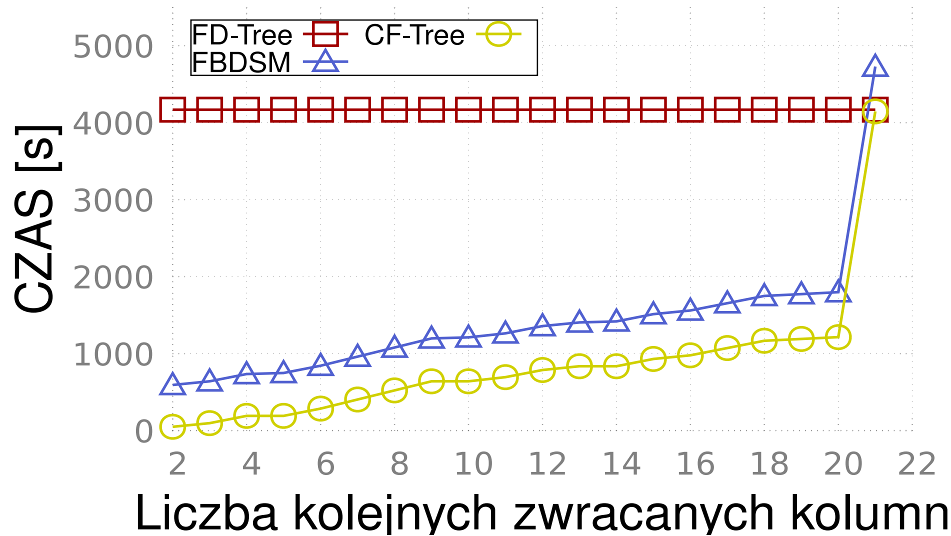

Rysunek 6.25: Czas wykonania zestawu kwerend ZP_{odczyt}
Selektywność 10%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

	Selektywność 1%			**Selektywność 5%**			**Selektywność 10%**		
Liczba zwracanych kolumn (bajtów)	**FD**	**FBDSM**	**CFT**	**FD**	**FBDSM**	**CFT**	**FD**	**FBDSM**	**CFT**
2 (8 B)	420 s	573 s	10 s	2084 s	581 s	25 s	4167 s	592 s	48 s
3 (16 B)	420 s	581 s	18 s	2084 s	605 s	49 s	4167 s	640 s	96 s
4 (32 B)	420 s	591 s	28 s	2084 s	653 s	97 s	4167 s	734 s	190 s
5 (34 B)	420 s	593 s	28 s	2084 s	659 s	97 s	4167 s	747 s	190 s
6 (50 B)	420 s	603 s	37 s	2084 s	707 s	145 s	4167 s	842 s	284 s
7 (70 B)	420 s	616 s	50 s	2084 s	766 s	204 s	4167 s	960 s	403 s
8 (90 B)	420 s	629 s	63 s	2084 s	826 s	264 s	4167 s	1078 s	521 s
9 (110 B)	420 s	641 s	76 s	2084 s	885 s	323 s	4167 s	1197 s	640 s
10 (112 B)	420 s	644 s	76 s	2084 s	891 s	323 s	4167 s	1210 s	640 s
11 (121 B)	420 s	650 s	82 s	2084 s	918 s	350 s	4167 s	1262 s	692 s
12 (137 B)	420 s	660 s	92 s	2084 s	966 s	398 s	4167 s	1357 s	787 s
13 (153 B)	420 s	668 s	100 s	2084 s	990 s	422 s	4167 s	1405 s	835 s
14 (155 B)	420 s	671 s	100 s	2084 s	997 s	422 s	4167 s	1418 s	835 s
15 (171 B)	420 s	680 s	109 s	2084 s	1045 s	470 s	4167 s	1512 s	929 s
16 (179 B)	420 s	688 s	117 s	2084 s	1069 s	494 s	4167 s	1560 s	977 s
17 (195 B)	420 s	698 s	127 s	2084 s	1117 s	542 s	4167 s	1645 s	1072 s
18 (211 B)	420 s	707 s	136 s	2084 s	1165 s	590 s	4167 s	1749 s	1166 s
19 (215 B)	420 s	713 s	142 s	2084 s	1178 s	603 s	4167 s	1773 s	1190 s
20 (219 B)	420 s	718 s	147 s	2084 s	1190 s	616 s	4167 s	1797 s	1214 s
21 (719 B)	420 s	1012 s	441 s	2084 s	2656 s	2081 s	4167 s	4728 s	4145 s

Tabela 6.10: Dokładnie wyniki eksperymentów dla ZP_{odczyt} z wyszukiwaniem zakresowym
Dysk: Intel DCP4511
Tabela: Klient (719 B)

Rozszerzony zestaw kwerend

Celem zestawu rozszerzonego jest symulacja hurtowni danych na podstawie zestawów w TPC-C. Początkowo tabela zawiera 10 mln rekordów. Następnie przeprowadzamy kolejno dodawanie, wyszukiwanie i usuwanie rekordów. Każde wyszukiwanie ma ustawioną selektywność na poziomie 1%, 5% lub 10% całej tabeli. Charakterystyka wszystkich czterech zestawów opisana w rozdziale **4** jest następująca:

1. ZR_{A} - 100 serii, każda seria zawiera operacje dodawania 5 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 5 rekordów,
2. ZR_{B} - 5 serii, każda seria zawiera operacje dodawania 100 000 rekordów, 5 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 100 000 rekordów,
3. ZR_{C} - 10 serii, każda seria zawiera operacje dodawania 10 000 000 rekordów, 20 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 1 000 000 rekordów,
4. ZR_{D} - 10 serii, każda seria zawiera operacje dodawania 1 000 000 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 10 000 rekordów.

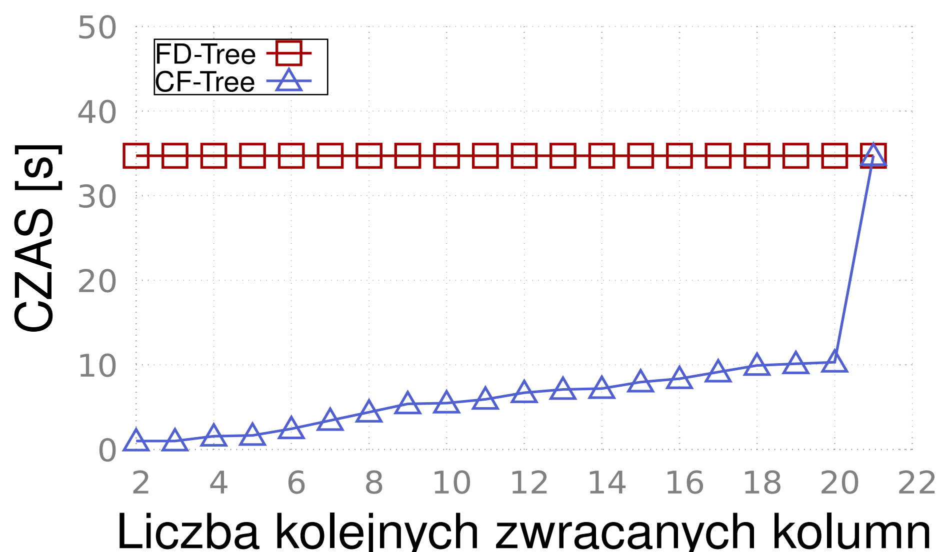

Rysunek 6.26: Czas wykonania zestawu kwerend ZR_A
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

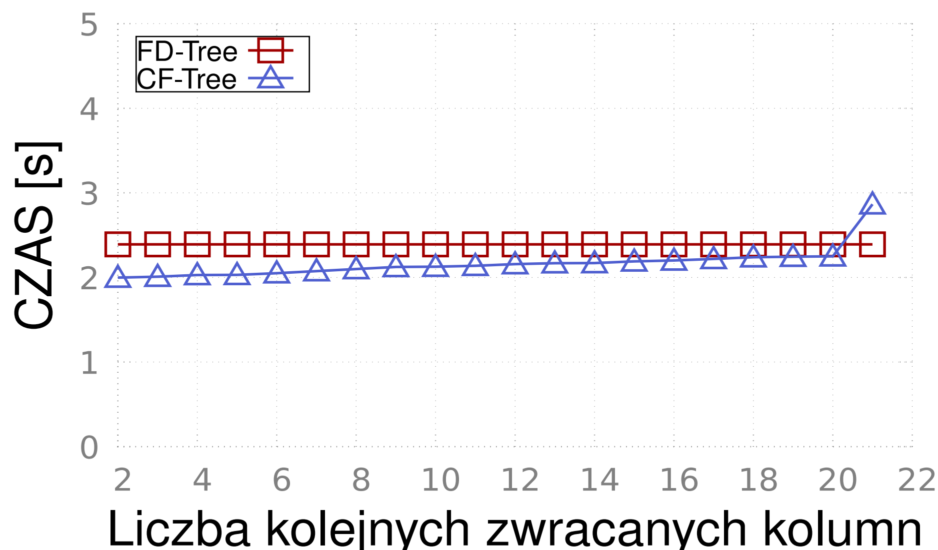

Rysunek 6.27: Czas wykonania zestawu kwerend ZR_B
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

W poprzedniej serii eksperymentów struktura FBDSM osiągnęła najgorsze wyniki pod względem czasu obsługi kwerend. Zarówno wyszukiwanie punktowe, jak i wyszukiwanie zakresu o małej selektywności wykonywały się dłużej w porównaniu do indeksowania CFT oraz do wierszowej implementacji drzewa FD. Również w tej serii eksperymentów FBDSM prezentowała najsłabsze osiągi. Aby lepiej zobrazować różnice pomiędzy FD a CFT, na wykresach nie umieściliśmy wyników struktury FBDSM. Mimo że różne modele dysków SSD osiągały różne czasy (ponieważ charakteryzują się różnym czasem wykonania odczytu i zapisu), to jednak charakterystyka obserwowana na wykresach była dokładnie taka sama. Z tego względu w pracy umieściliśmy tylko wyniki dla najszybszego dysku, Intel DCP4511.

Rysunki: 6.26, 6.27, 6.28, 6.29 przedstawiają całkowity czas potrzebny do wykonania zestawów ZR_A, ZR_B, ZR_C, i ZR_D odpowiednio, ze względu na liczbę zwracanych kolejnych kolumn z tabeli Klient (717B). Do eksperymentów użyto dysku Intel DSP4511, a selektywność ustawiono na 1%. Tabela 6.11 zawiera dokładne wyniki tych eksperymentów.

Zestaw ZR_A jest nastawiony na dużą liczbę wyszukiwań przy małej liczbie modyfikacji tabeli. Przy takim użyciu bazy danych, preferowanym sposobem przechowywania danych jest kolumnowe ułożenie rekordów. Dzięki temu, podczas wyszukiwania, wczytujemy tylko potrzebne fragmenty rekordu. Wyniki eksperymentów potwierdzają tę tezę: początkowo, gdy użytkownik potrzebuje tylko dwie kolumny, czas wykonania kwerendy przez CF-Tree jest ponad 30 razy mniejszy niż w oryginalnym drzewie FD. Oczywiście, im więcej kolumn musimy wczytać, tym czas potrzebny na wykonanie zapytania jest większy. Jednak zawsze kolumnowy indeks osiąga lepsze wyniki niż drzewo FD. Nawet gdy musimy wczytać cały rekord, obie struktury wykonują zestaw kwerend w podobnym czasie.

Zestaw ZR_B jest nastawiony na modyfikacje tabeli i zawiera tylko 5 wyszukiwań oraz 200 tys. operacji modyfikacji (dodawania i usuwania). Ze względu na charakterystykę tego zestawu, czas obsługi zapytań w momencie, gdy zwracamy ponad 12 kolumn, jest bardzo

podobny dla obu struktur. Poniżej tej liczby zwracanych kolumn, CFT osiąga wyniki około 10% lepsze od drzewa FD. Wynika to z faktu, iż czas uzyskany przez wyszukiwania jest tłumiony przez modyfikacje, które zajmują więcej czasu ze względu na charakterystykę dysku SSD. Warto również zauważyć, że w poprzednich eksperymentach, czas potrzebny na wykonanie kwerend podczas zwracania całego rekordu w zapytaniu był podobny dla obu indeksów. Tym razem oryginalne drzewo FD osiągnęło o 15% lepszy rezultat od kolumnowego indeksu CF-Tree.

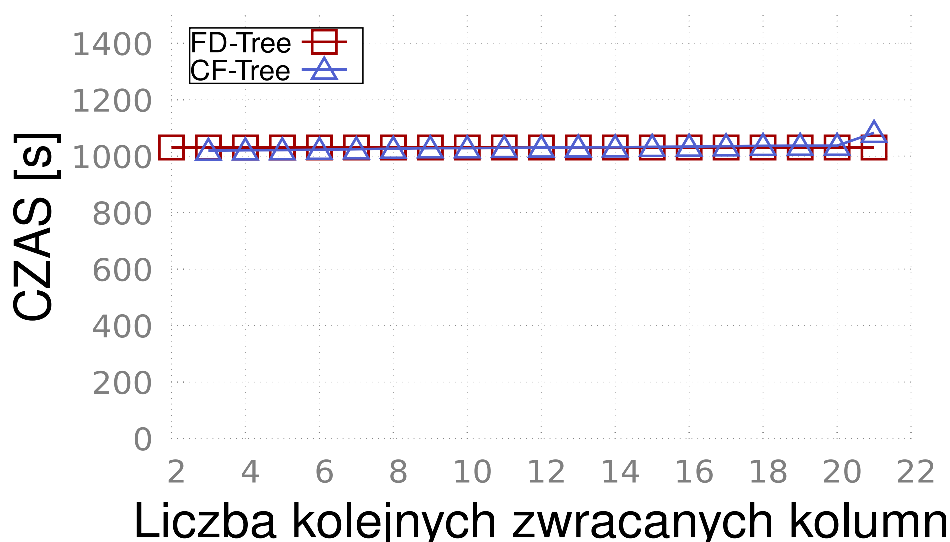

Rysunek 6.28: Czas wykonania zestawu kwerend ZR_C
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

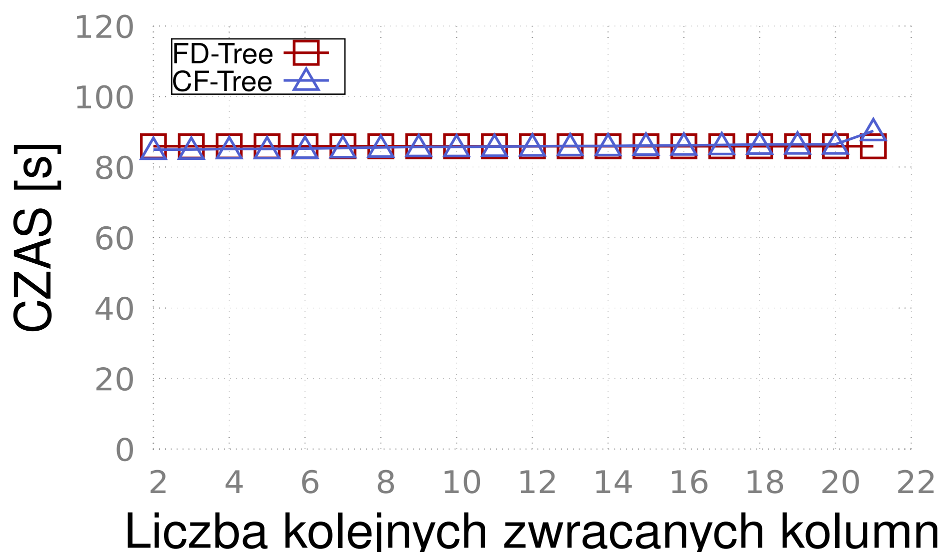

Rysunek 6.29: Czas wykonania zestawu kwerend ZR_D
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

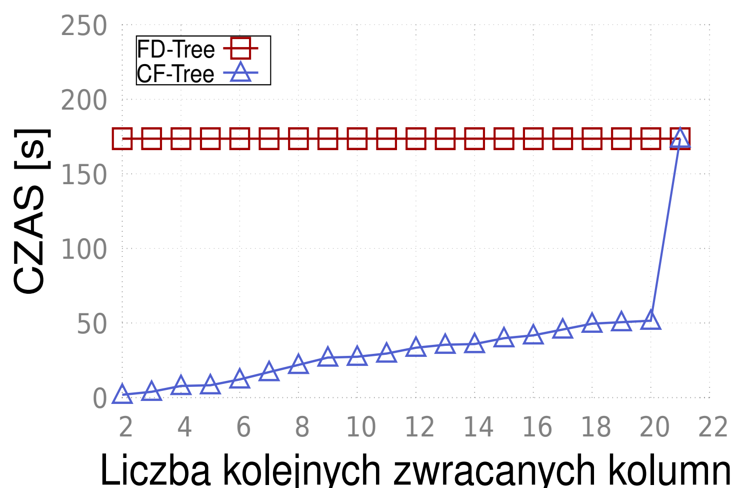

Rysunek 6.30: Czas wykonania zestawu kwerend ZR_A
Selektywność 5%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

	ZR_A		ZR_B		ZR_C		ZR_D	
Liczba zwracanych kolumn (bajtów)	**FD**	**CFT**	**FD**	**CFT**	**FD**	**CFT**	**FD**	**CFT**
2 (8 B)	34,7 s	1 s	2,39 s	1,99 s	1030 s	1019 s	86 s	84 s
3 (16 B)	34,7 s	1 s	2,39 s	2,0 s	1030 s	1019 s	86 s	84 s
4 (32 B)	34,7 s	1,56 s	2,39 s	2,02 s	1030 s	1021 s	86 s	85 s
5 (34 B)	34,7 s	1,66 s	2,39 s	2,03 s	1030 s	1021 s	86 s	85 s
6 (50 B)	34,7 s	2,44 s	2,39 s	2,05 s	1030 s	1022 s	86 s	85 s
7 (70 B)	34,7 s	3,42 s	2,39 s	2,07 s	1030 s	1024 s	86 s	85 s
8 (90 B)	34,7 s	4,41 s	2,39 s	2,09 s	1030 s	1026 s	86 s	85 s
9 (110 B)	34,7 s	5,38 s	2,39 s	2,12 s	1030 s	1028 s	86 s	85 s
10 (112 B)	34,7 s	5,47 s	2,39 s	2,12 s	1030 s	1028 s	86 s	85 s
11 (121 B)	34,7 s	5,91 s	2,39 s	2,13 s	1030 s	1029 s	86 s	85 s
12 (137 B)	34,7 s	6,7 s	2,39 s	2,15 s	1030 s	1030 s	86 s	85 s
13 (153 B)	34,7 s	7,09 s	2,39 s	2,16 s	1030 s	1031 s	86 s	85 s
14 (155 B)	34,7 s	7,19 s	2,39 s	2,17 s	1030 s	1031 s	86 s	85 s
15 (171 B)	34,7 s	7,97 s	2,39 s	2,19 s	1030 s	1033 s	86 s	86 s
16 (179 B)	34,7 s	8,36 s	2,39 s	2,2 s	1030 s	1033 s	86 s	86 s
17 (195 B)	34,7 s	9,14 s	2,39 s	2,21 s	1030 s	1035 s	86 s	86 s
18 (211 B)	34,7 s	9,92 s	2,39 s	2,23 s	1030 s	1036 s	86 s	86 s
19 (215 B)	34,7 s	10,12 s	2,39 s	2,24 s	1030 s	1037 s	86 s	86 s
20 (219 B)	34,7 s	10,32 s	2,39 s	2,24 s	1030 s	1037 s	86 s	86 s
21 (719 B)	34,7 s	34,73 s	2,39 s	2,86 s	1030 s	1042 s	86 s	88 s

Tabela 6.11: Dokładnie wyniki eksperymentów dla zestawów rozszerzonych
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

Cechy charakterystyczne zestawów ZR_C i ZR_D są dość podobne. Tak jak poprzedni zestaw ZR_B, obydwa są nastawione na modyfikacje tabeli. Jednak tym razem różnice w liczbie operacji modyfikacji są znacznie większe. Zestaw ZR_C zawiera 20 wyszukiwań i aż 11 milionów modyfikacji. Zestaw ZR_D składa się z 10 wyszukiwań i 1 milion modyfikacji. Chociaż wyniki obu eksperymentów różnią się całkowitym czasem wykonania, charakteryzują się podobnym trendem i zachowaniem. W obu przypadkach modyfikacje tabeli zajmują na tyle dużo czasu, że wpływ czasu potrzebnego na wyszukiwania jest marginalny. Należy jednak zauważyć, że kolumnowe indeksy są przede wszystkim zoptymalizowane do wyszukiwania rekordów. Nasza zaproponowana struktura CFT nie tylko dobrze radzi sobie w zestawach dominowanych przez odczyty danych, ale również w przypadku modyfikacji tabeli. Czas uzyskany podczas obu zestawów jest bardzo zbliżony – różnice nie przekraczają 5% pomiędzy indeksami. Taki wynik jest imponujący i pozwala wywnioskować, że CFT jest dobrym wyborem niezależnie od charakterystyki przeprowadzanych kwerend na bazie danych.

W kolejnej serii eksperymentów sprawdziliśmy, jak indeksy radzą sobie z zapytaniami o większej selektywności. Im więcej danych musimy wczytać, tym większe korzyści przynosi kolumnowe ułożenie danych, które pozwala pominąć więcej niepotrzebnych danych, które wierszowa implementacja musiałaby odczytać. Rysunki 6.30 oraz 6.31 przedstawiają wyniki tej serii eksperymentów. Tym razem skoncentrowaliśmy się tylko na zestawach ZR_A i ZR_C, które reprezentują skrajne charakterystyki zastosowań. Obserwowane wyniki potwierdzają naszą hipotezę: przy większej selektywności, równiej 5%, kolumnowy indeks CF-Tree osiąga lepsze czasy nie tylko w zestawie ZR_A, ale także w ZR_C. Dzieje się tak, ponieważ przy takiej selektywności operacja wyszukiwania staje się kosztem znacząco wpływającym na całkowity czas wykonania kwerend, co jest widoczne na omawianych wykresach.

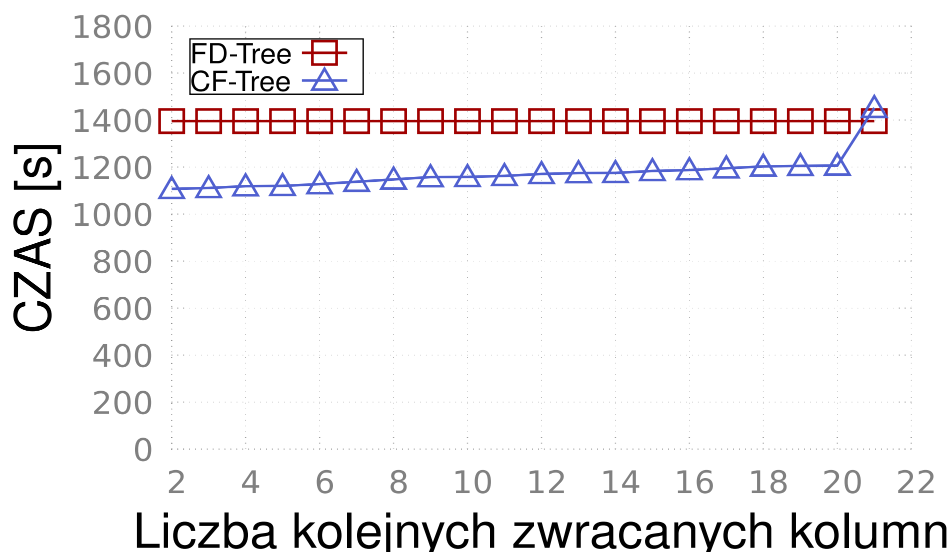

Rysunek 6.31: Czas wykonania zestawu kwerend ZR_C
Selektywność 5%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

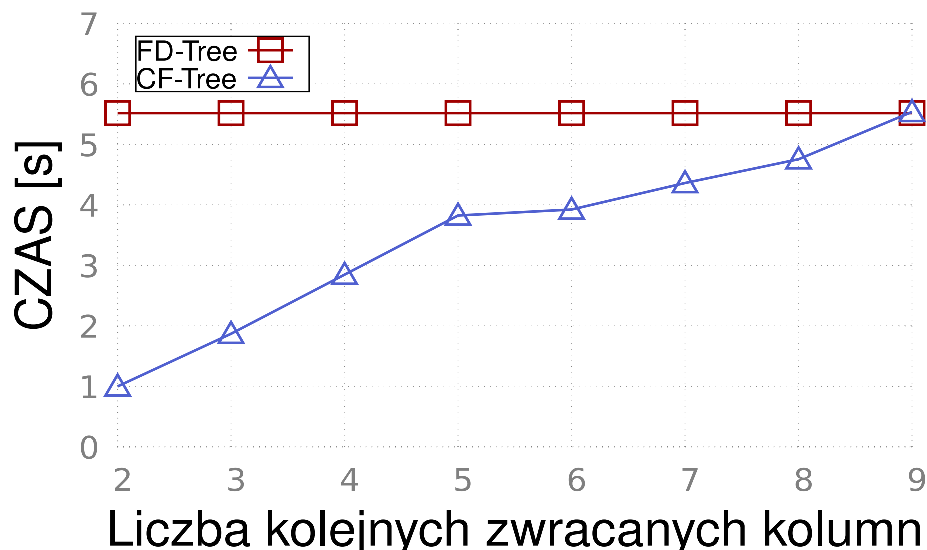

Rysunek 6.32: Czas wykonania zestawu kwerend ZR_A
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

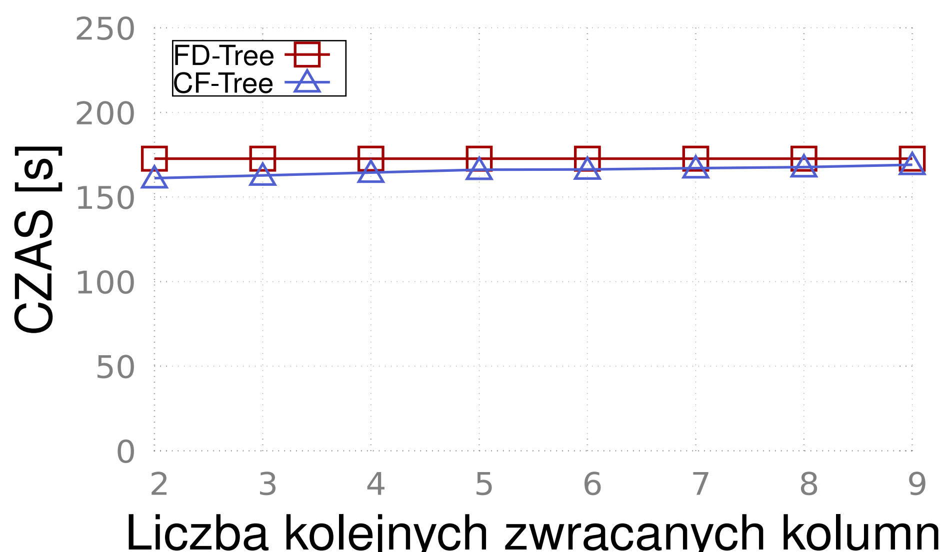

Rysunek 6.33: Czas wykonania zestawu kwerend ZR_C
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

Ostatnia seria eksperymentów została wykonana na mniejszej tabeli – Sklep, której rekord ma rozmiar tylko 113B, w przeciwieństwie do poprzedniej tabeli Klient o rozmiarze rekordu aż 719B. Celem tej serii jest zbadanie wpływu charakterystyki tabeli (rozmiar rekordu, liczba kolumn) na różnice pomiędzy wynikami osiągniętymi przy użyciu indeksu kolumnowego i wierszowego. Rysunki 6.32 i 6.33 przedstawiają wyniki ostatniej serii eksperymentów dla odpowiednio zestawów ZR_A i ZR_C, z selektywnością ponownie ustawioną

na 1%. Mniejsza tabela, zawierająca mniej kolumn, skutkuje mniejszym zyskiem z pominięcia fragmentów rekordu. Widoczne jest to na prezentowanych wykresach. Przy zestawie ZR_A, indeks kolumnowy CFT osiągnął ponad 30-krotnie lepszy czas od indeksu FD w przypadku, gdy użytkownik prosił o dwie kolumny z tabeli Klient. Tym razem ten zysk jest tylko 6-krotny i zmniejsza się znacznie szybciej niż w przypadku poprzednich kwerend. Charakterystyka wykresu 6.33 jest taka sama, jak charakterystyka wykresu 6.28. W obu przypadkach czas wykonywania kwerend z wykorzystaniem obu struktur jest bardzo podobny. Patrząc na charakterystykę obu wykresów, możemy stwierdzić, że rozmiar rekordu nie miał dużego wpływu na czas wykonania zestawu kwerend, ponieważ zestaw nastawiony jest na modyfikacje bazy, a nie na odczyty. Operacje dodawania i usuwania przeprowadzane są podczas reorganizacji drzew na całych rekordach, dlatego liczba kolumn obsługiwana przez kwerendy nie ma wpływu na ten zestaw.

Podsumowując, nowa struktura CF-Tree, dzięki kolumnowemu ułożeniu danych, wykonuje wyszukiwania znacznie szybciej niż oryginalna wierszowa implementacja drzewa FD. Niestety, podczas wyszukiwania punktowego, CF-Tree musi wykonać dodatkową procedurę scalania atrybutów w rekord. Chociaż ten algorytm ma logarytmiczny czas wykonania, to znacząco wpływa na pogorszenie wyników osiąganych przez CF-Tree w stosunku do FD, nawet gdy nie zwracamy pełnego rekordu. Całkiem inna sytuacja ma miejsce podczas wyszukiwania całego zakresu, gdzie algorytm scalania jest wykonywany tylko raz, co ma praktycznie zerowy wpływ na czas obsługi kwerendy. W zapytaniach, które wymagają małego podzbioru atrybutów, nowy indeks CF-Tree osiąga nawet 30-krotnie lepszy czas od drzewa FD. Oczywiście przewaga ta zależy od liczby zwracanych kolumn, selektywności zapytania oraz rozmiaru rekordu. Dodatkowo warto zauważyć, że CF-Tree radzi sobie świetnie nie tylko w zestawach nastawionych na wyszukiwania, ale również osiąga porównywalny czas względem wierszowego FD w zestawach modyfikujących bazę danych. Przeprowadzone analizy i eksperymenty pokazują praktyczną przydatność nowej, zaproponowanej struktury CF-Tree dla baz danych przechowywanych na dyskach SSD.

6.6 Indeksowanie częściowe

Stworzenie idealnego zbioru indeksów, który zawiera wszystkie potrzebne struktury, to bardzo trudne zadanie, przed którym stają administratorzy baz danych. Z tego powodu dąży się do automatyzacji procesu tworzenia indeksów [55], [56], [57]. Stosuje się podejścia, które próbują dostosować struktury bazy danych i kolejne indeksy w odpowiedzi na zmieniające się kwerendy. Kolumny, po których sortowane są dane podczas zapytań, są monitorowane i analizowane, aby silnik bazy danych mógł stwierdzić, czy potrzebny jest nowy indeks, oraz czy istniejący indeks przestał być używany. W ciągu ostatnich kilku lat rozwinęło się kolejne podejście do automatyzacji procesu indeksowania. W pracach [58] i [59] zaproponowano Indeks Cracking jako nową metodę automatycznego, iteracyjnego tworzenia indeksu. W wyniku działania kwerendy część tabeli jest reorganizowana, aby dostosować się do aktualnego wzorca zapytania. Proces ten próbuje rozłożyć koszt tworzenia indeksu na wiele etapów. Indeks Cracking używa metody podziału danych na partycje względem elementów z zakresu zapytania i działa podobnie do sortowania szybkiego (ang. *quicksort*) [60]. Mimo że Indeks Cracking jest bardzo obiecującym podejściem do automatyzacji tworzenia indeksu, metoda ta posiada kilka wad. Przede wszystkim częste reorganizacje na małych częściach tabeli mogą być stosunkowo wolne, zwłaszcza gdy używane są dyski SSD. Po drugie, szybkość tworzenia indeksu zależy od wzorca kwerend.

Podobnie jak w sortowaniu szybkim, złożoność obliczeniowa zależy od wyboru elementu rozdzielającego partycję (ang. *pivot*).

Kolejna metoda automatycznego tworzenia indeksów podczas kwerend została zaproponowana w [15]. Metoda Adaptive Merging, w przeciwieństwie do Indeks Cracking, korzysta z algorytmu scalania posortowanych list, podobnego do sortowania przez scalanie (ang. *mergesort*) [64]. Gdy po raz pierwszy potrzebujemy wyszukać elementy biorąc pod uwagę wartości z danej kolumny, kopiujemy tabelę, wczytując tyle danych na raz, ile mieści się w buforze, a następnie sortujemy wartości w obrębie danej partycji. W kolejnych zapytaniach usuwamy dane z posortowanych partycji i tworzymy nową. W ten sposób, po pewnym czasie, uzyskamy zbiór partycji, które są nie tylko posortowane wewnętrznie, ale także tworzą posortowany ciąg. Obie te metody zostały dokładnie omówione w rozdziale **2**. Ze względu na schemat działania obu algorytmów, Indeks Cracking jest zalecany dla baz danych zapisanych w szybkiej pamięci operacyjnej komputera, natomiast Adaptive Merging dla sytuacji, gdy tabela przechowywana jest na pamięciach blokowych, takich jak dyski HDD czy SSD. Niestety, w oryginalnej wersji Adaptive Merging nie uwzględniono różnic pomiędzy dyskami HDD a innymi pamięciami blokowymi, jak nowsze modele dysków SSD. Z tego powodu zaproponowaliśmy nowy system częściowego indeksowania danych, dostosowany w pełni do charakterystyki pamięci flash i dysków SSD – Lazy Adaptive Merging [4].

6.7 System Lazy Adaptive Merging

Lazy Adaptive Merging (LAM) [4] to kolejne iteracyjne podejście tworzenia indeksu częściowego jako efekt uboczny każdej kwerendy. Jest dostosowany do blokowej pamięci flash i dysków SSD oraz posiada wszystkie cechy dobrego systemu do przechowywania danych na tej pamięci. Należą do nich:

- **Buforowanie** - Dyski SSD najszybciej przeprowadzają zapis sekwencyjny, ponieważ mogą zapisać dane równolegle na kilku kościach jednocześnie. Podobnie jak pamięć podręczna procesora (ang. *cache*) jest ważna dla baz danych przechowywanych w pamięci RAM (ang. *in-memory database*), tak dla dysków SSD kluczowe jest umiejętne buforowanie danych w pamięci operacyjnej komputera (RAM). Zamiast zapisywać każdą daną pojedynczo, co prowokuje liczne operacje kasowania dużych bloków, efektywniej jest zastosować bufor o rozmiarze kilku kilobajtów, aby zapisywać pełne strony.
- **Wyrównanie (ang. *alignment*)** - Dyski SSD, używające pamięci flash typu NAND, odczytują i zapisują tylko pełne strony. Jeśli potrzebujemy zapisać pojedynczy bajt, musimy zapisać całą stronę. Kasowanie bloku jest jeszcze bardziej restrykcyjne, gdyż można je przeprowadzić tylko na pełnym bloku (32-64 strony). Dlatego istotne jest, aby zapisywać dane w sposób uporządkowany, aby możliwe było wczytanie wielu potrzebnych danych jedną operacją, bez marnowania czasu na odczytywanie niepotrzebnej zawartości strony.
- **Leniwe usuwanie** - Kasowanie bloku jest najwolniejszą operacją na pamięci flash. Ze względu na fizyczne ograniczenia, opisane w rozdziale **3**, każdy blok musi być skasowany przed ponownym zapisem danych. Jeśli więc chcemy zmienić wartość na danej stronie, musimy wczytać cały blok do pamięci RAM, zaktualizować dane,

skasować blok, a następnie zapisać go ponownie. Proces ten jest długi i kosztowny, dlatego warto go optymalizować. Skuteczną metodą jest wprowadzenie mechanizmu dzienników, który pozwala odroczyć kasowanie bloku i agregować zapotrzebowanie na tę operację.

- **Zbieranie informacji** - Częste gromadzenie metadanych może optymalizować pewne operacje. Jeśli wiadomo, że tabela jest częściej używana do odczytu niż zapisu, warto przeorganizować dane tak, aby przyspieszyć wyszukiwanie kosztem wstawiania. Nie należy jednak przesadzać z ilością tych danych, aby nie dominowały one kosztów operacyjnych. Najlepiej przechowywać je w szybkiej pamięci RAM, a w przypadku awarii systemu odzyskiwać podczas jego ponownego uruchomienia.

Podczas projektowania struktury danych do indeksowania nie musimy koncentrować się na wyżej wymienionych cechach systemu, ponieważ nowa struktura zostanie zintegrowana z silnikiem bazy danych, który już posiada te oraz inne mechanizmy przyspieszające obróbkę zgromadzonych danych. Jednak warto zwrócić uwagę, że Lazy Adaptive Merging (LAM) nie jest tylko strukturą danych, ale całościowym systemem wspierającym każdą operację podczas tworzenia kolejnych fragmentów indeksu. LAM nie może korzystać z gotowych rozwiązań silnika baz danych, gdyż wprowadza nowe operacje, które są nieznane dla standardowego silnika. Dlatego też, dostosowanie dobrej praktyki pracy na dyskach SSD jest istotnym elementem proponowanego algorytmu.

6.7.1 Struktura LAM

W odróżnieniu od klasycznego Adaptive Merging, Lazy Adaptive Merging (LAM) nie usuwa danych podczas tworzenia nowej partycji. Zamiast tego, rejestruje zużycie bloku w specjalnej tablicy, umożliwiając analizę liczby danych, które nie zostały usunięte. System ten jest kompatybilny zarówno z zapisem wierszowym, jak i kolumnowym, stosując algorytm wstawiania zbiorczego (ang. *bulkload*) do tworzenia indeksów. Wybór konkretnej struktury indeksowania zależy od zastosowanego formatu zapisu danych. W przypadku struktur zapisu kolumnowego, LAM efektywnie wykorzystuje tę cechę do tworzenia częściowych indeksów kolumnowych. Nasz nowy system może również współpracować ze strukturami zaprojektowanymi dla optymalizacji pod kątem pamięci flash, takimi jak LA ([28]) czy FD ([27]). Lazy Adaptive Merging korzysta z następujących struktur danych:

1. **Partycja** - podstawowa struktura przechowująca zbiór posortowanych danych. Wielkość partycji jest zawsze wielokrotnością rozmiaru bloku kości flash, aby zminimalizować narzut związany z zapisem, odczytem i usuwaniem danych. Podczas pierwszej kwerendy, dane są wczytywane do bufora, sortowane, a następnie zapisywane na dysku SSD. Kolejne partycje są tworzone podczas procesu scalania kilku partycji, co pozwala zmniejszyć liczbę używanych bloków. Dane są posortowane wewnątrz każdej partycji, co umożliwia szybkie wyszukiwanie potrzebnego klucza za pomocą klasycznego wyszukiwania binarnego. Dodatkowo każda partycja posiada informacje o najmniejszym i największym kluczu w partycji, które są zapisane w pamięci RAM lub w drzewie PB+ [65], umożliwiając szybkie stwierdzenie, czy partycja zawiera potrzebne dane.
2. **Drzewo PB+ (ang. *Partitioned B+ tree*)** - drzewo służy do zarządzania zbiorem partycji. Struktura i algorytmy wykonywane na tym drzewie są bardzo podobne do zwykłego drzewa B+. Każda partycja posiada klucz sztuczny, według którego jest

przechowywana w drzewie. Mając drzewo z adresami partycji, łatwo można nimi manipulować, dodając nowe i usuwając stare. Wyszukiwanie danych może odbywać się równolegle na kilku partycjach. Struktura najlepiej jest zapisana w pamięci RAM, ponieważ można ją łatwo zbudować ze zbioru partycji zapisanych na dyskach SSD. Pełny opis struktury można znaleźć w [65].

3. **Bufor do sortowania** - to fragment szybkiej pamięci RAM o ustalonym rozmiarze BS (ang. *Buffer Size*), używany do sortowania danych przed zapisem do partycji. Im większy bufor, tym więcej danych można posortować za jednym razem. Większe BS oznacza mniejszą liczbę partycji, co przyspiesza wyszukiwanie danych podczas zapytania.

4. **Tablica zużycia danych (ang. *usage*)** - tablica o rozmiarze odpowiadającym liczbie bloków potrzebnych do zapisania tabeli lub kolumny (w zależności od sposobu zapisu bazy). Każdy blok ma swoje własne pole w tablicy, w którym zapisana jest liczba użytych danych. Przykładowo, jeśli blok piąty ma rozmiar 32 strony, z których każda mieści 5 rekordów i 10 danych jest już zapisanych w indeksie, to $usage[5] = 10$. Tablica ta jest kluczową strukturą używaną przez LAM, ponieważ dzięki niej algorytm może podjąć decyzję o reorganizacji i usunięciu zduplikowanych danych. Reorganizacja przeprowadzana jest, gdy liczba bloków można zredukować o wartość większą lub równą parametrowi MT (ang. *Merge Threshold*). Tablica jest przechowywana w szybkiej pamięci RAM.

5. **Indeks** - do indeksowania można użyć dowolnej struktury, która jest dostosowana do pamięci flash i posiada cechy wymagane przez nasz system.

6. **Dziennik (ang. *journal*)** - ponieważ dane nie są usuwane natychmiastowo podczas wykonywania kwerendy, musimy stwierdzić, skąd czytamy dane: z indeksu czy z partycji. Wyszukiwanie w indeksie jest stosunkowo tanie, jednak skanowanie partycji jest kosztowne. Aby zredukować te koszty, wprowadzono dziennik, który jest listą par uporządkowanych, zawierającą zakresy kluczy znajdujących się w indeksie oraz dane, które usunięto z partycji. Dzięki temu podczas wyszukiwania możemy szybko stwierdzić, czy rekord znajduje się w indeksie. Taki proces jest znacznie szybszy od skanowania partycji w celu stwierdzenia nieobecności usuniętej danej. Dziennik jest zapisany na dysku oraz częściowo buforowany w pamięci RAM.

Rysunek 6.34 przedstawia przykładowy stan procesu tworzenia indeksu częściowego przez LAM. Dla uproszczenia załóżmy, że tabela ma 18 rekordów. Kolumna, po której zaczynamy sortować, ma układ w pamięci: (1, 26, 13, 5, 3, 20, 21, 10, 9, 12, 18, 6, 2, 4, 16, 20, 24, 11). Bufor może pomieścić tylko 6 rekordów na raz. Sytuacja przedstawiona na rysunku ma miejsce po wykonaniu czterech kwerend: {2 - 5, 21 - 24, 16 - 16, 6 - 9}. Wielkość partycji w tym momencie ograniczona jest przez wielkość bufora, w którym odbywa się sortowanie. Na rysunku przedstawione są trzy partycje $P1$, $P2$, $P3$, każda o pojemności trzech bloków. Każdy blok może pomieścić dwa rekordy. Zamiast całego rekordu przedstawione zostały wartości liczbowe, które reprezentują wartość klucza. Rekordy podczas pierwszego zapytania są sortowane w buforze i zapisywane do partycji. Dlatego dane wewnątrz każdej partycji są posortowane. Dostęp do partycji odbywa się poprzez drzewo PB+. Kolor szary symbolizuje dane wstawione do indeksu, które jednak ze względu na minimalizację liczby modyfikacji bloków dysku SSD nie zostały jeszcze usunięte. Czytając dziennik możemy łatwo zauważyć, które dane zostały przepisane do indeksu. Zatem, jeśli kolejna kwerenda będzie żądała wartości z zakresu (7 - 11), to analizując dziennik

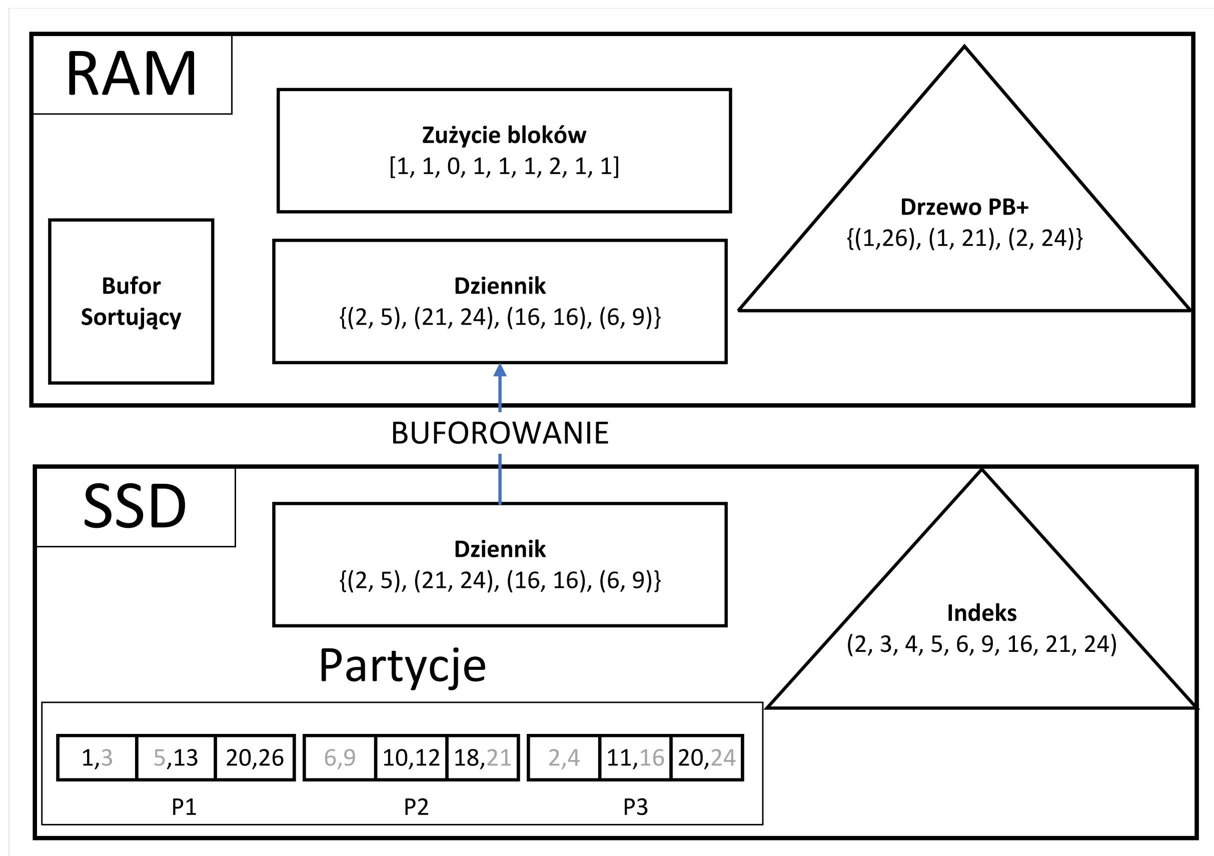

Rysunek 6.34: Przykład struktury LAM

stwierdzimy, że wartości (7-9) wczytamy z indeksu a (10 - 11) z partycji. Tablica zużycia bloków monitoruje liczbę danych, które czekają na usunięcie. Przykładowo, pierwszy blok z partycji pierwszej (P1) zawiera jedną przepisaną daną (w tym przykładzie strona jest w stanie pomieścić tylko jeden rekord), stąd $usage[0] = 1$, trzeci blok nie ma żadnej danej wstawionej do indeksu, dlatego $usage[3] = 0$. Dzięki tej tablicy, algorytm rozwiązujący problem ciągłego pakowania może znaleźć sposób na takie połączenie bloków w inną partycję, które zmniejsza znacząco liczbę bloków. Wtedy następuje reorganizacja: usuwane są stare partycje, a dodawane nowe. Dzięki strukturze PB+, operacje są proste do wykonania i nie zaburzają pracy algorytmu.

Rysunek 6.35 przedstawia cztery kroki systemu Lazy Adaptive Merging podczas tworzenia indeksu częściowego. Dla uproszczenia załóżmy, że tabela ma 15 rekordów, a każda liczba przedstawia wartość atrybutu, który będzie nowym kluczem. Kolumna, po której zaczynamy sortować, ma układ w pamięci: (5, 1, 10, 15, 7, 2, 8, 3, 4, 14, 11, 6, 12, 9, 13). Strona dysku SSD może pomieścić tylko jeden rekord, a blok maksymalnie 3 rekordy. Bufor może mieć rozmiar 6 rekordów, a więc tylko tyle możemy sortować jednocześnie. Zatem partycja może składać się z nie więcej niż z 6 rekordów (2 bloków). Aby uprościć rysunek, pominięte zostało drzewo PB+. Pamiętajmy jednak, że zapisane w nim są minimalne i maksymalne wartości kluczy każdej partycji oraz fizyczny adres na dysku. Ustalmy także parametr $MT = 2$ (ang. *Merge Treshold*). W związku z tym możemy przeprowadzić reorganizację dopiero wtedy, gdy istnieje możliwość zredukowania liczby bloków o przynajmniej dwa. Na początku dostajemy kwerendę z zakresu (13-13). Dane wczytywane są do bufora i sortowane, następnie zapisywane w partycjach. Sam zakres

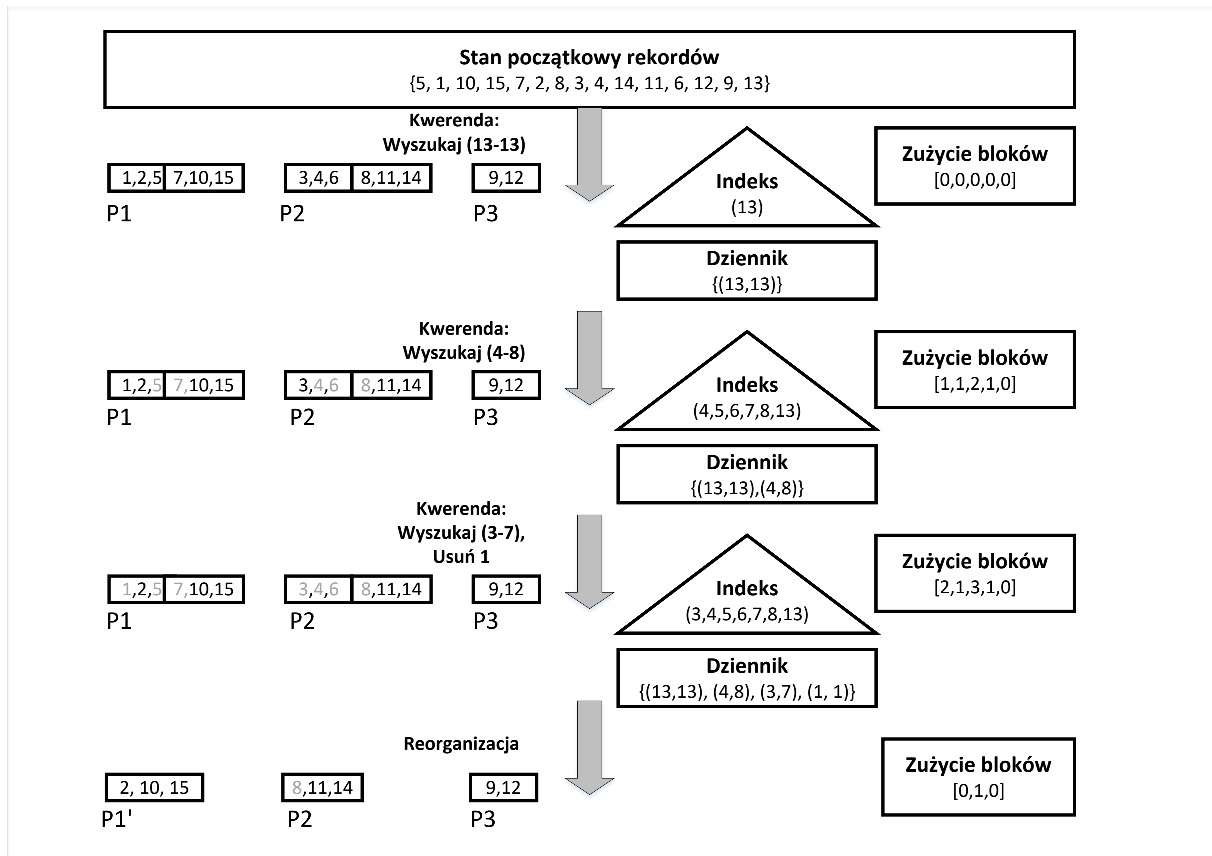

Rysunek 6.35: Przykładowy proces tworzenia częściowego indeksu z użyciem systemu LAM

kwerendy dodawany jest do indeksu. Z tego powodu w indeksie zapisaliśmy klucz 13, a także utworzyliśmy pierwszy wpis w dzienniku: parę (13,13). Kolejno mamy zapytanie o zakresie (4 - 8). Po pierwsze czytamy nasz dziennik aby sprawdzić, czy zakres zapytania pokrywa się z kluczami zapisanymi już w indeksie. Niestety wartość 13 jest poza zakresem (4 - 8), a więc musimy wczytać wszystkie wartości z partycji. Dzięki atrybutom partycji zapisanych w drzewie PB+ stwierdzamy, że partycja $P3$ nie zawiera potrzebnych danych, więc nie będziemy jej wczytywać. Używając informacji zapisanych w szybkiej pamięci RAM określimy, które strony z dysku musimy wczytać. Z partycji $P1$ kopiujemy 5 i 7, a z partycji $P2$ kopiujemy 4,6 oraz 8. Nie usuwamy danych z dysku, aby uniknąć niepotrzebnego wymazywania. W zamian wstawiamy dane do indeksu i zapisujemy przedział do dziennika. W naszym przypadku będzie to para (4,8). Aby zobrazować użyte lecz nieusunięte dane, na rysunku takie klucze zostały zaznaczone szarym kolorem. Aktualizujemy także zużycie bloków, z których coś skopiowaliśmy. Przykładowo, ponieważ z bloku pierwszego z partycji $P1$ skopiowaliśmy 5, to $usage[1] = 1$. Ostatnim krokiem jest sprawdzenie, czy możliwe jest takie połączenie bloków w inne partycje, które zmniejszy ich liczbę o co najmniej 2. Niestety okazuje się, że takie nie istnieje. Po wykonaniu wszystkich powyższych kroków, możemy zwrócić użytkownikowi wynik jego kwerendy. Następnie mamy sytuację, w której dostajemy zapytanie o zakresie (3 - 7). Jak poprzednio, czytamy najpierw dziennik. Widzimy, że (4-7) możemy wyszukać w indeksie. Resztę wczytamy z partycji. Kolejny raz stwierdzamy, że $P3$ nie zawiera potrzebnych danych, więc nie będziemy jej wczytywać. Z $P2$ kopiujemy klucz 3. Wstawiamy klucz do indeksu i zapisujemy kolejną parę (3, 7) do dziennika. Usuwamy także dane z kluczem 1. Znajduje

się on w partycji $P1$. Zamiast fizycznego usuwania, zaznaczamy go jako przepisany do indeksu. Dodajemy wpis do dziennika: (1, 1). Aktualizujemy tablicę użycia bloków analogicznie jak poprzednio oraz sprawdzamy, czy opłaca się wykonać reorganizację. Okazuje się, że tak. Możemy połączyć blok pierwszy z drugim oraz w pełni usunąć trzeci. Dzięki temu liczba bloków zmniejszy się o 2. Zatem wczytujemy wymienione bloki i za pomocą dziennika stwierdzamy, które dane można usunąć. Dolna część rysunku pokazuje sytuację po scaleniu i usunięciu bloków. Zatem nadal mamy 3 partycje (w miejsce $P1$, stworzyliśmy $P1'$, z $P2$ usunęliśmy blok), przy czym każda z nich ma tylko jeden blok. Zmieniona została także tablica użycia bloków, ponieważ zmienił się ich układ. Reorganizacja została zakończona, a więc możemy zwrócić wynik użytkownikowi.

Omówiony przykład bardzo dobrze pokazuje zysk wynikający z użycia naszego nowego systemu. Podczas rozpatrywanych zapytań, klasyczne podejście wymagałoby aż 6 usunięć bloków oraz 8 zapisów potrzebnych, aby na nowo przepisać dane z usuwanego bloku do nowego. Zaproponowany algorytm wymagał wykonania tylko 3 usunięć i 3 przepisań danych wynikających z usunięcia bloku. Warto zauważyć, że liczba odczytów jest podobna. Tak więc optymalizacja liczby kasowań nie wpłynęła na szybkość wyszukiwań. Kosztem dodatkowej pamięci, która jest zajęta do czasu reorganizacji, skróciliśmy czas wykonywania kwerendy.

6.7.2 Procedury systemu LAM

Wstawianie

W przeciwieństwie do Indeksu Cracking i Adaptive Merging, wstawianie w zaproponowanym sposobie tworzenia indeksu jest bardzo proste. Ponieważ używamy gotowej struktury danych do indeksowania rekordów, wstawianie odbywa się zgodnie z mechanizmami używanej struktury indeksowej. Nie ma więc potrzeby dodawania wartości do posortowanych partycji i zaburzania porządku danych. Ponieważ dane, które wstawiamy, dodajemy bezpośrednio do struktury indeksu, zapisujemy ten fakt w naszym dzienniku. Dzięki temu podczas wyszukiwania wiemy, że rekordu należy szukać w indeksie, a nie w partycjach.

Wyszukiwanie

Wyszukiwanie jest najważniejszą operacją w procesie tworzenia indeksu częściowego. To właśnie podczas wyszukiwania dokładamy kolejne rekordy do indeksu, zmieniając przy tym układ danych. Samo wyszukiwanie jest dość proste. Gdy przychodzi zapytanie od użytkownika, czytamy dziennik indeksu, aby określić, które dane możemy wczytać z gotowego indeksu, a które z partycji. Ponieważ dziennik to tylko lista zakresów kluczy przepisanych lub dodanych do indeksu, musimy odczytać całą listę, dlatego trzymamy go w pamięci RAM jako strukturę posortowanego drzewa, aby przyspieszyć ten proces. Oczywiście najlepszym przypadkiem jest zapytanie, które możemy obsłużyć czytając tylko indeks. Jeśli jednak tak nie jest, musimy wczytać dane z partycji. Odczytujemy wartość klucza uwzględniając klucz sztuczny w drzewie PB+ i znajdujemy partycję, która może posiadać tę daną. Przydatność partycji określamy na podstawie jej atrybutów. W fazie przygotowania zbieramy wszystkie potrzebne informacje zapisane w pamięci komputera, a następnie wykonujemy sekwencyjny odczyt na potrzebnych stronach z dysku. To, że klucz został zapisany w dzienniku, nie oznacza, że nadal jest w indeksie. Podczas usuwania lub

aktualizacji rekordów w indeksie zmieniamy indeks, ale nie zmieniamy dziennika. Robimy tak, aby przyspieszyć proces wyszukiwania oraz zachować jego poprawność. Gdybyśmy usunęli dane z dziennika, musielibyśmy odszukać go w zbiorze partycji. Ponieważ nie usuwamy danych natychmiastowo, możliwe jest, że znajdziemy klucz, który miał być usunięty. Podalibyśmy wtedy nieprawdziwą informację użytkownikowi. Nie usuwając wpisu, w czasie logarytmicznym wyszukujemy klucz w indeksie lub dochodzimy do wniosku, że dany klucz został usunięty. Chociaż po wczytaniu stron i ich analizie możemy zwrócić wynik użytkownikowi, to nie kończymy na tym operacji. Dzięki znajomości zakresu zapytania możemy dostosować układ danych tak, aby kolejne takie samo zapytanie lub zbliżone do niego było o wiele szybsze. W tym celu wszystkie dane wczytane z partycji sortujemy w buforze i wstawiamy do indeksu. Następnie krotkę opisującą wstawiony zakres zapisujemy w dzienniku. Nie usuwamy jednak danych z partycji. Kosztem dodatkowej pamięci minimalizujemy czas potrzebny na wykonanie operacji wymazania na niepełnym bloku. Zamiast fizycznego usuwania rekordów, zapisujemy kolejne zużycie danego bloku w odpowiadającym dla niego polu w tablicy *usage*. Jeśli zachodzi taka potrzeba, wykonujemy reorganizację na zbiorze partycji.

Usuwanie

Aby zminimalizować liczbę operacji usuwania bloków pamięci flash w dysku SSD, wprowadzono mechanizm leniwego usuwania. Gdy wartość jest już zapisana w indeksie, wystarczy wykonać potrzebną operację na wybranej do indeksowania strukturze. Jeżeli rekord jest przechowywany w partycji, nie należy go natychmiast usuwać z dysku. Zamiast tego dodajemy wpis do dziennika, aby umożliwić algorytmowi decyzję o odczycie z indeksu podczas wyszukiwania. Dzięki efektywnym strukturom indeksowym, które większość czasu gwarantują logarytmiczny czas wyszukiwania, szybko stwierdzimy, czy rekord znajduje się w indeksie, co oznacza, że został już usunięty z partycji. Podczas przeprowadzania tej operacji na partycji, konieczne jest również aktualizowanie tablicy zużycia bloków, aby móc podjąć decyzję o reorganizacji, opisanej w tym rozdziale.

Reorganizacja

Jak wcześniej wspomniano, LAM nie usuwa kluczy natychmiast, lecz zapisuje zużycie bloku w specjalnej tablicy i czeka na moment, gdy możliwe będzie zmniejszenie liczby bloków przynajmniej o wartość parametru MT (ang. *Merge Threshold*). Aby przeprowadzić reorganizację, musimy znaleźć takie połączenie bloków, które znacząco zredukuje ich liczbę. Ponieważ dane będą ponownie sortowane, możemy je dowolnie rozdzielać między inne partycje. Traktując fragmenty nieusuniętych danych jak przedmioty, a bloki jak pudełka, mamy do czynienia z ciągłym problemem pakowania (wariant, w którym przedmioty można dzielić) [189]. W odróżnieniu od klasycznego problemu pakowania [190], ten problem możemy łatwo rozwiązać. Wystarczy wczytać tyle fragmentów, ile potrzeba, aby utworzyć nowe, pełne bloki. Taki wynik uzyskujemy, gdy każdej danej przypiszemy objętość 1 oraz koszt (wartość) 1. Blok będzie miał pojemność równą liczbie danych, które może pomieścić. Przypisanie to pozwala na rozwiązanie ciągłego problemu pakowania, gdzie każda dana ma taką samą wartość i nie jest faworyzowana podczas wyboru. Na zakończenie wyszukiwania sprawdzamy wynik powyższego algorytmu. Jeśli okaże się, że możemy istotnie zmniejszyć liczbę bloków, przeprowadzamy reorganizację. W tym celu wczytujemy potrzebne bloki do pamięci RAM. Aby znaleźć dane do usunięcia, bierzemy część wspólną danych w bloku i zakresów zapisanych w dzienniku. Pozostałe dane sortu-

jemy i tworzymy nowe partycje (zakładamy, że możemy sortować tylko tyle danych, ile zmieści się w buforze sortującym). Ponieważ układ bloków uległ zmianie, aktualizujemy również tablicę zużycia. Stare partycje usuwamy z drzewa PB+ i dodajemy na ich miejsce nowe. Chociaż usunęliśmy dane z partycji, dziennik pozostaje niezmieniony, gdyż służy on nie tylko do określenia użytych danych, ale również dba o poprawność samego wyszukiwania. Jednakże, gdy dane są wczytywane równomiernie z całej tabeli, może się okazać, że potrafimy zmniejszyć liczbę bloków wczytując je wszystkie lub ich znaczną większość. Aby tego uniknąć, należy wprowadzić dodatkowy warunek, tak jak maksymalna liczba bloków użytych do jednorazowej reorganizacji, co pozwala kontrolować amortyzację kosztów usuwania. Początkowo wczytujemy duże liczby rekordów z nieposortowanych partycji, ale z czasem ta liczba będzie spadać, więc początkowo czas będzie duży, a później znacznie mniejszy. Biorąc na raz ustaloną liczbę bloków, zostawiamy zużyte bloki na kolejne kwerendy, co amortyzuje koszt usuwania i zapobiega nadmiernemu obciążeniu systemu oraz znaczącemu wydłużeniu czasu obsługi kwerendy.

6.7.3 Opis algorytmów

W tej sekcji szczegółowo omówimy dwa najważniejsze algorytmy systemu Lazy Adaptive Merging: wyszukiwanie 6.5 oraz reorganizację 6.6. Procedura wyszukiwania 6.5 przyjmuje na wejściu posortowany zbiór kluczy, dla których musimy zwrócić odpowiadające im rekordy. W tradycyjnym indeksie to byłaby jedyna funkcja algorytmu. W systemach częściowego indeksowania jest inaczej. Podczas procedury wyszukiwania, jako drugi główny krok, dodajemy znalezione rekordy do indeksu, jeśli wcześniej ich tam nie było. Każdy klucz może znajdować się albo w indeksie, albo w partycji. Algorytm najpierw przechodzi po każdym kluczu i sprawdza, czy jest on obecny w naszym dzienniku (linie 6-10). Jeśli nie jest, to możemy być pewni, że klucz nie znajduje się w indeksie, zatem musimy go wyszukać w zbiorze partycji. Jeśli klucz jest obecny w naszym dzienniku, oznacza to, że został on przepisany z partycji lub dodany bezpośrednio do indeksu. Po ustaleniu, które rekordy należy szukać w indeksie, w linii 12 rozpoczynamy ich poszukiwania. Należy pamiętać, że nie wszystkie klucze z dziennika znajdują się w indeksie. Możliwe, że wpis do dziennika został dodany podczas usuwania rekordu z partycji. Kolejnym krokiem jest przygotowanie listy partycji, które mogą zawierać szukane rekordy. Dzięki atrybutom każdej partycji zapisanym w drzewie PB+ możemy stworzyć taką listę bez konieczności wykonywania dodatkowego odczytu z dysku SSD (linie 14-18). Po przygotowaniu listy partycji, które mogą zawierać szukane rekordy, wykonujemy równoległy odczyt tych partycji (linie 20-26). Ponieważ partycje są posortowane wewnętrznie, wyszukiwanie rekordów po kluczu wewnątrz partycji może być wykonane za pomocą prostego wyszukiwania binarnego (linia 23). Poza tym, gdy przenosimy rekord, musimy zaktualizować to w tablicy *usage* (linia 26), gdyż bez tego nie będziemy mogli podjąć właściwej decyzji o konieczności reorganizacji. Gdy wyszukiwanie jest zakończone, następuje dodanie znalezionych w partycjach rekordów do indeksu (linie 30-32). Najpierw dodajemy dane fizycznie do indeksu, wykonując zbiorcze dodanie (linia 30), a następnie rejestrujemy w dzienniku informację określającą zakres kluczy, które właśnie dodaliśmy (linie 31-32). Na końcu procedury sprawdzamy, czy możliwe jest zmniejszenie liczby bloków dysku SSD o więcej niż parametr MT (ang. *Merge Threshold*). Jeśli tak, wykonujemy reorganizację partycji.

Pseudokod 6.6 opisuje proces reorganizacji. Najpierw musimy znaleźć kombinacje częściowo wykorzystanych bloków, aby móc zbudować z nich nową partycję. Zatem wykonujemy algorytm prostego wariantu pakowania i w tablicy *toLoad* zapisujemy bloki, które

Pseudokod 6.5: lamFind(input: Key $keys[\,]$)

```
1  Entry result[ ] := ∅
2  Entry toInsert[ ] := ∅
3  Key keysFromIndeks[ ] := ∅
4  Key keysFromPartitions[ ] := ∅
5
   // na podstawie dziennika określ, które klucze wczytujemy z partycji
6  foreach Key k ∈ keys do
7      if journalContains(k) = False then
8          keysFromPartitions := keysFromPartitions ∪ k
9      else
10         keysFromIndeks := keysFromIndeks ∪ k
11
12 result := result ∪ indexFindRange(keysFromIndeks)
13
   // znajdź partycje do wczytania na podstawie ich atrybutów
14 Partition toLoad[ ] := ∅
15 foreach Key k ∈ keysFromPartitions do
16     foreach Partition p ∈ PBTree do
17         if k ⩾ p.min AND k ⩽ p.max then
18             toLoad := toLoad ∪ p
19
   // wykonaj równolegle
20 foreach Partition p ∈ toLoad do
21     foreach Key key ∈ keysFromPartition do
22         if k ⩾ p.min AND k ⩽ p.max then
               // wyszukiwanie binarne lub tylko krok naprzód
23             Page page := pageFind(p, k) Entry e := entryFind(p, k)
24             toInsert := toInsert ∪ e
25             Block b := page.block
26             usage[b.id] := usage[b.id] + 1
27
28 result := result ∪ toInsert
29
   // wstaw nowe dane, aby powiększyć częściowy indeks
30 indexBulkloadInsert(toInsert)
31 Pair p := (min(keysFromPartition), max(keysFromPartition))
32 journalAdd(p)
33
34 if blocks.len - fractionalBPP(usage).len ⩾ MT then
35     lamReorganization()
36
37 return result
```

mamy użyć (linia 1). Następnie musimy oddzielić dane do usunięcia od tych do przepisania (linie 3-7). Możemy to wykonać dzięki dziennikowi. Jeśli klucz jest w dzienniku, oznacza to, że należy go usunąć, ponieważ został skopiowany do indeksu. W przeciwnym przypadku musimy go przepisać do nowej partycji. Ponieważ zmieniamy strukturę LAM usuwając stare bloki, zerujemy tablicę *usage* (linia 8). Po zgromadzeniu rekordów, sortujemy dane i tworzymy z nich nową partycję (linie 9-10), którą w ostatnim kroku zapisujemy na dysk (linia 11).

Pseudokod 6.6: lamReorganization()

```
   // wykonaj algorytm prostego wariantu pakowania
1  Block toLoad[ ] := fractionalBPP(usage) Entry entries[ ] := ∅
2
3  foreach Block b ∈ toLoad do
4  |  foreach Entry e ∈ b.entries do
5  |  |  if journalContains(e.key) = False then
   |  |  |  // skopiuj i zapisz do nowej partycji
6  |  |  |  entries := entries ∪ e
7  |  Usuń blok ze swojej partycji
8  |  usage[b.id] := 0
9
   // zapisz nową posortowaną partycję na dysku
10 sort(entries)
11 Partition p := partitionCreate(entries)
12 Zapisz p na dysku
```

6.7.4 Wybór Indeksu dla systemu LAM

W tej sekcji omówimy cechy, jakie musi spełniać indeks, aby mógł on wykorzystać w pełni charakterystykę systemu LAM oraz dysku SSD. W poprzednim podrozdziale omówiliśmy algorytmy wykonywane podczas indeksowania. Zauważmy, że wszystkie oprócz wyszukiwania korzystają bezpośrednio z podstawowych funkcji, jakie oferuje każda struktura danych, czyli: wstawiania pojedynczej danej, usuwania i wyszukiwania. Konstrukcja procedury powiększania indeksu pozwala na dodanie jednocześnie wielu danych, jeśli struktura danych wspiera dodawanie zbiorcze (ang. *bulkload*). Niestety nie wszystkie struktury posiadają takie algorytmy, na przykład drzewa B+ nie mają tej możliwości. Dlatego przedstawimy metodę (ang. *framework*) umożliwiającą w łatwy i efektywny sposób dodanie danych do drzewa.

Zauważmy, że system LAM dodaje rekordy w bardzo specyficzny sposób. Klucz rekordów jest unikatowy dla całego zbioru danych w tabeli. Nowe dane są dodawane bezpośrednio do indeksu za pomocą zwykłego wstawiania pojedynczej danej do struktury. Jednak większość danych nie jest dodawana w ten sposób, lecz w końcowej fazie wyszukiwania rekordów z podanego zakresu kluczy. Rezultat takiej kwerendy to zbiór posortowanych kluczy, który jest rozłączny ze zbiorem kluczy znajdującym się już w drzewie. Możemy więc stworzyć z tych danych poddrzewo i dodać je do istniejącego indeksu za pomocą zwykłego wskaźnika do pamięci tego poddrzewa.

Fakt 6.1 *Niech R_1, R_2 będą korzeniami dwóch poddrzew w uporządkowanym drzewie k-arnym. Załóżmy także, że $R_1 \prec R_2$. Niech M będzie maksymalnym kluczem w poddrzewie o korzeniu R_1. Wtedy $M < R_2.key$.*

Zatem, aby nie naruszyć struktury drzewa, musimy dodać korzeń naszego nowego poddrzewa do węzła, który posiada największy z mniejszych kluczy niż korzeń poddrzewa. Niestety, dodawanie danych w ten sposób może zaburzyć strukturę drzewa, na przykład poprzez utratę jego zbalansowania. Dlatego po każdej operacji należy sprawdzić, czy wszystkie właściwości indeksu zostały zachowane i naprawić strukturę, jeśli zajdzie taka potrzeba. Na szczęście zbalansowane struktury danych zazwyczaj posiadają wbudowane algorytmy naprawcze, które można wykorzystać.

Oczywiście struktura danych musi również posiadać pewne cechy, które umożliwią dodanie elementów w opisany sposób. Podsumowując, struktura musi spełniać następujące własności:

1. Struktura danych musi być typu drzewiastego.
2. Drzewo musi umożliwiać dodawanie danej bezpośrednio do każdego węzła, nie tylko do liści.
3. Drzewo musi posiadać algorytm naprawczy zdolny do reorganizacji i naprawy błędów wynikających z dodawania zbiorczego, na przykład ponowne zbalansowanie drzewa.
4. Metadane wewnętrzne powinny ulegać zmianie tylko na podstawie dodanych rekordów, lub zmiana ta powinna dotyczyć tylko węzłów znajdujących się na ścieżce od korzenia do dodanego poddrzewa.

Pierwsze ograniczenie wynika z konstrukcji algorytmu, który polega na podpinaniu poddrzewa. Drugie ograniczenie jest konieczne, ponieważ bez możliwości wstawienia całego poddrzewa poprzez wskaźnik do wybranego węzła, nie możemy efektywnie integrować nowych danych. Trzecie ograniczenie jest wymagane do naprawy struktury drzewa, której konkretna forma i własności mogą być nieznane. Nasz sposób wstawiania gwarantuje zachowanie porządku kluczy, ale nie zawsze zachowanie strukturalnych własności drzewa, co wymaga możliwości jego naprawy. Ostatnie ograniczenie wprowadzono, aby zwiększyć efektywność algorytmu. Jeśli zmiany w drzewie wymagałyby interwencji poza ścieżką odwiedzanych węzłów, zwiększyłoby to liczbę operacji, co obniżyłoby wydajność algorytmu. Przedstawiony algorytm jest dostosowany do pracy z pamięciami blokowymi, takimi jak dyski SSD, ponieważ nie wymaga wykonywania osobnych operacji dla każdej pojedynczej danej. Zamiast tego tworzy poddrzewo i zapisuje je na dysku w sposób sekwencyjny, co minimalizuje czas potrzebny na zapis. Jednak proces wstawiania poddrzewa trwa porównywalnie długo, jak wstawienie pojedynczego klucza. Koszt naprawy struktury drzewa, którego używamy, również jest ważnym czynnikiem. Większość algorytmów stabilizujących drzewa przeprowadza reorganizację tylko na pojedynczej ścieżce od węzła, który zaburzył własności struktury, do korzenia. Koszt takiego algorytmu jest logarytmiczny, jednak jego wykonanie na dyskach SSD może powodować dwa problemy:

1. Zmiana węzła powoduje zmianę jego fizycznego położenia w pamięci.
2. Brak pamięci na dodanie klucza bezpośrednio do węzła.

Pierwszy problem wydaje się być bardzo poważny. Zmiana jakiejkolwiek wartości

spowoduje wywołanie operacji wymazania przed ponownym zapisem. Aby przyspieszyć ten proces, często zmienia się położenie nowej strony. Jednak wtedy wszystkie wskaźniki będą posiadały niepoprawną wartość. Aby tego uniknąć, wystarczy wprowadzić mapowanie logiczno-fizyczne na blokach, które posiada między innymi FTL [91]. Dzięki temu zmiany są dla nas przeźroczyste, ponieważ odwołujemy się do adresu wirtualnego, który się nie zmienia. Obecnie każdy dysk SSD posiada wbudowany algorytm FTL.

Drugi problem jest nieco trudniejszy do rozwiązania. Najlepiej zarezerwować w każdym węźle kilka bajtów na dodatkowe wskaźniki (np. 2-3), wstawione w ten sposób. Jeśli jednak nadal brakuje pamięci na kolejny klucz, najlepiej wczytać tę część drzewa do RAM i wymusić reorganizację tego węzła.

Pamiętajmy, że powyższe ograniczenia są spowodowane optymalizacją samego dodawania dużych zbiorów danych do indeksu podczas przepisywania ich z partycji do indeksu. Z systemem LAM może współpracować dowolny indeks. Jednak gdy nie posiada wyżej wymienionych cech, czas dodawania do indeksu znacząco się wydłuży. Zamiast wykorzystania opisanego sposobu można również użyć struktur, które buforują dane i posiadają wsparcie dla operacji dodawania zbiorczego (ang. *bulkload*). Przykładem takiego drzewa jest struktura FD. Ze względu na dużą efektywność dodawania i usuwania rekordów oraz brak potrzeby modyfikacji wbudowanych operacji w celu przyspieszenia dodawania zbiorczego, struktura FD jest domyślnym indeksem systemu LAM.

6.7.5 Eksperymenty

		Pojemność		Prędkość losowego		Prędkość sekwencyjnego	
Model	Interfejs	Strony	Bloku	Odczytu	Zapisu	Odczytu	Zapisu
Samsung 840	SATA	8 KB	512 KB	390 MB/s	182 MB/s	585 MB/s	535 MB/s
Toshiba VX500	SATA	4 KB	256 KB	379 MB/s	267 MB/s	568 MB/s	525 MB/s
Intel DCP4511	NVMe	4 KB	256 KB	1,2 GB/s	240 MB/s	2 GB/s	1,47 GB/s

Tabela 6.12: Wybrane modele dysków SSD

W tej części rozdziału przedstawimy i przeanalizujemy eksperymenty wykonane za pomocą symulatora SIPS, który został dokładnie opisany w rozdziale 4. Jako indeks systemu LAM wybrano drzewo FD [27], ponieważ jest dobrze zoptymalizowane pod dyski SSD. Parametr MT ustawiono na 400 bloków. Dodatkowo, aby zminimalizować narzut na reorganizację, bierzemy pod uwagę tylko te bloki, które posiadają mniej niż 25% danych jeszcze nie przepisanych do indeksu. Dzięki temu unikniemy sytuacji, w której algorytm połączy ze sobą wszystkie bloki w celu zmniejszenia ich liczby o 400. Tabela 6.12 zawiera szczegółowe parametry różnych modeli dysków SSD, które są zawsze używane do testów w tej pracy. Przypomnijmy, że Samsung 840 charakteryzuje się bardzo dużą pojemnością strony jak i bloku, ponieważ pojemność strony to aż 8 KB, w przeciwieństwie do pozostałych modeli o standardowej pojemności 4 KB. Starsze modele z interfejsem SATA posiadają podobne prędkości sekwencyjnych operacji. Różnią się głównie prędkością losowego zapisu, przy czym model Samsunga jest gorszy w tej kwestii od modelu Toshiba aż o 80 MB/s. Najlepszym dyskiem w tym zestawieniu jest Intel DCP 4511. Ten model

charakteryzuje się ogromną prędkością sekwencyjnych operacji (ponad 1 GB/s) oraz bardzo szybkim odczytem losowym (1,2 GB/s). Największą wadą tego modelu jest bardzo wolny zapis losowy na poziomie tylko 240 MB/s. Eksperymenty zostały przeprowadzone na dwóch tabelach: Sklep i Klient.

Tworzenie pełnego indeksu

	Samsung 840		**Toshiba VX500**		**Intel DCP4511**	
	AM	**LAM**	**AM**	**LAM**	**AM**	**LAM**
SERIA I (Sklep, 1%)	141 s	71 s	178 s	78 s	192 s	24 s
SERIA II (Sklep, 5%)	88 s	68 s	105 s	76 s	70 s	23 s
SERIA III (Klient, 1%)	642 s	537 s	720 s	570 s	431 s	176 s
SERIA IV (Klient, 5%)	593 s	532 s	652 s	566 s	320 s	174 s

Tabela 6.13: Całkowity czas wykonania zestawu kwerend

	Samsung 840		**Toshiba VX500**		**Intel DCP4511**	
	AM	**LAM**	**AM**	**LAM**	**AM**	**LAM**
SERIA I (Sklep, 1%)	17 GB	10 GB	19 GB	12 GB	19 GB	12 GB
SERIA II (Sklep, 5%)	15 GB	10 GB	17 GB	12 GB	17 GB	12 GB
SERIA III (Klient, 1%)	125 GB	82 GB	130 GB	82 GB	130 GB	78 GB
SERIA IV (Klient, 5%)	123 GB	82 GB	120 GB	78 GB	128 GB	78 GB

Tabela 6.14: Zużycie pamięci (liczba nadpisanych i usuniętych gigabajtów)

Tworzenie pełnego indeksu to skomplikowany i często długi proces. Porównanie sumarycznych czasów nie jest wystarczające, aby zrozumieć charakterystykę systemów oraz ich słabe i mocne strony. Z tego względu, oprócz sumarycznych statystyk takich jak czas i zużycie pamięci, porównujemy również czas każdej kwerendy. Ta seria eksperymentów ma na celu analizę systemów Adaptive Merging i Lazy Adaptive Merging podczas procesu tworzenia indeksu. Polega ona na wykonaniu samych kwerend wyszukujących o ustalonej selektywności, aż do momentu gdy indeks nie zostanie w pełni utworzony. Dzięki temu będziemy mogli przeanalizować w pełni różnice i podobieństwa obu systemów. Zatem startujemy z bazą danych zawierającą 10 mln rekordów, które nie są w żaden sposób posortowane. Wykonujemy kolejne kwerendy z wyszukiwaniem losowym o podanej selektywności, w czasie których dodajemy odczytane rekordy do indeksu. Eksperyment kończy się, gdy indeks będzie w pełni utworzony.

W [139] pokazano bardzo dobry sposób na prowadzenie obserwacji takiego procesu. Sposób obserwacji został dokładnie opisany w rozdziale 4. Przypomnijmy jednak główne

zasady. Autorzy wyznaczyli cztery fazy, które można wyróżnić w każdym algorytmie indeksowania.

1. **Sadzenie (ang. *planting*)** - Pierwsza faza sadzenia polega na inicjalizacji całego procesu. Początkowo trzeba skopiować tabele, wykonując przy tym pewne operacje potrzebne do rozpoczęcia procesu. Pierwsze kroki tego typu algorytmów zazwyczaj potrzebują więcej czasu niż prosty skan całej tabeli. Indeks zawiera na tyle mało elementów, że prawdopodobieństwo jego użycia jest niewielkie. Dlatego musimy wykonać drogie skanowanie oraz dodać kilka operacji potrzebnych na powiększenie indeksu. Podsumowując, pierwsza faza trwa dopóki czas obsługi kwerendy jest większy niż czas wykonania zwykłego, prostego skanu tabeli.

2. **Pielęgnacja (ang. *nursing*)** - Druga faza zaczyna się, gdy czas obsługi kwerendy jest mniejszy niż czas potrzebny na prosty skan, ale nadal większy niż w przypadku użycia pełnego indeksowania. W tej fazie zaczynamy korzystać z posortowanych partii danych, jednocześnie obniżając koszty dodatkowych operacji, ponieważ dodajemy coraz mniej danych do indeksu.

3. **Wzrastanie (ang. *growing*)** - Trzecia faza rozpoczyna się, gdy natrafiamy na zapytanie, które możemy obsłużyć w minimalnym czasie, czyli takim samym jak przy użyciu pełnego indeksu. W tym okresie indeks jest na tyle duży, że prawdopodobieństwo jego przydatności jest wysokie. W prawie każdej kwerendzie częściowo z niego korzystamy, jednak poza pojedynczymi przypadkami nie jesteśmy w stanie dorównać wyszukiwaniu w posortowanym zbiorze danych.

4. **Zbiory (ang. *harvesting*)** - Ostatnia faza zbiorów zaczyna się, gdy indeks jest w pełni stworzony, a zatem nie mamy już czasowych narzutów na jego tworzenie. Czas na obsługę zapytania jest taki sam jak przy użyciu pełnego indeksu.

Aby zbadać wszystkie zmienne, które mogą wpłynąć na charakterystykę wyników, przeprowadziliśmy cztery serie testów. Każda z nich wykonywała wyszukiwania o wzorcu losowym, który najlepiej oddaje naturę hurtowni danych. Taki serwer ma tak wielu użytkowników, że mimo iż każdy z nich tworzy zapytania według jakiegoś wzorca, to łącząc wszystkie kwerendy w ciąg, zapytania wyglądają jak przypadkowe (losowe).

1. SERIA I - Tworzymy pełny indeks na tabeli Sklep, używamy do tego wyszukiwań z zakresu kluczy o selektywności 1%.

2. SERIA II - Tworzymy pełny indeks na tabeli Sklep, używamy do tego wyszukiwań z zakresu kluczy o selektywności 5%.

3. SERIA III - Tworzymy pełny indeks na tabeli Klient, używamy do tego wyszukiwań z zakresu kluczy o selektywności 1%.

4. SERIA IV - Tworzymy pełny indeks na tabeli Klient, używamy do tego wyszukiwań z zakresu kluczy o selektywności 5%.

Tabela 6.13 przedstawia dokładny sumaryczny czas tworzenia pełnego indeksu w każdej z serii testów, wykorzystując trzy wybrane modele dysków SSD. Dodatkowo, tabela 6.14 zawiera informacje o sumarycznym zużyciu pamięci dysku SSD, czyli liczbie gigabajtów nadpisaną i usuniętą z dysku podczas procesu tworzenia pełnego indeksu. Jak możemy zauważyć, większa selektywność skraca czas tworzenia pełnego indeksu w systemie Adaptive Merging. Interesujące jest, że selektywność nie wpływa na sumaryczny

czas działania systemu LAM, co wynika z większej liczby danych przekazywanych z partycji do indeksu, co z kolei prowadzi do intensywniejszej reorganizacji w systemie AM. Mniejsza liczba takich procesów oznacza mniej operacji kasowania (ang. *erase*) na dysku SSD, co skutkuje krótszym czasem tworzenia indeksu. System LAM potrafi buforować dane i opóźniać reorganizację, co oznacza, że jej wykonanie po 2 czy 200 kwerendach nie wpływa na sumaryczny czas. Potwierdzeniem tej hipotezy jest również liczba zużytych i usuniętych bajtów z tabeli 6.14. Jak widać, zużycie jest takie samo dla obu selektywności, co wskazuje na tę samą liczbę wykonanych reorganizacji, i dlatego nie wpływa to na efektywność systemu LAM. Z tego samego powodu największe różnice pomiędzy systemami AM i LAM zaobserwowano na dysku Intel, który charakteryzuje się bardzo wolnymi operacjami kasowania bloków. Redukcja liczby takich operacji w systemie LAM znacząco zwiększa efektywność tworzenia indeksu. Zauważmy również, że rozmiar rekordu wpływa na szybkość działania obu systemów. Większy rekord zajmuje na dysku więcej miejsca, przez co operacje na takiej bazie trwają dłużej. Testy przeprowadzone na tabeli Klient pokazują mniejsze różnice w działaniu algorytmów AM i LAM, co wynika z tego, że LAM używa bufora oraz parametru MT o stałych wielkościach, niezależnych od rozmiaru rekordu czy liczby rekordów w bazie. Im większy rekord, tym więcej bloków używamy do zapełnienia bazy oraz więcej bloków przepisujemy z partycji do indeksu, co wymaga częstszej reorganizacji i spowalnia proces.

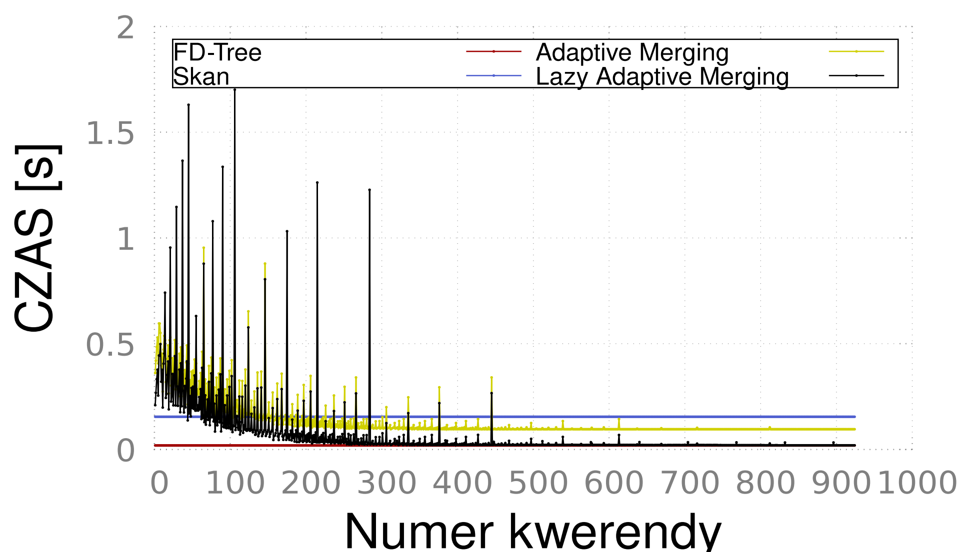

Rysunek 6.36: Czas tworzenia pełnego indeksu
Selektywność 1%
Dysk: Samsung 840
Tabela: Sklep (113 B)

Przeanalizujmy teraz wyniki serii I, przedstawione na rysunkach 6.36 i 6.37 dla odpowiednio dysków Samsung i Intel. Już na wstępie obserwujemy, że system AM na modelu Samsunga nie osiągnął fazy 3 (wzrastania); czas wykonania kwerendy był zawsze dłuższy niż czas wyszukiwania w pełnym indeksie. Dzieje się tak, ponieważ każda kwerenda wczytująca dane z partycji musi natychmiast przepisać je w inne miejsce, generując kosztowne operacje kasowania bloków. System LAM osiąga fazę 2 już w 51 kwerendzie, a fazę 3 osiągnął w kwerendzie 182. Mimo to, pojedyncze kwerendy mogą trwać znacznie dłużej niż proste wyszukiwanie całej bazy, głównie z dwóch powodów. Pierwszym z nich

jest zestaw kluczy do wczytania, gdzie często znaczną część rekordów musimy wczytać z partycji i przepisać do indeksu, co jest czasochłonne. Ponieważ oba systemy używają tych samych wylosowanych kwerend, sytuację tę możemy obserwować na omawianych rysunkach. W obu przypadkach, AM i LAM, wykonanie kwerendy może trwać dłużej niż zwykle. Druga sytuacja, kiedy kwerenda może trwać dłużej, to konieczność wykonania reorganizacji. System LAM nie usuwa danych natychmiastowo, lecz czeka, aż będzie mógł znacząco zredukować liczbę bloków. Gdy taka chwila nadejdzie, czas wykonania kwerendy jest znacznie dłuższy niż zazwyczaj.

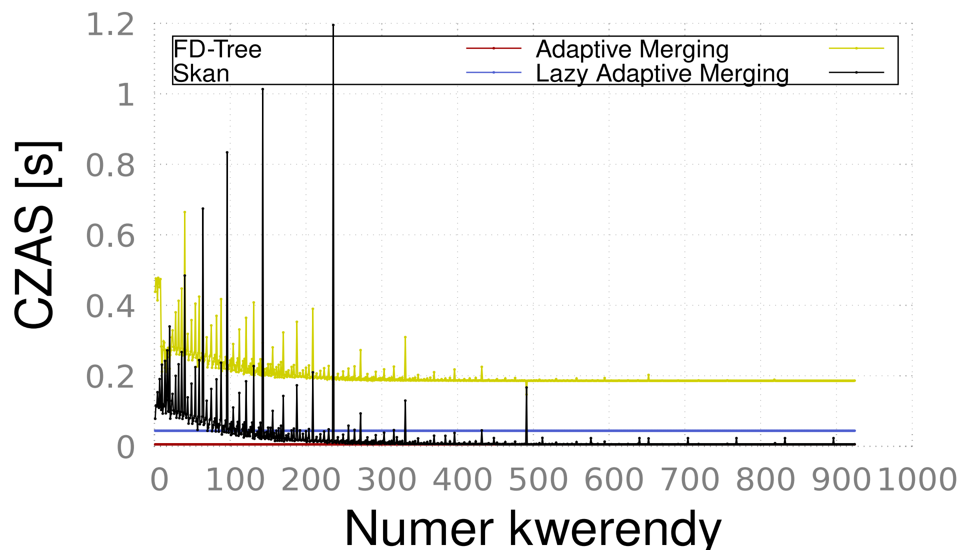

Rysunek 6.37: Czas tworzenia pełnego indeksu
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

Analizując wyniki eksperymentów na dysku Intel DCP4511, zaobserwować można, że system AM nie osiągnął nigdy fazy 2 (pielęgnacji). Czas wykonania kwerendy był zawsze dłuższy niż czas pełnego skanowania tabeli. Wynika to z charakterystyki tego dysku, który posiada bardzo szybki odczyt sekwencyjny, wykorzystywany do skanowania tabeli, oraz bardzo wolne kasowanie bloków, wymagane podczas reorganizacji danych w strukturze AM. System LAM prezentuje całkiem inną sytuację. Osiąga fazę 2 już w 78 kwerendzie, a fazę 3 w 158 kwerendzie. Jednakże nadal pojawiają się pojedyncze kwerendy trwające znacznie dłużej niż prosty odczyt całej bazy. Powody pojawienia się takich opóźnień są identyczne jak w przypadku testów przeprowadzanych na dysku Samsung. Mogą wynikać z konieczności wczytania znacznej części rekordów z partycji lub z momentów reorganizacji, które są niezbędne do optymalizacji struktury indeksu.

W niniejszej sekcji analizujemy wyniki serii eksperymentalnej I, która wykorzystuje dyski SSD o różnych charakterystykach. Na przykładach modeli Samsung i Intel obserwujemy, że czas przejścia do fazy drugiej jest zależny od charakterystyki konkretnego dysku SSD. Im wolniejsza jest operacja kasowania bloków przy jednocześnie szybkim odczycie sekwencyjnym, tym dłuższa jest faza pierwsza. W początkowych kwerendach, gdzie musimy wczytać znaczącą część danych z partycji, zwiększa się liczba przepisywanych rekordów i koniecznych reorganizacji struktur danych. Szybkość kasowania i zapisu ma

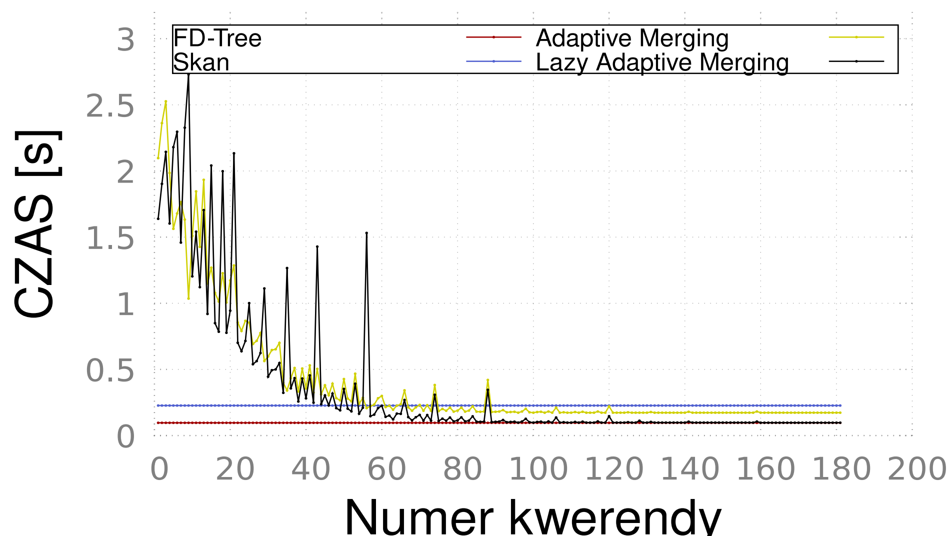

Rysunek 6.38: Czas tworzenia pełnego indeksu
Selektywność 5%
Dysk: Samsung 840
Tabela: Sklep (113 B)

więc kluczowe znaczenie dla długości trwania fazy pierwszej. Warto odnotować, że na obu modelach dysków, system LAM osiągnął fazę trzecią w podobnym czasie, co świadczy o jego stabilności i efektywności niezależnie od hardware'u.

Również w serii II, która korzysta z tabeli Sklep o rekordach o wielkości 113 B i selektywności 5%, obserwujemy zjawisko skrócenia czasu potrzebnego na zbudowanie pełnego indeksu. Rysunki 6.38 i 6.39 przedstawiają wyniki dla modeli Samsung 840 i Intel DCP4511. Przy wyższej selektywności, liczba kwerend potrzebna do zbudowania pełnego indeksu zmniejsza się z ponad 900 (w serii I) do zaledwie 180 w tej serii. Zgodnie z oczekiwaniami, większa ilość danych wczytywanych w ramach pojedynczej kwerendy przyspiesza proces indeksowania. W przypadku modelu Samsung 840 faza 2 (pielęgnacji) została osiągnięta już po 51 kwerendach, stanowiących 5,5% wszystkich kwerend, a w przypadku modelu Intel DCP4511, faza ta została osiągnięta po 41 kwerendach, co stanowi 22,6% wszystkich kwerend. Warto zwrócić uwagę, że system LAM osiągnął fazę 3 szybko po uzyskaniu fazy 2, co świadczy o skuteczności częściowego indeksowania w tym systemie, podczas gdy system AM w tych warunkach nie osiągnął fazy 3.

Zauważyć warto, że charakterystyka dysku Intel DCP4511, z jego szybkim odczytem sekwencyjnym i wolnym kasowaniem bloków, ponownie wpłynęła na wyniki - każda kwerenda trwała dłużej niż czas pełnego skanowania bazy danych. To pokazuje, jak znaczący wpływ na efektywność systemu indeksowania ma odpowiednie dobranie sprzętu do charakterystyki zadania.

Podsumowując, wyniki tej serii pokazują, że zwiększona selektywność przyspiesza proces tworzenia pełnego indeksu, ale jednocześnie wydłuża czas trwania fazy pierwszej w systemie LAM. Jest to spowodowane większą ilością danych do przepisania i częstszymi reorganizacjami w początkowej fazie indeksowania.

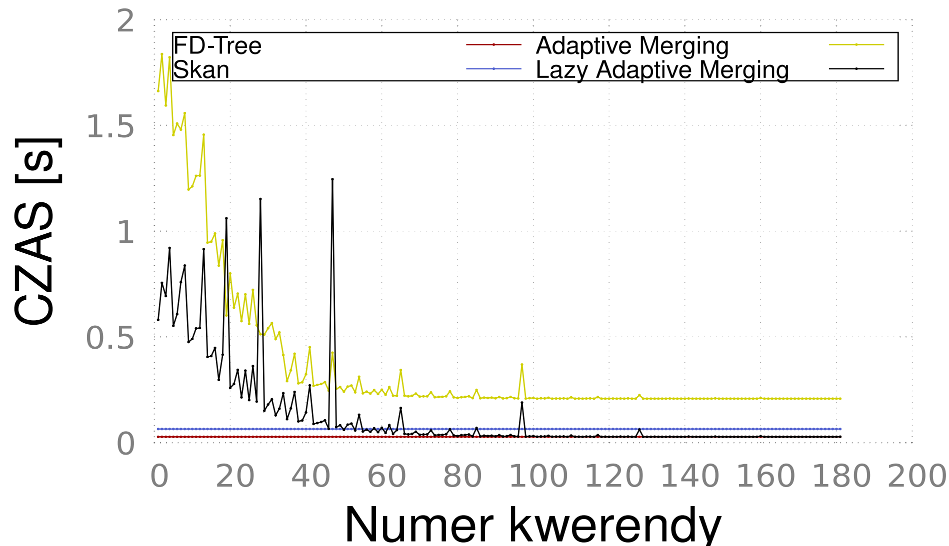

Rysunek 6.39: Czas tworzenia pełnego indeksu
Selektywność 5%
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

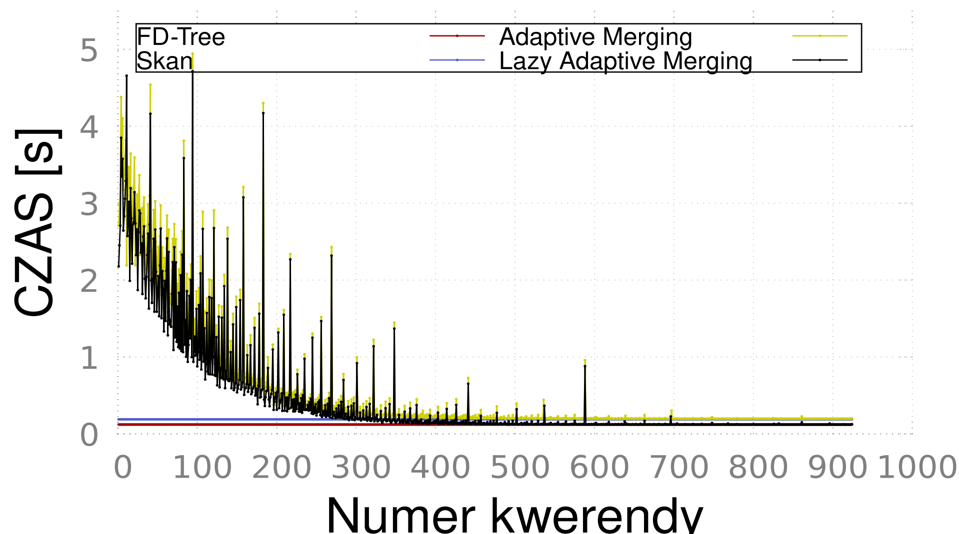

Rysunek 6.40: Czas tworzenia pełnego indeksu
Selektywność 1%
Dysk: Samsung 840
Tabela: Klient (719 B)

Seria III była realizowana na tabeli Klient, w której rozmiar rekordu wynosił aż 719 B. Selektywność wyszukiwań została ustawiona na 1% wielkości całej bazy danych, wynoszącej w każdej serii 10 milionów rekordów. Celem tej serii było zbadanie wpływu rozmiaru rekordu na proces tworzenia indeksu przy wykorzystaniu algorytmów AM i LAM. Rysunki 6.40 oraz 6.41 przedstawiają wyniki tej serii na modelach Samsung 840 i Intel DCP4511. Chociaż wielkość rekordu nie zmienia liczby kwerend, które musimy wykonać, aby zbudować pełny indeks, to jednak ma ona wpływ na czas trwania faz 1 i 2

procesu indeksowania.

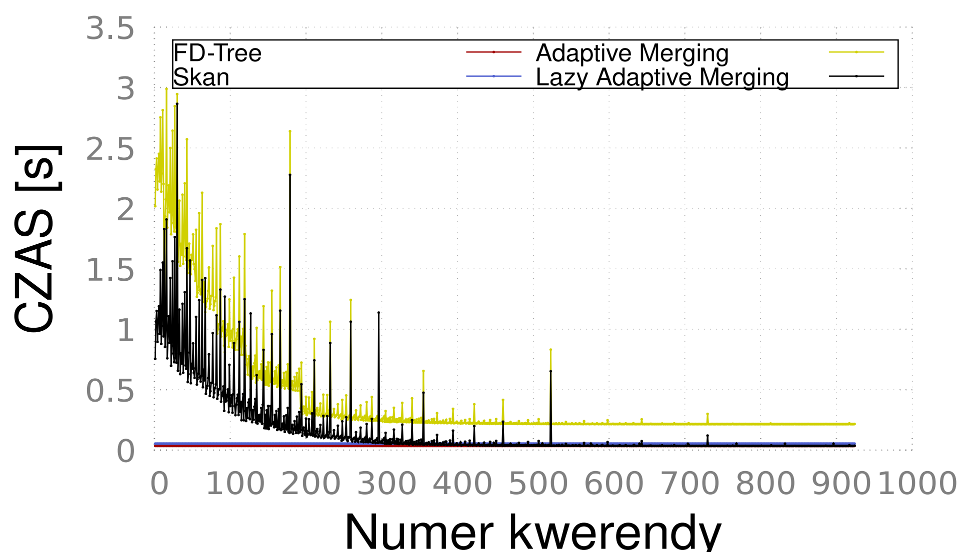

Rysunek 6.41: Czas tworzenia pełnego indeksu
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

Podobnie jak w serii II, czas potrzebny na osiągnięcie fazy 2 w obu systemach AM i LAM znacząco się wydłużył. Wynika to z asymetrii dysków SSD, gdzie odczyt danych jest znacznie szybszy niż ich zapis. Zatem, im większe rekordy, tym większa dysproporcja między czasem odczytu a zapisu. Ponadto, system LAM tworzy partycje o ustalonych wielkościach, co oznacza, że większe rekordy skutkują większą liczbą partycji. To z kolei prowadzi do częstszych reorganizacji podczas całego procesu. Przepisywanie danych trwa najdłużej w początkowej fazie, gdyż najwięcej danych musimy wczytać ze zbioru partycji i przepisać do indeksu, a w razie potrzeby przeprowadzić reorganizacje na zbiorze partycji. Dlatego faza 1 trwa znacznie dłużej niż w serii I.

Podsumowując, rozmiar rekordu nie wpływa na liczbę kwerend potrzebną do stworzenia indeksu, ale wydłuża czas trwania fazy 1, gdzie czas potrzebny na obsługę kwerendy jest znacznie dłuższy niż czas zwykłego skanowania nieposortowanych zbiorów danych. Seria IV zawierała podobne wyniki co serie II i III, dlatego zdecydowano się pominąć rysunki z tej serii w publikacji. Ze względu na dużą selektywność, liczba potrzebnych kwerend do zbudowania indeksu zmalała, tak jak w serii II. Jednocześnie, zwiększona selektywność oraz rozmiar rekordu spowodowały, że faza 1 trwała aż 50% czasu całego procesu zarówno na systemie LAM przy użyciu modeli Samsung 840 jak i Intel. Algorytm AM, podobnie jak we wcześniejszych seriach, nie osiągnął fazy 3 na dysku Samsung ani fazy 2 na pamięci Intel. Analizując omówione eksperymenty można stwierdzić, że nowy system LAM radzi sobie znacznie lepiej od oryginalnego algorytmu AM na dyskach SSD, nie tylko szybciej tworząc indeks (nawet ośmiokrotnie szybciej), ale również usuwając mniej bloków z dysku SSD i wykonując pojedyncze kwerendy szybciej. We wszystkich seriach fazy 1, 2 i 3 trwały znacznie krócej niż w systemie AM, co oznacza, że użytkownik szybciej zobaczy efekty naszego procesu oraz znaczne przyspieszenie wykonywania kolejnych zapytań.

Rozszerzony zestaw kwerend

W poprzedniej sekcji zbadaliśmy sam proces tworzenia częściowego indeksu. Zazwyczaj do bazy trafiają różne kwerendy, a nie tylko zapytania wyszukujące rekordy po kluczu. Dlatego w tej części rozdziału przeanalizujemy wyniki otrzymane podczas wykonywania kwerend z zestawu rozszerzonego. Charakterystyka wszystkich czterech zestawów opisana w rozdziale 4 jest następująca:

1. ZR_{A} - 100 serii, każda seria zawiera operacje dodawania 5 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 5 rekordów,
2. ZR_{B} - 5 serii, każda seria zawiera operacje dodawania 100 000 rekordów, 5 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 100 000 rekordów,
3. ZR_{C} - 10 serii, każda seria zawiera operacje dodawania 10 000 000 rekordów, 20 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 1 000 000 rekordów,
4. ZR_{D} - 10 serii, każda seria zawiera operacje dodawania 1 000 000 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 10 000 rekordów.

Do testów wybrano ponownie tabele Sklep i Klient, wykonując każdy zestaw testów dwa razy — raz z selektywnością na poziomie 1%, a drugi raz z selektywnością 5%. Dyski Toshiba i Samsung ponownie uzyskały podobne wyniki, charakteryzując się tą samą charakterystyką.

W pierwszej serii testów (Sklep, 1% selektywności) na obu dyskach, system LAM osiągał zawsze lepsze czasy niż klasyczny algorytm AM. Jest to widoczne na wykresach 6.42 oraz 6.43. Różnice w zestawach ZR_B, ZR_C oraz ZR_D są znikome, co wynika z kilku czynników. Po pierwsze, wstawianie danych w systemie LAM odbywa się poprzez bezpośrednie dodanie nowych danych do indeksu.

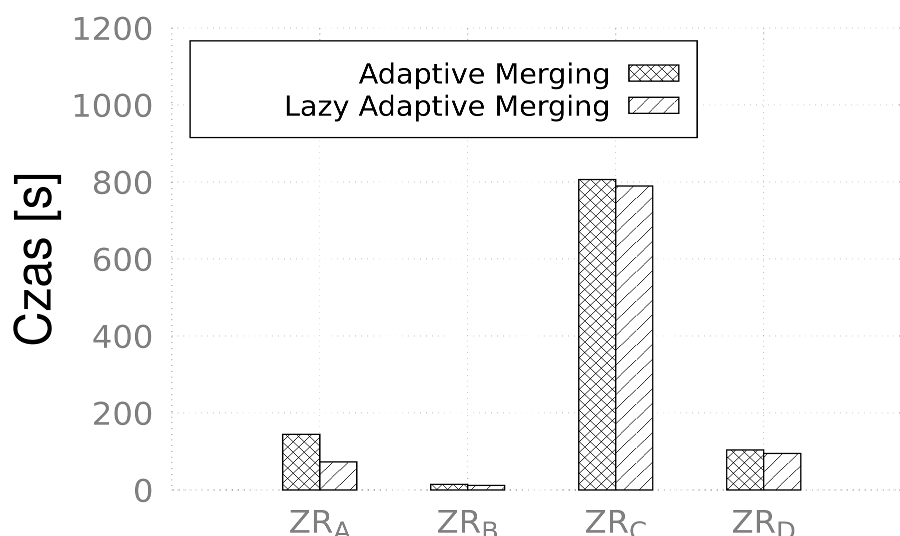

Rysunek 6.42: Czas zestawów kwerend
Selektywność 1%
Dysk: Samsung 840
Tabela: Sklep (113 B)

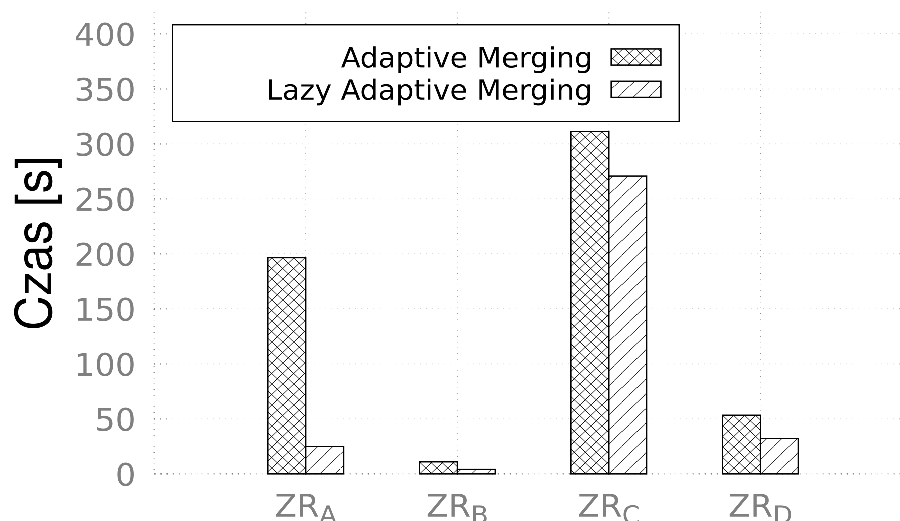

Rysunek 6.43: Czas zestawów kwerend
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

W systemie AM buforowanie danych i ich zapis bezpośrednio do posortowanej części indeksu tworzy nową partycję. Oznacza to, że dodawanie elementów jest dość jednolite i nie wprowadza większych zmian w procesie tworzenia indeksu częściowego. Drugą przyczyną jest zbyt mała liczba wyszukiwań przeprowadzanych w tych zestawach. Proces zwykle wymaga około 800 kwerend wyszukujących, a tutaj mamy odpowiednio 25, 200 i 100 kwerend, co oznacza, że jesteśmy w początkowej fazie tworzenia indeksu i nie można jeszcze obserwować znacznej przewagi LAM nad AM. Po trzecie, oba algorytmy uzyskują bardzo podobne czasy w pierwszej fazie. Dopiero w kolejnych fazach algorytm LAM znacząco przewyższa klasyczne podejście. Jednak warto zauważyć, że zestaw ZR_A, który zawiera aż 1000 wyszukiwań i tym samym tworzy pełny indeks, pokazuje ogromną przewagę LAM nad AM, szczególnie w testach na dysku Intela, gdzie algorytm LAM osiąga wyniki sześciokrotnie lepsze niż oryginalny algorytm.

Sytuacja w pozostałych seriach nie zmieniła się. Zwiększenie selektywności z 1% do 5% praktycznie nie wpłynęło na różnice w zestawach nastawionych na modyfikacje tabeli. Ponadto, wyższa selektywność zmniejszyła czas potrzebny algorytmowi AM na wykonanie wszystkich kwerend ZR_A. Jest to oczekiwany wynik, co można zaobserwować w tabeli 6.13, gdzie czas tworzenia częściowego indeksu dla algorytmu LAM pozostaje niezmienny, a dla systemu AM znacząco się zmniejsza.

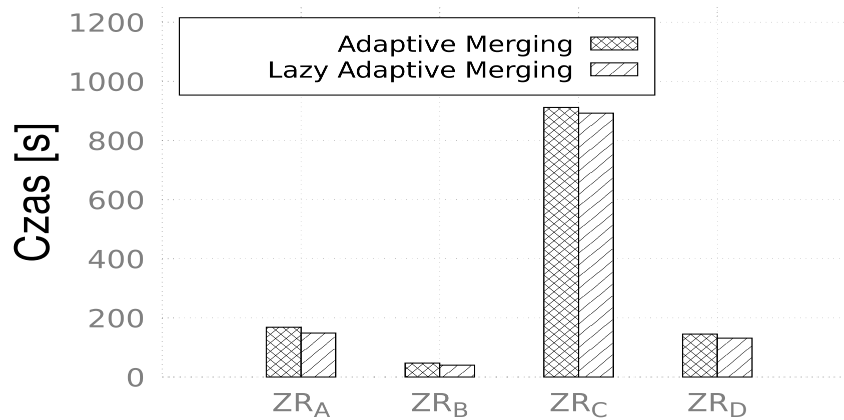

Rysunek 6.44: Czas zestawów kwerend
Selektywność 5%
Dysk: Samsung 840
Tabela: Sklep (113 B)

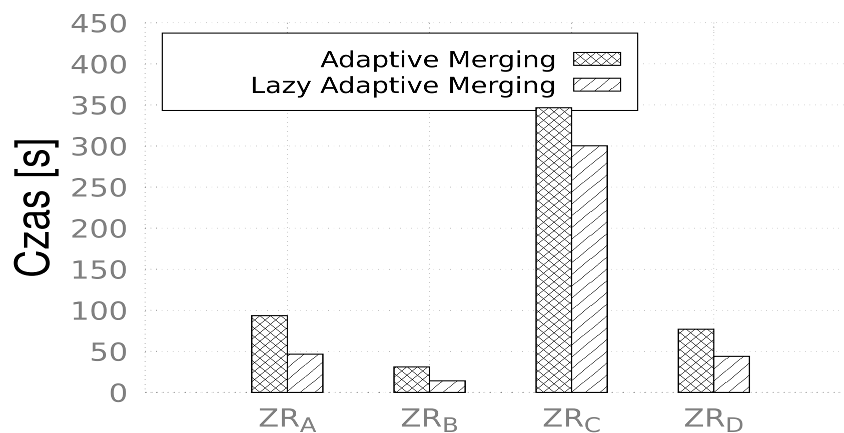

Rysunek 6.45: Czas zestawów kwerend
Selektywność 5%
Dysk: Intel DCP4511
Tabela: Sklep (113 B)

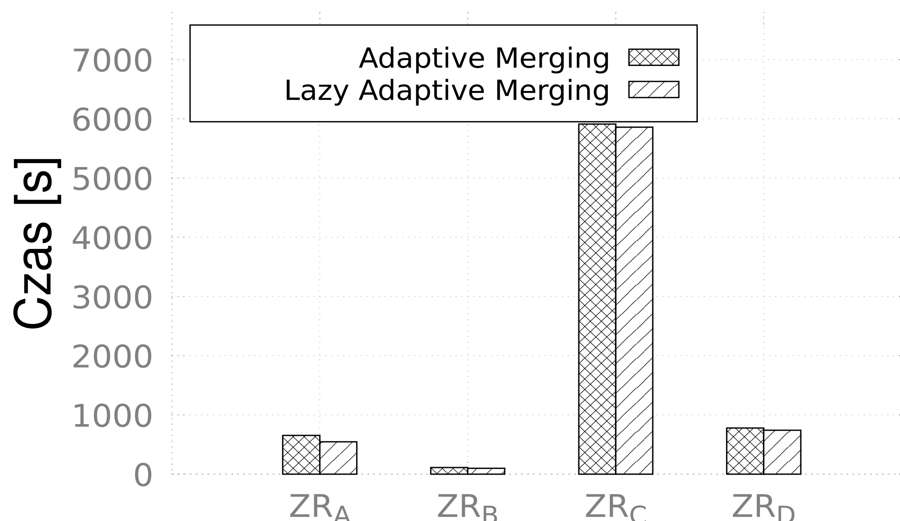

Rysunek 6.46: Czas zestawów kwerend
Selektywność 1%
Dysk: Samsung 840
Tabela: Klient (719 B)

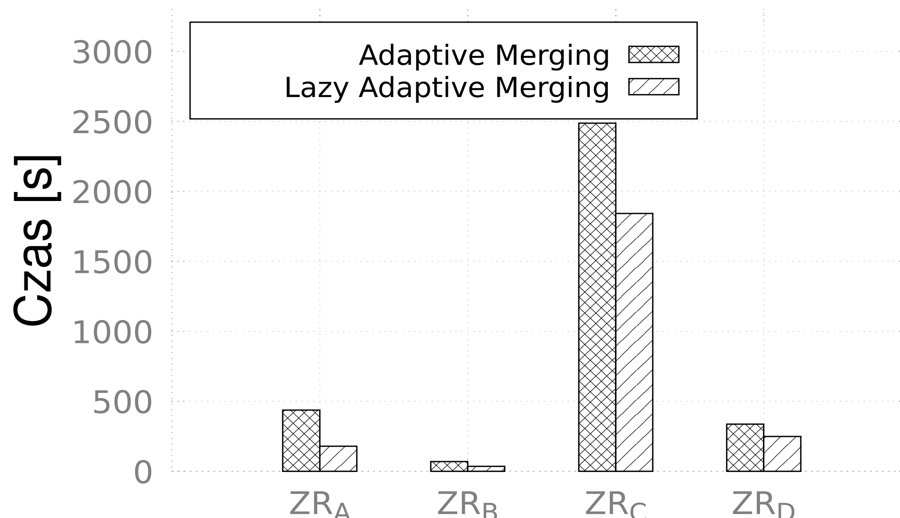

Rysunek 6.47: Czas zestawów kwerend
Selektywność 1%
Dysk: Intel DCP4511
Tabela: Klient (719 B)

Podsumowując, obie serie eksperymentów wykazały ogromny przyrost wydajności obsługi kwerend za pomocą nowego systemu Lazy Adaptive Merging (LAM) w porównaniu do pierwotnego algorytmu Adaptive Merging. Dzięki wprowadzonej mechanice leniwego usuwania, LAM nie tylko osiąga lepsze czasy obsługi zestawu kwerend, ale także nadpisuje i usuwa o wiele mniej pamięci, co przyczynia się do dłuższej żywotności dysku SSD. Kolejną ważną cechą nowego systemu jest elastyczność w amortyzacji czasu potrzebnego

na budowanie indeksu. W systemach częściowego indeksowania najwięcej czasu zajmuje samo przepisywanie danych do indeksu. Gdy takie systemy działają na dyskach SSD, dochodzi również czas obsługi kasowania bloków, aby przygotować pamięć na nowe dane. Dzięki parametrowi MT oraz dodatkowym parametrom takim jak minimalne zużycie bloku czy maksymalna liczba bloków reorganizowanych jednocześnie, możliwa jest precyzyjna kontrola mechanizmu łączenia bloków. Dzięki temu możemy rozłożyć w czasie koszt reorganizacji tak, aby użytkownik końcowy nie odczuwał znacznego spadku wydajności podczas niektórych zapytań.

Algorytmy indeksowania na pamięci PCM

W tym rozdziale omówimy metody indeksowania danych, aktualnie stosowane struktury oraz algorytmy wykorzystywane w silnikach baz danych na pamięci PCM. Przedstawimy także nowy system do tworzenia częściowego indeksu na tej pamięci [5], który został specjalnie dostosowany do charakterystyki pamięci PCM. Ogólny koncept każdego rodzaju indeksowania został omówiony w rozdziale **2**. W tym rozdziale skupimy się na dostosowaniu algorytmów indeksujących do specyfiki nowego typu pamięci zmiennofazowej PCM.

Charakterystyka pamięci PCM została przedstawiona w rozdziale **3**. Przypomnijmy jednak główne cechy tej pamięci: Pamięć zmiennofazowa PCM (ang. *Phase Change Memory*) [125] jest pamięcią nieulotną, opartą na nośniku krystalicznym. Rozwój tego rodzaju pamięci prowadzi głównie firma Intel [128]. Podobnie jak pamięć flash, PCM zachowuje dane po odłączeniu zasilania. Jednak jest znacznie bardziej wydajna. Prędkości zapisu i odczytu informacji w pamięci PCM są średnio kilkadziesiąt razy wyższe niż w przypadku NAND. Dodatkowo, podczas zapisu danych nie ma konieczności wymazywania całego bloku komórek. Dzięki temu pamięć PCM może być wykorzystywana nie tylko jako pamięć masowa, ale także jako pamięć operacyjna komputera [129], [130], [131]. Pamięć PCM jest także bajtowo adresowalna, podobnie jak pamięć RAM, i dzielona na strony o wielkości 64 B. Typowo kość PCM składa się z 4 lub 8 banków pamięci, choć obecnie preferowane jest wykorzystanie 8 banków, co umożliwia odczyt całej strony pamięci PCM (64 B) poprzez odczytanie z każdego banku pojedynczego słowa maszynowego w architekturze 64-bitowej, która dominuje obecnie w komputerach osobistych i serwerach. Niestety, podobnie jak w przypadku pamięci flash, mimo bardzo szybkiego odczytu, pamięć ta charakteryzuje się wolniejszym zapisem (nawet 10 razy). Kolejnym problemem jest ograniczona liczba zapisów do pojedynczej komórki, która wynosi od 10^7 do 10^8. Chociaż 10 milionów może wydawać się liczbą trudną do osiągnięcia, komputer wykorzystujący pamięć PCM jako pamięć operacyjną, mógłby zniszczyć pojedyncze komórki pamięci w zaledwie kilka minut. Jako rozwiązanie tego problemu zaproponowano kilka algorytmów mapujących linie pamięci PCM (64 B) oraz logiczne strony (4 KB) w sposób podobny do algorytmu FTL stosowanego w dyskach SSD [191], [192], [193]. Aby zapobiec całkowitemu zniszczeniu komórek PCM, system operacyjny operuje na tych samych adresach logicznych, chociaż adres fizyczny może się zmieniać. Dzięki temu taki system może funkcjonować przez dziesiątki lat. Rozwiązanie pełnego mapowania pamięci podzielonej na strony czy inne mniejsze fragmenty nie zostało porzucone po stworzeniu podstawowych systemów. Problem okazał się znacznie większy. Zwykle pamięci są wykorzystywane do jednego celu. Pamięć RAM jest szybką pamięcią operacyjną komputera lub buforem danych w wolniejszych dyskach. Pamięć flash jest wykorzystywana do budowy pamięci masowej w tym dysków SSD. Pamięć PCM jest wykorzystywana w różny sposób w zależ-

ności od architektury systemu. Niektóre systemy stosują PCM jako główną pamięć komputera [132], inne jako pamięć masową [133], a jeszcze inne jako bufor danych pomiędzy dyskami SSD a pamięcią RAM [134]. Z tego względu zaproponowano kolejne algorytmy pozwalające wydłużyć życie komórek pamięci. Niektóre z nich skupiały się na dynamicznym wykrywaniu użycia pamięci (np. dużo zapisów do pewnego obszaru pamięci) [194], [195], [196], inne tworzyły mapowanie na różnych poziomach systemu operacyjnego, aby zmaksymalizować korzyści z mapowania pamięci na żywotność komórek, w zależności od używanej architektury. W [197] zaproponowano system mapujący działający na poziomie sterowników, w [198] na poziomie systemu operacyjnego (głównie systemy plików), a w [199] stworzono moduł, który można użyć w dowolnej aplikacji (ang. user space). Porównanie najważniejszych metod mapowania pamięci można znaleźć w [200]. To właśnie ze względu na asymetrię pomiędzy czasem odczytu a zapisu oraz odmienną charakterystykę pamięci PCM od klasycznych dysków HDD jak i nowych dysków SSD, klasyczne struktury danych muszą być dostosowane do tego rodzaju pamięci.

7.1 Indeksowanie wierszowe

Indeksy wierszowe stanowią jedne z najbardziej popularnych struktur danych w bazach danych. Ich główną zaletą jest prostota implementacji oraz efektywność w utrzymaniu porządku. Cały rekord zapisywany jest w ciągłym obszarze pamięci, co umożliwia szybkie dodawanie nowych rekordów, usuwanie starych oraz modyfikowanie istniejących, przy wykorzystaniu pojedynczych operacji na pamięci. Jednakże, ten rodzaj indeksowania posiada również pewne wady. Typowo tabela zawiera kilka lub nawet kilkanaście atrybutów, a większość kwerend nie wymaga dostępu do wszystkich z nich. Niemniej, ze względu na ułożenie w pamięci, musimy wczytać cały rekord niezależnie od zapytania, co niepotrzebnie wydłuża czas trwania kwerendy.

Najpopularniejszą strukturą danych stosowaną do indeksowania wierszowego jest drzewo B+ [21], które jest często używane w bazach danych zapisanych na dyskach HDD oraz w pamięci operacyjnej komputera. Ze względu na jego popularność, podjęto wiele prób dostosowania drzewa B+ do charakterystyki pamięci PCM. W [136] porównano cztery modele drzew B+:

- **Standardowe drzewo B+ (ang. *sorted B+*)**, w którym zarówno liście, jak i węzły wewnętrzne są posortowane.
- **Całkowicie nieposortowane drzewo B+ (ang. *unsorted B+*)**, które zachowuje główną ideę struktury jako zbiór węzłów tworzących minimalnie częściowy porządek, ale gdzie same węzły są zbiorami nieposortowanymi.
- **Drzewo z nieposortowanymi liśćmi (ang. *unsorted leaf*)**, gdzie liście zawierające dane nie są posortowane, co minimalizuje liczbę modyfikacji w tym zbiorze, natomiast węzły wewnętrzne, służące głównie do wyszukiwania odpowiedniego liścia, pozostają posortowane, gdyż dominującą operacją na nich jest odczyt.
- **Drzewo z nieposortowanymi liśćmi posiadające bitmapę (ang. *unsorted leaf with bitmap*)**, będące wariantem modelu z nieposortowanymi liśćmi, ale dodatkowo każdy liść zawiera bitmapę określającą aktualny stan każdej wartości (1 – aktualna, 0 – nieaktualna/usunięta).

Z eksperymentów przedstawionych w [136] wynika, że w kontekście pamięci PCM, standardowe drzewo B+ radzi sobie najgorzej. Mimo że w pełni posortowane drzewo najskuteczniej wyszukuje klucze, każda modyfikacja, taka jak dodawanie lub usuwanie rekordów, wiąże się z dużymi kosztami. Aby utrzymać posortowanie węzłów, konieczne jest znalezienie odpowiedniego miejsca na nowy rekord i przeprowadzenie reorganizacji węzła, aby zbiór pozostał posortowany po dodaniu nowej wartości. Oczekiwana wartość takiej operacji to przepisanie nawet połowy węzła, co jest bardzo kosztowne biorąc pod uwagę charakterystykę pamięci PCM. Porównując trzy pozostałe modele, drzewo w pełni nieposortowane uzyskało najgorsze wyniki spośród wszystkich nieposortowanych struktur, mimo iż czas wykonania zestawu kwerend był znacząco krótszy niż w przypadku standardowego drzewa B+. Okazuje się, że w pełni nieposortowane drzewo B+ wyszukuje rekordy bardzo wolno, ponieważ zamiast szybkiego wyszukiwania binarnego, musi wczytać cały węzeł na każdym poziomie.

Najlepszym modelem pod względem szybkości wykonywania kwerend, zużycia pamięci oraz poboru energii okazał się model drzewa z nieposortowanymi liśćmi posiadającego bitmapę. Podział na nieposortowane liście, gdzie dokonuje się najwięcej modyfikacji, oraz posortowane węzły wewnętrzne, służące głównie do wyszukiwania rekordów, okazał się najlepszym rozwiązaniem spośród wszystkich czterech zaproponowanych modeli. Przede wszystkim dzięki wprowadzeniu bitmapy, usuwanie rekordu odbywa się poprzez nadpisanie pojedynczego bitu odpowiadającego usuwanej danej, co znacząco przyspiesza tę operację w porównaniu do modelu trzeciego (drzewo z nieposortowanymi liśćmi), gdzie dane są usuwane przez nadpisanie rekordu ostatnim rekordem w węźle. Efektem tej optymalizacji było osiągnięcie siedmiokrotnie mniejszego zużycia pamięci, 1,7-krotnie szybszego czasu wykonania zestawu kwerend przy wykorzystaniu dwukrotnie mniejszej ilości energii. Model ten nazwano drzewem UB+ (ang. *unsorted B+ Tree*).

W publikacji [29] stworzono strukturę OB+-Tree oraz zmodyfikowano algorytm reorganizacji drzewa tak, aby zamiast natychmiast modyfikować węzeł rodzica, dodawać kolejne węzły do listy (ang. *overflow node*). Autorzy skupili się na modelu drzewa z nieposortowanymi liśćmi wyposażonym w bitmapę (UB+-Tree). Zauważyli, że w przypadku braku miejsca na kolejny element w nieposortowanym liściu, jest on sortowany i dzielony na dwa podzbiory, podobnie jak w tradycyjnym drzewie B+. Proces sortowania, zależnie od wielkości węzła, może być czasochłonny, a dodawanie kolejnego wskaźnika do rodzica, który jest posortowany, wymaga wielu operacji nadpisywania danych, które są powolne w pamięci PCM. Aby uniknąć tych operacji, tworzony jest dodatkowy węzeł, który jest widoczny tylko na poziomie liścia jako lista dodatkowych węzłów. Podczas przepisywania danych nie dokonuje się sortowania rekordów, lecz wybiera się element rozdzielający (ang. *pivot*) i przepisuje się tylko rekordy o kluczu większym niż wybrany element. Oba węzły pozostają niesortowane, jednak dzięki elementowi rozdzielającemu podczas wyszukiwania wiadomo, który węzeł należy wczytać, aby znaleźć pożądany rekord. Ponieważ nowy węzeł jest widoczny tylko z poziomu liścia, do którego jest przypisany, nie ma potrzeby przeprowadzać kosztownej operacji nadpisywania danych w węźle rodzica. Mimo że taki zabieg wydłuża czas wyszukiwania rekordu, całkowity czas wykonywania zestawu kwerend spadł o 6% w porównaniu z pierwotnym modelem.

W [31] zaproponowano kolejną modyfikację, tym razem modelu struktury OB+-Tree. Wprowadzenie dodatkowych węzłów wydłuża czas wyszukiwania. Gdy użytkownik wykonuje więcej wyszukiwań niż modyfikacji, czas potrzebny drzewu OB+ na wykonanie wszystkich kwerend jest dłuższy niż czas uzyskany przez drzewo UB+. Autorzy, zauwa-

żywszy, że wprowadzenie dodatkowych węzłów zależy od wzorca kwerend, zaproponowali swoją modyfikację nazwaną drzewem CB+. Struktura ta wykrywa sposób użycia poszczególnych fragmentów drzewa i dynamicznie włącza lub wyłącza funkcjonalność związaną z dodatkowymi węzłami. Zmiana nie następuje natychmiastowo, gdyż algorytm potrzebuje czasu na stwierdzenie zmiany trendu. Mimo niewielkiego opóźnienia, struktura osiągnęła czas o 12% lepszy niż drzewo OB+.

W [201] oraz [202] skoncentrowano się na dostosowaniu rozmiaru węzła drzewa B+ do charakterystyki pamięci PCM. W przypadku pamięci RAM typowy rozmiar węzła odpowiada rozmiarowi strony logicznej tej pamięci (zazwyczaj 4 KB), podczas gdy dla dysków HDD i SSD rozmiar jest dostosowywany do pojemności fizycznych stron dysków (2 KB – 8 KB). Ponieważ pamięć PCM może być wykorzystywana jako pamięć operacyjna, bufor lub pamięć masowa, a sama jest podzielona na bardzo małe linie pamięci (64 B), ustalenie odpowiedniego rozmiaru węzła było wyzwaniem. W [201] badano wpływ wielkości węzła struktury B+ na szybkość wykonywania kwerend, gdy pamięć PCM była wykorzystywana jako główna pamięć komputera. Najlepsze wyniki osiągnięto dla węzłów o rozmiarze 4-8 razy większym niż linia pamięci podręcznej (ang. *cacheline*), co sugeruje, że w takim zastosowaniu najlepszy będzie rozmiar węzła 256 - 512 B. Z kolei w [202] przeprowadzono eksperymenty z pamięcią PCM jako pamięcią masową. Najlepsze wyniki uzyskano dla węzłów o wielkości jednej lub dwóch stron pamięci RAM, czyli 4 KB – 8 KB. Uzyskano to dzięki braku potrzeby ciągłego doczytywania fragmentów pamięci. Jednorazowy odczyt i zapis wystarczały do wykonania pełnych operacji na węźle.

W publikacji [30] analizowano model wykorzystania PCM jako pamięci dyskowej. Zaproponowano strukturę XB-Tree (ang. *eXtendend B+-Tree*), która w zależności od aktywności węzła umieszczała go w pamięci nieulotnej PCM lub w szybkiej pamięci RAM. Koncepcja ta jest podobna do drzewa wędrującego ([203]), stosowanego w wielu systemach plików na dyskach SSD, takich jak JFFS3 ([204]) czy UBIFS ([205]). W obu strukturach (XB-Tree i Wandering-Tree) monitorowane jest użycie węzła. Jeśli dominują odczyty, węzeł jest trwale buforowany w pamięci RAM, co znacząco przyspiesza dostęp. Natomiast gdy przeważają modyfikacje (dodawanie i usuwanie rekordów), węzeł jest zapisywany z powrotem na pamięć PCM (ang. flush). XB-Tree osiągnęło znacznie lepsze wyniki w testach kwerend dominujących odczytami, nawet o 40-60% lepsze niż w drzewach OB+ i CB+.

Podobne optymalizacje wprowadzono w strukturze FP-Tree (ang. *Fingering Persistent Tree*) [206]. W tym indeksie również większość węzłów jest stale buforowana w pamięci RAM. Każdy węzeł posiada osobny bufor na modyfikacje, co pozwala na agregację i równoczesne przeprowadzenie większości operacji.

W publikacji [207] zaproponowano całkowicie nowy indeks, specjalnie dostosowany do pamięci PCM i systemów wielowątkowych. Indeks DP-Tree składa się z trzech części. Pierwsza to bufor w pamięci RAM, będący niewielkim, klasycznym drzewem B+, które agreguje wszystkie operacje, dodając nowe elementy oraz oznaczając elementy do usunięcia. Druga część to główny indeks zapisany w pamięci PCM, będący strukturą podzieloną na poziomy, podobnie jak w drzewach LSM ([172]) czy FD ([27]). Gdy bufor osiąga maksymalną liczbę wpisów, jest łączony z głównym indeksem według specjalnie przygotowanego algorytmu. Dodatkowo, by zapobiec utracie danych w przypadku awarii systemu (pamiętajmy, że pamięć RAM jest ulotna), wprowadzono dziennik operacji, zapisany na nieulotnej pamięci PCM. Kluczową cechą systemu jest wsparcie dla ope-

racji wielowątkowych. Algorytm zapisywania buforowanego drzewa B+ do indeksu jest zaprojektowany tak, aby mógł obsługiwać wiele buforów jednocześnie. Oznacza to, że w zależności od liczby użytkowników (klientów bazy) możemy wprowadzić wiele buforów, z których każdy będzie obsługiwał operacje pojedynczego użytkownika, traktowanego jako wątek w systemie. Umiejętne zapisywanie tylko niezbędnych metadanych niezbędnych do odzyskania informacji oraz pełne buforowanie indeksu sprawiły, że indeks ten stał się obecnie domyślną strukturą używaną przez silniki baz danych działające na pamięci PCM.

Umiejętne zarządzanie buforowaniem i przechowywaniem danych w różnych rodzajach pamięci pozwala na zdecydowanie lepszą wydajność i mniejsze zużycie zasobów. To z kolei przekłada się na dłuższą żywotność i stabilność systemów korzystających z pamięci PCM. Dzięki temu nowe struktury indeksowe jak DP-Tree czy XB-Tree oferują znaczne ulepszenia w obszarach, gdzie tradycyjne drzewa B+ mogłyby sprawiać problemy, szczególnie w środowiskach o intensywnym dostępie do danych i dużej liczbie równoczesnych operacji.

Te nowatorskie podejścia w indeksowaniu otwierają nowe możliwości dla przyszłych badań i rozwoju w zakresie zarządzania pamięcią i przetwarzania danych, a także mogą wpłynąć na projektowanie przyszłych systemów bazodanowych, które będą mogły wykorzystywać zaawansowane technologie pamięci do zwiększenia swojej efektywności i niezawodności. Nowe metody mogą być szczególnie korzystne w aplikacjach wymagających szybkiego dostępu do dużych zbiorów danych, takich jak duże systemy transakcyjne, hurtownie danych czy rozwiązania z zakresu Big Data i uczenia maszynowego.

Podsumowując, adaptacja i optymalizacja struktur danych pod specyfikę pamięci PCM jest kluczowa, aby w pełni wykorzystać jej potencjał. Nie tylko zmniejsza to koszty operacyjne, ale również zwiększa ogólną wydajność systemów bazodanowych. Przedstawione innowacje stanowią ważny krok w kierunku osiągnięcia tych celów, a kontynuacja badań w tym obszarze z pewnością przyniesie jeszcze więcej korzystnych rozwiązań.

7.2 Indeksowanie kolumnowe

Indeksowanie kolumnowe zyskało na popularności w ostatnich latach, dzięki czemu większość nowoczesnych silników baz danych wspiera ten sposób zapisu tabeli. Wynika to z faktu, że większość zapytań do baz danych nie potrzebuje danych ze wszystkich kolumn. W wierszowej implementacji marnujemy odczyty z dysku na wczytanie całego wiersza i wyłuskanie tylko potrzebnych atrybutów. W podejściu kolumnowym na jednej stronie w pamięci przetrzymywane są wartości pojedynczej kolumny dla kilku rekordów, dzięki czemu podczas wyszukiwania wczytujemy tylko potrzebne informacje. Niestety, kolumnowe podejście jest wolniejsze podczas zapisywania nowych rekordów, ponieważ musimy zapisać podzielony rekord na kolumny w kilku miejscach na dysku [10]. Najpopularniejszą strukturą danych używaną obecnie do indeksowania rekordów zapisanych kolumnowo jest PDT [52] (ang. *Positional Delta Tree*). Indeks ten do niedawna wykorzystywany był tylko w bazach danych zapisanych w pamięci operacyjnej komputera (ang. *in-memory database*) oraz na dyskach talerzowych HDD. Obecnie struktura PDT jest domyślnym indeksem dla zapisu kolumnowego w silnikach MonetDB [47] oraz VectorWise [49]. Mimo że pamięć zmiennofazowa PCM posiada odmienną charakterystykę od pamięci RAM czy dysków HDD, struktura PDT jest również stosowana w bazach zapisanych w pamięci PCM. Możliwe, że w niedalekiej przyszłości zobaczymy próbę zaadoptowania znanych al-

gorytmów pod pamięci PCM takich jak kolumnowe drzewo FD [3], kolumnowe drzewo B+ [208] czy system zapisu danych PAX [53], który zapisuje dane kolumnowo w obrębie jednego fragmentu pamięci, zazwyczaj strony na dysku. Taki sposób zapisu można by łatwo zaadoptować do pamięci PCM, która w zależności od wykorzystania dzielona jest na mniejsze (64B) lub większe strony (4KB), odpowiadające stronom pamięci RAM czy dysku. W literaturze możemy znaleźć kilka prób implementacji nowego sposobu mapowania danych, tak aby efektywnie były wczytywane nie tylko z pamięci PCM (jak kiedyś z dysku) do pamięci RAM, ale także z PCM do pamięci podręcznej procesora [209], [210], [211], [212].

7.3 Indeksowanie częściowe

Zazwyczaj administrator bazy danych musi zdecydować, jak dobrać indeksy, aby efektywnie obsługiwać kwerendy użytkowników. Jest to trudne zadanie, dlatego coraz częściej stosuje się automatyzację tego procesu [55]. Często wykorzystuje się indeksowanie częściowe, które w wyniku kwerendy dodaje potrzebne dane do indeksu. W ten sposób rekordy zapisane w indeksie są tymi, które były kiedyś potrzebne i mogą być potrzebne w przyszłości. Dodatkowym atutem tego typu algorytmów jest amortyzacja kosztu tworzenia pełnego indeksu; zamiast długiego oczekiwania na finalizację tego procesu, dodajemy małe zbiory rekordów podczas każdego zapytania, nieznacznie wydłużając tylko czas jego obsługi, co zwykle jest niezauważalne dla użytkownika bazy. W [58], [59] zaproponowano Indeks Cracking. Algorytm ten używa metody podziału danych na partycje (ang. *partition*) względem elementów z zakresu zapytania i działa podobnie do sortowania szybkiego (ang. *quicksort*) [60]. Kolejną metodę automatycznego tworzenia indeksu podczas kwerend przedstawiono w [15]. Adaptive Merging, w przeciwieństwie do Indeksu Cracking, korzysta z algorytmu scalania posortowanych list podobnego do sortowania przez scalanie (ang. *mergesort*) [64]. Ze względu na schemat działania obu algorytmów, Indeks Cracking stosuje się dla baz danych zapisanych w szybkiej pamięci operacyjnej komputera, a Adaptive Merging gdy tabela przechowywana jest na pamięciach blokowych takich jak dyski HDD czy dyski SDD. Pamięć PCM jest adresowana bajtowo, zatem naturalnym wyborem algorytmu do częściowego indeksowania padł na Indeks Cracking. W [213], [214] przeprowadzono dogłębną analizę tego algorytmu i charakterystyki PCM oraz pokazano za pomocą eksperymentów, że Indeks Cracking poprzez częste reorganizacje doprowadza do szybkiego wypalenia się komórek pamięci PCM. Dodatkowo, biorąc pod uwagę asymetrię pomiędzy szybkim czasem odczytu a wolnym zapisem, częste nadpisywanie danych nie jest efektywne na tym rodzaju pamięci. Z tego powodu na pamięciach PCM używa się obecnie oryginalnego algorytmu Adaptive Merging.

Mimo że obecnie Adaptive Merging jest stosowany w bazach danych zapisanych na pamięci PCM, to nie jest on dostosowany do tego rodzaju pamięci i posiada liczne wady. Największą z nich jest konieczność reorganizacji partycji podczas przepisywania danych do nowej partycji. Każdy rekord, który jest przepisywany, musi zostać nadpisany innymi rekordami, aby partycja nie zawierała wolnych przestrzeni. Dodatkowo AM używa w pełni posortowanego wariantu drzewa B+ (PB+) [65], a z [136] wiemy, że takie podejście nie jest optymalne w pracy z pamięcią PCM. Z tych powodów postanowiliśmy dostosować algorytm Adaptive Merging do pamięci PCM. W [5] zaproponowaliśmy modyfikację tego algorytmu, nazwaną eAM (extended Adaptive Merging). W eAM partycje nadal są posortowane, jednak dopuszczamy obecność elementów nieaktualnych (usuniętych), które

są nadal zapisane w partycji. Każda partycja zawiera bitmapę określającą status każdego rekordu. Kiedy przepisujemy element w inne miejsce, zmieniamy jego status w bitmapie, nie nadpisując go innymi elementami zbioru. To eliminuje potrzebę przeprowadzania kosztownych operacji zapisu danych. Podczas wczytywania partycji, najpierw wczytujemy do pamięci RAM lub pamięci podręcznej procesora bitmapę, znajdującą się na początku partycji. Dzięki temu możemy szybko określić, które rekordy są aktualne i wymagają załadowania do pamięci. Drugą modyfikacją jest zmiana tworzonego indeksu. Zamiast posortowanej wersji B+, użyliśmy modyfikacji drzewa UB+, opisanej w [136]. Wprowadzenie nieposortowanego liścia nie tylko zmniejsza liczbę zapisów do pamięci PCM podczas bezpośredniego wstawiania nowych elementów do indeksu, ale także skraca czas potrzebny na posortowanie danych odczytanych z partycji. Niestety dalsze modyfikacje algorytmu AM były niemożliwe do przeprowadzenia. Brak oddzielnych modułów na indeks i zbiór partycji utrudnia proces optymalizacji tego algorytmu, ponieważ partycje są integralną częścią drzewa indeksu. Z tego powodu zaproponowaliśmy PAM (PCM Adaptive Merging) [5] – całkowicie nowy system do tworzenia częściowego indeksu.

7.3.1 System PAM (PCM Adaptive Merging)

PCM Adaptive Merging, w przeciwieństwie do klasycznego Adaptive Merging, nie nadpisuje danych podczas tworzenia nowej partycji. Zamiast tego, zapisuje w dzienniku parę kluczy odpowiadającą zakresowi przepisanemu z partycji do indeksu. Dzięki temu system unika kosztownej operacji nadpisywania danych w momencie ich przepisywania. System PAM potrafi współpracować z dowolnym indeksem, który wspiera zbiorcze dodawanie danych (ang. *bulkload*), takimi jak DPTree [207] i FPTree [206]. Oba te indeksy zostały przystosowane do charakterystyki pamięci PCM. Niestety, te indeksy nie potrafią w pełni wykorzystać wzorca dodawanych rekordów (zakresy kluczy), co skłoniło nas do zaproponowania nowej struktury opartej na drzewie B+Tree i DPTree – BB+Tree (Buffered B+Tree).

System PCM Adaptive Merging korzysta z następujących struktur danych:

1. **Partycja** – podstawowa struktura przechowująca zbiór posortowanych danych. Pomimo iż pamięć PCM jest bajtowo adresowalna, to dostęp do całej linii pamięci jest znacznie szybszy ze względu na buforowanie kontrolera pamięci. Dlatego wielkość partycji zawsze jest wielokrotnością linii pamięci PCM, aby zminimalizować narzut związany z zapisem i odczytem zbyt małych obszarów pamięci. Podczas pierwszej kwerendy dane wczytywane są do bufora znajdującego się w pamięci RAM i tam sortowane. Następnie są zapisywane na pamięci nieulotnej PCM. Dane są posortowane wewnątrz każdej partycji, zatem możemy wyszukać potrzebny klucz w czasie logarytmicznym używając klasycznego wyszukiwania binarnego. Dodatkowo każda partycja posiada dwa atrybuty, najmniejszą i największą wartość klucza w partycji. Atrybuty te są zapisane w pamięci RAM w metadanych zbioru partycji.

2. **Dane partycji** – struktura przechowująca potrzebne metadane o każdej partycji. W zależności od implementacji i wielkości zbioru, może być to lista lub struktura drzewa. Każdy rekord w tej strukturze posiada klucz sztuczny partycji, adres w pamięci oraz wartości minimalne i maksymalne kluczy w danej partycji. Wyszukiwanie danych może odbywać się równolegle na kilku partycjach, ponieważ możemy łatwo stwierdzić, które partycje z podanych adresów należy wczytać, a które nie. Struktura ta jest zapisana w pamięci RAM, ponieważ można ją łatwo zbudować ze

zbioru partycji zapisanych na nieulotnej pamięci.

3. **Bufor do sortowania** – fragment szybkiej pamięci RAM o ustalonym rozmiarze *BS* (ang. *Buffer Size*), używany do sortowania danych przed zapisem do partycji. Im większy bufor, tym więcej danych można posortować za jednym razem. Zatem, im większe *BS*, tym mniej partycji w zbiorze.

4. **Indeks** – do indeksowania można użyć dowolnej struktury, która jest dostosowana do pamięci PCM oraz posiada wszystkie cechy wymagane przez nasz system. Domyślnie używamy nowego drzewa BB+.

5. **Dziennik dodanych rekordów (ang. *insertion journal*)** – dziennik ten zawiera wszystkie zakresy kluczy, które zostały przepisane z partycji do indeksu. Samo wyszukiwanie w indeksie jest stosunkowo tanie, jednak skan partycji jest kosztowny. Aby zredukować te koszty, podczas wyszukiwania najpierw czytamy dziennik, który przechowywany jest w pamięci RAM. Na jego podstawie możemy stwierdzić, czy rekordy zostały wcześniej przepisane do indeksu czy też nie. Dzięki temu wczytujemy tylko potrzebne partycje. Tej struktury nie trzeba zapisywać w nieulotnej pamięci. Wystarczy podczas startu systemu odczytać rekordy znajdujące się w zbiorze partycji jak i w indeksie. Część wspólna tych zbiorów została przepisana z partycji do indeksu. Zatem należy dodać do dziennika zakresy tych zbiorów. Oczywiście tak utworzony dziennik nie będzie zawierał dokładnie tych samych danych co oryginalny (np. niektóre kwerendy zostaną połączone). Jednak nie wpływa to na poprawność działania systemu, a dokładne dane o kwerendach nie są potrzebne.

6. **Dziennik usuniętych rekordów (ang. *deletion journal*)** – dziennik ten zawiera wszystkie zakresy kluczy, które zostały usunięte z partycji. Usuniętych danych nie da się odzyskać w podobny sposób do danych zapisanych w dzienniku dodanych rekordów. Dlatego dziennik ten jest zapisany w nieulotnej pamięci RAM. Dzięki niemu nie musimy fizycznie usuwać danych z partycji. Zamiast tego wpisujemy odpowiedni klucz lub zakres kluczy do dziennika. Podczas wyszukiwania sprawdzamy, czy żądane przez użytkownika rekordy nie znajdują się w dzienniku. Jeśli tak, to odejmujemy je z wynikowego zbioru kwerendy, ponieważ zostały one wcześniej usunięte.

Rysunek 7.1 przedstawia przykładowy stan procesu tworzenia indeksu częściowego przez PAM. Dla uproszczenia załóżmy, że tabela ma 20 rekordów. Początkowy układ danych w pamięci wyglądał następująco: {2, 19, 26, 5, 9, 1, 3, 11, 17, 21, 24, 14, 16, 12, 4, 6, 18, 20, 13, 25}. Załóżmy również, że linia pamięci PCM może pomieścić maksymalnie 2 rekordy, a bufor sortujący ma pojemność 5 rekordów. Zatem wielkość partycji, wyrażona w rekordach, musi być mniejsza bądź równa 5 oraz musi być wielokrotnością 2. Pojemność równa czterem rekordom spełnia oba te warunki. Rysunek opisuje sytuację po dwóch kwerendach wyszukujących: (6-13) oraz (1-8), co możemy łatwo odczytać z dziennika dodanych rekordów. W zbiorze partycji składającym się z 4 partycji, oznaczonych na rysunku jako P1, P2, P3 i P4, rekordy przepisane do indeksu są oznaczone kolorem szarym. Jak widać, wszystkie dane, zarówno te które zostały przepisane, jak i te, które nie zostały pobrane przez użytkownika, są przechowywane w partycjach w pamięci PCM. Mimo że przepisane rekordy nie są już potrzebne, lepiej jest pozostawić je na miejscu i nie nadpisywać ich danymi aktualnymi. Dzięki temu unikamy niepotrzebnych operacji zapisu, które są bardzo kosztowne w tym modelu pamięci. Pamięć zostanie zwolniona, gdy wszystkie dane przepisane do indeksu w obrębie jednej partycji zostaną usunięte

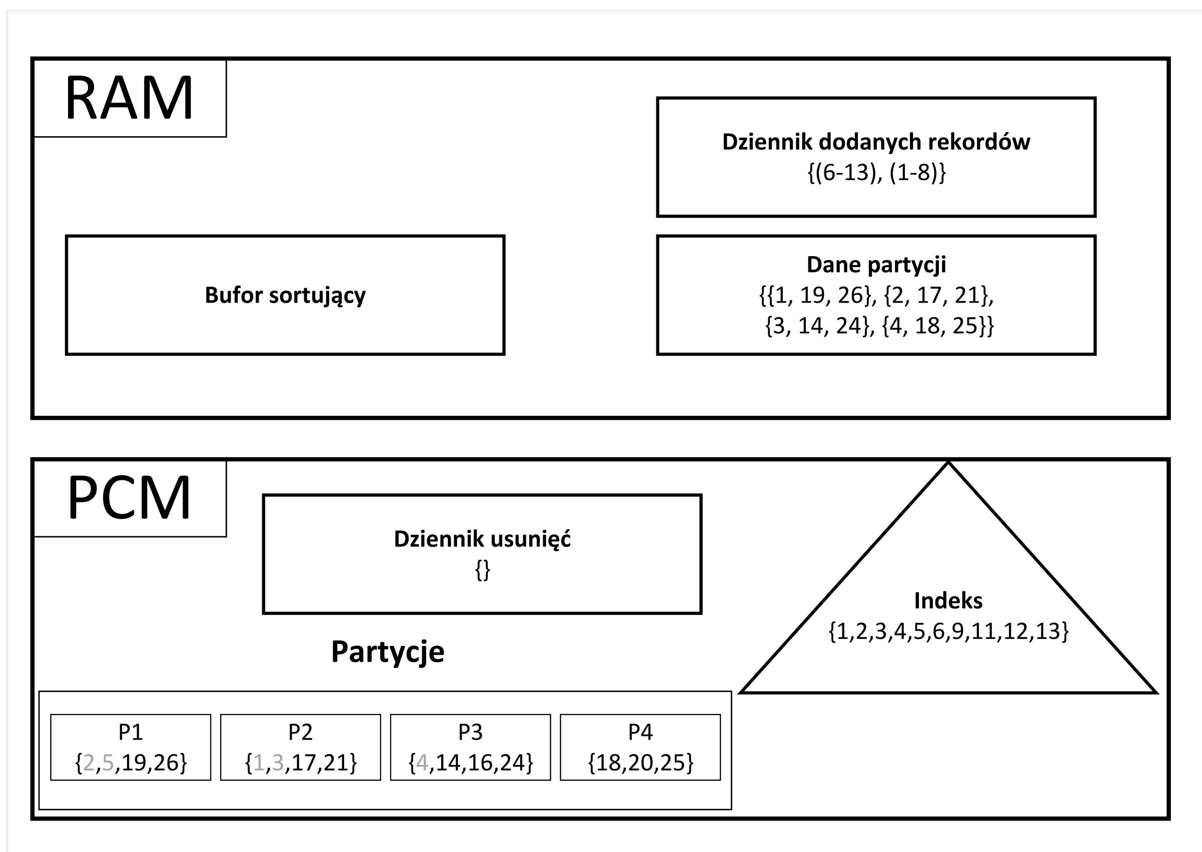

Rysunek 7.1: Przykład struktury PAM

na prośbę użytkownika. Warto również zauważyć, że metadane o zbiorze partycji są na bieżąco aktualizowane wraz z każdą zmianą w partycji. Przykładowo, mimo że partycja P1 zawiera dane {2, 5, 19, 26}, minimalny klucz zapisany w metadanych to 19, a nie 2, ponieważ wartości 2 i 5 są już nieaktualne i nie powinny być brane pod uwagę podczas kolejnych operacji wykonywanych na tej partycji.

Rysunek 7.2 przedstawia trzy kroki systemu PCM Adaptive Merging podczas tworzenia indeksu częściowego. Zakładamy, że tabela początkowo składała się z 20 rekordów: {2, 19, 26, 5, 9, 1, 3, 11, 17, 21, 24, 14, 16, 12, 4, 6, 18, 20, 13, 25}. Ze względu na pojemność linii pamięci PCM (2 rekordy) oraz pojemność bufora sortującego (5 rekordów), rozmiar partycji został ustalony na 4 rekordy. Pierwsze zapytanie dotyczyło kluczy z zakresu (6-13). Dane wczytane są do bufora, sortowane, a następnie zapisywane w partycjach. Zakres kwerendy dodawany jest do indeksu, dlatego w indeksie zapisujemy rekordy {6, 9, 11, 12, 13} i tworzymy pierwszy wpis w dzienniku, parę (6 - 13). Następnie przyszło zapytanie o zakresie (1 - 8). Po przeczytaniu dziennika stwierdzamy, że wartości 7 i 8 nie zostały wcześniej przepisane. Dlatego zapytanie (1 - 8) przekształcamy w kwerendę z zakresu (1 - 6). Analizując atrybuty partycji zapisane w pamięci RAM, ustalamy, że partycja P4 (zakres kluczy 18 - 25) nie zawiera szukanych rekordów. Pozostałe partycje: P1 (1-26), P2 (2-21) oraz P3 (4-24), mogą zawierać szukane dane. Po wczytaniu ich z pamięci PCM do bufora, z partycji P1 kopiujemy wartości 2 i 5, z P2 wartości 1 i 3, a z P3 wartość 4. Kopiowane dane dodajemy do indeksu. Zamiast usuwać przepisane dane, zostawiamy je na miejscu i dodajemy odpowiedni wpis do dziennika dodanych rekordów. Wpis do dziennika dla zakresu (1-8) wskazuje, że te dane zostały przepisane do indeksu, więc nie wymagają ponownego odczytu z partycji. Ostatnia przedstawiona kwerenda dotyczy usuwania war-

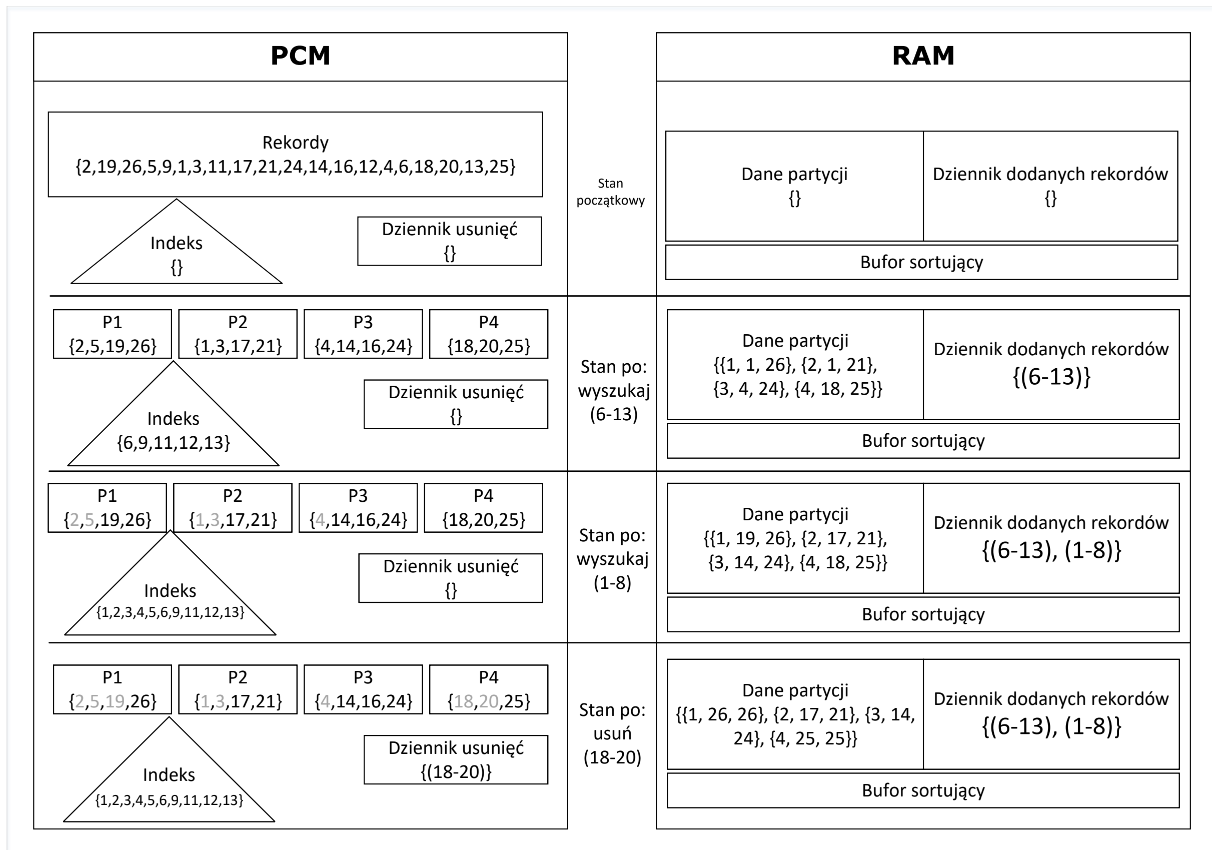

Rysunek 7.2: Przykładowy proces tworzenia częściowego indeksu z użyciem systemu PAM

tości z zakresu (18-20). Ponownie, zaczynamy od przeczytania dziennika. Wszystkie dane do usunięcia pochodzą z partycji, więc odczytujemy metadane i stwierdzamy, że odpowiednie rekordy mogą znajdować się w każdej partycji. Po wczytaniu danych z pamięci PCM, okazuje się, że z partycji P1 należy usunąć wartość 19, a z P4 wartości 18 i 20. Mimo polecenia użytkownika o usunięcie tych rekordów, system PAM tego nie wykonuje. Zamiast tego dodaje zakres (18-20) do dziennika usunięć i aktualizuje metadane partycji.

7.3.2 Procedury systemu PAM

Wstawianie

Dodawanie nowych rekordów do systemu PAM jest bardzo proste. Wykorzystujemy gotową strukturę indeksową do zarządzania rekordami. Wstawianie odbywa się zgodnie z procedurami opisanymi dla danej struktury indeksowej. Dzięki temu unikamy zaburzenia porządku w posortowanych partycjach, co mogłoby prowadzić do konieczności ich reorganizacji. Nie dodajemy również nowych partycji, co zmniejsza koszty operacyjne systemu. Dodane rekordy od razu umieszczamy w indeksie, przewidując ich wykorzystanie w przyszłości.

Wyszukiwanie

Wyszukiwanie to kluczowa operacja w procesie tworzenia indeksu częściowego. W trakcie wyszukiwania dokładamy do indeksu kolejne rekordy, zmniejszając liczbę danych

przechowywanych w partycjach. Proces ten jest prosty. Po otrzymaniu kwerendy od użytkownika, przeglądamy dziennik dodanych rekordów, aby ustalić, które dane są już dostępne w indeksie, a które musimy wczytać z partycji. Jako że dziennik to tylko lista zakresów kluczy przepisanych, konieczne jest przeczytanie całej listy. Optymalnie, gdy kwerenda może być obsłużona wyłącznie przez indeks, unikamy dodatkowych odczytów. Jeśli jednak niezbędne są dane z partycji, korzystamy z metadanych zgromadzonych w pamięci RAM, aby wczytać tylko te partycje, które mogą zawierać potrzebne informacje. Przedwcześnie zbieramy wszelkie niezbędne informacje, po czym równolegle wczytujemy wymagane segmenty pamięci. Należy pamiętać, że obecność klucza w dzienniku nie gwarantuje jego obecności w indeksie. W trakcie usuwania lub aktualizacji danych w indeksie, dziennik nie jest modyfikowany, co ma na celu przyspieszenie wyszukiwania i zachowanie jego poprawności. Jeśli dane zostały usunięte, muszą zostać odnalezione w zbiorze partycji. Nie usuwając natychmiastowo danych z dziennika, szybko lokalizujemy klucz w indeksie lub stwierdzamy, że został usunięty. Ponieważ nie wszystkie rekordy w partycji są aktualne, sprawdzamy przed ich dodaniem do wyników, czy nie znajdują się one w dzienniku usunięć. Jeśli tak, omijamy je w odpowiedzi na zapytanie. Po zebraniu wszystkich danych sortujemy je i dodajemy do indeksu, aktualizując równocześnie metadane partycji i wpisując nowy zakres do dziennika dodanych rekordów. Po przeprowadzeniu tych operacji możemy przedstawić użytkownikowi wynik kwerendy.

Usuwanie

System PAM równolegle zarządza partycjami i indeksem, które razem tworzą. Dzięki dziennikowi dodanych rekordów system jest w stanie zdecydować, którą strukturę należy przeszukać w celu odnalezienia rekordów do usunięcia. Jeżeli rekord znajduje się w indeksie, wystarczy wykonać odpowiednią operację na strukturze indeksowej. Jeśli jednak jest zapisany w partycji, nie usuwamy go bezpośrednio z pamięci PCM. Zamiast tego, dodajemy wpis do dziennika usunięć, co pozwoli algorytmowi zdecydować o odczytaniu danych z indeksu przy następnym wyszukiwaniu.

7.3.3 Opis algorytmów

Pseudokod 7.1 przedstawia dokładny opis kroków algorytmu wyszukującego dane w systemie PAM. Procedura na wejściu przyjmuje posortowany zbiór kluczy, dla których musimy znaleźć odpowiadające rekordy. W pierwszym kroku próbujemy znaleźć rekord w indeksie (linia 5). Jeśli indeks nie zawiera danej wartości, przechodzimy do kolejnego kroku. Jeśli klucz jest zapisany w strukturze, dodajemy go do zbioru wynikowego (linie 6-7). Kolejnym krokiem jest odczyt partycji. Wiemy, że klucz znajduje się w partycji, jeśli nie został przepisany do indeksu (dziennik dodanych rekordów nie zawiera szukanego klucza) oraz jeśli nie został usunięty z partycji (dziennik usunięć nie zawiera szukanego klucza). Gdy spełniamy oba te warunki (linia 9), musimy podjąć próbę znalezienia rekordu w zbiorze partycji. Pamiętajmy, że nie musimy wczytywać wszystkich partycji. Mając aktualne metadane zapisane w pamięci RAM, możemy stwierdzić, czy klucz może znajdować się w partycji czy też nie (linia 10). Gdy wczytujemy dane z partycji, za pomocą wyszukiwania binarnego (linia 12) w bardzo krótkim czasie stwierdzamy, czy rekord jest zapisany w partycji. Jeśli tak, dodajemy go nie tylko do zbioru wynikowego (linia 15), ale także do zbioru rekordów, które będą przepisane do indeksu w kolejnym kroku (linia 14). Ostatnim krokiem wyszukiwania jest przepisanie znalezionych danych do indeksu. Najpierw dodajemy rekordy do struktury (linia 17), następnie dodajemy wpis do dziennika dodanych

Pseudokod 7.1: pamFind(input: Key *keys*[ ])

```
1  Entry result[ ] := ∅
2  Entry toInsert[ ] := ∅
3
   // na podstawie dziennika określ, które klucze wczytujemy z partycji
4  foreach Key k ∈ keys do
5      Seek Entry e with key k in ind
6      if e exists in index then
7          result := result ∪ e
8
9      if insertionJournal.contains(k) = FALSE and deletionJournal.contains(k) =
        FALSE then
           // Wybór partycji dokonujemy za pomocą danych partrycji w RAM (pid, min, max)
10         Select Partition partitions[] containing k
11         foreach Partition p ∈ partitions do
12             Seek Entry e with key k in p
13             if e exists in p then
14                 toInsert := toInsert ∪ e
15                 result := result ∪ e
16
   // Wstaw nowe dane, aby powiększyć częściowy indeks
17 indexBulkloadInsert(toInsert)
18
   // Aktualizuj dane w RAM
19 Pair p := (min(keys), max(keys))
20 insertionJournalAdd(p)
21 updateParitionsData()
22
23 return result
```

rekordów (linie 19-20) oraz aktualizujemy metadane każdej partycji (linia 21).

7.3.4 Wybór Indeksu dla systemu PAM

System PAM potrafi współpracować z dowolnym indeksem. Operacje, które wykonujemy na strukturze PAM, dzielą się na te, które musimy wykonać na zbiorze partycji, oraz na te, które wykonujemy na strukturze indeksu. System nie wymaga żadnych specyficznych dla struktury operacji, wykorzystuje jedynie podstawowe procedury takie jak dodawanie, usuwanie i wyszukiwanie elementów w indeksie. Z tego powodu możemy użyć dowolnego indeksu w systemie PAM. Jednak nie każdy wybór będzie tak samo dobry. Po pierwsze, powinniśmy wybrać taką strukturę, która jest dostosowana do modelu pamięci PCM. Takimi strukturami są m.in. drzewo UB+ [136], OB+ [29] i DP [207]. Po drugie, struktura powinna wspierać operację dodawania zbiorczego (ang. *bulkload*), ponieważ kopiowanie danych z partycji do indeksu zazwyczaj odbywa się z udziałem dużych zbiorów danych. Po trzecie, ze względu na charakterystykę pamięci PCM (wolny zapis, szybki od-

czyt), struktura powinna buforować te części drzewa, które są często wczytywane, ale nie modyfikowane, w szybkiej pamięci RAM. Wszystkie trzy kryteria spełnia tylko indeks DP. Niestety DP-Tree nie jest dostosowany do systemów tworzenia indeksów częściowych. Nie jest w stanie w pełni wykorzystać faktu, że podczas kopiowania dane można podzielić na posortowane podzbiory, które można w szybki sposób dodać do indeksu. W przypadku, gdy podzbiór zapisany jako zakres wartości tworzy część wspólną z wartościami zapisanymi już w drzewie, trzeba dodać rekordy do istniejącego węzła. W przypadku, gdy jest to zbiór składający się z nowych wartości, wystarczy stworzyć nowy węzeł i podpiąć go do struktury drzewa. Zamiast tego drzewo DP buforuje dane w pamięci RAM, a następnie uniwersalnym i bardzo kosztownym algorytmem dodaje wszystkie rekordy z bufora do głównego drzewa zapisanego na pamięci PCM. Z tego powodu, w pracy poświęconej systemowi PAM [5], zaproponowaliśmy również indeks BB+ (Buffered B+), który nie tylko spełnia wszystkie trzy wcześniej wymienione kryteria, ale także jest dostosowany do systemów tworzenia częściowych indeksów.

7.3.5 Nowy indeks BB+ (buffered B+-Tree)

Struktura BB+ jest modyfikacją popularnego drzewa B+, inspirowaną po części indeksem DP-Tree. W szybkiej pamięci RAM zapisujemy dane, które powinny zostać dodane, oraz te, które powinny zostać usunięte z głównego indeksu. Dodatkowo węzły wewnętrzne, które głównie służą do wyznaczenia ścieżki z korzenia do liścia, również są buforowane, podobnie jak w strukturze DP. Liście drzewa zapisane są zawsze w pamięci PCM i nigdy nie są buforowane, ponieważ zawierają rekordy dodane przez użytkownika. Utrata tych danych podczas awarii systemu jest niedopuszczalna. Wszystkie pozostałe struktury można łatwo odzyskać. Węzły wewnętrzne odzyskujemy, budując drzewo na nowo na podstawie liści. Bufor dodanych i usuniętych rekordów możemy odzyskać z systemowego dziennika transakcji, dostępnego w popularnych systemach operacyjnych, takich jak Windows i Linux, oraz w silnikach baz danych, np. MySQL czy PostgreSQL.

Podczas analizy kwerend wykonywanych w systemie PAM zauważyliśmy, że raz zbudowany węzeł nie jest tak często modyfikowany jak w przypadku zwykłego indeksu. Dzieje się tak, ponieważ dane kopiowane z partycji do indeksu są rozłączne z rekordami już skopiowanymi. Zatem zbudowany węzeł jest bardzo często odczytywany, a jednocześnie rzadko modyfikowany. Z tego względu zdecydowaliśmy się na podział węzła w drzewie BB+ na dwie sekcje: posortowaną i nieposortowaną. Początkowo, gdy tworzymy węzeł, czy to przez kopiowanie danych z partycji, czy przez reorganizację drzewa BB+, podobną do znanej z indeksu B+, zapisujemy dane do części posortowanej. Kolejne odczyty tego węzła będą bardzo szybkie, ponieważ przejście po węźle odbywać się będzie za pomocą wyszukiwania binarnego. Podczas modyfikacji istniejącego węzła nowe dane dodawane są do sekcji nieposortowanej, tak jak w przypadku drzewa UB+. Tak samo jak w drzewie UB+, indeks BB+ posiada bitmapę dla każdego węzła, mówiącą, które dane są aktualne. Dzięki temu, zamiast reorganizować węzeł podczas każdego usuwania, zaznaczamy fakt usunięcia w bitmapie i kończymy procedurę usuwania. Jako efekt uboczny możliwe, że powstanie puste miejsce w środku jakiejś sekcji. Wypełnianie sekcji nieposortowanej jest tak samo tanie jak dodawanie rekordu na koniec węzła. Zatem traktujemy wypełnienie pustych miejsc w tej sekcji jako priorytet. Niestety, jeśli dodamy rekord w środek sekcji posortowanej, utracimy porządek tej sekcji. Wtedy przesuwamy wskaźniki obu sekcji, zmniejszając sekcję posortowaną i zwiększając nieposortowaną, tak aby nowy element oraz wszystkie elementy na prawo od niego znalazły się w sekcji nieposortowanej.

Podsumowując, nowa struktura BB+ posiada następujące cechy:

- Drzewo BB+ jest modyfikacją drzewa B+ w pełni dostosowaną do systemu PAM i pamięci PCM,
- W pamięci RAM buforuje elementy, które trzeba dodać i usunąć z głównego indeksu,
- Węzły wewnętrzne (ang. *internal nodes*) buforowane są w pamięci RAM,
- Liście zapisane są w nieulotnej pamięci PCM,
- Każdy węzeł podzielony jest na 2 sekcje: posortowaną i nieposortowaną,
- Rozmiar węzła dostosowany jest do architektury wykorzystania pamięci PCM. Jest wielokrotnością linii pamięci podręcznej procesora (ang. *cacheline*) lub jest równa stronie w pamięci RAM.

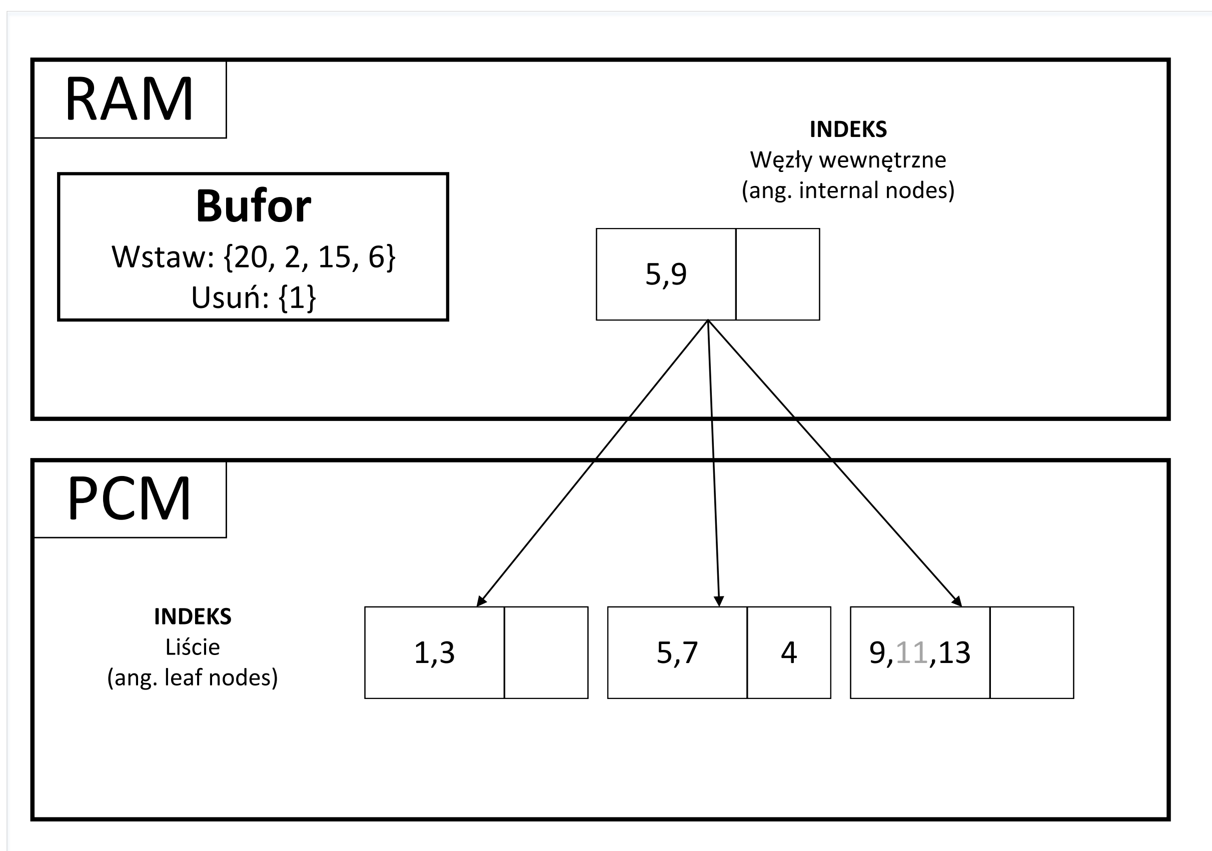

Rysunek 7.3: Przykładowy indeks BB+

Rysunek 7.3 przedstawia przykładowe drzewo BB+. Obecnie w buforze przetrzymujemy cztery rekordy, które należy dodać do drzewa oraz jeden rekord, który należy usunąć. Sama struktura podzielona jest na warstwy węzłów wewnętrznych, która również buforowana jest w szybkiej pamięci RAM oraz warstwę liści, która zapisana jest w pamięci PCM. Każdy węzeł podzielony jest na dwie sekcje. Sekcja posortowana znajduję się w lewej części węzła, a nieposortowana w prawej części. Przykładowo wartości 5 i 7 należą do części posortowanej liścia środkowego, a klucz o wartości 4 jest zapisany w sekcji nieposortowanej. Widzimy również, że wartość 11 w ostatnim liściu oznaczona jest kolorem szarym a nie czarnym. Oznacza to, że rekord 11 został usunięty przez użytkownika, co zostało

zaznaczone w bitmapie, nie wykonując przy tym fizycznego usuwania w pamięci. W następnych operacjach dodawania rekordów do tego węzła puste miejsce zostanie zapełnione przez nowe rekordy.

Pseudokod 7.2: bbpBulkload(input: Node *node*, Entry *entries*[ ])

```
1  if length(entries) = 0 then
2      return
3
4  if isLeaf(node) = TRUE then
5      bbpLeafInsert(node, entries)
6      return
7
8  Key lastMax := −∞
9
   // Idziemy z góry na dół do odpowiednich węzłów z podzbiorem o wartościach z zakresu
      < minKey,node.keys[i])
10 for i ← 1 to FANOUT do
11     Key minKey := lastMax
12
       // node.keys[FANOUT] ustalamy jako ∞
13     Key maxKey := node.keys[i]
14     lastMax := maxKey
15
       // Stwórz podzbiór slice z entries zawierający dane z zakresu < minKey, maxKey)
16     Entry slice[ ] := sliceMake(entries, minKey, maxKey)
17
       // Wykonaj rekurencyjnie
18     bulkload(node.child[i], slice)
```

Pseudokod 18 opisuje procedurę dodawania całego zbioru elementów do drzewa BB+. Algorytm wykonujemy rekurencyjnie, dlatego na początku musimy ustalić warunki zakończenia. Pierwszym warunkiem jest pusty zbiór wejściowy rekordów (linia 1). Jeśli zbiór ten jest pusty, nie mamy czego dodać do obecnego poddrzewa, więc kończymy ciąg wywołań rekurencyjnych dla tej części drzewa. Drugim warunkiem jest rodzaj węzła. Gdy osiągniemy poziom liści (linie 4-6), nie szukamy dalej poddrzew, ponieważ znaleźliśmy właściwy węzeł. Należy wówczas dodać elementy do wyznaczonego liścia, korzystając z funkcji `bbpLeafInsert` (algorytm 19). Od linii 8 zaczyna się właściwe ciało funkcji `bbpBulkload`. Celem każdego wywołania procedury jest wyznaczenie podzbioru elementów na podstawie wartości kluczy oraz rekurencyjne wywołanie algorytmu na poddrzewie i wyznaczonym podzbiorze. Korzystając z własności drzew B+, gdzie każdy wskaźnik wskazuje na węzły (poddrzewa) o wartościach mniejszych niż klucz wskaźnika, celujemy w zachowanie wszystkich własności strukturalnych drzewa. Dlatego podzbiory elementów, które mają być dodane, wyznaczane są w sposób analogiczny do ścieżki podczas wyszukiwania. Algorytm zaczyna się od ustawienia wartości ostatniego maksimum na $-\infty$ (linia 8). Następnie iterujemy po wszystkich wskaźnikach danego węzła (linia 10). W każdym przejściu pętli ustalamy minimum zbioru jako poprzednie maksimum, a maksimum zbioru jako wartość obecnego wskaźnika. Ponieważ wartość wskaźnika nie należy do poddrzewa,

na które wskazuje, tworzymy podzbiór z zakresu $< min, max)$, gdzie jest lewostronnie domknięty (linia 16). Gdy podzbiór jest gotowy, procedurę wykonujemy rekurencyjnie dla poddrzewa obecnego wskaźnika i utworzonego podzbioru.

Pseudokod 7.3: bbpLeafInsert(input: Node *node*, Entry *entries*[ ])

```
1  Node n = node
2  foreach Entry e ∈ entries do
       // Dodanie danych do usunięcia może doprowadzić do posiadania zbyt małego węzła. W
          tym przypadku scalamy węzły i aktualizujemy węzeł rodzica
3      if numValidEntries(n) < FANOUT/2 then
4          n = MergeNodes()
5          UpdateInnerNodes()
6
       // Dodanie nowych danych, może doprowadzić do przepełniani węzła. Wtedy dzielimy
          węzeł i aktualizujemy wskaźniki w węźle rodzica
7      if numValidEntries(n) > FANOUT then
8          n = SplitNode()
9          UpdateInnerNodes()
10
11     if e.ToDelete = TRUE then
12         delete(n,e)
13     else
           // Wstawianie danych do posortowanej części węzła jest kosztowne. Dlatego najpierw
              sprawdzamy, czy istnieje miejsce w części nieposortowanej
14         if existsGapInUnsorted(n) = TRUE then
15             insertIntoUnsortedGap(n,e)
16         else if unsortedNotFull(n) = TRUE then
17             insertIntoUnsorted(n,e)
18         else if existsGapInSorted(n) = TRUE then
19             insertIntoSortedGap(n,e)
```

Aby zminimalizować liczbę zapisów na pamięci PCM oraz zmaksymalizować korzyści wynikające ze wstawiania dużych, posortowanych zbiorów danych do drzewa, struktura BB+ składa się z węzłów podzielonych na dwie sekcje. Sekcja posortowana jest tworzona na początku życia węzła. Gdy alokujemy pamięć na nowy węzeł i zapisujemy do niego pierwsze posortowane elementy, wszystkie rekordy trafiają do sekcji posortowanej. Dzięki temu, gdy dominują kwerendy wyszukujące dane, możemy bardzo szybko przeprowadzić wyszukiwanie szukanego klucza. Jednocześnie, aby zminimalizować liczbę zapisów, nowe rekordy są dodawane głównie do sekcji nieposortowanej. Pseudokod 19 zawiera listę kroków algorytmu dodającego nowe klucze do węzła. Jako argument wejściowy procedura przyjmuje węzeł, na którym musi pracować, oraz zbiór danych, które trzeba dodać lub usunąć (zbiór rekordów może zawierać dane do usunięcia). Mimo że algorytm modyfikuje węzeł kilkukrotnie (w każdej iteracji pętli), należy pamiętać, że w rzeczywistości węzeł jest buforowany. Z pamięci PCM odczytujemy potrzebne fragmenty węzła do pamięci RAM, tam przeprowadzamy wszystkie modyfikacje, a następnie aplikujemy zmiany na pamięci

Model	Pojemność strony	Szybkość odczytu	Szybkość zapisu
Testowy Model PCM	64 B	6,4 GB/s	1,6 GB/s

Tabela 7.1: Parametry testowego modelu pamięci PCM [167]

PCM. Początkowo w każdej iteracji pętli sprawdzamy, czy modyfikacje węzła nie zaburzyły jego podstawowych własności. Jeśli węzeł jest zbyt mały, należy go scalić z innymi węzłami (linie 3-5). Analogicznie, jeśli węzeł nie jest w stanie pomieścić kolejnego rekordu, jest dzielony na dwa węzły (linie 7-9). Gdy jesteśmy pewni, że możemy przeprowadzić operację na węźle, sprawdzamy, czy rekord, który obecnie odczytujemy ze zbioru wejściowego, jest do usunięcia czy do dodania. Jeśli musimy usunąć rekord (linie 11-12), wyłączamy odpowiedni bit w bitmapie, ale nie usuwamy rekordu z pamięci. Dzięki bitmapie wiemy, że usunięty rekord jest nieaktualny i nie będziemy go brali pod uwagę podczas wyszukiwania czy kolejnego usuwania. Gdy dodajemy rekord, postępujemy zgodnie z ustalonymi priorytetami. Po pierwsze, jeśli istnieje przestrzeń do wypełnienia w sekcji nieposortowanej (linie 14-15), należy ją wypełnić. Po drugie, jeśli sekcja nieposortowana nie jest pełna, dodajemy kolejny rekord na koniec tej sekcji (linie 16-17). Gdy sekcja nieposortowana nie jest w stanie pomieścić kolejnego rekordu (linie 18-19), musimy dodać element do przestrzeni w sekcji posortowanej (przypadek, gdy sekcja posortowana jest również pełna, nie jest obsługiwany, ponieważ to oznacza, że węzeł należałoby podzielić). Niestety, po dodaniu elementu do części posortowanej, zaburzamy porządek tej sekcji. Należy zatem zmniejszyć część posortowaną i jednocześnie zwiększyć nieposortowaną. Opisane kroki wykonujemy dla każdego elementu znajdującego się w zbiorze danych wejściowych.

7.3.6 Eksperymenty

W tej części rozdziału przedstawimy i przeanalizujemy eksperymenty wykonane za pomocą symulatora SIPS, który został dokładnie opisany w rozdziale 4. Do eksperymentów wykorzystano model referencyjny pamięci PCM przedstawiony w [167]. Ten sam model został użyty do testów w [136], [161], [215]. Jest to zatem bardzo popularny model, który używa się do przedstawienia wyników w sytuacji, gdy nie mamy możliwości użycia realnej kości pamięci, która wymaga zakupu dość drogiego procesora (Intel Xeon Gold lub Platinum). Referencyjny model przedstawiony w tabeli 7.1 charakteryzuje się pojemnością strony (linii pamięci) równą pojemności strony pamięci podręcznej procesora (ang. *cache-line*). Ponieważ procesor wczytuje pełne strony pamięci podręcznej, równa ich wielkość wpływa korzystnie na szybkość wczytywania danych z pamięci PCM. Dodatkowo, model ten posiada szybkość zapisu na poziomie 1,6 GB/s oraz szybkość odczytu równą 6,4 GB/s. Jak widać, model posiada również bardzo dużą asymetrię pomiędzy wolną modyfikacją pamięci a bardzo szybkim odczytem. Jest to charakterystyka dobrze znana z pamięci flash i dysków SSD z niej zbudowanych. Wiemy zatem, że algorytmy minimalizujące liczbę zapisów osiągną największe korzyści z redukcji tej operacji. W testowanej bazie danych rola pamięci PCM jest podobna do zwykłego dysku. Jest to pamięć nieulotna, w której zapisujemy wszystkie dane trwałe. Nie służy ona do buforowania, gdyż do tego celu w naszej architekturze wykorzystujemy pamięć RAM. Z tego powodu, rozmiar węzłów drzew B+ został ustalony na wielkość 4 KB, czyli na rozmiar strony w RAM. Dzięki temu uzyskaliśmy mapowanie 1:1 z pamięcią PCM. Oczywiście pamięć ta jest bajtowo adresowalna. Oznacza to, że możemy w teorii odczytać dowolny pojedynczy bajt. W praktyce, kontroler pamięci pozwala na odczyt dowolnej strony (64 B). Zatem, mimo że wielkość węzła

w pamięci PCM jest równa 4 KB, to procesor będzie odczytywał potrzebne fragmenty o wielkości strony pamięci podręcznej 64 B. Eksperymenty zostały przeprowadzone na dwóch charakterystycznych tabelach popularnego zestawu kwerend TPC-C ([13]): Sklep oraz Klient. Charakterystyka tabel została dokładnie opisana w rozdziale 4.

Tworzenie pełnego indeksu

	AM	eAM	PAM
SERIA I (Sklep, 1%)	157 s	72 s	37 s
SERIA II (Sklep, 5%)	156 s	69 s	37 s
SERIA III (Klient, 1%)	905 s	313 s	223 s
SERIA IV (Klient, 5%)	902 s	309 s	221 s

Tabela 7.2: Całkowity czas wykonania zestawu kwerend

	AM	eAM	PAM
SERIA I (Sklep, 1%)	15,2 GB	4,8 GB	3 GB
SERIA II (Sklep, 5%)	15,2 GB	4,8 GB	3 GB
SERIA III (Klient, 1%)	68 GB	34 GB	22 GB
SERIA IV (Klient, 5%)	68 GB	34 GB	22 GB

Tabela 7.3: Zużycie pamięci (liczba nadpisanych i usuniętych gigabajtów)

Z rozdziałów 4 oraz 6 wiemy, że tworzenie pełnego indeksu to skomplikowany i często długi proces. Porównanie sumarycznych czasów nie jest wystarczające, aby zrozumieć charakterystykę systemów oraz ich słabe i mocne strony. Z tego względu porównujemy również czas każdej kwerendy. Ta seria eksperymentów ma na celu analizę systemów Adaptive Merging (AM), extended Adaptive Merging (eAM) oraz PCM Adaptive Merging (PAM) podczas procesu tworzenia indeksu. Każdy z tych systemów został dokładnie opisany w tym rozdziale. AM jest oryginalnym podejściem do tworzenia częściowego indeksu na pamięciach blokowych. eAM jest naszą modyfikacją oryginalnego algorytmu AM, dostosowaną do pamięci PCM, na tyle, na ile pozwalała architektura algorytmu AM. PAM to całkiem nowe podejście do tworzenia indeksu, w pełni dostosowane do modelu PCM, które dodatkowo potrafi współpracować z wieloma indeksami. Domyślnie, jak i w eksperymentach, w systemie PAM został użyty nowy indeks BB+.

Pierwsza seria eksperymentów polega na wykonaniu samych kwerend wyszukujących o ustalonej selektywności do momentu, gdy indeks nie zostanie w pełni utworzony. Dzięki temu będziemy mogli przeanalizować w pełni różnice i podobieństwa porównywanych

systemów. Każdy eksperyment rozpoczyna swoje działanie na bazie danych zawierającej 10 mln rekordów, które nie są w żaden sposób posortowane. Wykonujemy kolejne kwerendy z wyszukiwaniem losowym o podanej selektywności, w czasie których dodajemy odczytane rekordy do indeksu. Eksperyment kończy się, gdy indeks będzie w pełni utworzony.

W [139] pokazano bardzo dobry sposób na prowadzenie obserwacji takiego procesu. Sposób obserwacji został dokładnie opisany w rozdziale 4. Przypomnijmy jednak główne zasady. Autorzy wyznaczyli cztery fazy, które można wyróżnić w każdym algorytmie indeksowania.

1. **Sadzenie (ang. *planting*)** - Pierwsza faza sadzenia polega na inicjalizacji całego procesu. Początkowo trzeba skopiować tabele, wykonując przy tym pewne operacje potrzebne do rozpoczęcia procesu. Pierwsze kroki tego typu algorytmów zazwyczaj potrzebują więcej czasu niż prosty skan całej tabeli. Indeks zawiera na tyle mało elementów, że prawdopodobieństwo jego użycia jest niewielkie. Dlatego musimy wykonać drogie skanowanie oraz dodać kilka operacji potrzebnych na powiększenie indeksu. Podsumowując, pierwsza faza trwa dopóki czas obsługi kwerendy jest większy niż czas wykonania zwykłego, prostego skanu tabeli.

2. **Pielęgnacja (ang. *nursing*)** - Druga faza zaczyna się, gdy czas obsługi kwerendy jest mniejszy niż czas potrzebny na prosty skan, ale nadal większy niż w przypadku użycia pełnego indeksowania. W tej fazie zaczynamy korzystać z posortowanych partii danych, jednocześnie obniżając koszty dodatkowych operacji, ponieważ dodajemy coraz mniej danych do indeksu.

3. **Wzrastanie (ang. *growing*)** - Trzecia faza rozpoczyna się, gdy natrafiamy na zapytanie, które możemy obsłużyć w minimalnym czasie, czyli takim samym jak przy użyciu pełnego indeksu. W tym okresie indeks jest na tyle duży, że prawdopodobieństwo jego przydatności jest wysokie. W prawie każdej kwerendzie częściowo z niego korzystamy, jednak poza pojedynczymi przypadkami nie jesteśmy w stanie dorównać wyszukiwaniu w posortowanym zbiorze danych.

4. **Zbiory (ang. *harvesting*)** - Ostatnia faza zbiorów zaczyna się, gdy indeks jest w pełni stworzony, a zatem nie mamy już czasowych narzutów na jego tworzenie. Czas na obsługę zapytania jest taki sam jak przy użyciu pełnego indeksu.

Aby zbadać wszystkie zmienne, które mogą wpłynąć na charakterystykę wyników, przeprowadziliśmy cztery serie testów. Każda z nich wykonywała wyszukiwania o wzorcu losowym, który najlepiej oddaje naturę hurtowni danych. Taki serwer ma tak wielu użytkowników, że mimo iż każdy z nich tworzy zapytania według jakiegoś wzorca, to łącząc wszystkie kwerendy w ciąg, zapytania wyglądają jak przypadkowe (losowe).

1. SERIA I - Tworzymy pełny indeks na tabeli Sklep, używamy do tego wyszukiwań z zakresu kluczy o selektywności 1%.

2. SERIA II - Tworzymy pełny indeks na tabeli Sklep, używamy do tego wyszukiwań z zakresu kluczy o selektywności 5%.

3. SERIA III - Tworzymy pełny indeks na tabeli Klient, używamy do tego wyszukiwań z zakresu kluczy o selektywności 1%.

4. SERIA IV - Tworzymy pełny indeks na tabeli Klient, używamy do tego wyszukiwań z zakresu kluczy o selektywności 5%.

Tabela 7.2 zawiera dokładny sumaryczny czas, jaki uzyskały algorytmy częściowego indeksowania na testowym modelu PCM. Dodatkowo, tabela 7.3 zawiera całkowite zużycie pamięci PCM, czyli liczbę gigabajtów nadpisaną i usuniętą podczas procesu tworzenia pełnego indeksu. Widzimy, że selektywność nie wpływa znacząco na czas ani na zużycie pamięci. Sytuacja ma miejsce w przypadku użycia każdego z porównywanych systemów. Dzieje się tak, ponieważ pamięć PCM nie jest blokowa, tak jak dysk SSD. Oznacza to, że jednoczesny odczyt ogromnych zbiorów danych jest porównywalnie szybki, jak kilkaset mniejszych odczytów. Analogiczna sytuacja ma miejsce podczas zapisywania. Dlatego zużycie pamięci jest dokładnie takie samo w przypadku obu selektywności (1% i 5%). Oczywistym faktem jest, że tabela o większym rekordzie zajmuje więcej miejsca na dysku. Zatem praca na tabeli Klient zajmuje więcej czasu oraz zużywa więcej zasobów niż praca na tabeli Sklep. Można zaobserwować, że czas jak i zużycie pamięci rośnie liniowo wraz z rosnącym rozmiarem rekordu. Warto nadmienić, że system eAM uzyskał dwukrotnie lepszy czas od oryginalnego systemu AM podczas pracy na tabeli Sklep oraz trzy razy lepszy czas podczas pracy na tabeli Klient. Dodatkowo, nowy system PAM uzyskał średnio 4 razy lepszy czas przy wykorzystaniu obu tabel. Znacząco też poprawiło się zużycie pamięci. Algorytm PAM wykonał 5 razy mniej modyfikacji w przypadku tabeli Sklep oraz 3 razy mniej w przypadku tabeli Klient. W każdej serii czas oraz zużycie pamięci przez algorytm eAM było zawsze lepsze od oryginalnego AM, a wyniki uzyskane przez system PAM były zawsze najlepsze w przeprowadzonych testach.

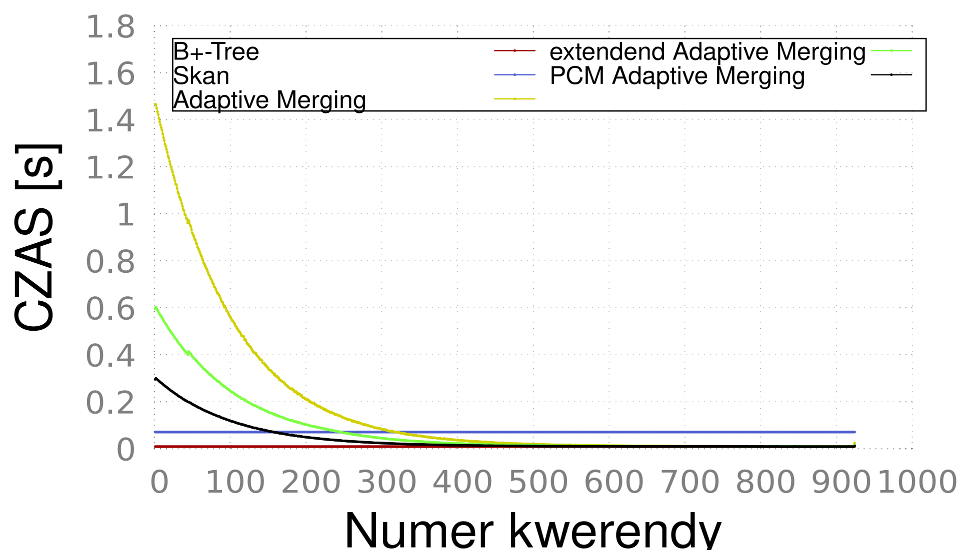

Rysunek 7.4: Czas tworzenia pełnego indeksu
Selektywność 1%
Tabela: Sklep (113 B)

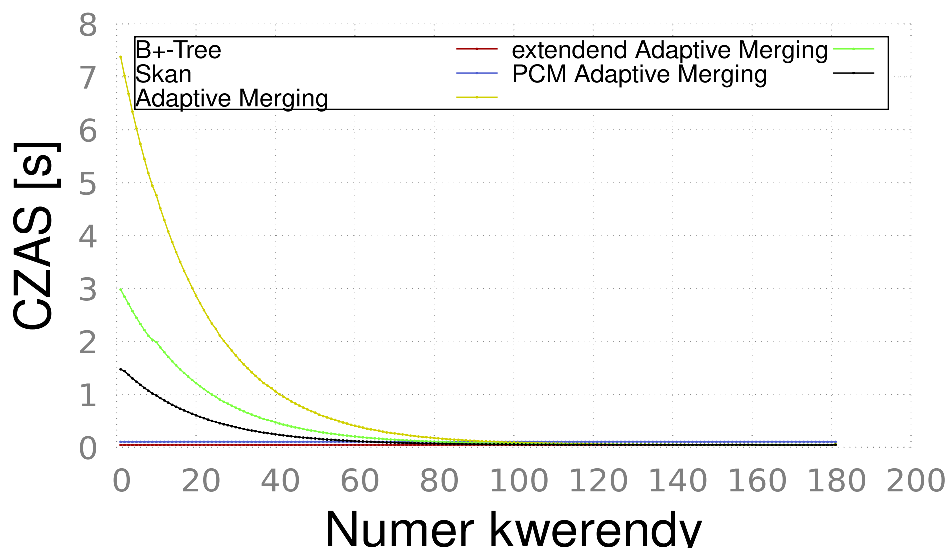

Rysunek 7.5: Czas tworzenia pełnego indeksu
Selektywność 5%
Tabela: Sklep (113 B)

Przeanalizujmy teraz wyniki serii I dla tabeli Sklep. Przy badaniu każdej kwerendy użyliśmy również pełnego indeksu B+ oraz pełnego skanowania tabeli jako punktów odniesienia. Rysunki 7.4 i 7.5 przedstawiają czas uzyskany przez wszystkie użyte algorytmy dla każdej z kwerend odpowiednio dla wyszukiwań z selektywnością na poziomie 1% i 5%. Na wstępie możemy zauważyć, że mimo iż selektywność nie wpływała na całkowity czas wykonania zestawu kwerend, to ma ona wpływ na liczbę kwerend potrzebną do zbudowania pełnego indeksu. Jest to związane z tym, że przy większej selektywności odczytujemy więcej danych jednocześnie, co skutkuje kopiowaniem większej ilości danych do indeksu. Dlatego proces tworzenia pełnego indeksu przy wykorzystaniu kwerend wyszukujących o selektywności 1% trwał 920 kwerend, a przy 5% tylko 178. Selektywność nie miała wpływu na trend widoczny na obu wykresach. Zawsze system PAM osiągał najlepszy czas obsługi kwerendy, a oryginalny AM był najgorszy. Dodatkowo, algorytm PAM najszybciej osiągał kolejne fazy budowania częściowego indeksu. Przy selektywności 1% fazę pielęgnacji osiągnął już w 134 kwerendzie (AM dopiero w 328), a fazę wzrostu już w 402 kwerendzie (AM dopiero w 605). Analizując wykresy 7.6 i 7.7, widzimy, że tak samo jak selektywność, również rozmiar rekordu nie wpływa na charakterystykę trendu. Ponownie system PAM był najszybszy, a oryginalny AM najwolniejszy. Warto jednak zauważyć, że rozmiar rekordu tabeli wpływa na czas uzyskania kolejnych faz przez wszystkie algorytmy. Poprzednio, przy pracy na tabeli Sklep, system PAM osiągnął fazę II przy 134 i 65 kwerendzie odpowiednio dla serii I (selektywność 1%) i II (selektywność 5%). Tym razem, dla tych samych selektywności, algorytm PAM osiągnął fazę pielęgnacji w 298 i 72 kwerendzie. Oznacza to, że im większy rekord, tym dłużej trzeba czekać, aż systemy tworzenia częściowego indeksu będą w stanie obsłużyć kwerendę szybciej niż procedura pełnego skanowania tabeli. Wynika to z dużej asymetrii pomiędzy czasem operacji zapisu i odczytu. Różnica w referencyjnym modelu PCM jest tak duża, że szybciej jest liniowo odczytać całą bazę danych niż dodawać nowe rekordy do indeksu. Oczywiście, taka sytuacja kończy się wraz z zakończeniem fazy sadzenia, kiedy to mamy tyle danych w indeksie, że system jest szybszy niż proste skanowanie bazy.

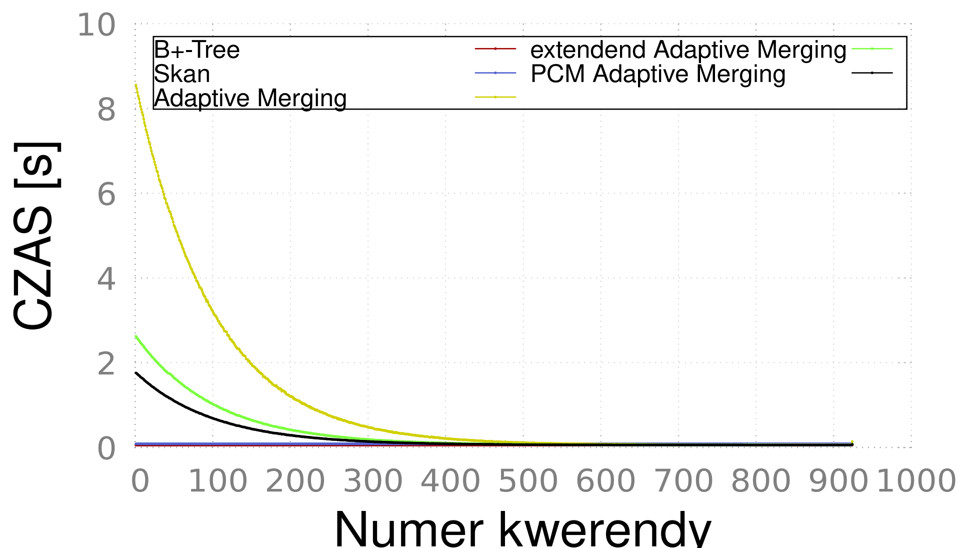

Rysunek 7.6: Czas tworzenia pełnego indeksu
Selektywność 1%
Tabela: Klient (719 B)

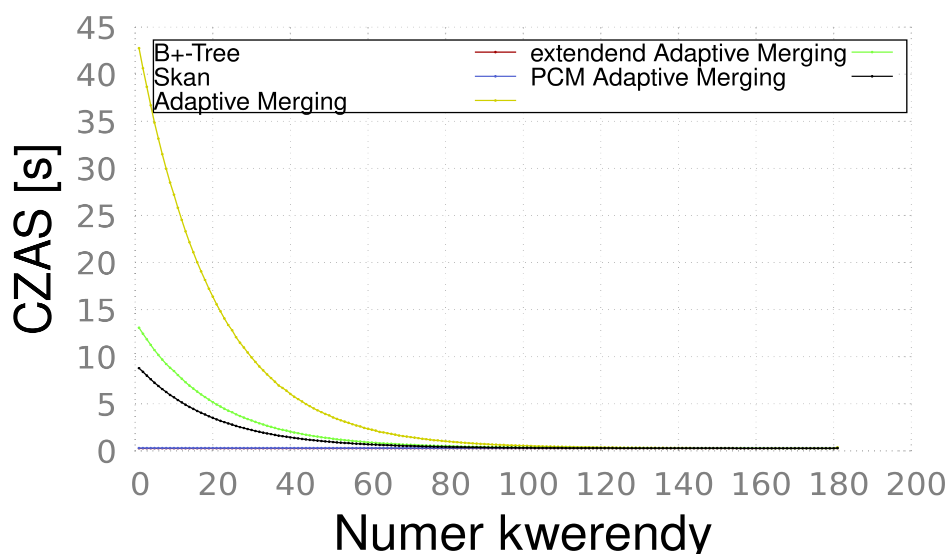

Rysunek 7.7: Czas tworzenia pełnego indeksu
Selektywność 5%
Tabela: Klient (719 B)

Rozszerzony zestaw kwerend

W poprzedniej sekcji zbadaliśmy sam proces tworzenia częściowego indeksu. Zazwyczaj do bazy trafiają różne kwerendy, a nie tylko zapytania wyszukujące rekordy po kluczu. Dlatego w tej części rozdziału przeanalizujemy wyniki otrzymane podczas wykonywania kwerend z zestawu rozszerzonego. Charakterystyka wszystkich czterech zestawów opisana w rozdziale 4 jest następująca:

1. ZR_{A} - 100 serii, każda seria zawiera operacje dodawania 5 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 5 rekordów,

2. ZR_B - 5 serii, każda seria zawiera operacje dodawania 100 000 rekordów, 5 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 100 000 rekordów,
3. ZR_C - 10 serii, każda seria zawiera operacje dodawania 10 000 000 rekordów, 20 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 1 000 000 rekordów,
4. ZR_D - 10 serii, każda seria zawiera operacje dodawania 1 000 000 rekordów, 10 wyszukiwań o podanej selektywności (domyślnie 1%) oraz usuwanie 10 000 rekordów.

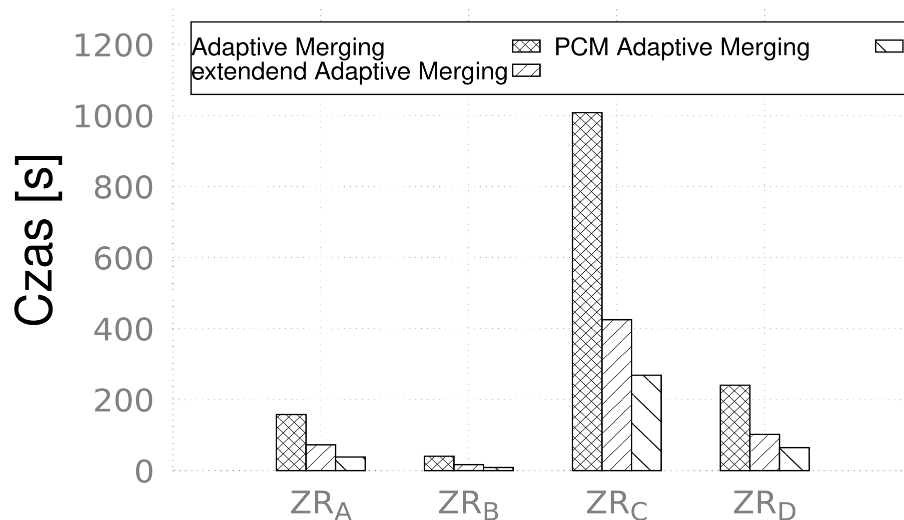

Rysunek 7.8: Czas zestawów kwerend
Selektywność 1%
Tabela: Sklep (113 B)

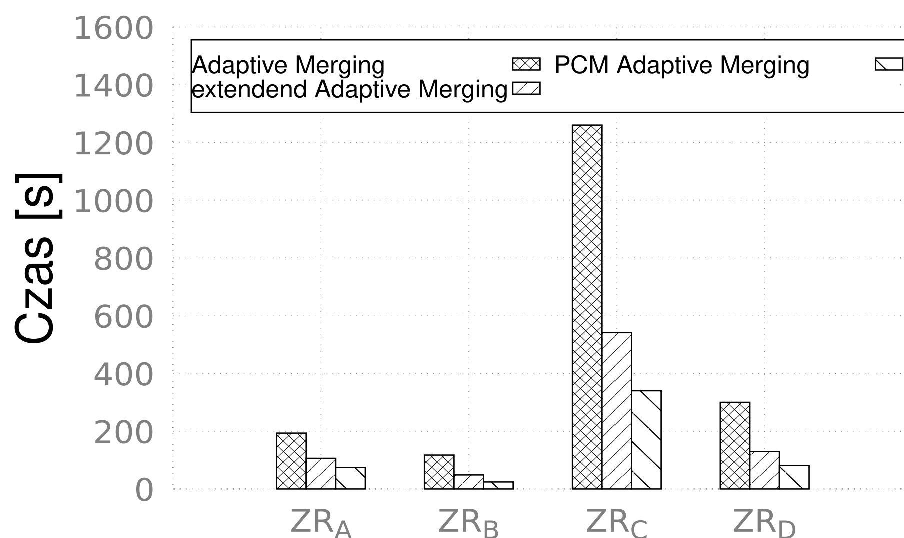

Rysunek 7.9: Czas zestawów kwerend
Selektywność 5%
Tabela: Sklep (113 B)

Przeanalizujmy zatem wyniki eksperymentów przeprowadzonych z użyciem zestawu rozszerzonego. Wykresy 7.8 i 7.9 przedstawiają wyniki testów przeprowadzonych na tabeli Sklep z kwerendami wyszukującymi o selektywności odpowiednio 1% i 5%. Widzimy, że selektywność nie ma dużego wpływu na rezultaty. Pamięć PCM charakteryzuje się bardzo szybkim odczytem i o wiele wolniejszym zapisem. W zestawie dominującym operacjami dodawania lub usuwania rekordów, czas potrzebny na wyszukiwanie jest znikomy w porównaniu do czasu modyfikacji bazy. Również oczywistym faktem jest, że zestaw ZR_C, który zawiera najwięcej operacji dodawania i usuwania, wykonywał się najwolniej ze wszystkich zestawów. Analogicznie zestawy ZR_A i ZR_B, które skupiają się głównie na wyszukiwaniach, wykonywały się najszybciej. W każdym zestawie, niezależnie od selektywności, najwolniejszy był system Adaptive Merging, a najszybszy PCM Adaptive Merging. W zestawach dominujących odczytami, PAM był czterokrotnie szybszy od AM, a w zestawie ZR_C nawet sześciokrotnie szybszy od oryginalnego algorytmu. Rysunki 7.10 i 7.11 przedstawiają wyniki tego samego zestawu kwerend, przeprowadzonego na tabeli Klient, również z selektywnościami ustawionymi odpowiednio na 1% i 5%. Analizując wyniki testów, możemy dojść do tych samych wniosków co przy testach na tabeli Sklep. Ponownie selektywność nie ma dużego wpływu na czas obsługi całego zestawu. Kolejny raz system AM był najwolniejszy, a system PAM najszybszy. Tym razem w zestawach ZR_A i ZR_B, PAM uzyskał trzykrotną przewagę (wcześniej była czterokrotna), a w zestawach ZR_C i ZR_D, algorytm PAM był czterokrotnie szybszy (wcześniej nawet sześciokrotnie) od oryginalnego algorytmu AM. Możemy również zauważyć, że czas obsługi każdego z zestawów rośnie bardzo podobnie wraz ze wzrostem rozmiaru rekordu. Przykładowo, dla rekordu z tabeli Sklep, system PAM potrzebował 1050s aby wykonać zestaw ZR_C przy ustalonej selektywności na 1%. Ten sam zestaw, algorytm wykonywał 5,62 razy dłużej dla rekordu z tabeli Klient, którego rekord jest 6.3 razy większy niż rekord tabeli Sklep.

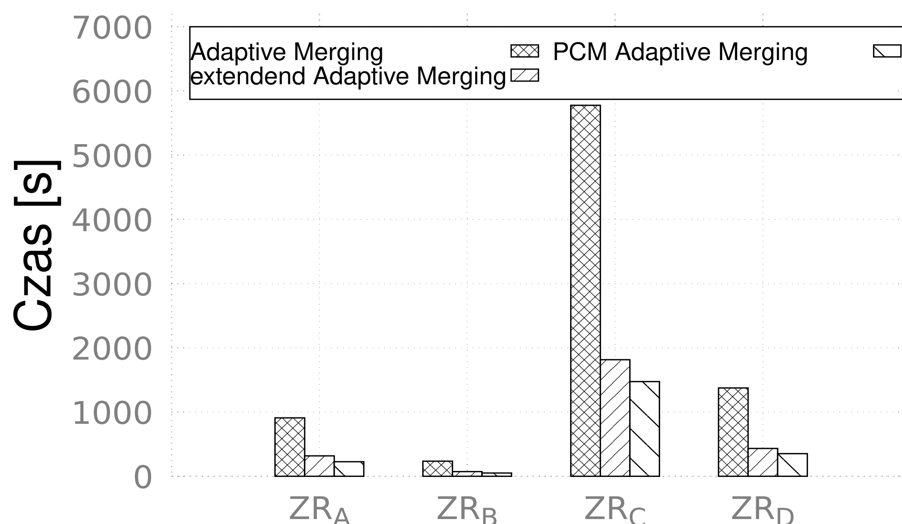

Rysunek 7.10: Czas zestawów kwerend
Selektywność 1%
Tabela: Klient (719 B)

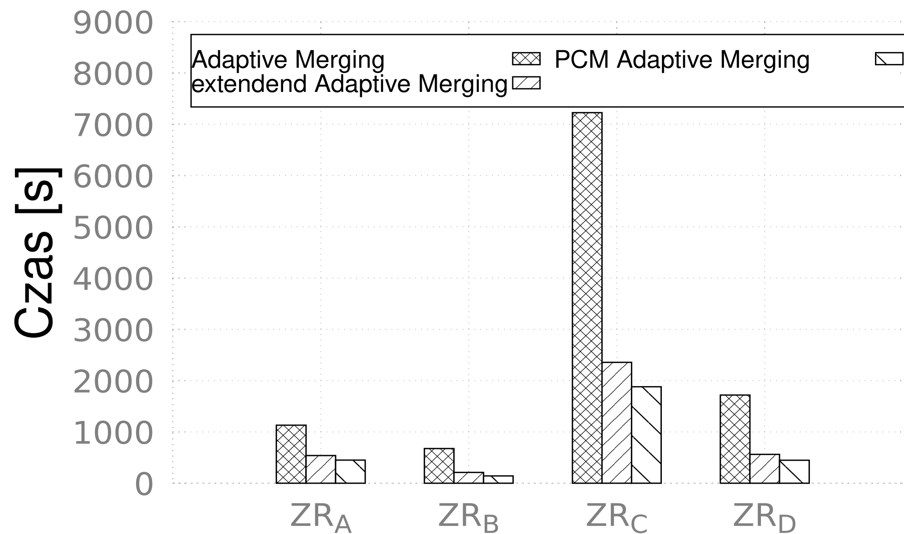

Rysunek 7.11: Czas zestawów kwerend
Selektywność 5%
Tabela: Klient (719 B)

Podsumowując, system PAM radzi sobie świetnie nie tylko w przypadku samego wyszukiwania, ale także w sytuacji, gdy baza danych jest modyfikowana, a indeks nie jest jeszcze w pełni stworzony. Wprowadzenie dzienników, które minimalizują liczbę modyfikacji pamięci, znacząco przyspieszyło operacje oznaczania danych jako usuniętych. Dodatkowo, indeks BB+ jest w pełni przystosowany do obsługi kwerend, które są typowe dla systemów częściowego indeksowania. Oba te główne usprawnienia sprawiają, że system PAM nie tylko osiąga wyniki nawet czterokrotnie lepsze od oryginalnego algorytmu Adaptive Merging, ale także jest dwukrotnie bardziej wydajny niż dostosowana do PCM wersja eAM.

Zakończenie

8.1 Podsumowanie

Praca poświęcona jest indeksowaniu baz danych na różnych nowoczesnych typach pamięci, takich jak pojedyncze kości flash, dyski SSD oraz pamięć zmiennofazowa PCM. W dzisiejszych czasach indeks to nie tylko prosta struktura danych wyposażona w podstawowe procedury, to często duży, rozbudowany system, który uwzględnia wiele czynników, m.in. charakterystykę pamięci. Dotyczy to w szczególności ograniczeń liczby możliwych usunięć danych z komórek pamięci, jak również asymetrii pomiędzy kosztami zapisu i odczytu. Efektywny sposób indeksowania rekordów nie tylko powinien minimalizować czas potrzebny na wykonanie kwerendy, ale także powinien wydłużać czas życia nowych nośników pamięci. Niestety szybkie pamięci, takie jak dyski SSD oraz PCM, posiadają ograniczenia wynikające z fizycznych limitów surowca użytego do budowy dysku. W hurtowniach danych codziennie zapisuje się terabajty informacji. W tym kontekście minimalizacja zużycia pamięci jest bardzo istotna nie tylko z punktu widzenia ekonomicznego, ale także ekologicznego.

Algorytm indeksowania musi być bezpieczny. Oznacza to, że wszystkie dane, które są w nim zapisane, muszą zostać nienaruszone podczas awarii systemu. Mimo to, algorytmy indeksujące bardzo często używają różnych technik buforowania, aby przyspieszyć wykonywanie zapytań. Informacje te zapisywane są w ulotnej pamięci RAM, a w chwili awarii systemu tracone. Zatem bardzo ważnym aspektem takich algorytmów jest zdolność przywrócenia stanu przed awarią. Z reguły jest to realizowane poprzez odtworzenie wszelkich utraconych danych na podstawie innych informacji zapisanych na dysku.

Pierwszym głównym celem pracy jest analiza popularnych algorytmów i systemów wykorzystywanych w silnikach baz danych do indeksowania rekordów. Drugim celem jest opracowanie nowych metod indeksowania oraz implementacja zaprojektowanych struktur danych. W pracy zaproponowano kilka nowych algorytmów i systemów porządkowania danych, realizujących indeksowanie rekordów. Każdy z algorytmów przeanalizowano, dołączając analizę teoretyczną złożoności obliczeniowej oraz dowód poprawności.

W rozdziale **5** omówiono algorytmy indeksujące rekordy na pamięci flash. Przedstawiono także nowy algorytm indeksowania FA-Tree (ang. Flash Aware Tree) [1]. Zaproponowana struktura danych FA-Tree osiągała nawet 20-krotnie lepszy czas obsługi kwerend zorientowanych na modyfikacje bazy od klasycznego indeksu opartego na drzewie B+. Jednocześnie indeks FA-Tree zużył 6-krotnie mniej pamięci od drzewa B+.

W rozdziale **6** omówiono sposoby indeksowania danych zapisanych na dyskach SSD. Przedstawiono nowe algorytmy indeksowania danych, takie jak wierszowy indeks FALSM-Tree (ang. Flash Aware LSM-Tree) [2], strukturę w pełni dostosowaną do dysków SSD jak i wspierającą operację dodawania zbiorczego rekordów (ang. bulkload). Dzięki wprowadze-

niu nowej metody dodawania rekordów, czas obsługi takiej kwerendy został zredukowany aż 6-krotnie względem oryginalnego indeksu LSM. Dodatkowo warto również zauważyć, że eksperymenty przeprowadzone na zestawach TPC-C wykazały, że nowy algorytm nadpisywał nawet 6-krotnie mniej pamięci. Zatem znacząco wydłużył czas życia dysków SSD.

W tym samym rozdziale omówiono także całkiem nowy kolumnowy indeks CFT (ang. Columned FD-Tree) [3]. Indeks ten jest zbiorem struktur danych typu FD-Tree połączonych ze sobą specjalnie zaprojektowanymi metadanymi. Mimo kolumnowego ułożenia, indeks CFT osiągał czas modyfikacji struktury mocno zbliżony do czasu wykonania modyfikacji przez oryginalne wierszowe podejście z wykorzystaniem drzewa FD. Maksymalne odchylenie na niekorzyść kolumnowego indeksu wynosiło 6%.

W tym samym rozdziale również przedstawiono nowy mechanizm indeksowania częściowego LAM (ang. Lazy Adaptive Merging) [4]. System ten jest w pełni przystosowany do charakterystyki dysków SSD. Nie tylko osiągał 2-krotnie lepsze wyniki od algorytmu AM podczas tworzenia samego indeksu, ale także wykonywał kwerendy modyfikujące tabelę średnio o 15% szybciej.

W rozdziale **7** omówiono indeksowanie baz danych używających pamięć zmiennofazową PCM do przechowywania danych. Przedstawiono także nową strukturę danych BB+-Tree (ang. Buffered B+-Tree) oraz nowy sposób częściowego indeksowania dostosowanego do pamięci PCM - PAM (ang. PCM Adaptive Merging) [5]. Wyniki pokazują ogromną przewagę nowego przedstawionego systemu nad oryginalnym algorytmem Adaptive Merging. Algorytm PAM stworzył indeks nawet 5-krotnie szybciej, modyfikując także 5-krotnie mniej pamięci, co znacząco wydłużyło żywotność tego nośnika pamięci.

8.2 Dalsze kierunki badań

Technologia rozwija się w bardzo szybkim tempie. Jeszcze 20 lat temu, dyski HDD o pojemności 10 GB wystarczały na zapisanie wszystkich potrzebnych plików i danych. Dziesięć lat temu dyski o pojemności 256 GB były powszechnie używane i uznawane za dostatecznie pojemne. Obecnie każdy w komputerze osobistym posiada dyski o pojemności od 1 do 4 TB, co i tak nie wystarcza, aby pomieścić wszystkie potrzebne pliki, takie jak zdjęcia i filmy o wysokiej rozdzielczości. Prawo Moore'a ([216]) dokładnie opisuje to zjawisko. Wedle tej teorii, liczba danych potrzebnych ludzkości rośnie wykładniczo z roku na rok, a co za tym idzie, liczba tranzystorów i komórek pamięci również musi rosnąć wykładniczo, aby zaspokoić potrzeby rynkowe [217].

Szybko rosnąca potrzeba na przechowywanie coraz większej ilości danych powoduje nie tylko zwiększanie pojemności dysków w hurtowniach danych, np. poprzez użycie pamięci NAND QLC [218], która pozwala na zapis większej ilości danych przy podobnym koszcie modelu pamięci, ale także wymusza na dostawcach oprogramowania ulepszanie algorytmów przetwarzających te dane. Jedną z podstawowych technik optymalizacji jest zrównoleglenie niektórych operacji: zbiorczego dodawania (ang. *bulkload*) [219], odczytywania tabeli (ang. *scan*) [220], czy łączenia danych z tabeli (ang. join) [221]. Zazwyczaj silniki baz danych, które wykorzystują pełny potencjał procesora poprzez użycie wielu wątków, osiągają o wiele lepsze wyniki od silników jednowątkowych [222], [223].

Potrzeba polepszenia wydajności w procesie przetwarzania danych spowodowała adopcję nowych komponentów sprzętowych w hurtowniach danych. Wprowadzone nowe mo-

dele dysków SSD z interfejsem PCIe 4.0 osiągają szybkość odczytu na poziomie aż 7 GB/s, a modele z interfejsem PCIe 5.0 posiadają prędkość odczytu sięgającą nawet do 10 GB/s. Najnowsze modele dysków SSD borykają się z problemem nadmiernego nagrzewania się, przy ciągłym użyciu dysku na maksymalnym poziomie. Gdy taka sytuacja ma miejsce, kontroler obniża wydajność dysku, aby uchronić go przed nadmiernym przegrzaniem (ang. *thermal throttling*) [**?**]. Aby tego uniknąć, silnik baz danych powinien odpowiednio rozdzielać zadania tak, aby przetwarzać dane podzielone na zbiory w taki sposób, żeby dysk miał czas na schłodzenie, a procesor w tym czasie wykonał swoje zadanie. Dzięki temu kontroler dysku dostosuje pobieraną moc przez model dysku, co skutkuje mniejszymi temperaturami, przekładającymi się na większą sumaryczną wydajność [224].

Kolejnym ciekawym nurtem jest użycie kart graficznych (ang. GPU) do przetwarzania niektórych danych. Karta graficzna posiada kompletnie inną architekturę od zwykłych procesorów: o wiele wolniej wykonuje operacje decyzyjne, jednocześnie posiada bardzo wysoką wydajność operacji arytmetycznych jak i prostej obróbki danych [225], [226]. Z tego względu w ciągu kilku minionych lat zostało zaproponowanych wiele algorytmów wykorzystujących GPU w hurtowniach danych [227], [228], [229], [230].

Każde z wcześniej wymienionych problemów i trendów wymaga wprowadzania coraz to nowych algorytmów i usprawnień, aby nadążyć za problemami rynku. Uważam, że wymienione przeze mnie problemy mogą zostać głębiej przestudiowane w ramach rozszerzenia tej pracy.

Bibliografia

[1] W. Macyna and M. Kukowski, "Flash-aware clustered index for mobile databases," in *2018 International Conference on Industrial Enterprise and System Engineering (ICoIESE 2018)*, pp. 25–30, Atlantis Press, 2019.

[2] W. Macyna and M. Kukowski, "Bulk loading of the secondary index in lsm-based stores for flash memory," in *European Conference on Advances in Databases and Information Systems*, pp. 133–143, Springer, 2022.

[3] W. Macyna and M. Kukowski, "Flash-aware storage of the column oriented databases," *Fundamenta Informaticae*, vol. 173, no. 1, pp. 47–72, 2020.

[4] W. Macyna and M. Kukowski, "Partially indexing on flash memory," in *International Conference on Database and Expert Systems Applications*, pp. 95–105, Springer, 2019.

[5] M. Kukowski and W. Macyna, "Adaptive merging on phase change memory," *Fundamenta Informaticae*, vol. 188, 2023.

[6] A. Bhattacharya, *Fundamentals of database indexing and searching.* CRC Press, 2014.

[7] E. Bertino, B. C. Ooi, R. Sacks-Davis, K.-L. Tan, J. Zobel, B. Shidlovsky, and D. Andronico, *Indexing techniques for advanced database systems*, vol. 8. Springer Science & Business Media, 2012.

[8] Y. Manolopoulos, Y. Theodoridis, and V. Tsotras, *Advanced database indexing*, vol. 17. Springer Science & Business Media, 2012.

[9] S. S. Lightstone, T. J. Teorey, and T. Nadeau, *Physical Database Design: the database professional's guide to exploiting indexes, views, storage, and more.* Morgan Kaufmann, 2010.

[10] V. Bhagat and A. Gopal, "Comparative study of row and column oriented database," in *2012 Fifth International Conference on Emerging Trends in Engineering and Technology*, pp. 196–201, IEEE, 2012.

[11] D. J. Abadi, S. R. Madden, and N. Hachem, "Column-stores vs. row-stores: how different are they really?," in *Proceedings of the 2008 ACM SIGMOD international conference on Management of data*, pp. 967–980, 2008.

[12] A. S. Kanade and A. Gopal, "Choosing right database system: Row or column-store," in *2013 International Conference on Information Communication and Embedded Systems (ICICES)*, pp. 16–20, IEEE, 2013.

[13] S. T. Leutenegger and D. Dias, "A modeling study of the tpc-c benchmark," in *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data*, SIGMOD '93, (New York, NY, USA), p. 22–31, Association for Computing Machinery, 1993.

[14] "Tpc-h – transaction performance council." http://www.tpc.org.

[15] G. Graefe and H. Kuno, "Self-selecting, self-tuning, incrementally optimized indexes," in *Proceedings of the 13th International Conference on Extending Database Technology*, EDBT '10, (New York, NY, USA), pp. 371–381, ACM, 2010.

[16] C. J. Date, *An introduction to database systems.* Pearson Education India, 1975.

[17] H. Garcia-Molina, *Database systems: the complete book.* Pearson Education India, 2008.

[18] M. Athanassoulis and S. Idreos, "Design tradeoffs of data access methods," in *Proceedings of the 2016 International Conference on Management of Data*, pp. 2195–2200, 2016.

[19] S. P. Ghosh and M. E. Senko, "File organization: on the selection of random access index points for sequential files," *Journal of the ACM (JACM)*, vol. 16, no. 4, pp. 569–579, 1969.

[20] R. J. Srodawa and L. A. Bates, "An efficient virtual machine implementation," in *Proceedings of the workshop on virtual computer systems*, pp. 43–73, 1973.

[21] R. Bayer and E. M. McCreight, "Organization and maintenance of large ordered indexes," *Acta Informatica*, vol. 1, pp. 173–189, Sep 1972.

[22] B. Bloom, "Space/time trade-offs, in, hash, coding, with," *Communications, of, A CM,, pages*, 1970.

[23] L. Qiaoyu, L. Jianwei, and X. Yubin, "Performance analysis of data organization of the real-time memory database based on red-black tree," in *2010 International Conference on Computing, Control and Industrial Engineering*, vol. 1, pp. 428–430, IEEE, 2010.

[24] C. C. Foster, "A generalization of avl trees," *Communications of the ACM*, vol. 16, no. 8, pp. 513–517, 1973.

[25] J.-I. Aoe, K. Morimoto, and T. Sato, "An efficient implementation of trie structures," *Software: Practice and Experience*, vol. 22, no. 9, pp. 695–721, 1992.

[26] D. R. Morrison, "Patricia—practical algorithm to retrieve information coded in alphanumeric," *Journal of the ACM (JACM)*, vol. 15, no. 4, pp. 514–534, 1968.

[27] Y. Li, B. He, R. J. Yang, Q. Luo, and K. Yi, "Tree indexing on solid state drives," *Proceedings of the VLDB Endowment*, vol. 3, no. 1-2, pp. 1195–1206, 2010.

[28] D. Agrawal, D. Ganesan, R. Sitaraman, Y. Diao, and S. Singh, "Lazy-adaptive tree: An optimized index structure for flash devices," *Proceedings of the VLDB Endowment*, vol. 2, no. 1, pp. 361–372, 2009.

[29] P. Chi, W.-C. Lee, and Y. Xie, "Making b+-tree efficient in pcm-based main memory," in *Proceedings of the 2014 international symposium on Low power electronics and design*, pp. 69–74, 2014.

[30] L. Li, P. Jin, C. Yang, S. Wan, and L. Yue, "Xb+-tree: A novel index for pcm/dram-based hybrid memory," in *Australasian Database Conference*, pp. 357–368, Springer, 2016.

[31] L. Li, P. Jin, C. Yang, Z. Wu, and L. Yue, "Optimizing b+-tree for pcm-based hybrid memory.," in *EDBT*, pp. 662–663, 2016.

[32] G. P. Copeland and S. N. Khoshafian, "A decomposition storage model," *Acm Sigmod Record*, vol. 14, no. 4, pp. 268–279, 1985.

[33] M. Stonebraker, D. J. Abadi, A. Batkin, X. Chen, M. Cherniack, M. Ferreira, E. Lau, A. Lin, S. Madden, E. O'Neil, *et al.*, "C-store: a column-oriented dbms," in *Making Databases Work: the Pragmatic Wisdom of Michael Stonebraker*, pp. 491–518, 2018.

[34] D. Abadi, P. Boncz, S. Harizopoulos, S. Idreos, S. Madden, *et al.*, "The design and implementation of modern column-oriented database systems," *Foundations and Trends® in Databases*, vol. 5, no. 3, pp. 197–280, 2013.

[35] F. Yu, T. J. Matacic, B. J. Latronica, and W.-C. Hou, "Ob-tree: a new write optimisation index on out-of-core column-store databases," *International Journal of Intelligent Information and Database Systems*, vol. 11, no. 1, pp. 46–66, 2018.

[36] M. Boissier, T. Djürken, R. Schlosser, and M. Faust, "A cost-aware and workload-based index advisor for columnar in-memory databases," in *International Conference on Information and Software Technologies*, pp. 285–299, Springer, 2016.

[37] D. Tsirogiannis, S. Harizopoulos, M. A. Shah, J. L. Wiener, and G. Graefe, "Query processing techniques for solid state drives," in *Proceedings of the 2009 ACM SIGMOD International Conference on Management of data*, pp. 59–72, 2009.

[38] E. V. Ivanova and L. B. Sokolinsky, "Parallel processing of very large databases using distributed column indexes," *Programming and Computer Software*, vol. 43, no. 3, pp. 131–144, 2017.

[39] A. Floratou, J. Patel, E. Shekita, and S. Tata, "Column-oriented storage techniques for mapreduce," *arXiv preprint arXiv:1105.4252*, 2011.

[40] K.-C. Kim and C.-S. Kim, "Parallel processing of sensor network data using column-oriented databases," *AASRI Procedia*, vol. 5, pp. 2–8, 2013.

[41] D. Abadi, S. Madden, and M. Ferreira, "Integrating compression and execution in column-oriented database systems," in *Proceedings of the 2006 ACM SIGMOD international conference on Management of data*, pp. 671–682, 2006.

[42] C. Binnig, S. Hildenbrand, and F. Färber, "Dictionary-based order-preserving string compression for main memory column stores," in *Proceedings of the 2009 ACM SIGMOD International Conference on Management of data*, pp. 283–296, 2009.

[43] T. Waage, *A Framework for Property-preserving Encryption in Wide Column Store Databases.* PhD thesis, Dissertation, Göttingen, Georg-August Universität, 2017, 2017.

[44] J. Hildebrandt, D. Habich, and W. Lehner, "Model-driven integration of compression algorithms in column-store database systems.," in *LWDA*, pp. 30–41, Citeseer, 2016.

[45] M. Boissier and M. Jendruk, "Workload-driven and robust selection of compression schemes for column stores.," in *EDBT*, pp. 674–677, 2019.

[46] K. Sridhar and J. Johnson, "Entropy aware adaptive compression for sql column stores," in *International Conference: Beyond Databases, Architectures and Structures*, pp. 90–104, Springer, 2018.

[47] P. A. Boncz, M. Zukowski, and N. Nes, "Monetdb/x100: Hyper-pipelining query execution.," in *Cidr*, vol. 5, pp. 225–237, Citeseer, 2005.

[48] M. Stonebraker, L. Rowe, and M. Hirohama, "The implementation of postgres," *Knowledge and Data Engineering, IEEE Transactions on*, vol. 2, pp. 125 – 142, 04 1990.

[49] M. Zukowski and P. A. Boncz, "Vectorwise: Beyond column stores," *IEEE Data Engineering Bulletin*, vol. 35, no. 1, pp. 21–27, 2012.

[50] F. Yang, E. Tschetter, X. Léauté, N. Ray, G. Merlino, and D. Ganguli, “Druid: A real-time analytical data store,” in *Proceedings of the 2014 ACM SIGMOD international conference on Management of data*, pp. 157–168, 2014.

[51] T. T. F. S. B. SPECIFICATIONS, “Stac-m3™ benchmarks,” 2013.

[52] S. Héman, M. Zukowski, N. J. Nes, L. Sidirourgos, and P. Boncz, “Positional update handling in column stores,” in *Proceedings of the 2010 ACM SIGMOD International Conference on Management of data*, pp. 543–554, 2010.

[53] M. A. Shah, S. Harizopoulos, J. L. Wiener, and G. Graefe, “Fast scans and joins using flash drives,” in *Proceedings of the 4th international workshop on Data management on new hardware*, pp. 17–24, 2008.

[54] Q. Cao, Z. Liang, Y. Fan, and X. Meng, “A flash-based decomposition storage model,” in *International Conference on Database Systems for Advanced Applications*, pp. 73–80, Springer, 2012.

[55] M. Zaman, J. Surabattula, and L. Gruenwald, “An auto-indexing technique for databases based on clustering,” in *Proceedings. 15th International Workshop on Database and Expert Systems Applications, 2004.*, pp. 776–780, IEEE, 2004.

[56] S. Das, M. Grbic, I. Ilic, I. Jovandic, A. Jovanovic, V. R. Narasayya, M. Radulovic, M. Stikic, G. Xu, and S. Chaudhuri, “Automatically indexing millions of databases in microsoft azure sql database,” in *Proceedings of the 2019 International Conference on Management of Data*, pp. 666–679, 2019.

[57] W. G. Pedrozo and M. S. M. G. Vaz, “A tool for automatic index selection in database management systems,” in *2014 International Symposium on Computer, Consumer and Control*, pp. 1061–1064, IEEE, 2014.

[58] S. Idreos, M. L. Kersten, and S. Manegold, “Database cracking,” in *CIDR*, 2007.

[59] M. L. Kersten, S. Manegold, M. Kersten, and S. Manegold, “Cracking the database store,” in *In CIDR*, 2005.

[60] C. A. R. Hoare, “Algorithm 64: Quicksort,” *Commun. ACM*, vol. 4, pp. 321–, July 1961.

[61] S. Idreos, M. L. Kersten, and S. Manegold, “Self-organizing tuple reconstruction in column-stores,” in *Proceedings of the 2009 ACM SIGMOD International Conference on Management of Data*, SIGMOD ’09, (New York, NY, USA), pp. 297–308, ACM, 2009.

[62] F. Halim, S. Idreos, P. Karras, and R. H. C. Yap, “Stochastic database cracking: Towards robust adaptive indexing in main-memory column-stores,” *Proc. VLDB Endow.*, vol. 5, pp. 502–513, Feb. 2012.

[63] S. Idreos, M. L. Kersten, and S. Manegold, “Updating a cracked database,” in *Proceedings of the 2007 ACM SIGMOD International Conference on Management of Data*, SIGMOD ’07, (New York, NY, USA), pp. 413–424, ACM, 2007.

[64] D. E. Knuth, *The Art of Computer Programming, Volume 3: (2Nd Ed.) Sorting and Searching.* Redwood City, CA, USA: Addison Wesley Longman Publishing Co., Inc., 1998.

[65] G. Graefe, “Sorting and indexing with partitioned b-trees,” in *CIDR*, 2003.

[66] J. Lee, H. Roh, and S. Park, “External mergesort for flash-based solid state drives,” *IEEE Transactions on Computers*, vol. 65, pp. 1518–1527, May 2016.

[67] V. Alvarez, F. M. Schuhknecht, J. Dittrich, and S. Richter, "Main memory adaptive indexing for multi-core systems," in *Proceedings of the Tenth International Workshop on Data Management on New Hardware*, DaMoN '14, (New York, NY, USA), pp. 3:1–3:10, ACM, 2014.

[68] S. Idreos, S. Manegold, H. Kuno, and G. Graefe, "Merging what's cracked, cracking what's merged: Adaptive indexing in main-memory column-stores," *Proc. VLDB Endow.*, vol. 4, pp. 586–597, June 2011.

[69] Z. Xue, X. Qin, X. Zhou, S. Wang, and A. Yu, "Optimized adaptive hybrid indexing for in-memory column stores," in *Proceedings of the 18th International Conference on Database Systems for Advanced Applications - Volume 7827*, (New York, NY, USA), pp. 101–111, Springer-Verlag New York, Inc., 2013.

[70] D. Comer, "Ubiquitous b-tree," *ACM Comput. Surv.*, vol. 11, pp. 121–137, 1979.

[71] Y. Li, B. He, Q. Luo, and K. Yi, "Tree indexing on flash disks," in *2009 IEEE 25th International Conference on Data Engineering*, pp. 1303–1306, IEEE, 2009.

[72] "Oficjalne źródła jądra systemu operacyjnego linux." https://github.com/torvalds/linux.

[73] "Oficjalna dokumentacja systemu operacyjnego linux." https://linux.die.net/man/.

[74] M. Snir and J. Yu, "On the theory of spatial and temporal locality," 01 2005.

[75] S. Dong, A. Kryczka, Y. Jin, and M. Stumm, "Rocksdb: Evolution of development priorities in a key-value store serving large-scale applications," *ACM Trans. Storage*, vol. 17, oct 2021.

[76] "Oficjalna dokumentacja systemu mysql." https://dev.mysql.com/doc/.

[77] P. Hong-Jin, "A study of the innodb storage engine in the mysql 5.6," 01 2017.

[78] S. Mueller, *Upgrading and Repairing PCs (17th Edition)*. USA: Que Corp., 2006.

[79] G. Graefe, "Write-optimized b-trees," pp. 672–683, VLDB Endowment, 2004.

[80] B.Buvaneswari, "A survey on multi gate mosfets," *International Journal of Innovative Research in Science, Engineering and Technology*, vol. 3, 2014.

[81] S. Electronics, *Nand Flash Memory & Smartmedia Data*. 2007.

[82] K. Naruke, S. Yamada, E. Obi, S. Taguchi, and M. Wada, "A new flash-erase eeprom cell with a sidewall select-gate on its source side," in *International Technical Digest on Electron Devices Meeting*, pp. 603–606, 1989.

[83] G. Samachisa, C.-S. Su, Y.-S. Kao, G. Smarandoiu, C.-Y. Wang, T. Wong, and C. Hu, "A 128 k flash eeprom using double-polysilicon technology," *IEEE Journal of Solid-State Circuits*, vol. 22, no. 5, pp. 676–683, 1987.

[84] A. Amin, "Design, selection and implementation of flash erase eeprom memory cells," *IEE Proceedings G (Circuits, Devices and Systems)*, vol. 139, no. 3, pp. 370–376, 1992.

[85] S. Skorobogatov, "Data remanence in flash memory devices," in *Cryptographic Hardware and Embedded Systems – CHES 2005* (J. R. Rao and B. Sunar, eds.), (Berlin, Heidelberg), pp. 339–353, Springer Berlin Heidelberg, 2005.

[86] J. Hu, H. Jiang, L. Tian, and L. Xu, "Pud-lru: An erase-efficient write buffer management algorithm for flash memory ssd," in *2010 IEEE International Symposium on Modeling, Analysis and Simulation of Computer and Telecommunication Systems*, pp. 69–78, 2010.

[87] E. Gal and S. Toledo, "Algorithms and data structures for flash memories," *ACM Comput. Surv.*, vol. 37, p. 138–163, jun 2005.

[88] Y. Deng and J. Zhou, "Architectures and optimization methods of flash memory based storage systems," *Journal of Systems Architecture*, vol. 57, no. 2, pp. 214–227, 2011.

[89] S.-y. Park, D. Jung, J.-u. Kang, J.-s. Kim, and J. Lee, "Cflru: a replacement algorithm for flash memory," in *Proceedings of the 2006 international conference on Compilers, architecture and synthesis for embedded systems*, pp. 234–241, 2006.

[90] A. Ban, "Flash file system," United States Patent No. 5,404,485, 1995.

[91] T.-S. Chung, D.-J. Park, S. Park, D.-H. Lee, S.-W. Lee, and H.-J. Song, "A survey of flash translation layer," *Journal of Systems Architecture*, vol. 55, no. 5-6, pp. 332–343, 2009.

[92] B. I. Petro Estakhri, "Moving sequential sectors within a block of information in a flash memory mass storage architecture," United States Patent No. 5,930,815, 1999.

[93] J. Kim, J. M. Kim, S. H. Noh, S. L. Min, and Y. Cho, "A space-efficient flash translation layer for compactflash systems," *IEEE Transactions on Consumer Electronics*, vol. 48, no. 2, pp. 366–375, 2002.

[94] S. J. Kwon and T.-S. Chung, "An efficient and advanced space-management technique for flash memory using reallocation blocks," *IEEE Transactions on Consumer Electronics*, vol. 54, no. 2, pp. 631–638, 2008.

[95] B.-s. Kim and G.-y. Lee, "Method of driving remapping in flash memory and flash memory architecture suitable therefor," Apr. 30 2002. US Patent 6,381,176.

[96] T.-S. Chung and H.-S. Park, "Staff: A flash driver algorithm minimizing block erasures," *Journal of Systems Architecture*, vol. 53, no. 12, pp. 889–901, 2007.

[97] A. Kawaguchi, S. Nishioka, and H. Motoda, "A flash-memory based file system.," in *USENIX*, pp. 155–164, 1995.

[98] A. Schierl, G. Schellhorn, D. Haneberg, and W. Reif, "Abstract specification of the ubifs file system for flash memory," in *International Symposium on Formal Methods*, pp. 190–206, Springer, 2009.

[99] X. Cai and S. Shao, "An optimization algorithm for ubifs wear-leveling," in *2010 2nd International Workshop on Intelligent Systems and Applications*, pp. 1–4, IEEE, 2010.

[100] J. Cichon and W. Macyna, "Approximate counters for flash memory," in *2011 IEEE 17th International Conference on Embedded and Real-Time Computing Systems and Applications*, vol. 1, pp. 185–189, IEEE, 2011.

[101] H. Prodinger, "Approximate counting with m counters: a detailed analysis," *Theoretical Computer Science*, vol. 439, pp. 58–68, 2012.

[102] F. Geier, "The differences between ssd and hdd technology regarding forensic investigations," 2015.

[103] V. Kasavajhala, "Solid state drive vs. hard disk drive price and performance study," *Proc. Dell Tech. White Paper*, pp. 8–9, 2011.

[104] L. Jeevitha, B. Umadevi, and M. Hemavathy, "Sata protocol implementation on fpga for write protection of hard disk drive/solid state device," in *2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)*, pp. 614–617, IEEE, 2019.

[105] M. Knowles, "Survey of the storage evolution," in *2003 User Group Conference. Proceedings*, pp. 362–367, 2003.

[106] E. C. Lee, J. Rho, B. J. Lee, and H. Kang, "Heat dissipation analysis of m.2 nvme solid-state drive in vacuum," in *2019 International Vacuum Electronics Conference (IVEC)*, pp. 1–2, 2019.

[107] H.-J. Kim, Y.-S. Lee, and J.-S. Kim, "Nvmedirect: A user-space i/o framework for application-specific optimization on nvme ssd," in *8th USENIX Workshop on Hot Topics in Storage and File Systems (HotStorage 16)*, 2016.

[108] H. Riggs, S. Tufail, I. Parvez, and A. Sarwat, "Survey of solid state drives, characteristics, technology, and applications," in *2020 SoutheastCon*, pp. 1–6, IEEE, 2020.

[109] H. Cho, D. Shin, and Y. I. Eom, "Kast: K-associative sector translation for nand flash memory in real-time systems," in *2009 Design, Automation & Test in Europe Conference & Exhibition*, pp. 507–512, IEEE, 2009.

[110] M. Jung and M. Kandemir, "Revisiting widely held ssd expectations and rethinking system-level implications," *ACM SIGMETRICS Performance Evaluation Review*, vol. 41, no. 1, pp. 203–216, 2013.

[111] Y. Du, J. Gu, Z. Xiao, and M. Huang, "Ssw: A strictly sequential writing method for open-channel ssd," *Journal of Systems Architecture*, vol. 109, p. 101828, 2020.

[112] S.-W. Lee, B. Moon, C. Park, J.-M. Kim, and S.-W. Kim, "A case for flash memory ssd in enterprise database applications," in *Proceedings of the 2008 ACM SIGMOD international conference on Management of data*, pp. 1075–1086, 2008.

[113] Y. Liu, J. Huang, C. Xie, and Q. Cao, "Raf: A random access first cache management to improve ssd-based disk cache," in *2010 IEEE Fifth International Conference on Networking, Architecture, and Storage*, pp. 492–500, IEEE, 2010.

[114] M. Canim, G. A. Mihaila, B. Bhattacharjee, K. A. Ross, and C. A. Lang, "Ssd bufferpool extensions for database systems," *Proceedings of the VLDB Endowment*, vol. 3, no. 1-2, pp. 1435–1446, 2010.

[115] K. Smith, "Garbage collection," *SandForce, Flash Memory Summit, Santa Clara, CA*, pp. 1–9, 2011.

[116] P. Yang, N. Xue, Y. Zhang, Y. Zhou, L. Sun, W. Chen, Z. Chen, W. Xia, J. Li, and K. Kwon, "Reducing garbage collection overhead in {SSD} based on workload prediction," in *11th USENIX Workshop on Hot Topics in Storage and File Systems (HotStorage 19)*, 2019.

[117] M. Jung, R. Prabhakar, and M. T. Kandemir, "Taking garbage collection overheads off the critical path in ssds," in *ACM/IFIP/USENIX International Conference on Distributed Systems Platforms and Open Distributed Processing*, pp. 164–186, Springer, 2012.

[118] S. Yan, H. Li, M. Hao, M. H. Tong, S. Sundararaman, A. A. Chien, and H. S. Gunawi, "Tiny-tail flash: Near-perfect elimination of garbage collection tail latencies in nand ssds," *ACM Transactions on Storage (TOS)*, vol. 13, no. 3, pp. 1–26, 2017.

[119] N. Shahidi, M. T. Kandemir, M. Arjomand, C. R. Das, M. Jung, and A. Sivasubramaniam, “Exploring the potentials of parallel garbage collection in ssds for enterprise storage systems,” in *SC'16: Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis*, pp. 561–572, IEEE, 2016.

[120] J. Guo, Y. Hu, B. Mao, and S. Wu, “Parallelism and garbage collection aware i/o scheduler with improved ssd performance,” in *2017 IEEE International Parallel and Distributed Processing Symposium (IPDPS)*, pp. 1184–1193, IEEE, 2017.

[121] S. Ahn and S. Park, “An analytical approach to evaluation of ssd effects under mapreduce workloads,” *JSTS: Journal of Semiconductor Technology and Science*, vol. 15, no. 5, pp. 511–518, 2015.

[122] G. Kim and D. Shin, “Performance analysis of ssd write using trim in ntfs and ext4,” in *2011 6th International Conference on Computer Sciences and Convergence Information Technology (ICCIT)*, pp. 422–423, IEEE, 2011.

[123] J. Kim, H. Kim, S. Lee, and Y. Won, “Ftl design for trim command,” in *The Fifth International Workshop on Software Support for Portable Storage*, pp. 7–12, 2010.

[124] T. Frankie, G. Hughes, and K. Kreutz-Delgado, “Ssd trim commands considerably improve overprovisioning,” *Flash Memory Summit*, 2011.

[125] G. W. Burr, M. J. Breitwisch, M. Franceschini, D. Garetto, K. Gopalakrishnan, B. Jackson, B. Kurdi, C. Lam, L. A. Lastras, A. Padilla, *et al.*, “Phase change memory technology,” *Journal of Vacuum Science & Technology B, Nanotechnology and Microelectronics: Materials, Processing, Measurement, and Phenomena*, vol. 28, no. 2, pp. 223–262, 2010.

[126] G. W. Burr, M. J. Brightsky, A. Sebastian, H.-Y. Cheng, J.-Y. Wu, S. Kim, N. E. Sosa, N. Papandreou, H.-L. Lung, H. Pozidis, *et al.*, “Recent progress in phase-change memory technology,” *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, vol. 6, no. 2, pp. 146–162, 2016.

[127] L. Bo, S. Zhi-Tang, Z. Ting, F. Song-Lin, and G. Fu-Xi, “Novel material for nonvolatile ovonic unified memory (oum)–ag11in12te26sb51 phase change semiconductor,” *Chinese Physics*, vol. 13, no. 7, p. 1167, 2004.

[128] B. Beeler, “Intel optane dc persistent memory module (pmm),” *Retrieved March*, vol. 11, p. 2021, 2019.

[129] O. Zilberberg, S. Weiss, and S. Toledo, “Phase-change memory: An architectural perspective,” *ACM Computing Surveys (CSUR)*, vol. 45, no. 3, pp. 1–33, 2013.

[130] M. K. Qureshi, S. Gurumurthi, and B. Rajendran, “Phase change memory: From devices to systems,” *Synthesis Lectures on Computer Architecture*, vol. 6, no. 4, pp. 1–134, 2011.

[131] G. Servalli, “A 45nm generation phase change memory technology,” in *2009 IEEE International Electron Devices Meeting (IEDM)*, pp. 1–4, IEEE, 2009.

[132] J. Condit, E. B. Nightingale, C. Frost, E. Ipek, B. Lee, D. Burger, and D. Coetzee, “Better i/o through byte-addressable, persistent memory,” in *Proceedings of the ACM SIGOPS 22nd symposium on Operating systems principles*, pp. 133–146, 2009.

[133] B. C. Lee, E. Ipek, O. Mutlu, and D. Burger, “Architecting phase change memory as a scalable dram alternative,” in *Proceedings of the 36th annual international symposium on Computer architecture*, pp. 2–13, 2009.

[134] M. K. Qureshi, V. Srinivasan, and J. A. Rivers, "Scalable high performance main memory system using phase-change memory technology," in *Proceedings of the 36th annual international symposium on Computer architecture*, pp. 24–33, 2009.

[135] P. Zhou, B. Zhao, J. Yang, and Y. Zhang, "A durable and energy efficient main memory using phase change memory technology," *ACM SIGARCH computer architecture news*, vol. 37, no. 3, pp. 14–23, 2009.

[136] S. Chen, P. B. Gibbons, S. Nath, *et al.*, "Rethinking database algorithms for phase change memory.," in *Cidr*, vol. 11, pp. 9–12, 2011.

[137] P. P. Kalua and E. L. Robertson, *Benchmark queries for temporal databases.* Citeseer, 1993.

[138] M. H. Dunham, R. Elmasri, M. A. Nascimento, and M. Sobol, *Benchmarking temporal databases: A research agenda.* Citeseer, 1995.

[139] G. Graefe, S. Idreos, H. Kuno, and S. Manegold, "Benchmarking adaptive indexing," in *Technology Conference on Performance Evaluation and Benchmarking*, pp. 169–184, Springer, 2010.

[140] H. Kim, E. H. Nam, K. S. Choi, Y. J. Seong, J.-y. Choi, and S. L. Min, "Development platforms for flash memory solid state disks," in *2008 11th IEEE International Symposium on Object and Component-Oriented Real-Time Distributed Computing (ISORC)*, pp. 527–528, IEEE, 2008.

[141] "Projekt openssd." http://www.openssd-project.org.

[142] S. Lee, K. Fleming, J. Park, K. Ha, A. Caulfield, S. Swanson, J. Kim, *et al.*, "Bluessd: An open platform for cross-layer experiments for nand flash-based ssds," in *WARP-5th Annual Workshop on Architectural Research Prototyping*, 2010.

[143] Y. Cai, E. F. Haratsch, M. McCartney, and K. Mai, "Fpga-based solid-state drive prototyping platform," in *2011 IEEE 19th Annual International Symposium on Field-Programmable Custom Computing Machines*, pp. 101–104, IEEE, 2011.

[144] F. Bellard, "Qemu, a fast and portable dynamic translator.," in *USENIX annual technical conference, FREENIX Track*, vol. 41, pp. 10–5555, Califor-nia, USA, 2005.

[145] "Projekt qemu." https://github.com/qemu/qemu.

[146] H. Li, M. Hao, M. H. Tong, S. Sundararaman, M. Bjørling, and H. S. Gunawi, "The {CASE} of {FEMU}: Cheap, accurate, scalable and extensible flash emulator," in *16th USENIX Conference on File and Storage Technologies (FAST 18)*, pp. 83–90, 2018.

[147] J. Yoo, Y. Won, J. Hwang, S. Kang, J. Choi, S. Yoon, and J. Cha, "Vssim: Virtual machine based ssd simulator," in *2013 IEEE 29th Symposium on Mass Storage Systems and Technologies (MSST)*, pp. 1–14, IEEE, 2013.

[148] M. Jung, J. Zhang, A. Abulila, M. Kwon, N. Shahidi, J. Shalf, N. S. Kim, and M. Kandemir, "Simplessd: Modeling solid state drives for holistic system simulation," *IEEE Computer Architecture Letters*, vol. 17, no. 1, pp. 37–41, 2017.

[149] D. Lee, D. Hong, W. Choi, and J. Kim, "Mqsim-e: An enterprise ssd simulator," *IEEE Computer Architecture Letters*, 2022.

[150] N. Agrawal, V. Prabhakaran, T. Wobber, J. D. Davis, M. Manasse, and R. Panigrahy, "Design tradeoffs for {SSD} performance," in *2008 USENIX Annual Technical Conference (USENIX ATC 08)*, 2008.

[151] G. Ganger, B. Worthington, and Y. Patt, "The disksim simulation environment (v4. 0)," *Parallel Data Lab, http://www. pdl. cmu. edu/DiskSim/Online-document*, 2009.

[152] V. Prabhakaran and T. Wobber, "Ssd extension for disksim simulation environment," *Microsoft Reseach*, 2009.

[153] J. Lee, E. Byun, H. Park, J. Choi, D. Lee, and S. H. Noh, "Cps-sim: configurable and accurate clock precision solid state drive simulator," in *Proceedings of the 2009 ACM symposium on Applied Computing*, pp. 318–325, 2009.

[154] Y. Kim, B. Tauras, A. Gupta, and B. Urgaonkar, "Flashsim: A simulator for nand flash-based solid-state drives," in *2009 First International Conference on Advances in System Simulation*, pp. 125–131, IEEE, 2009.

[155] P. Jin, X. Su, Z. Li, and L. Yue, "A flexible simulation environment for flash-aware algorithms," in *Proceedings of the 18th ACM conference on information and knowledge management*, pp. 2093–2094, 2009.

[156] M. Jung, E. H. Wilson, D. Donofrio, J. Shalf, and M. T. Kandemir, "Nandflashsim: Intrinsic latency variation aware nand flash memory system modeling and simulation at microarchitecture level," in *2012 IEEE 28th Symposium on Mass Storage Systems and Technologies (MSST)*, pp. 1–12, IEEE, 2012.

[157] J. He, S. Kannan, A. C. Arpaci-Dusseau, and R. H. Arpaci-Dusseau, "The unwritten contract of solid state drives," in *Proceedings of the twelfth European conference on computer systems*, pp. 127–144, 2017.

[158] Y. Hu, H. Jiang, D. Feng, L. Tian, H. Luo, and S. Zhang, "Performance impact and interplay of ssd parallelism through advanced commands, allocation strategy and data granularity," in *Proceedings of the international conference on Supercomputing*, pp. 96–107, 2011.

[159] J. Yoo, Y. Won, S. Kang, J. Choi, S. Yoon, and J. Cha, "Analytical model of ssd parallelism," in *2014 4th International Conference On Simulation And Modeling Methodologies, Technologies And Applications (SIMULTECH)*, pp. 551–559, IEEE, 2014.

[160] D. Zhang, P. Jin, X. Wang, C. Yang, and L. Yue, "Dphsim: A flexible simulator for dram/pcm-based hybrid memory," in *Asia-Pacific Web (APWeb) and Web-Age Information Management (WAIM) Joint Conference on Web and Big Data*, pp. 319–323, Springer, 2017.

[161] J.-G. Kim, D.-Y. Kim, and Y.-H. Choe, "Pcm simulator," *The Magazine of the IEIE*, vol. 3, no. 2, pp. 46–55, 1976.

[162] X. Li, K. Lu, and X. Zhou, "Sim-pcm: a pcm simulator based on simics," in *2012 Fourth International Conference on Computational and Information Sciences*, pp. 1236–1239, IEEE, 2012.

[163] D. Gouk, M. Kwon, J. Zhang, S. Koh, W. Choi, N. S. Kim, M. Kandemir, and M. Jung, "Amber*: Enabling precise full-system simulation with detailed modeling of all ssd resources," in *2018 51st Annual IEEE/ACM International Symposium on Microarchitecture (MICRO)*, pp. 469–481, IEEE, 2018.

[164] Z. Shao, N. Chang, and N. Dutt, "Ptl: Pcm translation layer," in *2012 IEEE Computer Society Annual Symposium on VLSI*, pp. 380–385, IEEE, 2012.

[165] R. Micheloni and L. Crippa, *Solid-State-Drives (SSDs) Modeling.* Springer, 2017.

[166] J. Zhang, P. Li, B. Liu, T. G. Marbach, X. Liu, and G. Wang, "Performance analysis of 3d xpoint ssds in virtualized and non-virtualized environments," in *2018 IEEE 24th International Conference on Parallel and Distributed Systems (ICPADS)*, pp. 1–10, 2018.

[167] J. Izraelevitz, J. Yang, L. Zhang, J. Kim, X. Liu, A. Memaripour, Y. J. Soh, Z. Wang, Y. Xu, S. R. Dulloor, *et al.*, "Basic performance measurements of the intel optane dc persistent memory module," *arXiv preprint arXiv:1903.05714*, 2019.

[168] C. Delimitrou, S. Sankar, B. Khessib, K. Vaid, and C. Kozyrakis, "Time and cost-efficient modeling and generation of large-scale tpcc/tpce/tpch workloads," in *Technology Conference on Performance Evaluation and Benchmarking*, pp. 146–162, Springer, 2011.

[169] R. N. Avula and C. Zou, "Performance evaluation of tpc-c benchmark on various cloud providers," in *2020 11th IEEE Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)*, pp. 0226–0233, IEEE, 2020.

[170] M. A. Kandaswamy and R. L. Knighten, "I/o phase characterization of tpc-h query operations," in *Proceedings IEEE International Computer Performance and Dependability Symposium. IPDS 2000*, pp. 81–90, IEEE, 2000.

[171] F. M. Schuhknecht, A. Jindal, and J. Dittrich, "The uncracked pieces in database cracking," *Proceedings of the VLDB Endowment*, vol. 7, no. 2, pp. 97–108, 2013.

[172] P. O'Neil, E. Cheng, D. Gawlick, and E. O'Neil, "The log-structured merge-tree (lsm-tree)," *Acta Informatica*, vol. 33, no. 4, pp. 351–385, 1996.

[173] C.-H. Wu, T.-W. Kuo, and L. P. Chang, "An efficient b-tree layer implementation for flash-memory storage systems," vol. 6, p. 19–es, jul 2007.

[174] T. Gleixner, F. Haverkamp, and A. Bityutskiy, "Ubi-unsorted block images," *Rapport technique, adresse: http://linux-mtd. infradead. org/doc/ubidesign/ubidesign. pdf*, 2006.

[175] W. Effelsberg and T. Haerder, "Principles of database buffer management," *ACM Transactions on Database Systems (TODS)*, vol. 9, no. 4, pp. 560–595, 1984.

[176] G. M. Sacco and M. Schkolnick, "Buffer management in relational database systems," *ACM Transactions on Database Systems (TODS)*, vol. 11, no. 4, pp. 473–498, 1986.

[177] Y. Ou, T. Härder, and P. Jin, "Cfdc: a flash-aware replacement policy for database buffer management," in *Proceedings of the fifth international workshop on data management on new hardware*, pp. 15–20, 2009.

[178] J. Bercken and B. Seeger, "An evaluation of generic bulk loading techniques," VLDB, 2001.

[179] G. Roumelis, A. Fevgas, M. Vassilakopoulos, A. Corral, P. Bozanis, and Y. Manolopoulos, "Bulk-loading and bulk-insertion algorithms for xBR^{+}-trees in Solid State Drives," *Computing*, vol. 101, no. 10, pp. 1539–1563, 2019.

[180] G. Roumelis, M. Vassilakopoulos, A. Corral, and Y. Manolopoulos, "An efficient algorithm for bulk-loading xbr+-trees," *Computer Standards & Interfaces*, vol. 57, pp. 83–100, 2018.

[181] Y. Zhu, Z. Zhang, P. Cai, W. Qian, and A. Zhou, "An efficient bulk loading approach of secondary index in distributed log-structured data stores," in *International Conference on Database Systems for Advanced Applications*, pp. 87–102, Springer, 2017.

[182] C. Luo and M. J. Carey, "Lsm-based storage techniques: a survey," *The VLDB Journal*, vol. 29, no. 1, pp. 393–418, 2020.

[183] N. Dayan and S. Idreos, "Dostoevsky: Better space-time trade-offs for lsm-tree based key-value stores via adaptive removal of superfluous merging," in *Proceedings of the 2018 International Conference on Management of Data*, pp. 505–520, 2018.

[184] L. Lu, T. S. Pillai, H. Gopalakrishnan, A. C. Arpaci-Dusseau, and R. H. Arpaci-Dusseau, "Wisckey: Separating keys from values in ssd-conscious storage," *ACM Transactions on Storage (TOS)*, vol. 13, no. 1, pp. 1–28, 2017.

[185] S.-M. Wu, K.-H. Lin, and L.-P. Chang, "Kvssd: Close integration of lsm trees and flash translation layer for write-efficient kv store," in *2018 Design, Automation & Test in Europe Conference & Exhibition (DATE)*, pp. 563–568, IEEE, 2018.

[186] P. Wang, G. Sun, S. Jiang, J. Ouyang, S. Lin, C. Zhang, and J. Cong, "An efficient design and implementation of lsm-tree based key-value store on open-channel ssd," in *Proceedings of the Ninth European Conference on Computer Systems*, pp. 1–14, 2014.

[187] Z. Cao, S. Dong, S. Vemuri, and D. H. Du, "Characterizing, Modeling, and Benchmarking RocksDB Key-Value Workloads at Facebook," in *18th USENIX Conference on File and Storage Technologies (FAST 20)*, pp. 209–223, 2020.

[188] H. Lee, M. Lee, and Y. I. Eom, "Sfm: Mitigating read/write amplification problem of lsm-tree-based key-value stores," *IEEE Access*, vol. 9, pp. 103153–103166, 2021.

[189] C. A. Mandal, P. P. Chakrabarti, and S. Ghose, "Complexity of fragmentable object bin packing and an application," *Computers & Mathematics with Applications*, vol. 35, no. 11, pp. 91–97, 1998.

[190] S. Martello and P. Toth, "Bin-packing problem," *Knapsack problems: Algorithms and computer implementations*, pp. 221–245, 1990.

[191] M. K. Qureshi, J. Karidis, M. Franceschini, V. Srinivasan, L. Lastras, and B. Abali, "Enhancing lifetime and security of pcm-based main memory with start-gap wear leveling," in *2009 42nd Annual IEEE/ACM international symposium on microarchitecture (MICRO)*, pp. 14–23, IEEE, 2009.

[192] Y. Ou, L. Chen, J. Xu, and T. Härder, "Wear-aware algorithms for pcm-based database buffer pools," in *International Conference on Web-Age Information Management*, pp. 165–176, Springer, 2014.

[193] Z. Wu, P. Jin, and L. Yue, "Efficient space management and wear leveling for pcm-based storage systems," in *International Conference on Algorithms and Architectures for Parallel Processing*, pp. 784–798, Springer, 2015.

[194] S. D. Viglas, "Write-limited sorts and joins for persistent memory," *Proceedings of the VLDB Endowment*, vol. 7, no. 5, pp. 413–424, 2014.

[195] X. Liu and W. Golab, "Brief announcement: Towards a theory of wear leveling in persistent data structures," in *Proceedings of the 2022 ACM Symposium on Principles of Distributed Computing*, pp. 220–223, 2022.

[196] K. Zeng, Y. Lu, H. Wan, and J. Shu, "Efficient storage management for aged file systems on persistent memory," in *Design, Automation & Test in Europe Conference & Exhibition (DATE), 2017*, pp. 1769–1774, IEEE, 2017.

[197] P. Zhou, B. Zhao, J. Yang, and Y. Zhang, "A durable and energy efficient main memory using phase change memory technology," *ACM SIGARCH computer architecture news*, vol. 37, no. 3, pp. 14–23, 2009.

[198] C. Pan, M. Xie, J. Hu, M. Qiu, and Q. Zhuge, "Wear-leveling for pcm main memory on embedded system via page management and process scheduling," in *2014 IEEE 20th International Conference on Embedded and Real-Time Computing Systems and Applications*, pp. 1–9, IEEE, 2014.

[199] D. Liu, T. Wang, Y. Wang, Z. Shao, Q. Zhuge, and E. Sha, "Curling-pcm: Application-specific wear leveling for phase change memory based embedded systems," in *2013 18th Asia and South Pacific Design Automation Conference (ASP-DAC)*, pp. 279–284, IEEE, 2013.

[200] S. Rashidi, M. Jalili, and H. Sarbazi-Azad, "A survey on pcm lifetime enhancement schemes," *ACM Computing Surveys (CSUR)*, vol. 52, no. 4, pp. 1–38, 2019.

[201] R. A. Hankins and J. M. Patel, "Effect of node size on the performance of cache-conscious b+-trees," in *Proceedings of the 2003 ACM SIGMETRICS international conference on Measurement and modeling of computer systems*, pp. 283–294, 2003.

[202] S. Chen, P. B. Gibbons, and T. C. Mowry, "Improving index performance through prefetching," *ACM SIGMOD Record*, vol. 30, no. 2, pp. 235–246, 2001.

[203] V. Dubeyko, "Method of resolving wandering tree problem of log-structured file systems by means of segment-based extent approach,"

[204] A. B. Bityuckiy, "Jffs3 design issues," *Memory technology device (MTD) subsystem for Linux*, 2005.

[205] A. Schierl, G. Schellhorn, D. Haneberg, and W. Reif, "Abstract specification of the ubifs file system for flash memory," in *International Symposium on Formal Methods*, pp. 190–206, Springer, 2009.

[206] I. Oukid, J. Lasperas, A. Nica, T. Willhalm, and W. Lehner, "Fptree: A hybrid scm-dram persistent and concurrent b-tree for storage class memory," in *Proceedings of the 2016 International Conference on Management of Data*, pp. 371–386, 2016.

[207] X. Zhou, L. Shou, K. Chen, W. Hu, and G. Chen, "Dptree: differential indexing for persistent memory," *Proceedings of the VLDB Endowment*, vol. 13, no. 4, pp. 421–434, 2019.

[208] G. Graefe, "Efficient columnar storage in b-trees," *ACM SIGMOD Record*, vol. 36, no. 1, pp. 3–6, 2007.

[209] K. Wu, K. Tu, Y. Patel, R. Sen, K. Park, A. Arpaci-Dusseau, and R. Arpaci-Dusseau, "Nyxcache: Flexible and efficient multi-tenant persistent memory caching," in *20th USENIX Conference on File and Storage Technologies (FAST 22)*, pp. 1–16, 2022.

[210] B. Daase, L. J. Bollmeier, L. Benson, and T. Rabl, "Maximizing persistent memory bandwidth utilization for olap workloads," in *Proceedings of the 2021 International Conference on Management of Data*, pp. 339–351, 2021.

[211] I. Neal, G. Zuo, E. Shiple, T. A. Khan, Y. Kwon, S. Peter, and B. Kasikci, “Rethinking file mapping for persistent memory,” in *19th USENIX Conference on File and Storage Technologies (FAST 21)*, pp. 97–111, 2021.

[212] Y. Yang, Q. Cao, J. Yao, Y. Dong, and W. Kong, “Spmfs: A scalable persistent memory file system on optane persistent memory,” in *50th International Conference on Parallel Processing*, pp. 1–10, 2021.

[213] G. Graefe and H. Kuno, “Self-selecting, self-tuning, incrementally optimized indexes,” in *Proceedings of the 13th International Conference on Extending Database Technology*, pp. 371–381, 2010.

[214] F. M. Schuhknecht, A. Jindal, and J. Dittrich, “An experimental evaluation and analysis of database cracking,” *The VLDB Journal*, vol. 25, no. 1, pp. 27–52, 2016.

[215] L. Li, P. Jin, C. Yang, Z. Wu, and L. Yue, “Optimizing b+-tree for pcm-based hybrid memory.,” in *EDBT*, pp. 662–663, 2016.

[216] R. Schaller, “Moore’s law: past, present and future,” *IEEE Spectrum*, vol. 34, no. 6, pp. 52–59, 1997.

[217] C. A. Mack, “Fifty years of moore’s law,” *IEEE Transactions on Semiconductor Manufacturing*, vol. 24, no. 2, pp. 202–207, 2011.

[218] S. Liang, Z. Qiao, S. Tang, J. Hochstetler, S. Fu, W. Shi, and H.-B. Chen, “An empirical study of quad-level cell (qlc) nand flash ssds for big data applications,” in *2019 IEEE International Conference on Big Data (Big Data)*, pp. 3676–3685, 2019.

[219] B. W. Low, B. Y. Ooi, and C. S. Wong, “Scalability of database bulk insertion with multi-threading,” in *Software Engineering and Computer Systems* (J. M. Zain, W. M. b. Wan Mohd, and E. El-Qawasmeh, eds.), (Berlin, Heidelberg), pp. 151–162, Springer Berlin Heidelberg, 2011.

[220] D. Mrozek, B. Socha, S. Kozielski, and B. Małysiak-Mrozek, “An efficient and flexible scanning of databases of protein secondary structures: With the segment index and multithreaded alignment,” *Journal of Intelligent Information Systems*, vol. 46, pp. 213–233, 2016.

[221] P. Garcia and H. F. Korth, “Database hash-join algorithms on multithreaded computer architectures,” CF ’06, (New York, NY, USA), p. 241–252, Association for Computing Machinery, 2006.

[222] J. Zhou, J. Cieslewicz, K. A. Ross, and M. Shah, “Improving database performance on simultaneous multithreading processors,” 2005.

[223] J. Cieslewicz, J. Berry, B. Hendrickson, and K. A. Ross, “Realizing parallelism in database operations: Insights from a massively multithreaded architecture,” DaMoN ’06, (New York, NY, USA), p. 4–es, Association for Computing Machinery, 2006.

[224] R. Khamamkar and A. Keswani, “Analyzing power management in non-volatile memory express (nvme) solid state drives,” in *2019 IEEE Pune Section International Conference (PuneCon)*, pp. 1–4, 2019.

[225] Z. Jia, M. Maggioni, B. Staiger, and D. P. Scarpazza, “Dissecting the nvidia volta gpu architecture via microbenchmarking,” *arXiv preprint arXiv:1804.06826*, 2018.

[226] J. Cong, Z. Fang, M. Lo, H. Wang, J. Xu, and S. Zhang, “Understanding performance differences of fpgas and gpus,” in *2018 IEEE 26th Annual International Symposium on Field-Programmable Custom Computing Machines (FCCM)*, pp. 93–96, IEEE, 2018.

[227] T.-Y. Wang, C.-F. Wu, C.-W. Tsao, Y.-H. Chang, and T.-W. Kuo, “Scheduling-aware prefetching: Enabling the pcie ssd to extend the global memory of gpu device,” in *2021 IEEE 10th Non-Volatile Memory Systems and Applications Symposium (NVMSA)*, pp. 1–6, 2021.

[228] A. Shanbhag, S. Madden, and X. Yu, “A study of the fundamental performance characteristics of gpus and cpus for database analytics,” in *Proceedings of the 2020 ACM SIGMOD International Conference on Management of Data*, SIGMOD ’20, (New York, NY, USA), p. 1617–1632, Association for Computing Machinery, 2020.

[229] R. Lee, M. Zhou, C. Li, S. Hu, J. Teng, D. Li, and X. Zhang, “The art of balance: A rateupdb™ experience of building a cpu/gpu hybrid database product,” *Proc. VLDB Endow.*, vol. 14, p. 2999–3013, jul 2021.

[230] H. K. H. Subramanian, B. Gurumurthy, G. C. Durand, D. Broneske, and G. Saake, “Analysis of gpu-libraries for rapid prototyping database operations : A look into library support for database operations,” in *2021 IEEE 37th International Conference on Data Engineering Workshops (ICDEW)*, pp. 36–41, 2021.