Wykład 10
Systemy plików
Interfejs i implementacja

Systemy plików

- Przechowują olbrzymie ilości informacji
  - Gigabajty => Terabajty => Petabajty
- Przechowywana informacja nie jest tracona po zakończeniu procesu.
  - Czas życia od sekund do lat.
  - Potrzebny jest sposób odnajdywania informacji
- Wiele procesów musi być w stanie wykorzystywać tę samą informację współbieżnie.

Nazwy plików

- Konieczność ***odnalezienia*** pliku, po tym jak został utworzony.
- Każdy plik ma co najmniej jędną nazwę.
- Nazwa może być:
  - Łatwa dla zrozumienia dla człowieka: np. “Notatka.txt”, “program3.cpp”.
  - Odczytywana bezpośrednio przez maszynę: np. 65231
- Duże i małe litery mogą być rozróżniane lub nie
- Nazwa może zawierać informacje o przeznaczeniu pliku.
  - Wygodne z punktu widzenia użytkownika.
  - Wykorzystywane przez programy użytkowe
  - Przykład (Nazwa z rozszerzeniem)
    - abc.jpg Obraz w formacie jpeg
    - p1.c Program w języku C
    - f.txt Ogólny plik tekstowy

Struktura pliku

- Brak struktury: plik jest ciągiem bajtów.
- Plik rekordów
  - Rekordy o stałej lub zmiennej długości.
- Plik o skomplikowanej strukturze
  - Tekst sformatowany
  - Program wykonywalny.
- Każdą strukturę pliku można zasymulować za pomocą ciągu bajtów i wykorzystując znaki kontrolne.
  - Dlatego często system operacyjny traktuje plik jako ciąg bajtów.
  - Struktura pliku jest ustalana na poziomie programu użytkownika (ale nie zawsze - przykład. pliki wykonywalne .exe)

Atrybuty pliku

- Nazwa pliku
- Rozmiar
- Właściciel
- Prawa dostępu
- Czasy (utworzenia/ostatniego dostępu/ostatniej modyfikacji).
- Hasło
- Inne informacje, z reguły niedostępne dla programu użytkownika
  - Na przykład informacja o położeniu pliku na dysku

Operacje na plikach

- Utworzenie (ang. create)
- Usunięcie (ang. delete)
- Otwarcie (ang. open) – przygotowanie pliku do dostępu.
- Zamknięcie (ang. close) – wskazanie, że dostęp do pliku nie będzie dalej potrzebny.
- Odczyt (ang. read) (do bufora w pamięci procesu)
- Zapis (ang. write) (z bufora w pamięci procesu)
- Przesunięcie wskaźnika bieżącej pozycji (ang. seek).
  - Operacje read oraz write wykonują odczyt oraz zapis z miejsca wskazywanego przez wskaźnik bieżącej pozycji; wartość wskaźnika jest zwiększana o liczbę odczytanych lub zapisanych bajtów.
  - Operacja seek pozwala na ***dostęp swobodny*** do pliku (ang. random access), jeżeli nie jest zaimplementowana mówimy o ***dostępie sekwencyjnym***.
- Dołączenie (ang. append) – zapis na końcu pliku
- Odczyt/Zmiana atrybutów (w tym nazwy)

Pliki odwzorowane w pamięci (ang. memory mapped files)

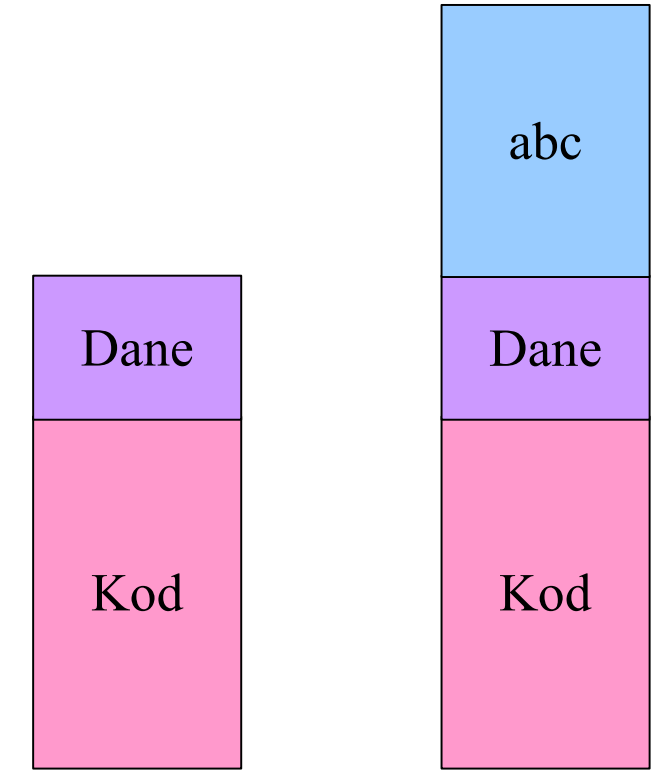

- Po otwarciu pliku wykonywana jest operacja mmap.
- Plik staje się częścią przestrzeni adresowej procesu.
  - Wygodna abstrakcja
  - Unikamy podwójnego kopiowania danych
  - Implementacja na ogół wykorzystuje mechanizm pamięci wirtualnej
- Problemy:
  - Plik współdzielony przez kilka procesów.
  - Próba dostępu “za końcem” pliku.

Katalogi

- Proste nadawanie nazw nie wystarcza w przypadku tysięcy plików na dysku.
  - Problem: wiele plików o identycznej nazwie, np. różne wersje tego samego programu
- Ludzie mają tendencję do grupowania informacji związanych ze sobą.
- Systemy plików umożliwiają to przy pomocy katalogów (ang. directory), zwanych także folderami.
- Grupowanie pozwala na.
  - Łatwiejsze znalezienie plików.
  - Określenie, które pliki są ze sobą związane.
- Operacje na katalogach:
  - Głównie odczyt i przeszukiwanie katalogu.
  - Także tworzenie nowych dowiązań.

Katalog o strukturze jednopoziomowej i dwupoziomowej

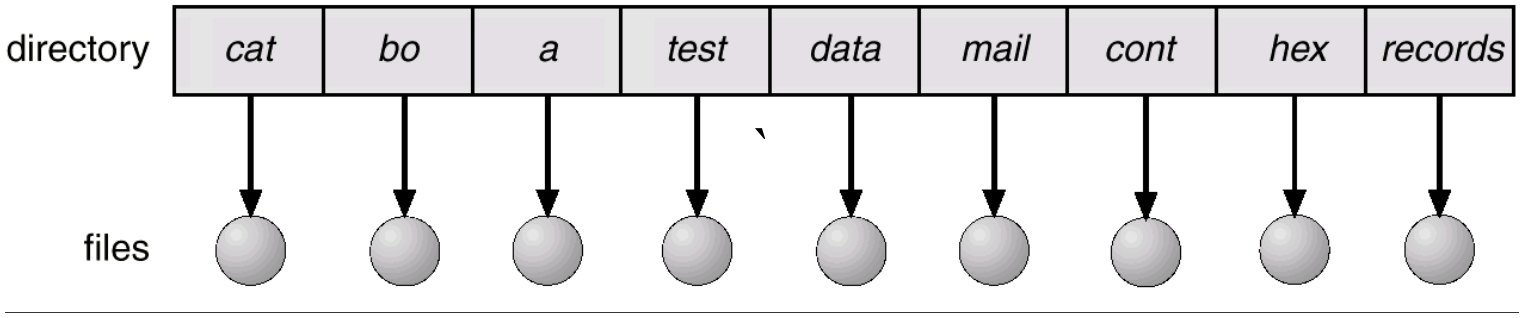

- Jeden katalog dla wszystkich użytkowników.
- Problemy: (a) Nie pozwala na grupowania (b) Konflikty nazw plików.

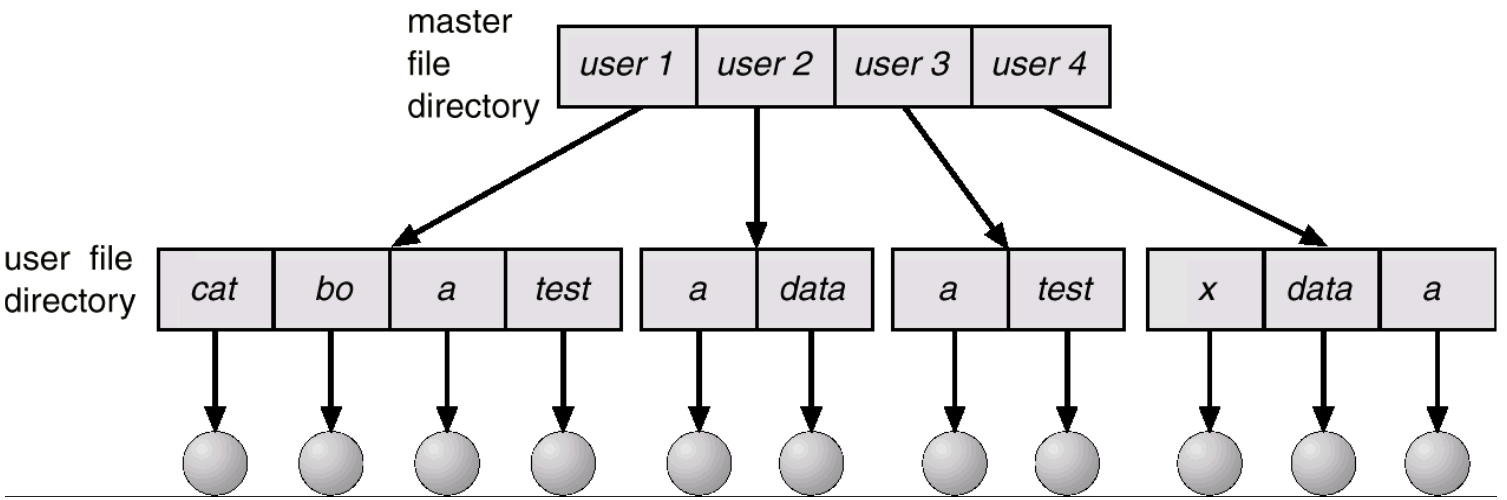

- Katalog główny + Odrębny katalog dla każdego z użytkowników
  - Nadal nie pozwala na grupowania plików

Katalog o strukturze drzewa

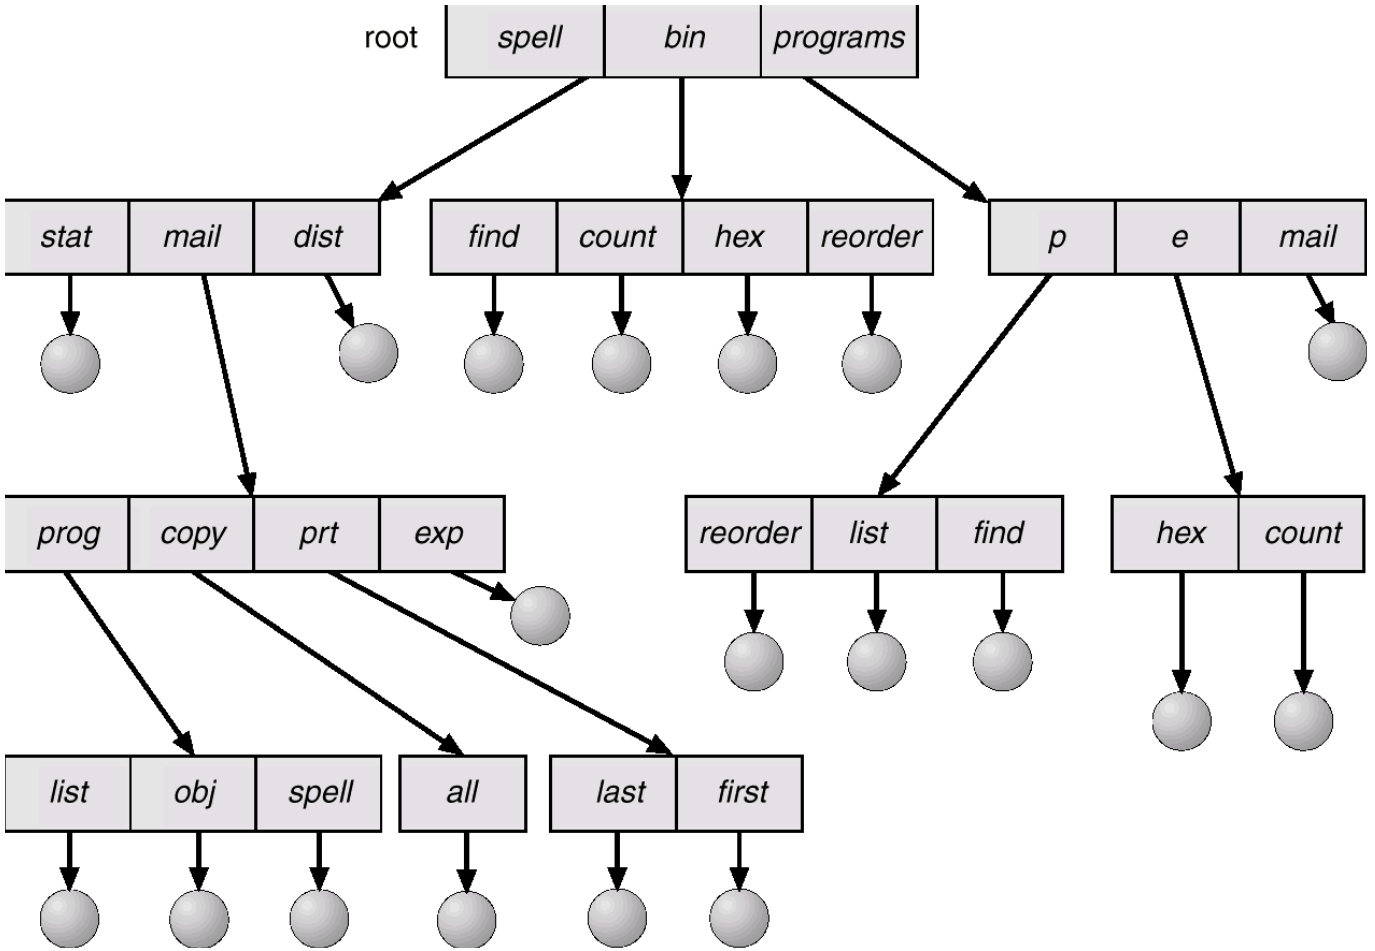

- Umożliwia grupowanie.
- Katalog aktualny (ang. current directory).
- Lokalizacja pliku podana przez ścieżkę.
  - Scieżka bezwlględna: początek w korzeniu drzewa.
  - Ścieżka względna: początek w katalogu aktualnym.

- /bin/hex albo ./p/list (jeżeli /programs jest katalogiem głównym)

Katalog o strukturze grafu acyklicznego

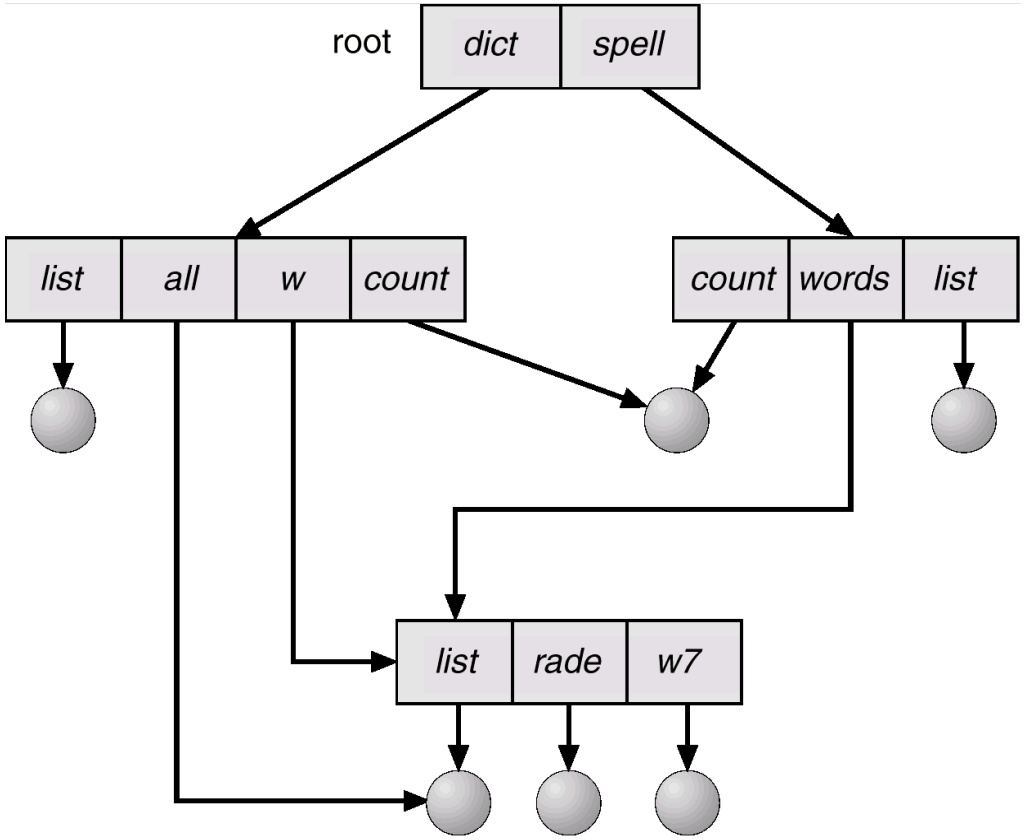

- Brak cykli w grafie chroni przed ścieżkami o nieskończonej długości.
- Plik może mieć dwie różne nazwy (aliasy)
- Problem wiszących wskaźników
  - Gdy usuniemy *list*
- Jak zapewnić acykliczność grafu ?
- W Uniksie hard links i symbolic links.
  - twarde dowiązania to kolejna nazwa tego samego pliku.
  - symboliczne dowiązania to specjalny plik wskazujący na inny.
- Tylko super-użytkownik może utworzyć twarde dowiązanie do katalogu.

Interfejs systemu plików a jego implementacja

- Użytkownik, programista aplikacji jest zainteresowany interfejsem do systemu plików udostępnianym przez system operacyjny.
  - Operacje na plikach i katalogach.

- Projektanta systemu interesuje, jak te operacje mogą zostać zaimplementowane.
  - Jak przechowywać informację o blokach dyskowych zajętych przez plik.
  - Jak szybko odnaleźć i-ty blok danego pliku (operacja *seek*)
  - Jak przechowywać informacje o wolnych blokach (blokach nie zajętych przez żaden z plików, ale które mogą być przydzielone w przyszłości)
  - Gdzie przechowywać informacje o atrybutach pliku
  - Gdzie przechowywać informacje o strukturze (np. drzewiastej) systemu plików..

Podział dysku na partycje

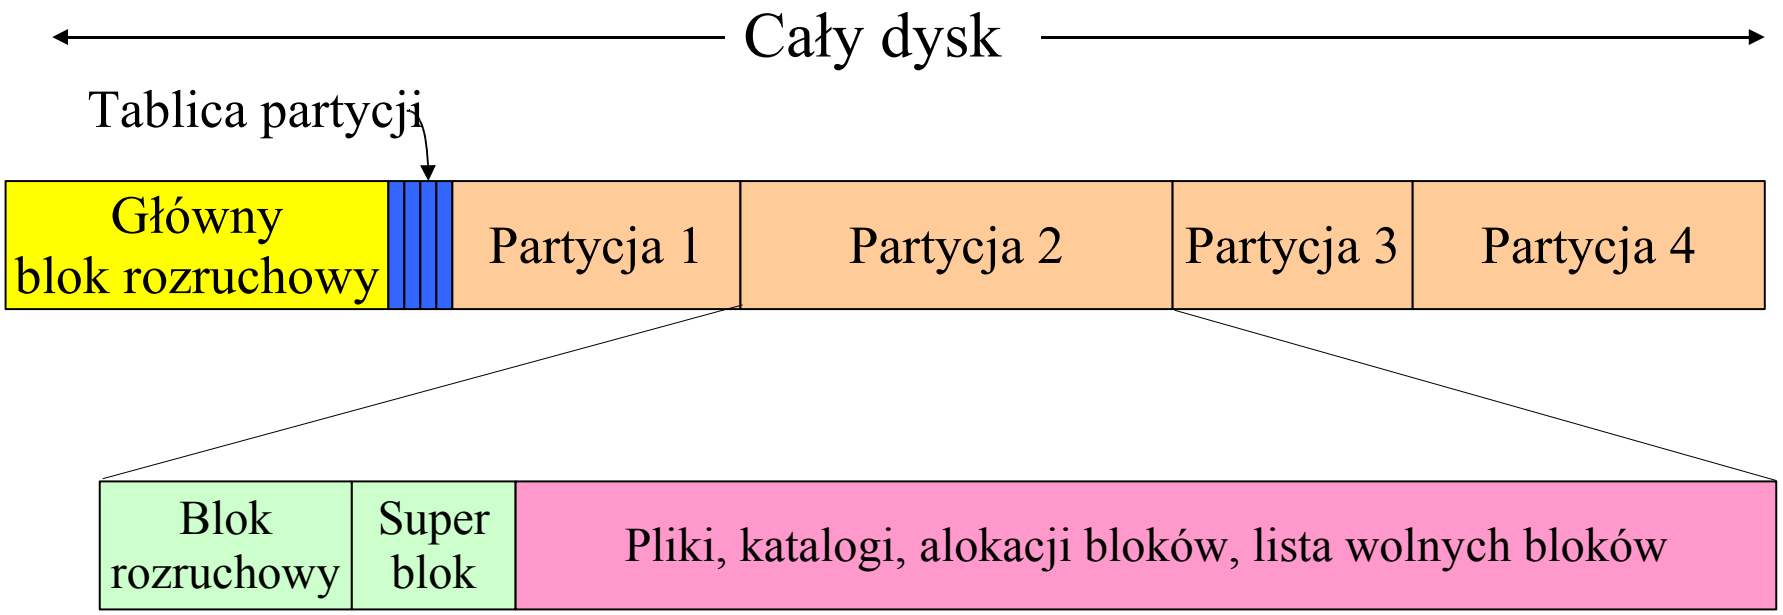

- Bloki rozruchowe (boot blocks) zawierają kod ładujący system operacyjny do pamięci.
- Każda partycja zawiera odrębny system plików (mogą to być systemy różnych typów). Tablica partycji zawiera informacje o podziale dysku na partycje (początek i koniec)
- Super blok zawiera informacje ogólne o systemie (np. całkowita liczba bloków danych, całkowita liczba plików)

Ciągła alokacja bloków danych

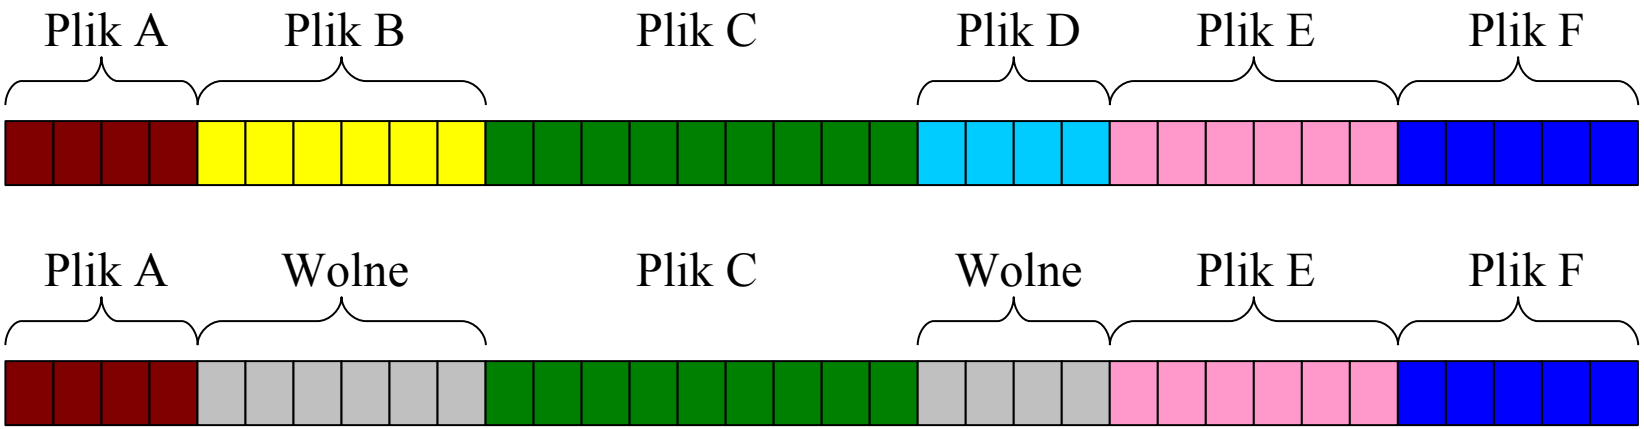

- Każdy plik zajmuje nieprzerwany ciąg bloków.
  - Bardzo szybki odczyt.
  - Bardzo proste zarządzanie informacją o blokach danego pliku – wystarczy tylko pamiętać numer pierwszego bloku oraz liczbę bloku.
  - Bardzo szybka operacja *seek*.

Wady ciągłej alokacji

- Może powstać fragmentacja (podobnie jak w przypadku pamięci RAM) – a kompakcja w pamięci dyskowej jest ***bardzo*** wolna.
- Musimy z góry znać maksymalny rozmiar pliku przy jego tworzeniu – problemy przy zwiększaniu rozmiaru pliku.

- Powyższe wady sprawiają że ciągła alokacja jest stosowana w systemach plików tylko do odczytu – np. ISO9600 dla pamięci CD-ROM.
  - W tym przypadku kompletny system plików, wraz ze wszystkimi plikami jest tworzony przy wypalaniu (wytłaczaniu) płytki.
  - Raz utworzony system plików nie będzie już modyfikowany (w płytkach wielosesyjnych każda sesja to odrębny system plików).
  - Nie ma potrzeby zarządzania wolnymi blokami, uwzględnienia możliwości zwiększenia rozmiaru plików etc.

Alokacja listowa

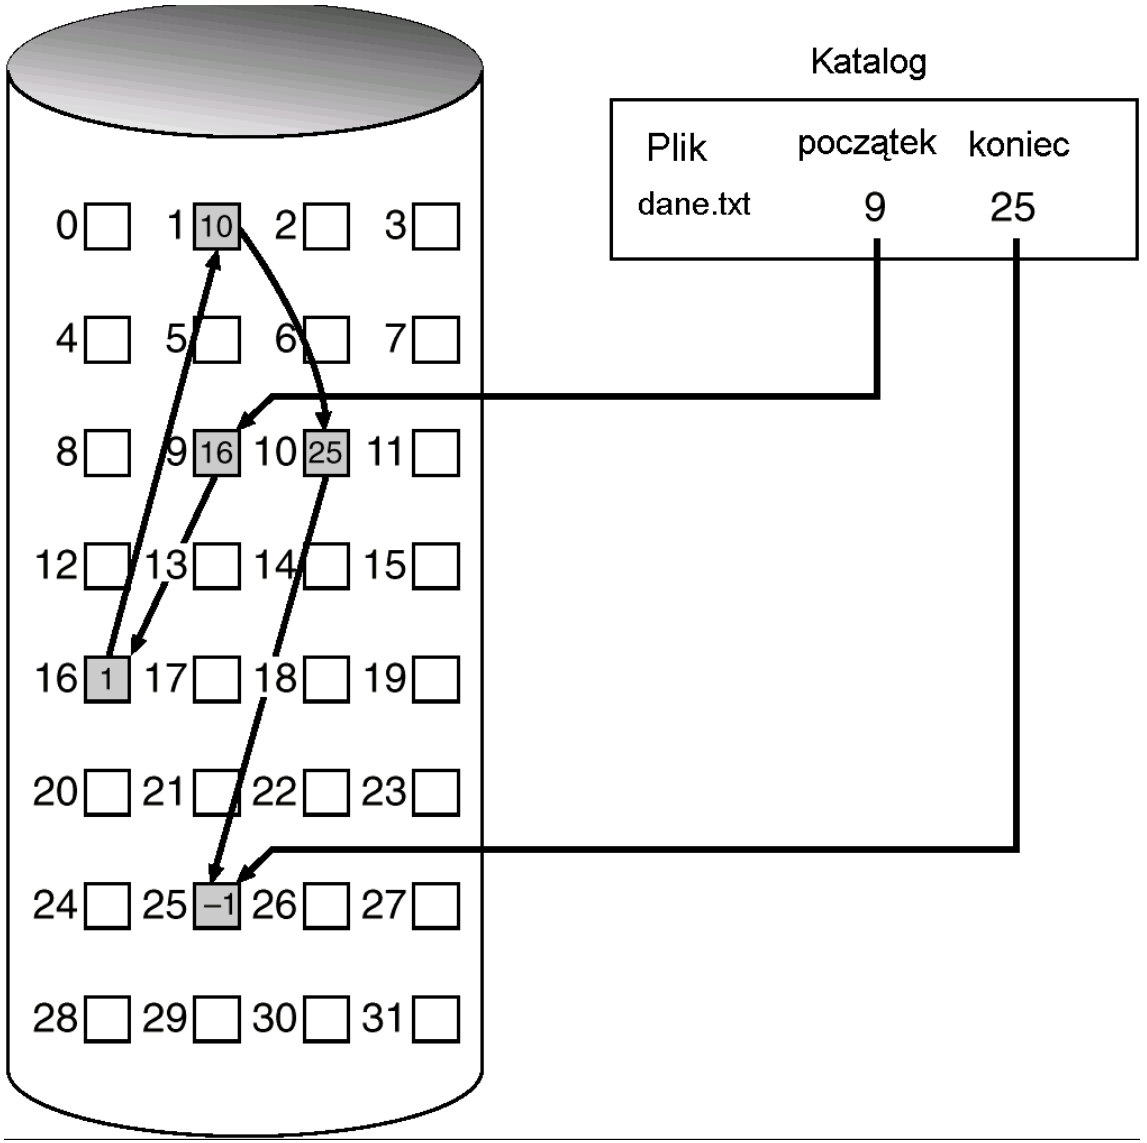

- Ostatnie (dwa, cztery) bajty bloku danych są zarezerwowane na numer następnego bloku.
- W katalogu przechowywany jest numer pierwszego bloku + numer ostatniego (aby umożliwić rozrost pliku).
- -1 oznacza ostatni blok pliku.

- Zaleta: Plikowi możemy przydzielić dowolny blok danych na dysku.
- Wada: Nie nadaje się do dostępu swobodnego, ponieważ aby wykonać operację *seek* musimy przeczytać wiele bloków na liście.

Tablica alokacji plików – FAT (ang. File Allocation Table)

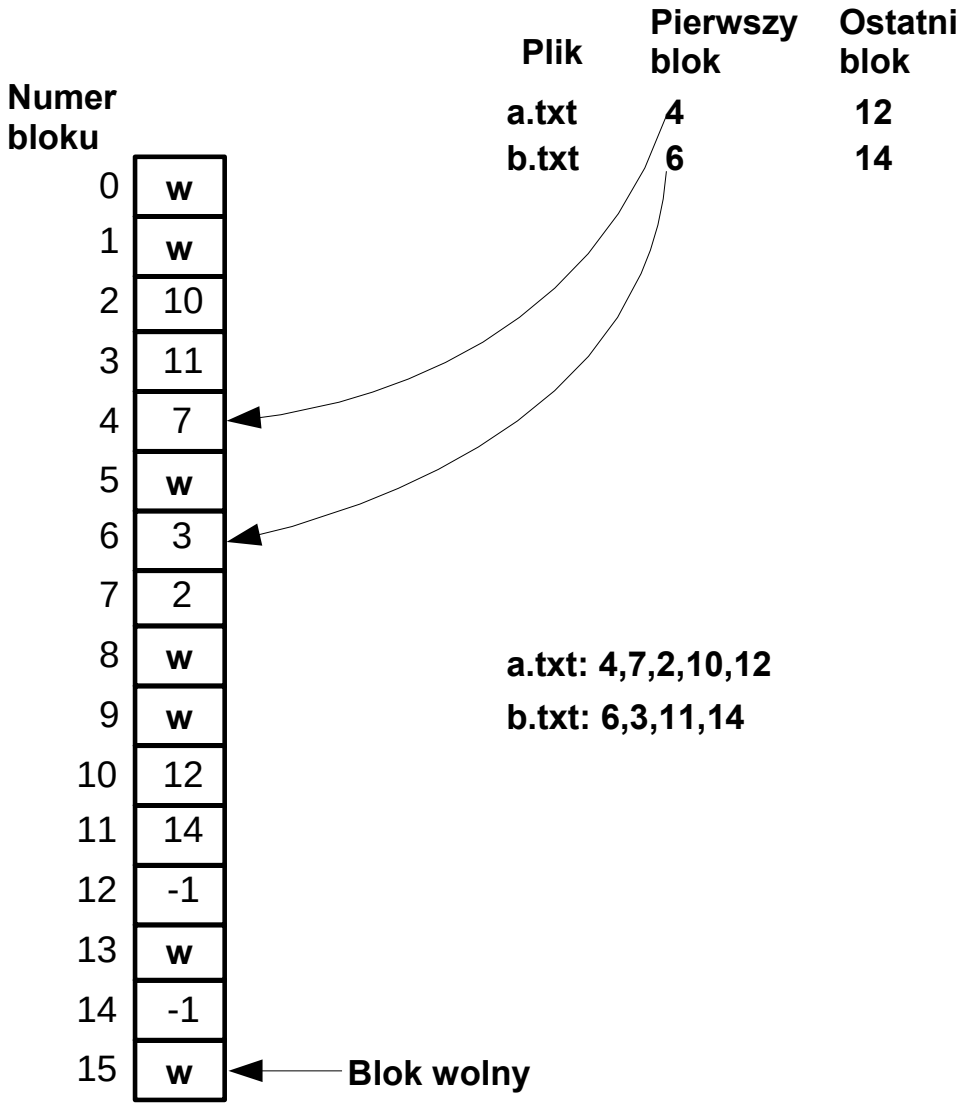

- Odmiana alokacji listowej, w której numery następnych bloków przechowywane są w odrębnej tablicy (FAT).
- Specjalne znaczniki na blok wolny (w) i ostatni blok pliku (-1).
  - Rozwiązany problem zarządzania wolnymi blokami danych.
- Tablica może znajdować się (w części lub w całości) w pamięci RAM, co zwiększa wydajność, zwłaszcza operacji *seek*.
- Problem zapewnienia spójności pomiędzy kopią tablicy w pamięci RAM, a oryginałem w pamięci dyskowej.
- Uszkodzenie tablicy FAT może prowadzić do utraty całego systemu plików.
- Potencjalnie bardzo duży rozmiar tablicy np. 80MB dla dysku 20GB

Alokacja indeksowa

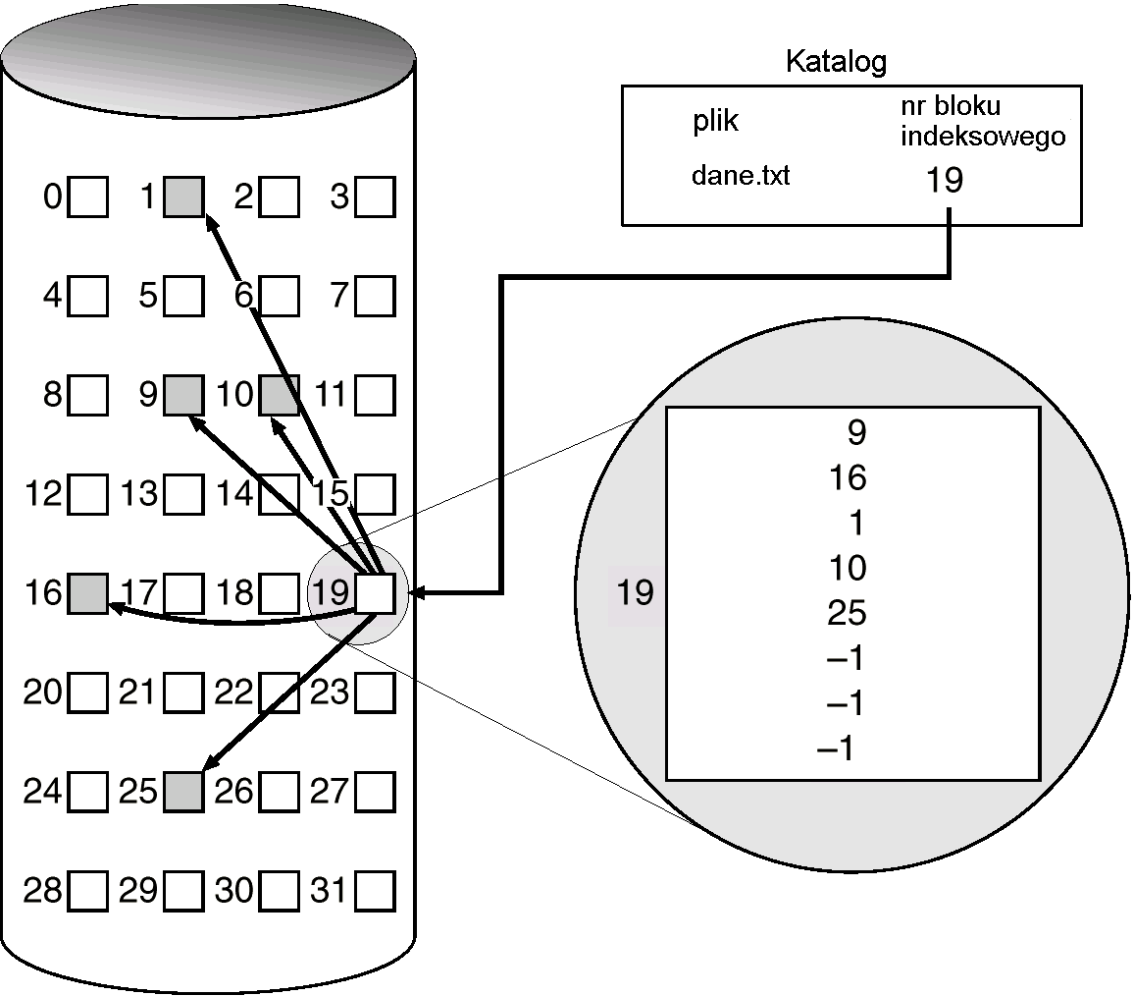

- Oddzielny blok indeksowy poświęcony na numery bloków z danymi.
- Dobra wydajność.
- Zakładając 1KB bloki i 32-bitowe numery w bloku indeksowym zmieści się 256 numerów. Co zrobić gdy rozmiar pliku jest większy od 256 KB ?
- Rozwiązanie: Indeksowanie pośrednie

Indeksowanie pośrednie

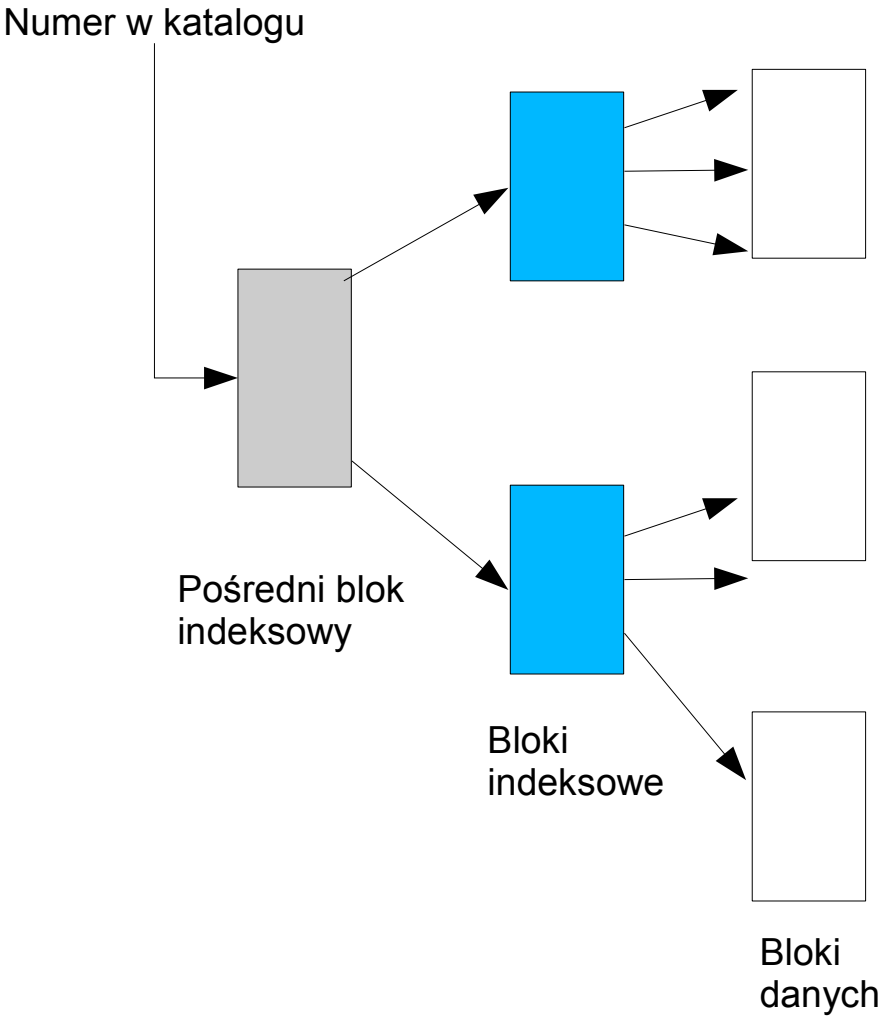

- Katalog zawiera numer bloku pośredniego, który z kolei zawiera numery bloków indeksowych.
- Plik może mieć maksymalną długość 256*256 KB=64MB.
- Potrzebujemy indeksowania podwójnie pośredniego (maks 16GB) lub potrójnie pośredniego.
- Problem utraty miejsca na bloki indeksowe

Zarządzanie wolnym blokami

- W systemie plików, w miarę jak pliki są tworzone i usuwane musimy przydzielać i zwalniać bloki danych (i być może indeksowe).
- W systemach FAT wystarczy wykorzystać specjalny znacznik w tablicy
- System musi być w stanie szybko odnaleźć wolny blok.
- Najprostszy sposób: mapy bitowe

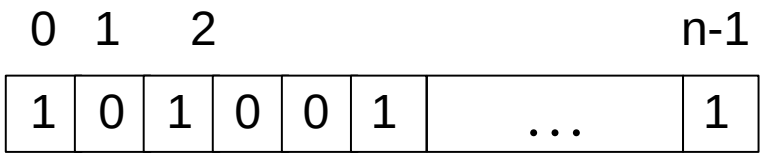

- Liczba bitów w mapie jest równa liczbie dynamicznie alokowanych bloków
  - Pozycja 0 oznacza blok wolny
  - Pozycja 1 oznacza blok wykorzystywany.
- Znowu powstaje problem zachowania spójności struktur w pamięci i na dysku

- Inne rozwiązanie: Lista wolnych obszarów

Przechowywanie atrybutów pliku

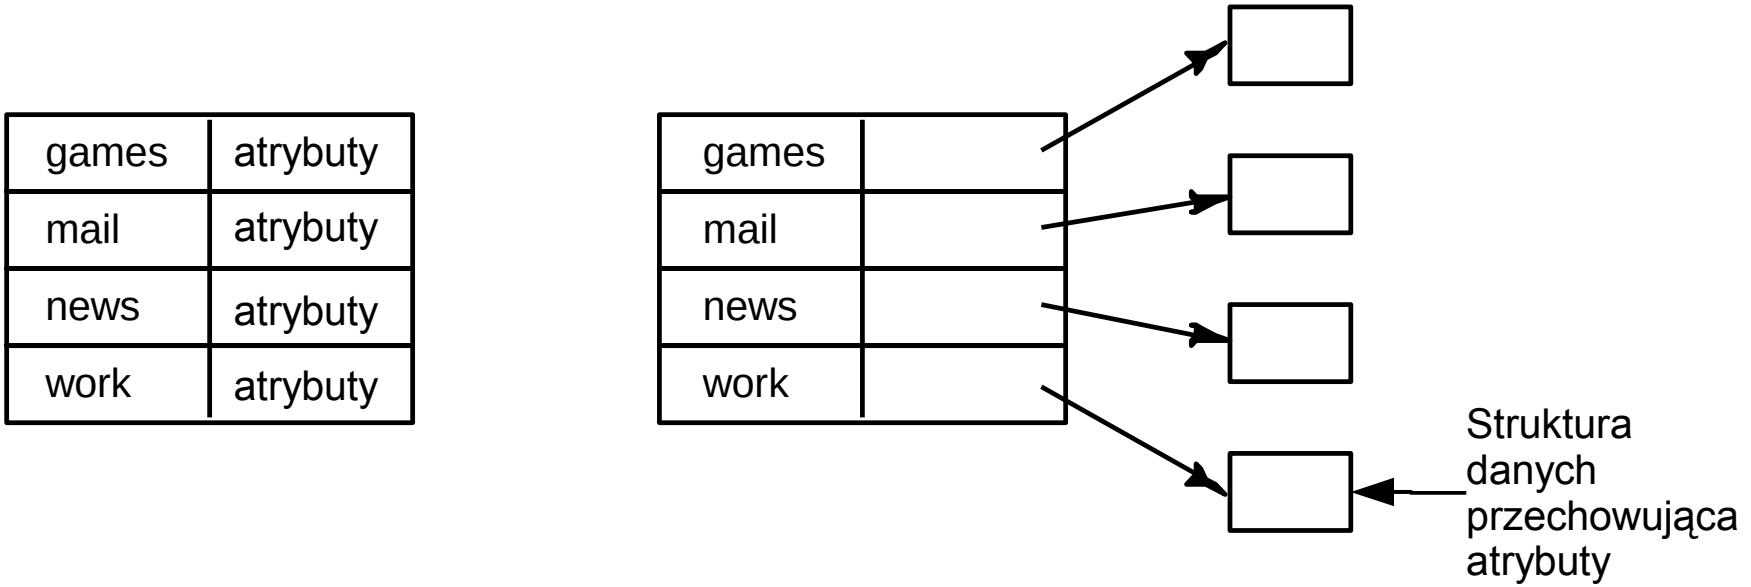

- Atrybuty przechowują dane zarówno widoczne dla użytkownika (długość,prawa dostępu, daty) jak i niewidoczne np. numer(y) bloków.
- Rozwiązanie z systemu MS-DOS wszystkie atrybuty przechowywane są w katalogu.
- Rozwiązanie z systemu UNIX atrybuty przechowywane są w odrębnej strukturze zwanej i-węzłem (ang. i-node) Każdy plik oraz katalog ma swój i-węzeł. Pewna część bloków na dysku jest poświęcona na tablicę i-węzłów. Pozycja katalogu zawiera jedynie numer i-węzła.

Pozycja katalogu w systemie MS-DOS

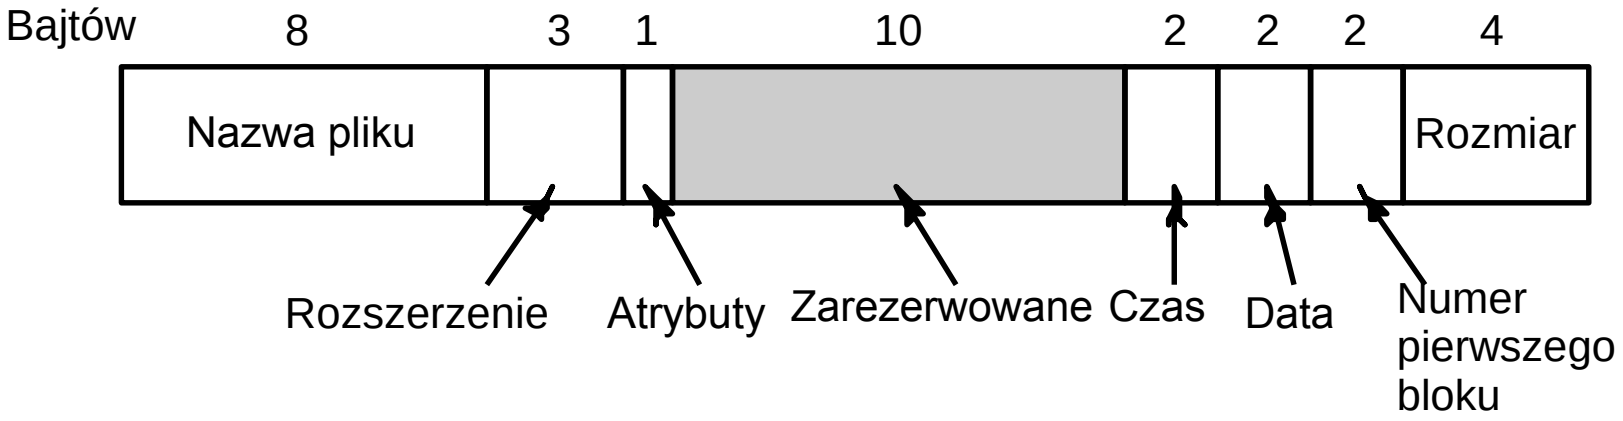

- MSDOS wykorzystuje tablicę FAT. Numer bloku w tablicy może mieć 12 (FAT12) 16 (FAT16) albo 32 (FAT32 Windows95SE) bity.
- Pozycja katalogu ma stały rozmiar (32bajty) i przechowuje wszystkie atrybuty pliku.
- Katalog jest szczególnym typem pliku.
- W kolejnych wersjach wykorzystano zarezerwowane bajty (np. dodatkowe 16-bitów numeru pierwszego bloku w systemie FAT32)
- Sektor startowy przechowuje informacje o liczbie kopii i położeniu tablic FAT oraz o położeniu głównego katalogu.

Klasyczny system plików Uniksa

- Uniks wykorzystuje alokację indeksową (szczegóły za chwilę).
- Katalog traktowany jest jako szczególny plik.
- Wszelkie atrybuty pliku przechowywane są w i-węźle. I-węzły przechowywane są w tablicy na dysku.
  - Potrzebujemy odrębnej mapy bitowej do zarządzania wolnym miejscem w tablicy i-węzłów. (pliki są tworzone i usuwane).
  - Całkowita liczba plików i katalogów w systemie nie może być większa od rozmiaru tablicy i-węzłów.

Postać i-węzła w Uniksie

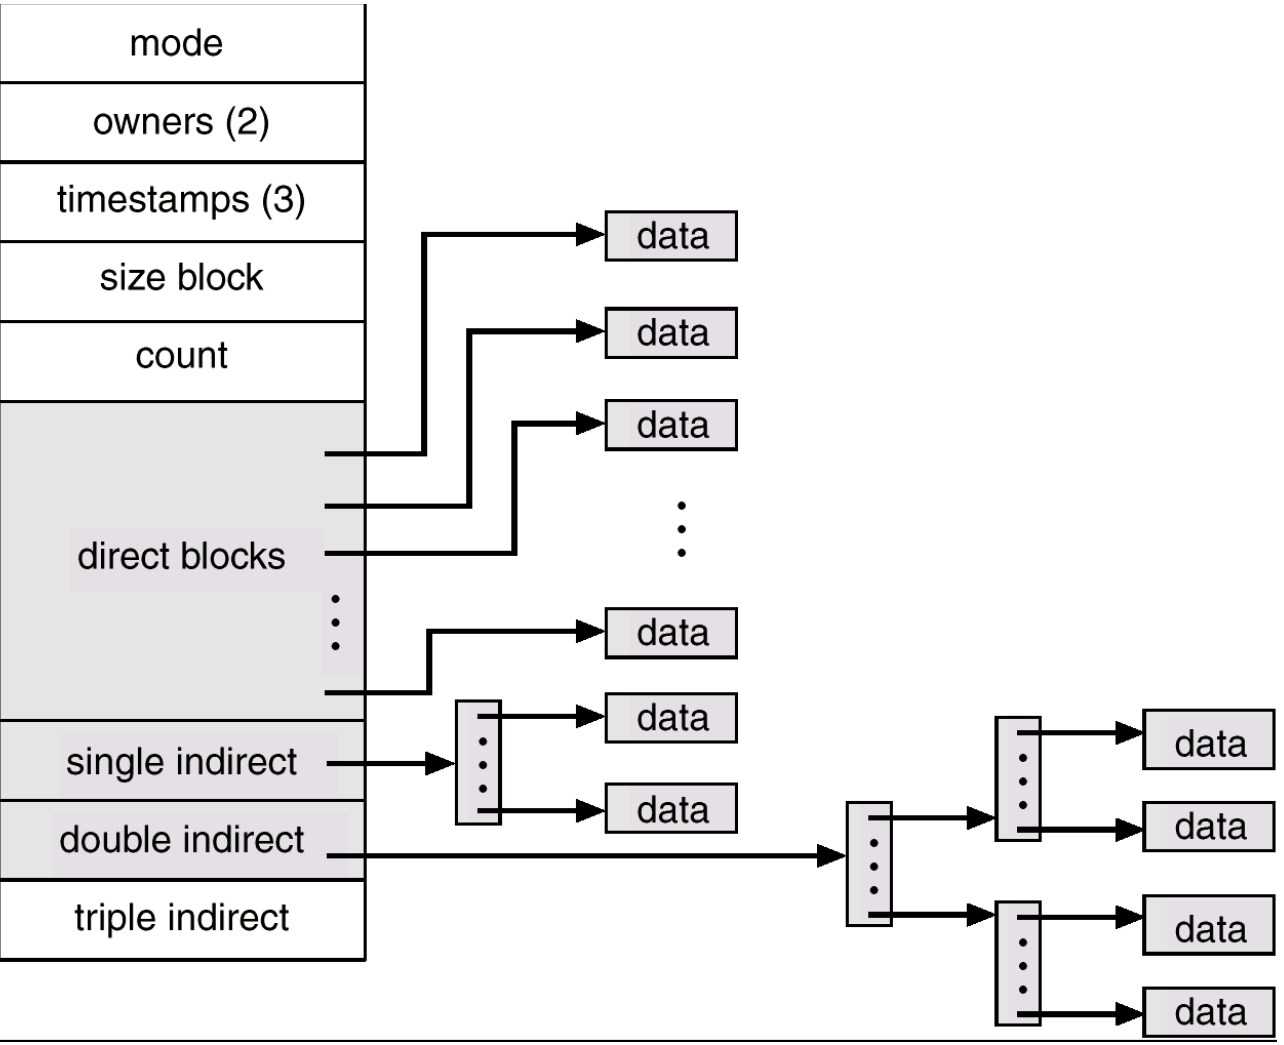

- Dla małych plików (np. Do 14 bloków numery są przechowywane bezpośrednio w i-węźle).
- Dla większych wykorzystuje się blok indeksowy (single indirect).
- Dla jeszcze większych indeksowanie podwójnie i potrójnie pośrednie.

Katalogi w Uniksie

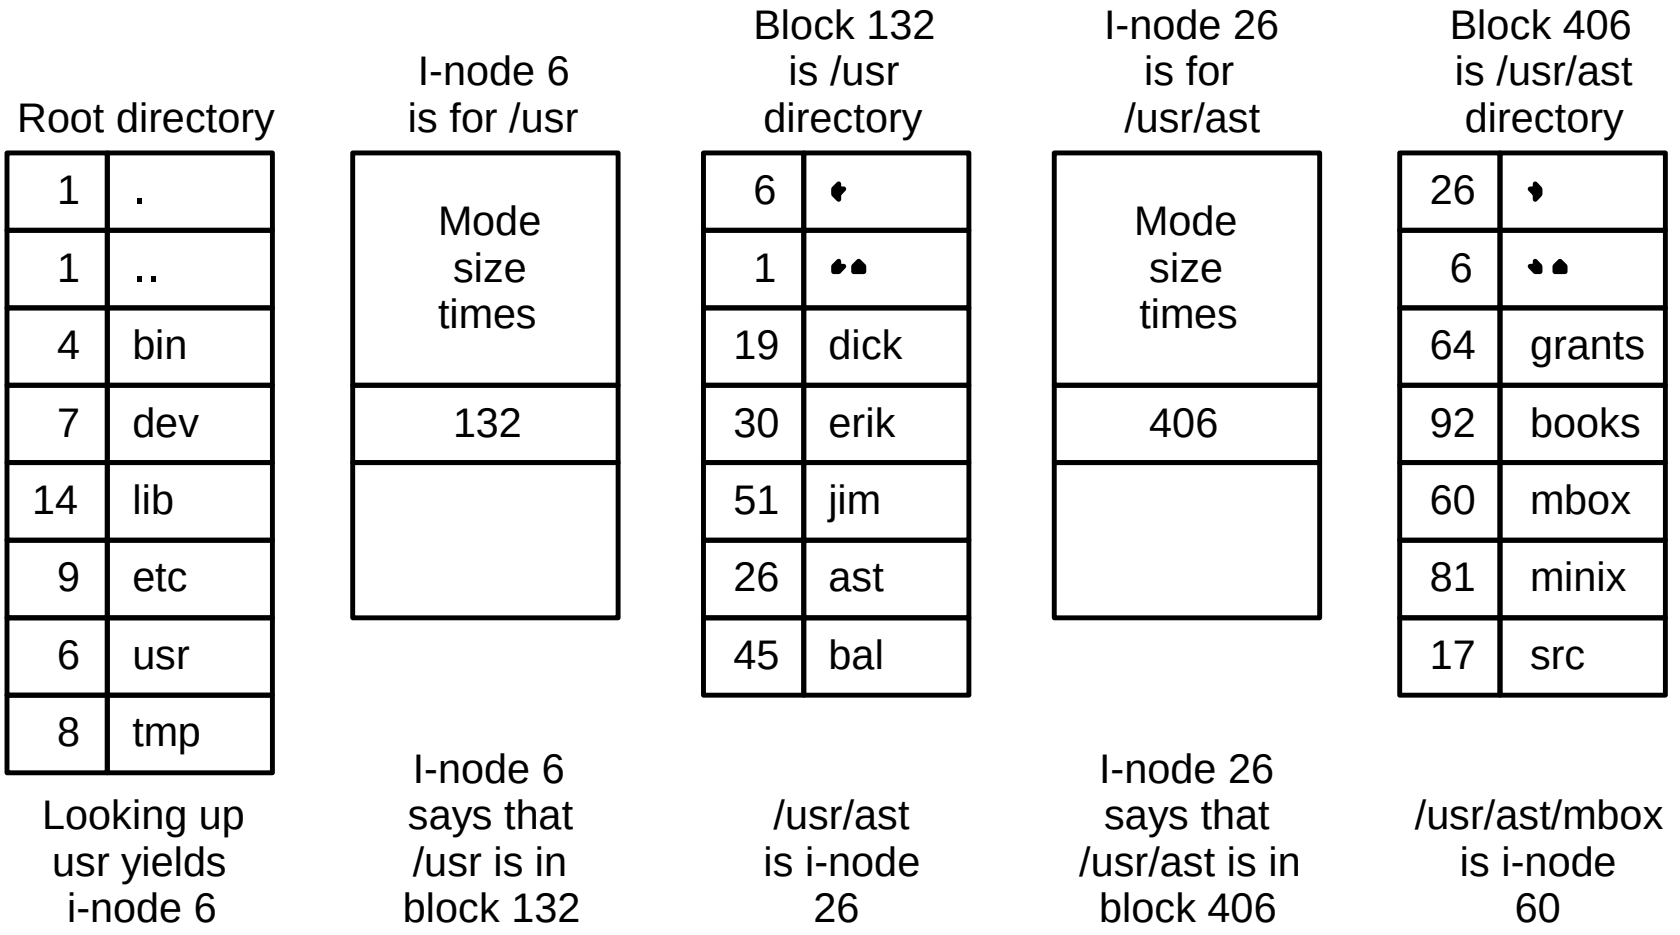

- Tłumaczenie nazwy ścieżki /usr/ast/mbox na numer i-węzła
- Pozycja katalogu zawiera wyłącznie numer i-węzła

Systemy plików z kroniką (ang. log)

- Cel - minimalizacja prawdopodobieństwa katastrofalnej awarii systemu plików, skrócenie czasu naprawy systemu po utracie zasilania. Uwaga: systemy z kronikowaniem nie zastąpią UPSa !!!
- Specjalny obszar zwany kroniką (ang. journal).
- Zmiana w systemie plików przebiega w sposób następujący: (a) zapisz (commit) bloki dyskowe które zmieniasz do kroniki - zapisywane są bloki składające się na ***transakcję*** (b) jeżeli pierwszy commit powiódł się wykonaj właściwy commit do systemu plików (c) jeżeli drugi zapis się powiódł to możesz (niekoniecznie od razu) usuń bloki z kroniki (kronika działa jak trochę podobnie jak kolejka FIFO.
  - Jeżeli awaria nastąpiła przed zakończeniem (a) to nic się nie dzieje - nastąpi utrata danych, ale system plików pozostanie w stanie spójnym.
  - Jeżeli awaria nastąpi pomiędzy (a) - (b), to przy naprawie systemu plików wykonaj ponowny commit transakcji z kroniki.
- Różne możliwości funkcjonowania kroniki: (a) kronikowane są bloki z danymi jak i meta-danymi (np. tablica i-węzłów, bitmapy i-węzłów i bloków, bloki indeksowe), (b) wyłącznie bloki z metadanymi, po awarii zasilania system plików zachowa spójność ale jest duża szansa na utratę danych plików zapisywanych w momencie awarii.
- Uwaga: gwarancja pozostawienie systemu plików w stanie spójnym nie oznacza gwarancji że dane przechowywane w pliku będą spójne z punktu widzenia aplikacji.

Strategie optymalizacji wydajności

- Generalnie powinniśmy dążyć do tego aby kolejne bloki danych tego samego pliku zostały umieszczone w kolejnych blokach na dysku.
- Programy typu Defrag – mogą być bardzo czasochłonne.
- Inne strategie
  - Prealokacja bloków: jeżeli przy zapisie do pliku potrzebujesz jednego nowego bloku, to przydziel od razu k (typowo k=8,16) bloków zajmujących ciągły obszar dysku, w nadziei, że za chwilę będą potrzebne nowe bloki. Jeżeli dodatkowe bloki nie zostaną wykorzystane, to są zwalniane przy zamykaniu pliku.
  - Wykorzystaj pamięć podręczną
  - Zwiększ rozmiar bloku

Wybór rozmiaru bloku (Tannenbaum, 2004)

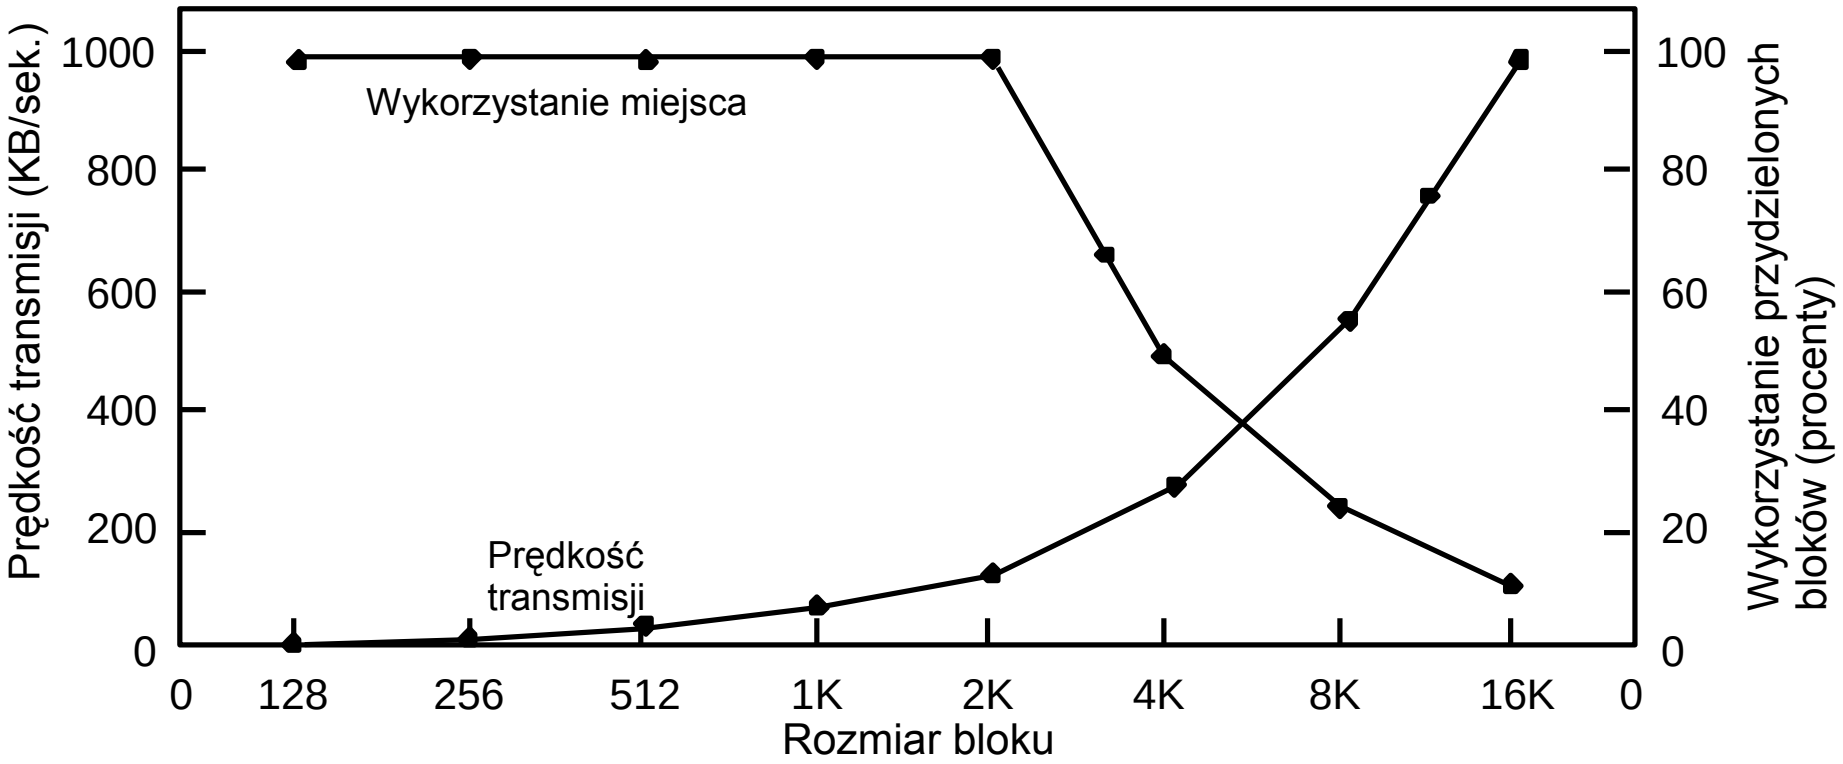

- Pamięć masowa jest podzielona na 512-bajtowe sektory (2048 bajtów w CD-ROMie). Blok dyskowy jest wielokrotnością sektora. Typowe rozmiaru bloku to 1,2,4,8 sektortów.
- Większy rozmiar bloku => większa prędkość transmisji (mniejsza fragmentacja, czyli mniej ruchów głowicą).
- Większy rozmiar bloku => mniej efektywne wykorzystanie miejsca na dysku. Przeciętnie z każdym plikiem wiąże się utrata miejsca równa połowie długości bloku

Pamięć podręczna (ang. cache) dysku

- Idea: Przeznaczyć część pamięci RAM na przechowywanie najczęściej używanych bloków w celu poprawienia wydajności systemu.
- Musimy dostarczyć mechanizm (np. tablice mieszające) pozwalający szybko sprawdzić czy blok o numerze i jest w pamięci podręcznej.
  - Jeżeli bloku nie ma to jest on wczytywany z dysku i dodawany do pamięci podręcznej.
- Musimy określić algorytm wyboru bloku usuwanego z pamięci podręcznej (np. LRU).
- Musimy określić strategię obsługi zapisów:
  - Write-through – zapisywany blok trafia jednocześnie do pamięci podręcznej i na dysk.
  - Blok jest zapisywany z opóźnieniem – większa wydajność, ale większe niebezpieczeństwo uszkodzenia systemu. Większość systemów wprowadza maksymalne opóźnienie np. 20 s dla bloków danych zwykłych plików (nie katalogów) i 2 sekundy dla pozostałych bloków

Przykład implementacji pamięci podręcznej

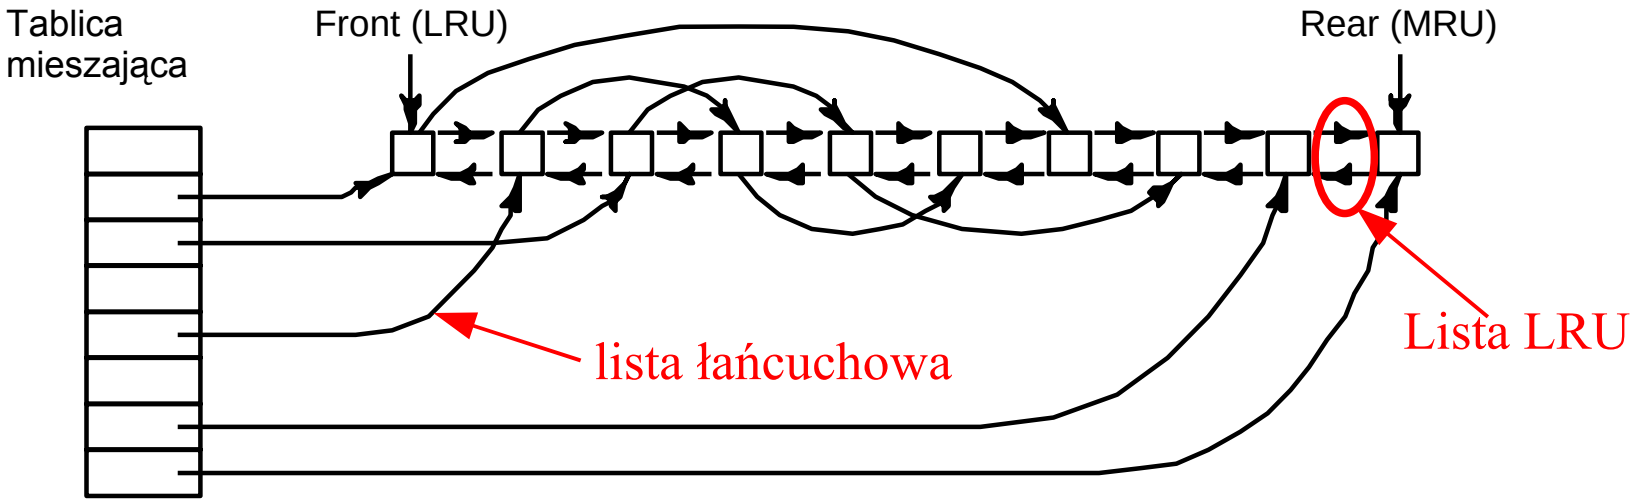

- Tablica mieszająca: pozwala na szybkie sprawdzenie, czy blok jest w pamięci. Każdy element odpowiada jednej wartości funkcji mieszającej.
- Każdy blok jest elementem dwóch list: dwukierunkowej listy LRU, oraz listy łańcuchowej na której przechowywane są bloki o identycznej wartości funkcji mieszającej.
- W przypadku trafienia (ang. cache hit) blok pobrany z pamięci jest przesuwany na koniec listy LRU .
- Nowy blok jest wczytywany w miejsce bloku na pierwszej pozycje listy i przesuwany na koniec.