# Wykład 9
# Struktury pamięci masowej

# Struktura dysku

- Dane przechowywane są na powierzchniach
  - Maksimum dwie powierzchnie na talerzu.
  - Conajmniej jeden talerz
- Dane znajdują się na koncentrycznych ścieżkach.
  - Ścieżki podzielone są na sektory
  - Odpowiednie ścieżki na wszystkich powierzchniach tworzą cylinder
- Dane są zapisywane i odczytywane przez głowice.
  - Głowice przesuwane są przez napęd krokowy
  - Wszystkie głowice przesuwane są jednocześnie
- Dysk z wymiennym lub niewymiennym nośnikiem

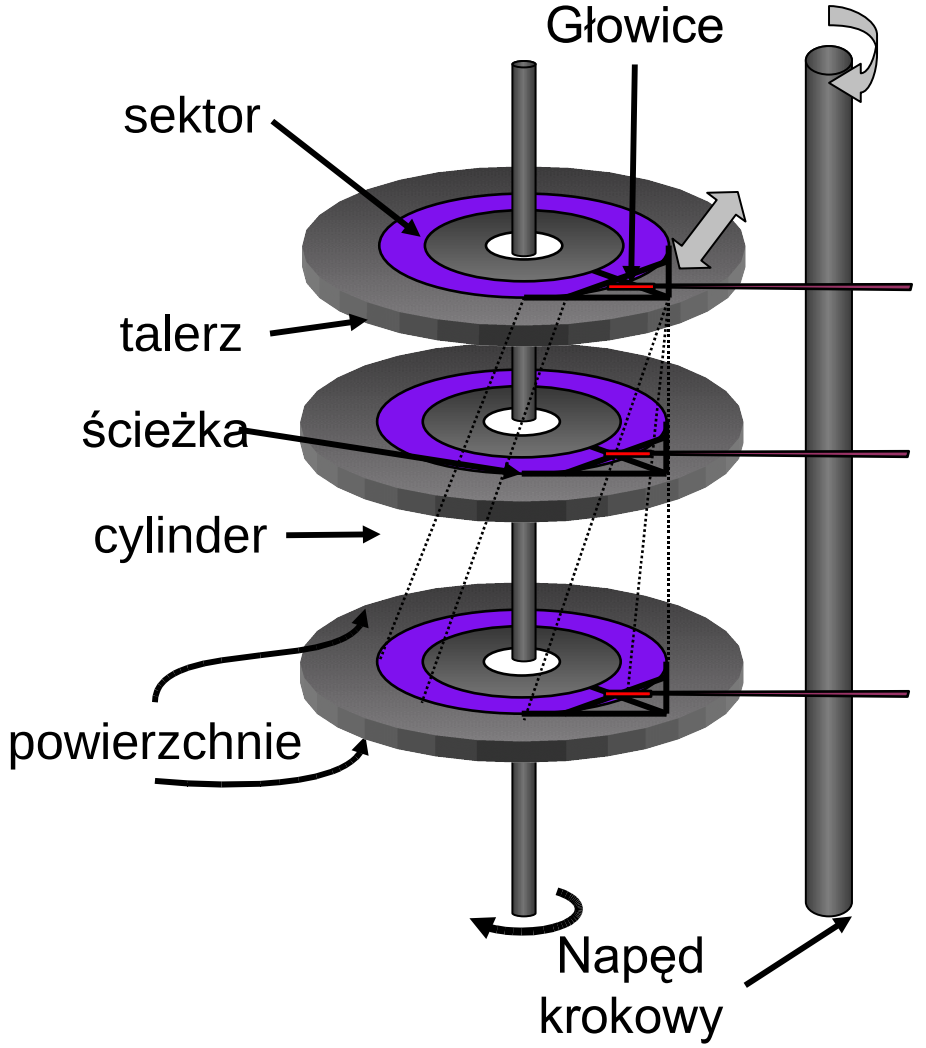

# Przykład

| | IBM 360KB floppy | WD 18GB HD |
|---|---|---|
| Cylinders | 40 | 10601 |
| Tracks per cylinder | 2 | 12 |
| Sectors per track | 9 | 281 (średnio !!!) |
| Sectors per disk | 720 | 35742000 |
| Bytes per sector | 512 | 512 |
| Capacity | 360 KB | 18.3 GB |
| Seek time (minimum) | 6 ms | 0.8 ms |
| Seek time (average) | 77 ms | 6.9 ms |
| Rotation time | 200 ms | 8.33 ms |
| Spinup time | 250 ms | 20 sec |
| Sector transfer time | 22 ms | 17 µsec |

# Adresowanie dysku

- Dysk może mieć miliony sektorów. Jak je zaadresować.
- Metoda 1: Cylinder/Głowica/Sektor.
  - Liczba sektorów na ścieżce może się zmieniać.
- Metoda 2: Numerowanie sekwencyjne
  - Dysk odwzorowuje globalny numer sektora z zakresu [0-max] na numer cylindra,ścieżki oraz sektora w cylindrze.
  - Odwzorowanie może się zmieniać !!!
    - Przemieszczanie błędnych sektorów
    - Optymalizacja wydajności.
- Nowoczesne dyski wykorzystują metodę 2.
- Dzięki temu szczegóły geometrii są ukryte przed systemem operacyjnym
  - Ale zawsze opłaca się w jednym żądaniu odczytywać grupę kolejnych sektorów

# Układ sektorów na dysku

- Wewnętrzne ścieżki są krótsze niż zewnętrzne.
- Dwa rozwiązania:
  - (a) dłuższe bity
  - (b) więcej sektorów na ścieżkach zewnętrznych
- Stacja dysków elastycznych wykorzystuje rozwiązanie (a)
- Nowoczesne dyski wykorzystują rozwiązanie (b).
- Dysk podzielony jest na kilka stref (8-20).
- W każdej ze stref na jedną ścieżkę przypada stała liczba sektorów
- W rozwiązaniu (b) odczyt sektorów ze ścieżek zewnętrznych następuje szybciej.

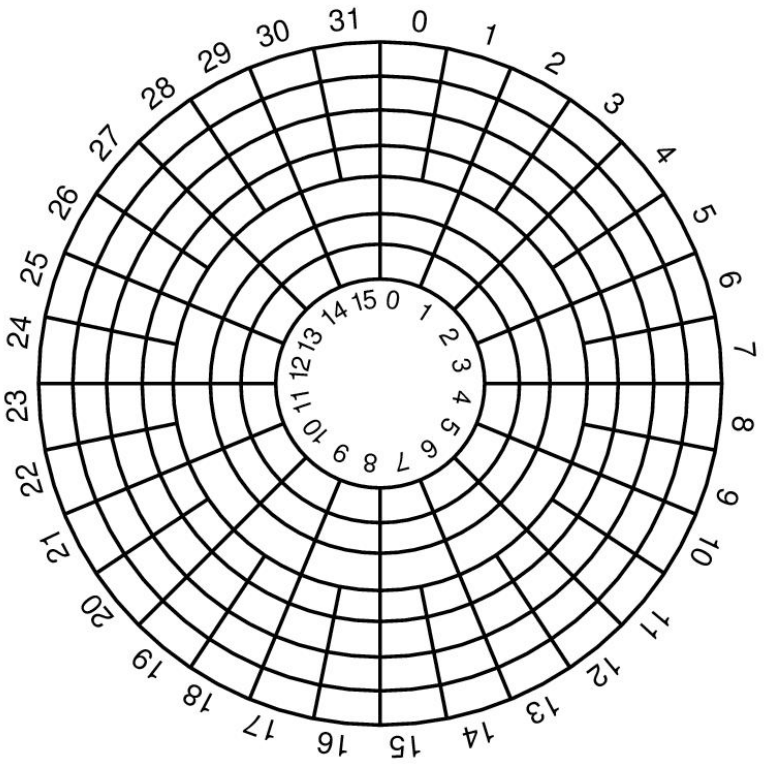

# “Zapasowe” sektory

- Ścieżka może zawierać dodatkowe sektory.
- Gdy dany sektor zaczyna sprawiać problemy (dużo błędów poprawianych przez ECC), przenoszony jest do sektora dodatkowego.
- Pogarsza to wydajność.
  - Aby temu zapobiec, można na nowo posortować sektory na ścieżce, ale zajmuje to dużo czasu
- Mechanizm ten jest często ukryty przed systemem operacyjnym

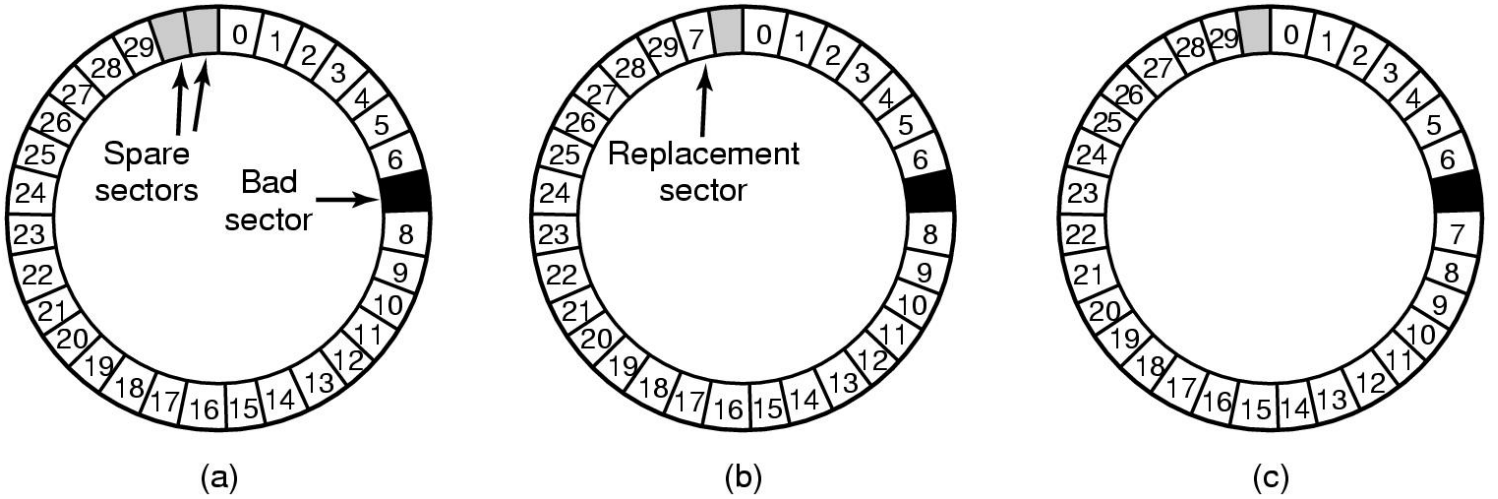

# Napędy optyczne - CD-ROM, DVD-ROM, ...

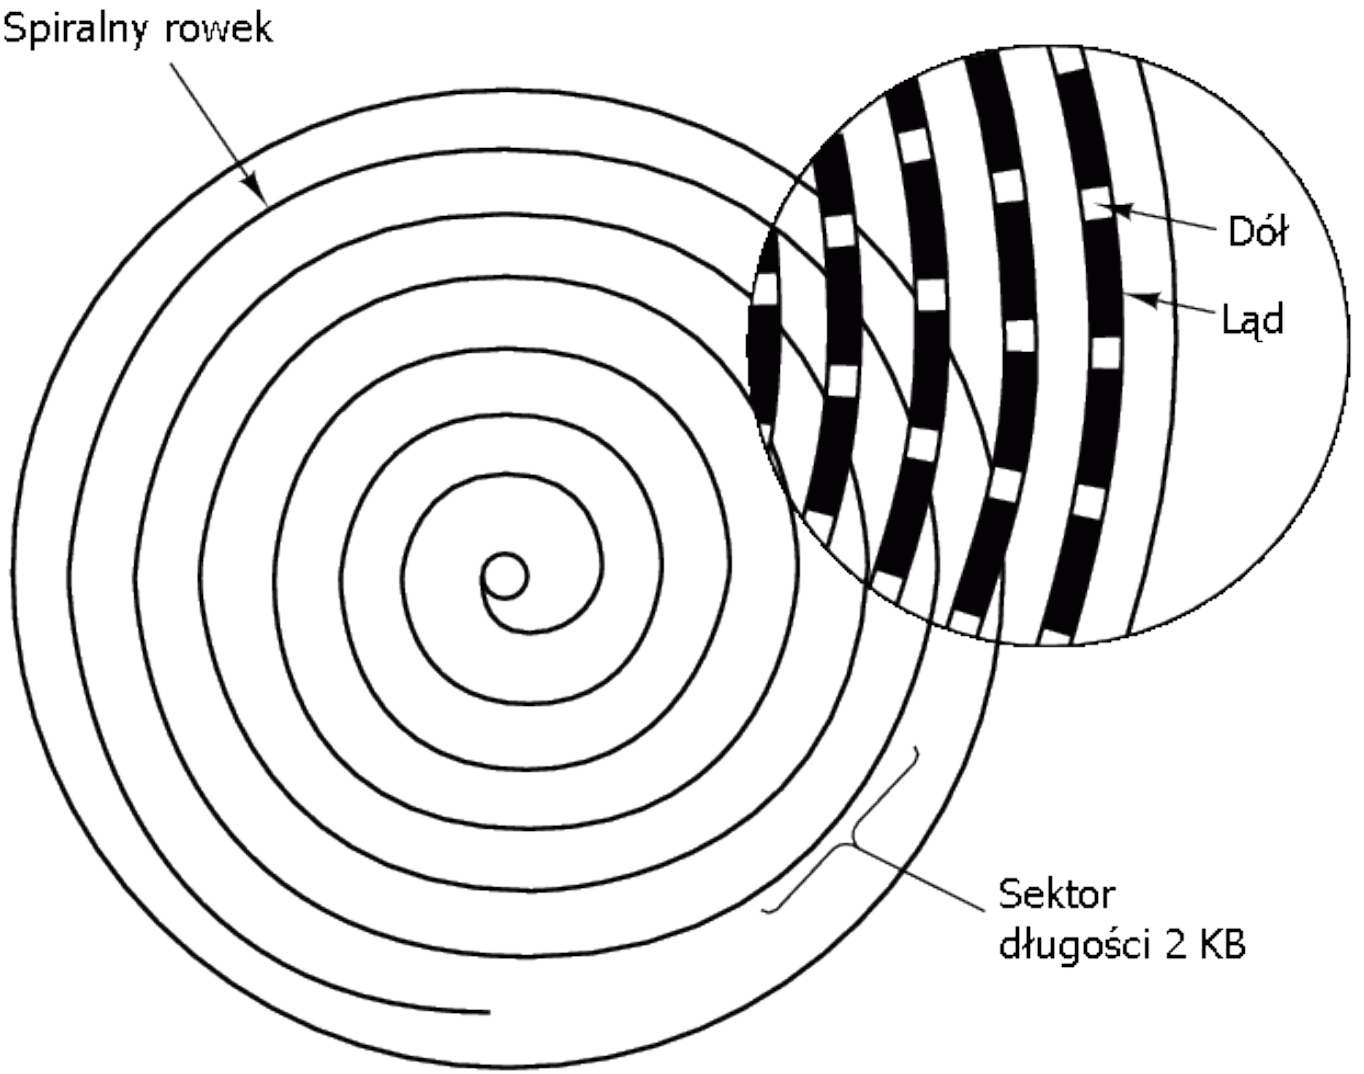


- W napędach optycznych nie mamy koncentrycznych ścieżek, a spiralę.
- Sektor ma 2KB

# Struktura sektora dyskowego


- Preambuła – zawiera numer sektora, i cylindra
- Dane (długość 256, 512 lub 1024 bajty)
- ECC (ang. error correcting code) – nadmiarowe informacje pozwalające na wykrycie (prawie) wszystkich błędów i poprawienie niektórych z nich

# Czas wykonania operacji

- Czas operacji=Czas dostępu + Czas transferu
- Czas dostępu, zależy od dwóch składników.
  - Czas wyszukiwania (ang. seek time) czas niezbędny na ustawienie się głowicy dysku nad właściwym cylindrem.
  - Oczekiwanie aż głowica znajdzie się nad odpowiednim sektorem.
    - Zależy od prędkości obrotowej dysku, średnio ½ czasu wykonania obrotu przez talerz.
- System operacyjny może próbować optymalizować czas wyszukiwania.
- Czas transferu też zależy od prędkości obrotowej dysku.
- Przykład
  - Czas wyszukiwania = 7ms; Czas oczekiwania 4ms => Czas dostępu 11ms
  - Czas transferu 22us (trzy rzędy wielkości mniej !!!)
- Wniosek: staraj się przesyłać wiele kolejnych sektorów w jednym żądaniu.

# Planowanie żądań do dysku

- Cel: Minimalizuj czas spędzany na przesuwaniu głowicy i oczekiwaniu.
  - Na oczekiwanie mamy niewielki wpływ.
- Umieszczaj bloki składające się na dany plik w “pobliżu siebie”.
- Używaj algorytmów planowania do ustalania kolejności obsługi żądań.
- Istnieje wiele algorytmów planowania.

- Przykład:
  - Głowica nad blokiem 53.
  - Zakładamy kolejność żądań: 98, 183, 37, 122, 14, 124, 65, 67
  - Zakładamy, że kontroler przetwarza jedno żądanie - w nowych dyskach nie jest to do końca prawdą.

# Algorytm FCFS (ang. First come, First served)

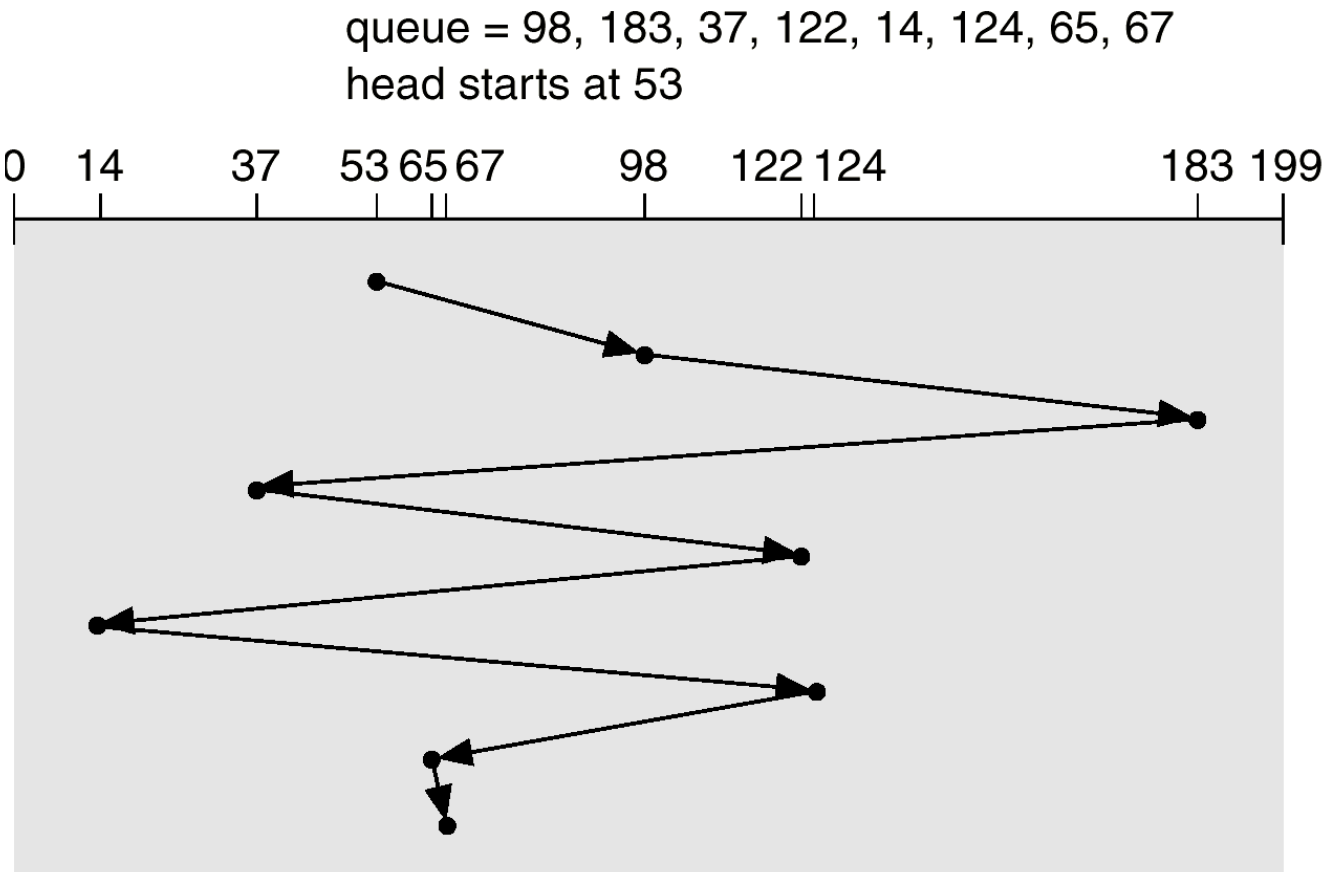


- Obsługuj żądania w kolejności zgłoszenia.

# Algorytm SSTF (ang. Shortest Seek Time First)

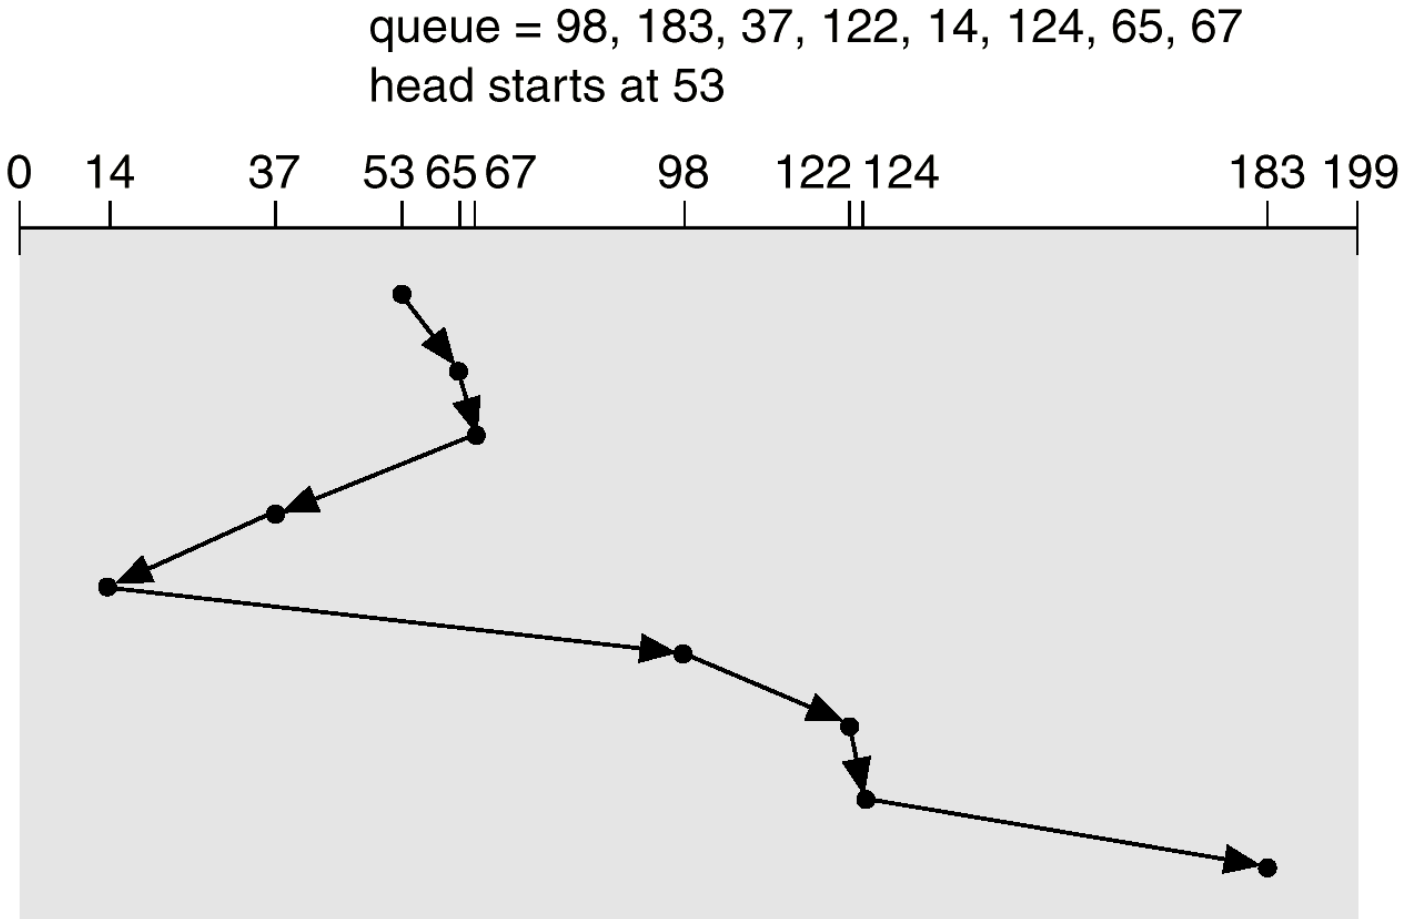


- Wybierz żądanie o najkrótszym czasie oczekiwania.
- Możliwość zagłodzenia

# Algorytm SCAN

- Zwany również algorytmem windy (ang. Elevator).
- Ramię dysku porusza się od jednego końca dysku do drugiego, obsługując po drodze żądania.
- Po dojściu do końca dysku kierunek poruszania się ramienia ulega zmianie.

# Algorytm SCAN: Przykład

queue = 98, 183, 37, 122, 14, 124, 65, 67
head starts at 53

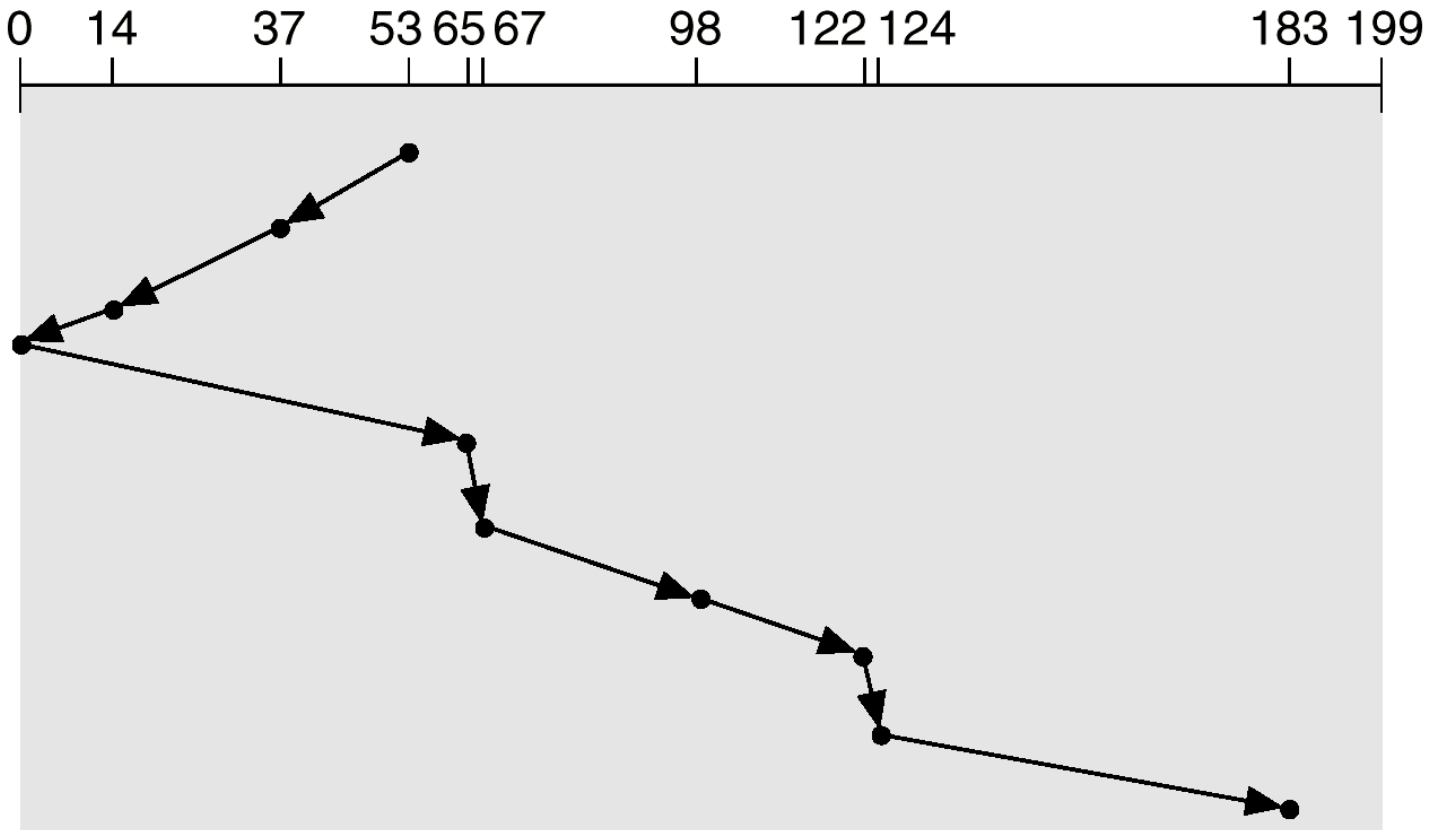

# Algorytm C-SCAN

- Ulepszona wersja algorytmu SCAN. Gdy głowica dotrze do końca dysku, natychmiast jest przesuwana z powrotem na początek, bez obsługiwania kolejnych żądań.

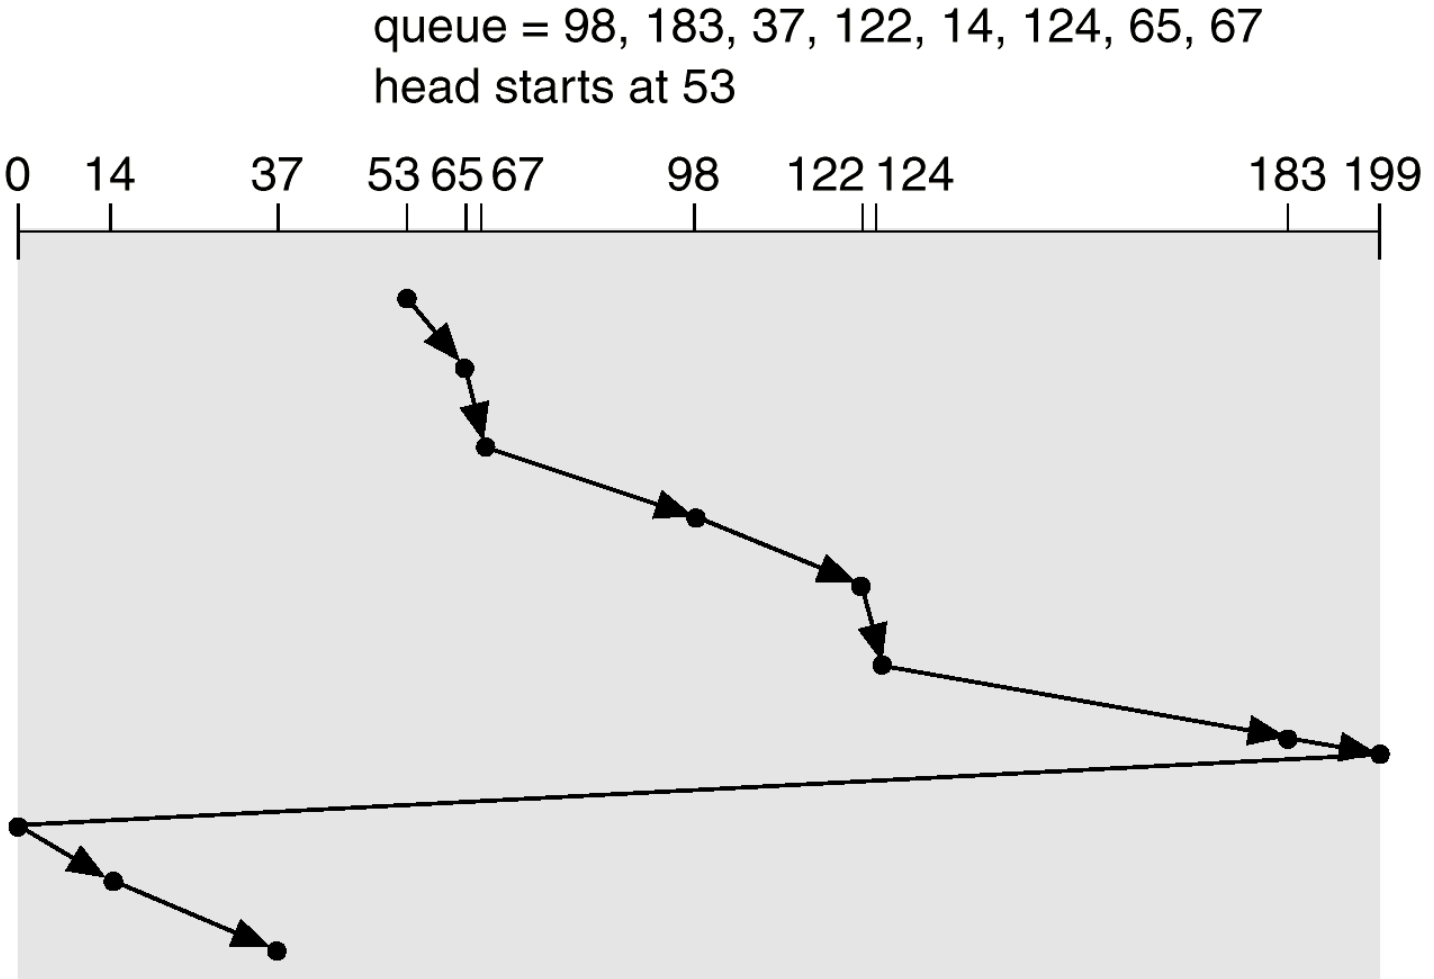

# Algorytm C-LOOK

- Ramię przesuwa się, nie do końca a tylko tak daleko aby obsłużyć ostatnie żądanie.

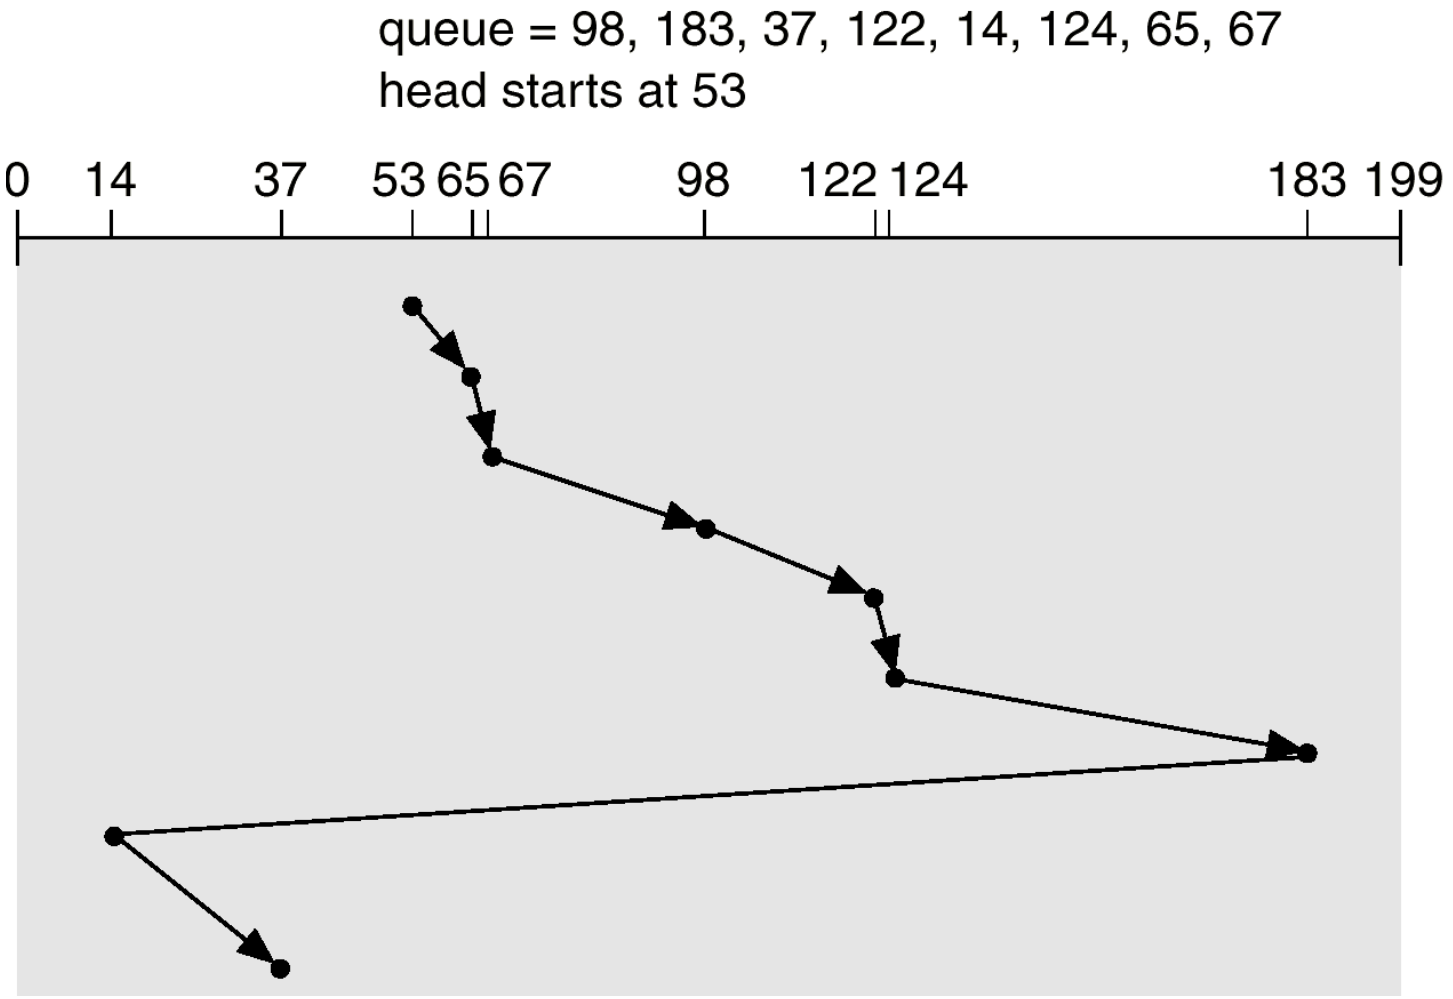

# Jaki algorytm wybrać

- SSTF łatwy do zaimplementowania i ma dobrą wydajność, gdy obciążenie dysku jest niewielkie.
- Algorytmy typu SCAN mają lepszą wydajność przy dużym obciążeniu dysku
  - Brak możliwości zagłodzenia
  - Wersje LOOK unikają niepotrzebnego przesuwania głowicy
- Przejście od jednego końca dysku do drugiego jest stosunkowo mało kosztowne.
  - Dlatego C-LOOK jest lepszy niż C-LOOK, bo zapewnia małą wariancję czasu dostępu.
- Konkluzja:
  - SSTF dla słabo obciążonych systemów
  - C-LOOK dla bardzo obciążonych systemów .
- Ponadto: Wraz ze wzrostem wyrafinowania elektroniki dysku (duże pamięci cache, integracja z pamięciami FLAS) pojawia się tendencja do implementacji części lub całości algorytmów szeregowania przez kontroler.
  - Przykład: Natywne kolejkowanie komend (NCQ - ang. native command queueing) w standardzie Serial ATA.

# Jak zbudować lepszy dysk

- Wydajność procesorów wzrasta wykładniczo.
- W przypadku dysków nie jest to prawdą.
  - Czas dostępu jest ograniczony przez mechanikę dysku
- Niezawodność dysków nie jest wysoka.
  - Nic dziwnego, dysk ma miliony sektorów.
- Rozwiązanie: wykorzystaj kilka dysków
  - Dane przesyłane równolegle z wielu dysków
  - Dane zapamiętane w paskach (ang. Stripe).
  - Bit parzystości na dodatkowym dysku.
- Technika nosi nazwę RAID (ang. redudant array of independent drives).

# Macierze RAID

- Redudant Array of Inexpensive Discs Nadmiarowa Macierz Tanich Dysków (Patterson i wsp., 1988) - ma działać lepiej niż SLED (Single Large Expensive Disc)
- Idea: Zbiór (macierz) dysków dzięki specjalnemu kontrolerowi widoczny dla reszty systemu jako jeden “virtualny” dysk.
- Virtualny dysk dzielony jest na paski (ang. strips), które są rozpraszane na dyskach tworzących macierz.
  - Pasek ma rozmiar k-sektorów.
- Redundancja pozwala na zmniejszenie ryzyka awarii.
- Ponieważ dyski w macierzy pracują równolegle, żądania mogą być realizowane szybciej.
- Komercyjnie dostępne poziomy 0,1, 0+1, 4,5

# RAID Level 0

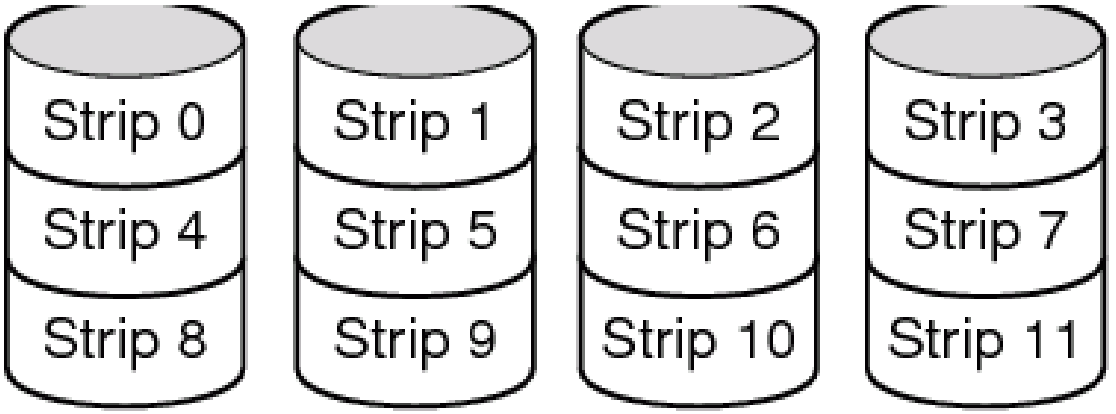


- Nie jest to prawdziwa macierz RAID - nie ma redundancji. Paski są rozpraszane równomiernie po wszystkich dyskach - pojemność dysku się nie marnuje.
- Dwa żądania mają szanse dotyczyć dwóch niezależnych dysków i być obsłużone równolegle - krótszy czas oczekiwania na żądanie.
- Duże żądanie może dotyczyć kilku kolejny pasków (np. strip2,strip3, strip4) wtedy czas oczekiwania jest taki sam, ale czas transmisji się znacznie skraca - dyski pracują równolegle.
- Awaryjność ***wzrasta*** (i to znacznie - patrz wykład ze statystyki)

# RAID Level 1

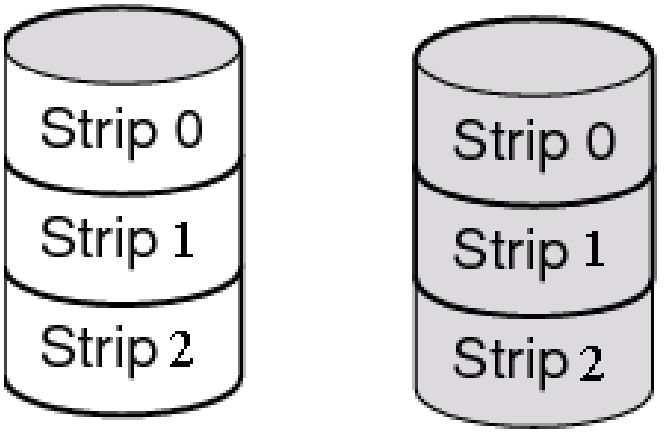


- Jeden dysk jest kopią drugiego - odtworzenie stanu macierzy po awarii jest szybkie.
- Mamy zapewnioną redundancję, ale kosztem dwukrotnego zmniejszenia pojemności.
- Dla żądań odczytu największa możliwa wydajność ze wszystkich konfiguracji RAID (dwa żądania ***zawsze*** mogą być obsłużone równolegle).
- Żądania zapisu nie są przyspieszane.

# RAID Level 4

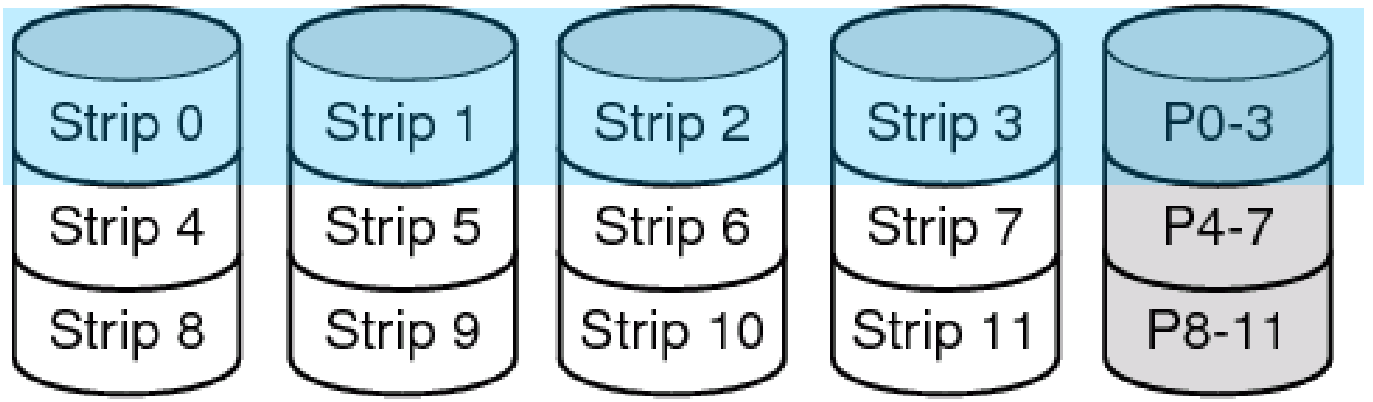


- Jeden z dysków przechowuje bity parzystości - w razie awarii któregoś z dysków brakujące dane można odtworzyć na podstawie bitów parzystości i zawartości pozostałych dysków. Odbudowa po awarii macierzy jest czasochłonna.
- Bardziej efektywne wykorzystanie pojemności dysków.
- Każdy Zapis wymaga ponownego obliczenia bitów parzystości, dzięki czemu dysk przechowujący te bity staje się wąskim gardłem przy zapisach.
- Ponadto zapis może wymagać przeprowadzenia ***odczytów*** z innych dysków w celu obliczenia parzystości - potencjalnie dwa odczyty i dwa zapisy jeżeli dane zajmują część paska - dwukrotne spowolnienie

# RAID Level 5

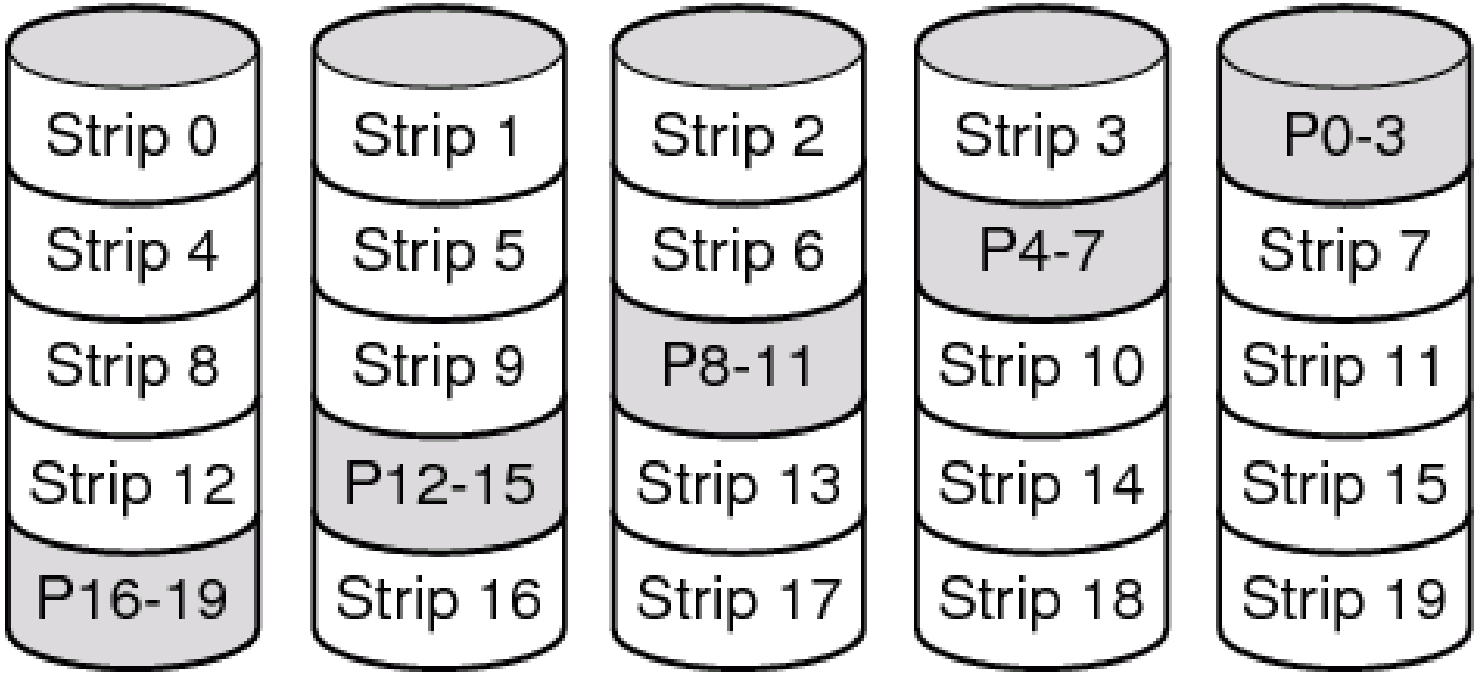


- Podobnie, jak RAID Level 4, ale paski z parzystością są równomiernie rozproszone po wszystkich dyskach macierzy, co usuwa wąskie gardło przy zapisach.

# RAID 0+1 oraz RAID 1+0

- RAID 0+1: dwie macierze RAID 0 (z przeplotem) tworzą macierz RAID 1. Minimum 4 dyski. Lepsza wydajność niż RAID 5, ale pojemność macierzy 50%.
- RAID 1+0 (RAID 10). dwie macierze RAID 1 (mirror) tworzą macierz RAID 0 (z przeplotem). Minimum 4 dyski. Pewne zalety w porównaniu z RAID 0+1: np. może przetrwać awarię dwóch dysków.
- Schematy RAID 0+1 oraz 1+0 często implementowane programowo (np. większość "kontrolerów RAID" zintegrowanych z płytami głównymi).

# Napędy taśmowe

- Napęd taśmowy wykorzystuje nośnik wymienny.
- Jeżeli chodzi o koszt jednego bitu, napęd taśma jest znacznie tańsza od dysku.
- Prędkość transmisji danych jest porównywalna z dyskiem.
- Czas dostępu jest bardzo duży, rzędy minut
  - Wymagane jest przewinięcie taśmy.
- Z powyższych powodów napędy taśmowe wykorzystuje się przede wszystkim do archiwizacji danych zapisanych na dysku i tworzenia kopii zapasowych.
  - W przypadku awarii dysku, kopia zapasowa pozwala na odtworzenie danych

# Dostęp danych w dyskowych

- System operacyjny umożliwia programom użytkownika, dostęp do dysku na dwa sposoby.
- Sposób 1: Dostęp za pomocą systemu plików.
  - Organizacja systemu plików (np. drzewo katalogów)
  - Prawa dostępu do plików.
  - Operacje otwarcia pliku, odczytu, zapisu i zamknięcia.
  - Alokacja sektorów dysku dla pliku
- Sposób 2: Dostęp surowy (ang. raw):
  - Dysk traktowany jest jako tablica sektorów.
  - Dostęp surowy często wymaga specjalnych przywilejów.
  - Pominięcie warstwy systemu plików pozwala na zwiększenie wydajności.

  Przykład 1: Baza danych Oracle.

  Przykład 2: Program fsck w systemach Unix (naprawiający system plików)

# Awaryjność

- Napędy z nośnikami wymiennymi są bardziej narażone na awarie.
- Nośniki optyczne są mniej awaryjne niż nośniki magnetyczne.
  - Mniej wrażliwe na zakłócenia wewnętrzne
- W napędzie z nośnikami niewymiennym głowica nie kontaktuje się z nośnikiem
  - Talerz znajdują się w hermetycznie zamkniętej obudowie.
  - Głowica porusza się na poduszce powietrznej.
  - Kontakt głowicy z nośnikiem (np. w wyniku wstrząsu, upadku) bardzo często prowadzi do awarii.
  - Awaria napędu oznacza utratę danych.
- W napędzie z nośnikiem wymiennym, po awarii napędu bardzo często nie występuje utrata danych.