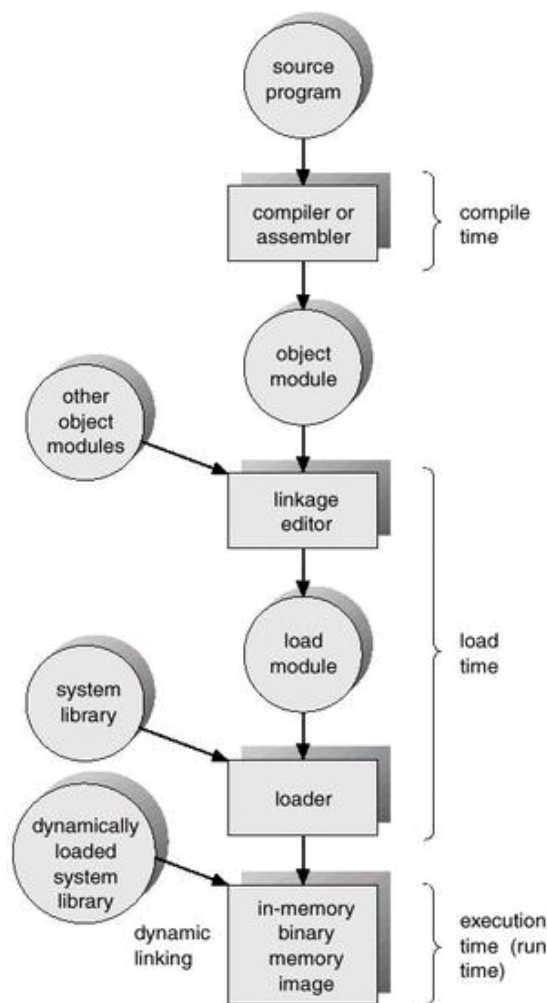


# Zarządzanie pamięcią

## Wstęp

- Aby program można było wykonać trzeba go umieścić w pamięci w ramach pewnego procesu.
- Kolejka wejściowa — zbiór procesów na dysku czekających na umieszczenie w pamięci.
- Przed rozpoczęciem wykonywania program przechodzi szereg faz.
- Zmiana sposobu reprezentacji adresów: symboliczne → względne → bezwzględne.



## Wiązanie rozkazów i danych z adresami

Możliwe jest w każdym z kroków:

- Czas kompilacji: jeśli znamy położenie kodu w pamięci możemy generować kod absolutny. Zmiana tego położenia wymaga rekompilacji kodu.
- Czas ładowania: jeśli nie znamy adresu początkowego w pamięci musimy generować kod relokowalny — ostateczne wiązanie odkłada się do czasu ładowania.
- Czas wykonania: jeśli proces może zmieniać położenie w trakcie wykonywania wiązanie odkłada się do czasu wykonania — konieczny specjalny sprzęt, np. rejestr bazowy i graniczny.

## Ładowanie dynamiczne

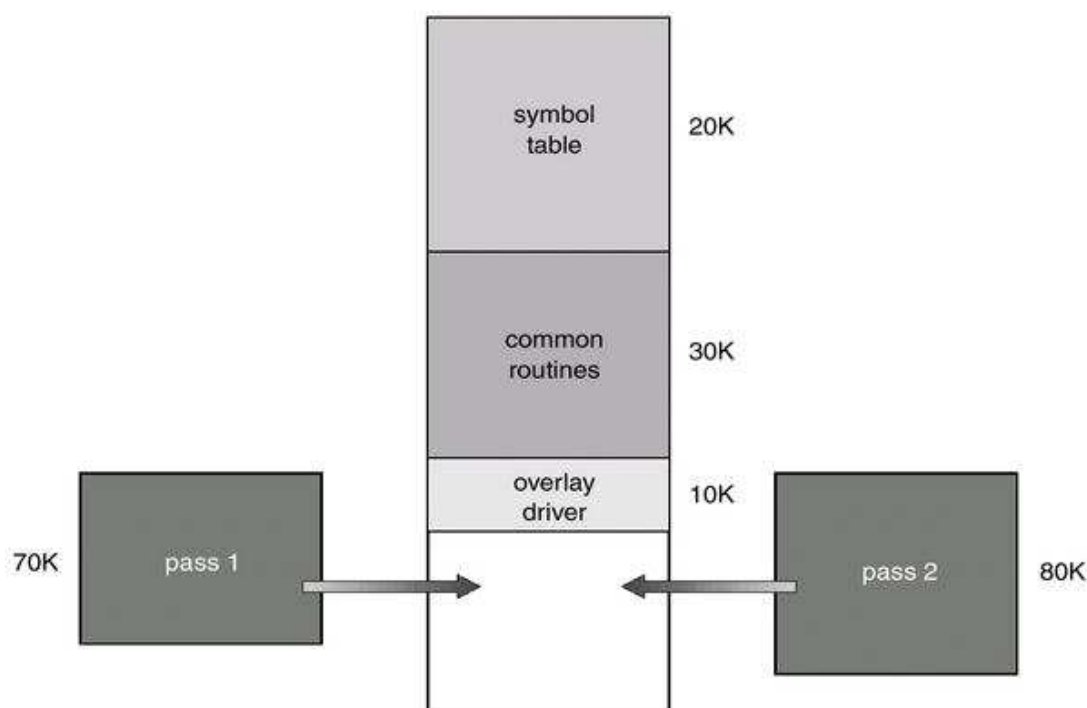
Pozwala na lepsze wykorzystanie pamięci.

- Procedura (w postaci relokowalnej) jest ładowana do pamięci w momencie wywołania.
- Użyteczne w przypadku dużych procedur obsługujących rzadko występujące przypadki.
- Nie wymaga wsparcia ze strony systemu operacyjnego. System może wspierać użytkownika dostarczając procedur odpowiednich bibliotecznych.

## Łączenie (linking) dynamiczne

- Konsolidacja jest odłożona do czasu wykonania programu (por. dynamically loaded library).

- Zakładka (stub) w obrazie binarnym w miejscu odwołania się do procedury. Lokalizuje w pamięci albo ładuje odpowiedni kod proceduru oraz realizuje wykonanie.
- Niezbędna pomoc systemu operacyjnego ze względu na mechanizmy ochronne pamięci.
- Umożliwia bezproblemowe zastępowanie bibliotek nowszymi wersjami.



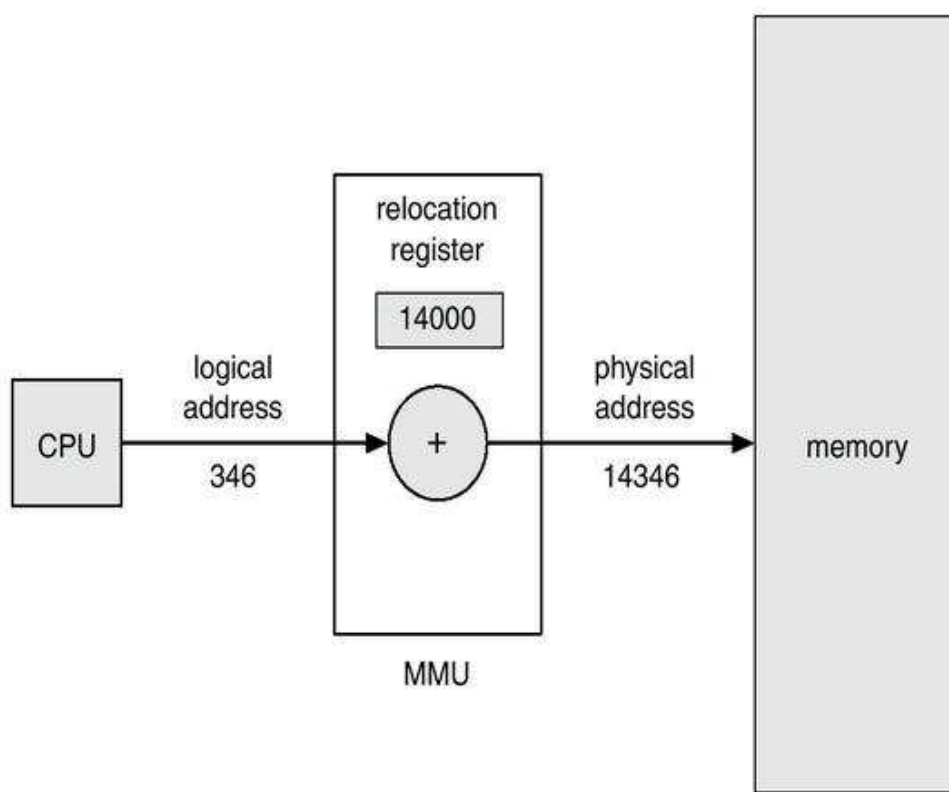
## Nakładki (overlay)

- W pamięci znajdują się tylko fragmenty potrzebne w danej chwili.
- Pozwalają na wykonanie programu większego niż dostępny obszar pamięci.
- Nie wymagają wsparcia ze strony systemu — możliwa realizacja środkami programowymi. Implementacja spoczywa na użytkowniku.

Wymaga bardzo dokładnej analizy dużego programu, co nie musi być proste

## Logiczna i fizyczna przestrzeń adresowa


- Adres logiczny — adres z punktu widzenia programu, generowany przez CPU.
- Adres fizyczny — adres widziany przez jednostkę pamięci.
- Wiązanie adresów w trakcie kompilacji i ładowania powoduje, że adresy fizyczne i logiczne są identyczne.
- Wiązanie w trakcie wykonania prowadzi do schematu, w którym adresy te są różne.
- MMU — Memory Management Unit.



- Sprzęt mapujący adresy logiczne na fizyczne w trakcie wykonania programu.
- Istnieje kilka sposobów realizacji takiego odwzorowania.
- Jeden z prostszych — wykorzystanie rejestru relokacji.

## Wymiana (swapping)

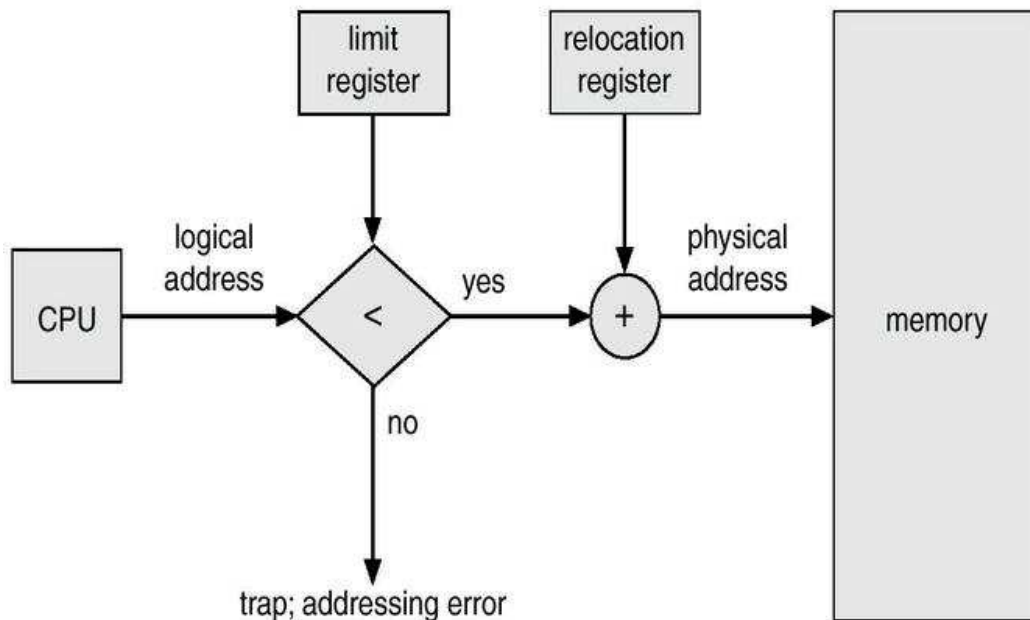
- Proces może zostać czasowo usunięty z pamięci do pamięci pomocniczej a następnie sprowadzony ponownie w celu kontynuowania obliczeń.



- Urządzenie wymiany — szybki dysk, dostatecznie duży aby pomieścić wszystkie obrazy pamięci wszystkich użytkowników i zapewniający dostęp bezpośredni do tych obrazów.

- Roll out, roll in — strategia wymiany w przypadku szeregowania priorytetowego. Procesy o niższych priorytetach są usuwane, aby procesy z wyższymi priorytetami mogły zostać wykonane.
- Podstawowa część czasu wymiany poświęcona jest na transmisję z dysku/ na dysk.
- Wymianie podlegają procesy całkowicie bezczynne. Procesy czekające na zakończenie we/wy nie podlegają wymianie (dostęp do buforów w pamięci użytkownika).
- Warianty wymiany stosowane są w wielu systemach: Unix, Linux, Windows.

## Przydział ciągły



Pamięć podzielona zwykle na dwa obszary:

- Rezydentny system operacyjny w obszarze niskich adresów.
- Program użytkownika w pozostałej części.

## **Przydział pojedynczego obszaru**

- Schemat rejestru przemieszczenia stosowany do ochrony programów użytkowników przed sobą i przed naruszaniem kodu systemu.
- Rejestr przemieszczenia zawiera najmniejszy adres fizyczny obszaru użytkownika, rejestr graniczny zawiera zakres adresów logicznych.

## **Przydział wielu obszarów**

- Dziura — spójny obszar wolnej pamięci operacyjnej. Dziury są rozsiane po całej pamięci.
- Pojawiający się proces otrzymuje obszar pamięci dostatecznie duży, aby się w nim zmieścić.
- System zarządza informacją o przydzielonych obszarach i o wolnych dziurach.
- Jaki obszar spośród wolnych wybrać?
  - first-fit — pierwszy, który się nadaje;
  - best-fit — najmniejszy spośród dostatecznie dużych, wymaga przeszukiwania listy, powoduje powstanie najmniejszej dziury;
  - worst-fit — największy możliwy, powoduje powstanie dużej dziury.
- Dwie pierwsze metody są lepsze (prędkość przetwarzania, wykorzystanie pamięci).

## **Fragmentacja pamięci**

- Fragmentacja zewnętrzna — łączny obszar wolnej pamięci jest wystarczający do zaspokojenia zamówienia, ale nie jest w spójnym kawałku.

- Fragmentacja wewnętrzna — przydzielona partycja jest nieco większa niż zamówienie (nie opłaca się trzymać informacji o tak małym wolnym obszarze). Należy do przestrzeni procesu mimo, że nie jest wykorzystana.
- Zapobieganie defragmentacji przez upakowanie (kompresję).
  - Przemieszczenie zawartości tak, żeby powstał spójny wolny obszar.
  - Konieczne jest korzystanie z dynamicznego wiązania adresów.
  - Problemy z we/wy.
    - \* Blokowanie procesów aż do zakończenia we/wy.
    - \* We/wy wyłącznie przez bufor systemowe.

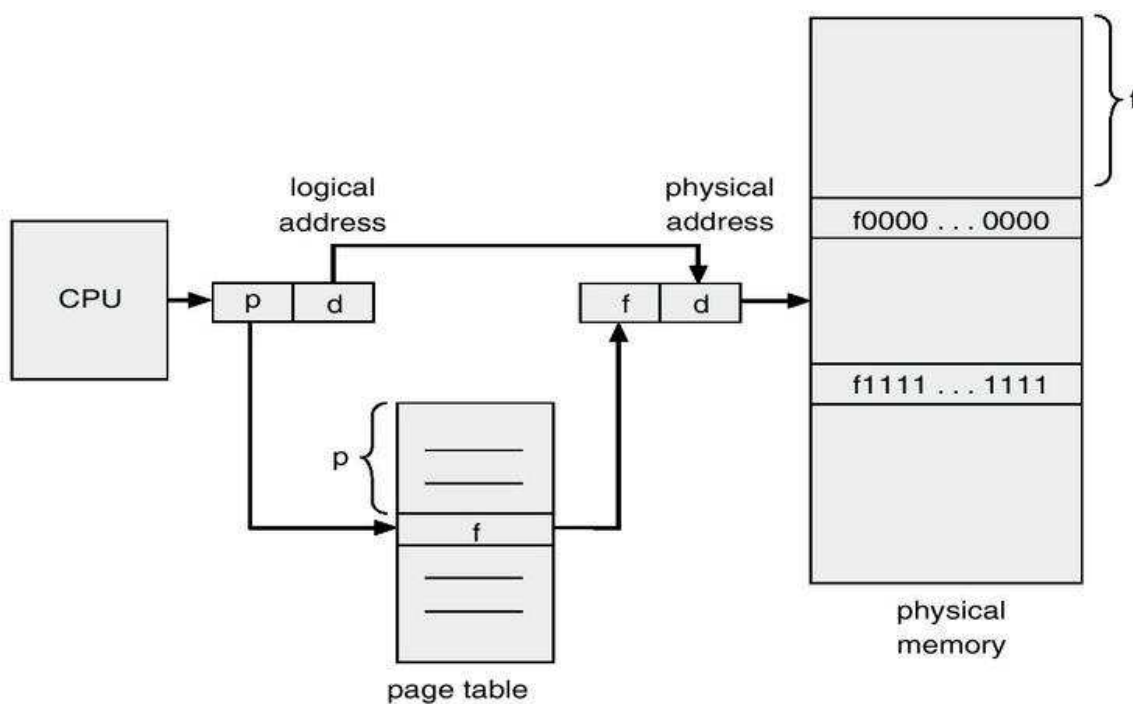
## Stronnicowanie pamięci

- Dzielimy pamięć fizyczną na jednakowe fragmenty — ramki, wielkości 512 – 8192 bajtów.
- Dzielimy logiczną przestrzeń adresową na takie same fragmenty — strony.
- Utrzymujemy informację o wszystkich wolnych ramkach — tablica ramek.
- Aby wykonać program o  $n$  stronach trzeba znaleźć  $n$  wolnych ramek i załadować program.
- Tworzymy tablicę stron do tłumaczenia adresów logicznych na fizyczne.
- Fragmentacja wewnętrzna.

Adres logiczny jest dzielony na:



- numer strony będący indeksem do tablicy stron, gdzie znajduje się adres początku tej strony w pamięci fizycznej,
- przesunięcie na stronie, które dodane do adresu podstawowego da adres w pamięci fizycznej.



page 0
page 1
page 2
page 3

logical  
memory

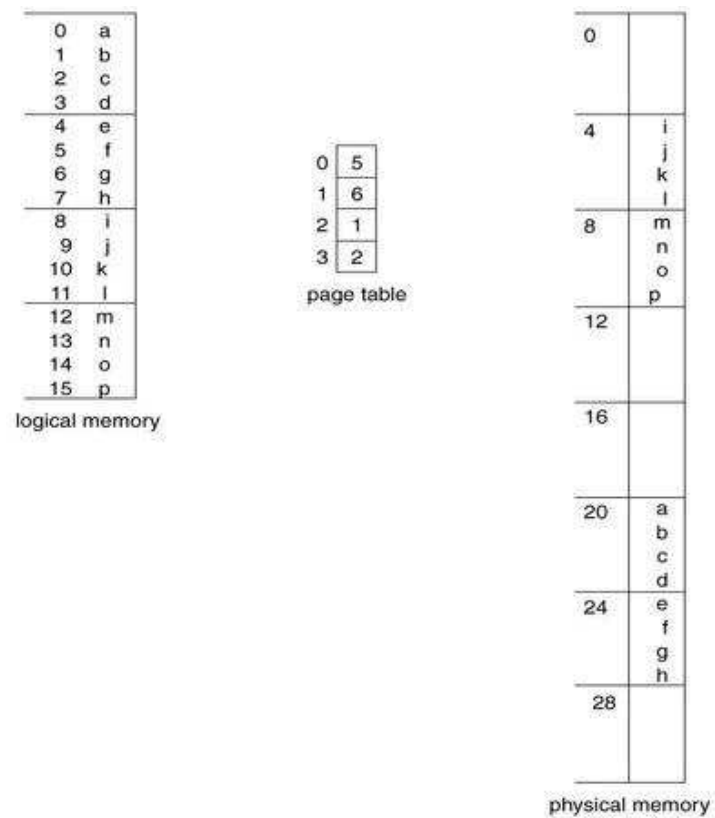
0	1
1	4
2	3
3	7

page table


frame  
number

0	
1	page 0
2	
3	page 2
4	page 1
5	
6	
7	page 3

physical  
memory

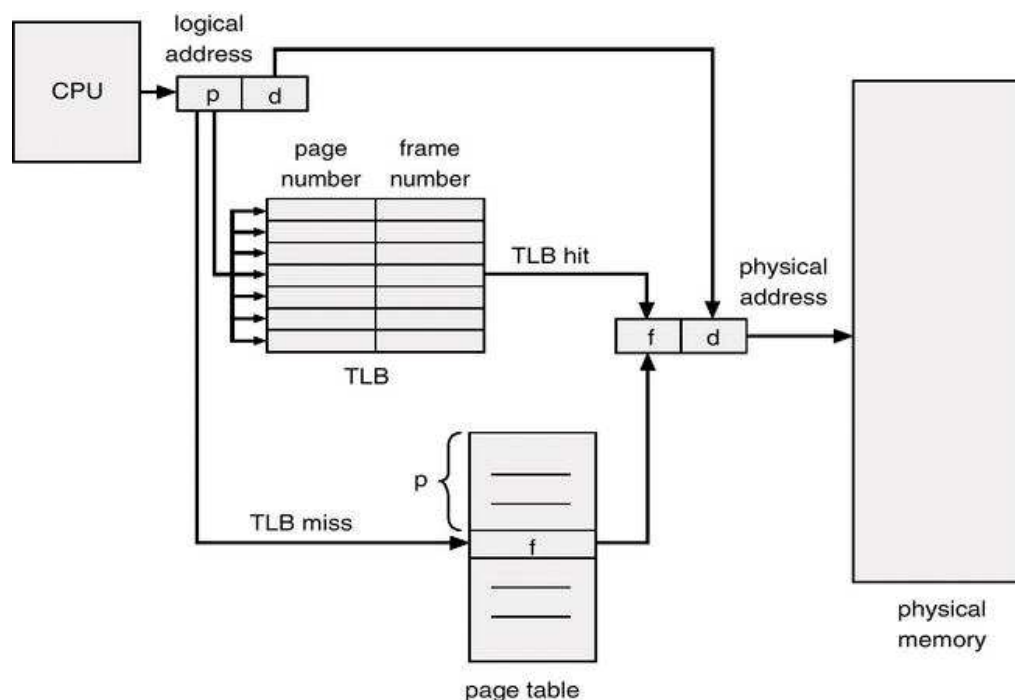


Wolne ramki



## Implementacja tablicy stron

- Podstawowy wariant — tablica stron znajduje się w pamięci.
- Rejestr PTBR wskazuje początek tablicy, rejestr PTLR — długość tablicy stron.
- Przy tym schemacie każdy dostęp do danych/instrukcji wymaga dwóchostępów do pamięci.
- Problem można rozwiązać przez wykorzystanie rejestrów TLB — małej i szybko przeszukiwalnej pamięci asocjacyjnej.



Efektywny czas dostępu dla takiej implementacji:


- czas szukania asocjacyjnego —  $\epsilon$ ,
- czas dostępu do pamięci — 1 mikrosekunda,
- współczynnik trafień (prawdopodobieństwo, że numer strony jest rejestrze asocjacyjnym) —  $\alpha$ ,

- efektywny czas dostępu

$$EAT = (1 + \epsilon)\alpha + (2 + \epsilon)(1 - \alpha)$$

## Kontrola poprawności

- Ochrona pamięci może być realizowana przez dołączenie do każdej pozycji tablicy stron dodatkowego bitu poprawności.
- Ustawienie tego bitu na 'v' oznacza, że strona należy do przestrzeni adresowej procesu — odwołanie się jest legalne.
- Ustawienie na 'i' oznacza stronę nieważną.
- Fragmentacja wewnętrzna — część adresów ostatniej legalnej strony jest niepoprawna.

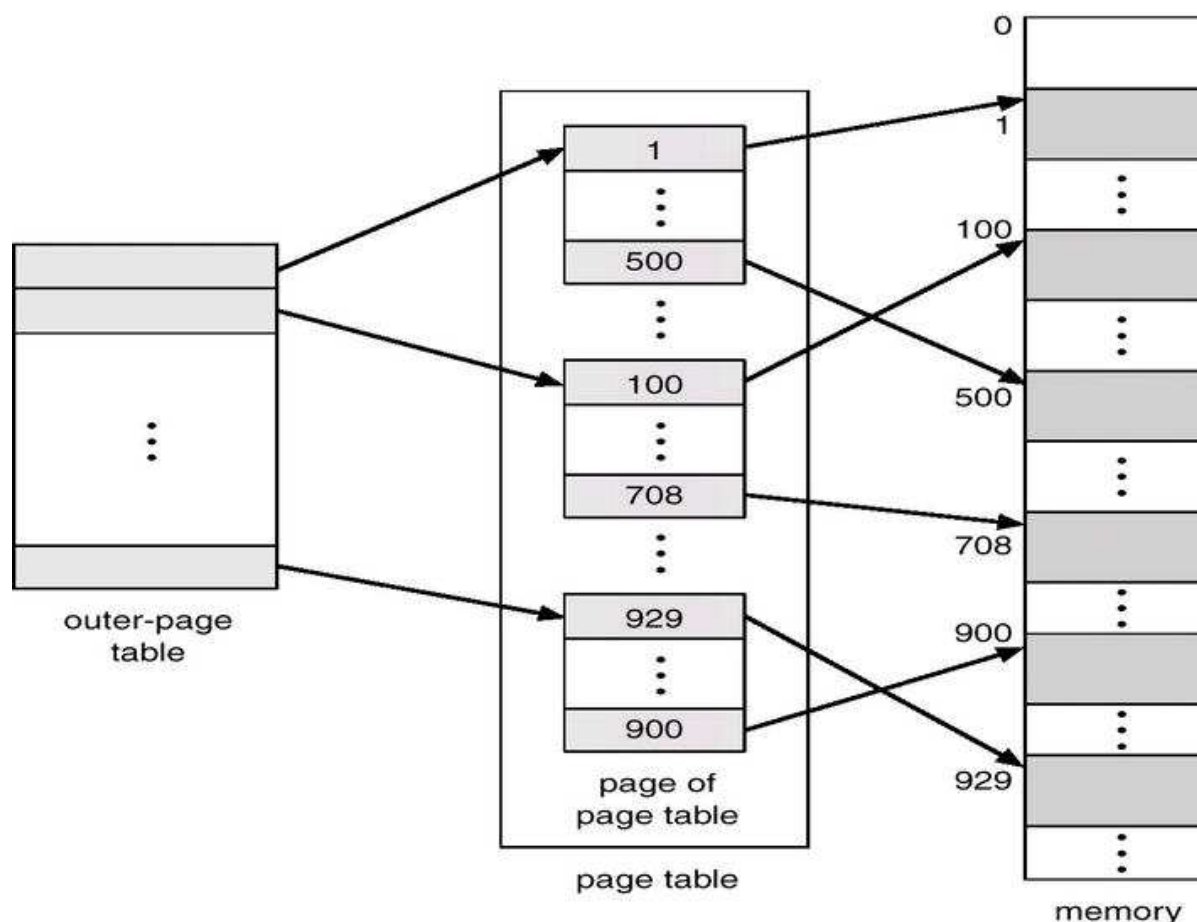


## Stronicowanie wielopoziomowe

- Duże przestrzenie adresowe powodują, że tablice stron mogą być bardzo duże (przy 32 bitowym adresie i stronie wielkości 4kB - tablica stron ma 1M pozycji, czyli wielkość 4MB).
- Nie chcemy przydzielać ciągłego obszaru na taką tablicę.
- Rozwiązanie — podzielenie tablicy stron na mniejsze części (można to zrobić na kilka sposobów).

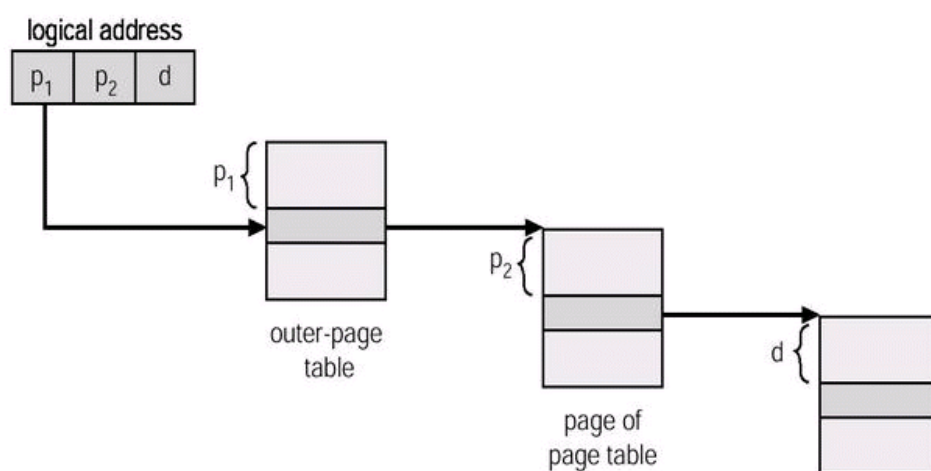
## Stronicowanie dwupoziomowe

Tablica stron podzielona jest na strony.



Przykład:

- Adres 32 bitowy, przy stronie wielkości 4kB dzieli się na:
  - 20 bitowy numer strony,
  - 12 bitowy offset na stronie.
- Ponieważ tablica stron ma być stronicowana więc numer strony dzieli się dalej na:
  - 10 bitowy numer strony,
  - 10 bitową odległość na stronie.
- Ostatecznie adres logiczny przyjmuje postać:
  - $p_1$  — indeks w zewnętrznej tablicy stron,
  - $p_2$  — przesunięcie na stronie zewnętrznej tablicy stron,
  - $d$  — odległość na stronie.

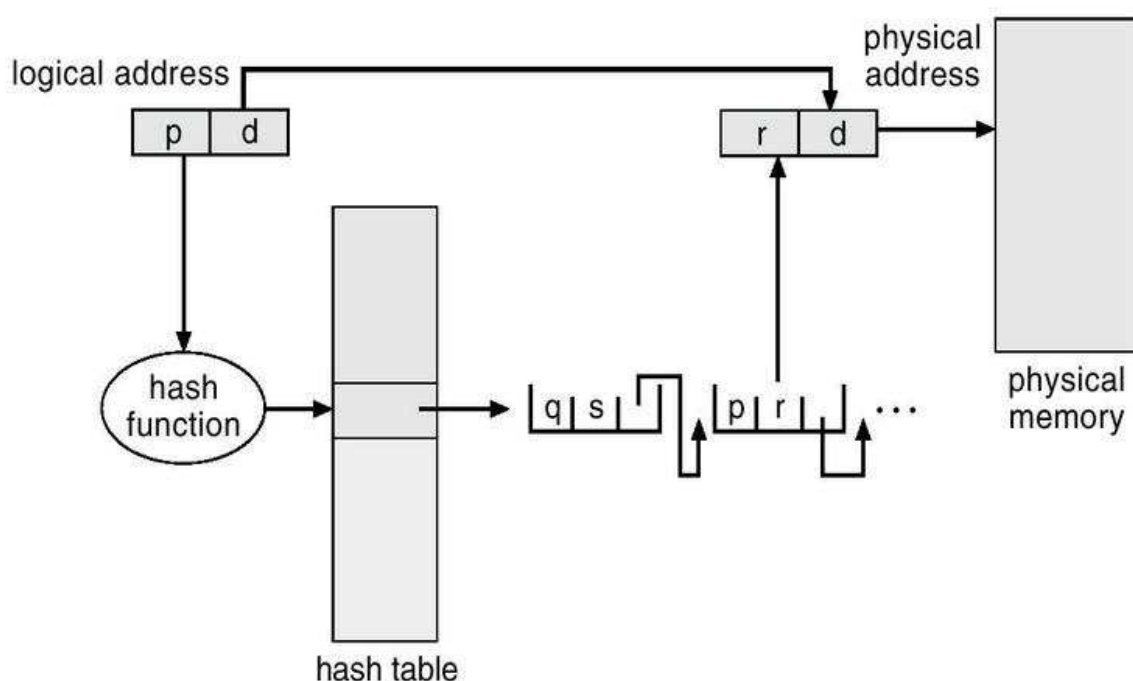


## Hashowane tablice stron

Dla większych przestrzeni adresowych schemat dwupoziomowy może być niewystarczający.

Zastosowanie większej ilości poziomów wyraźnie zwiększa efektywny czas dostępu.

Inne rozwiązanie to zastosowanie funkcji hashującej (mieszającej).

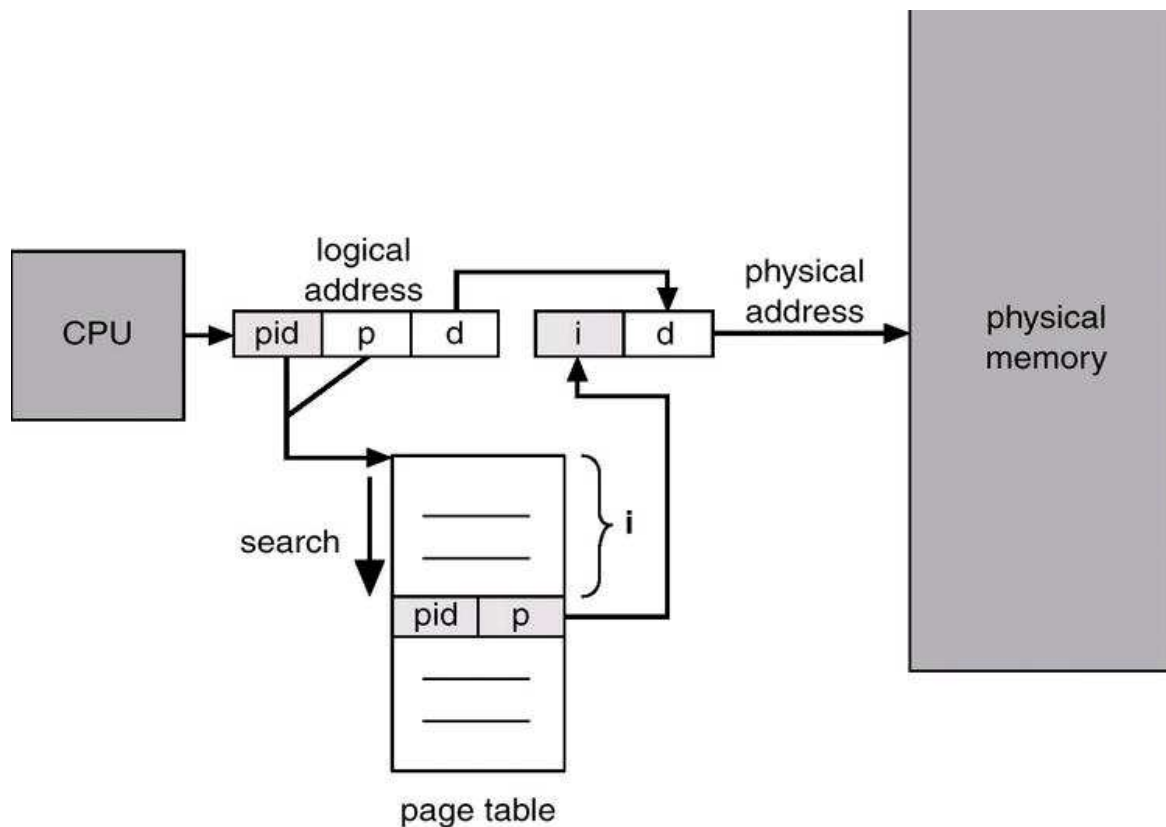


## Odwrót(odwrócona) tablica stron

Tablice stron w systemie w sumie zajmują bardzo dużo miejsca w pamięci.

Niekiedy stosuje się inną koncepcję.

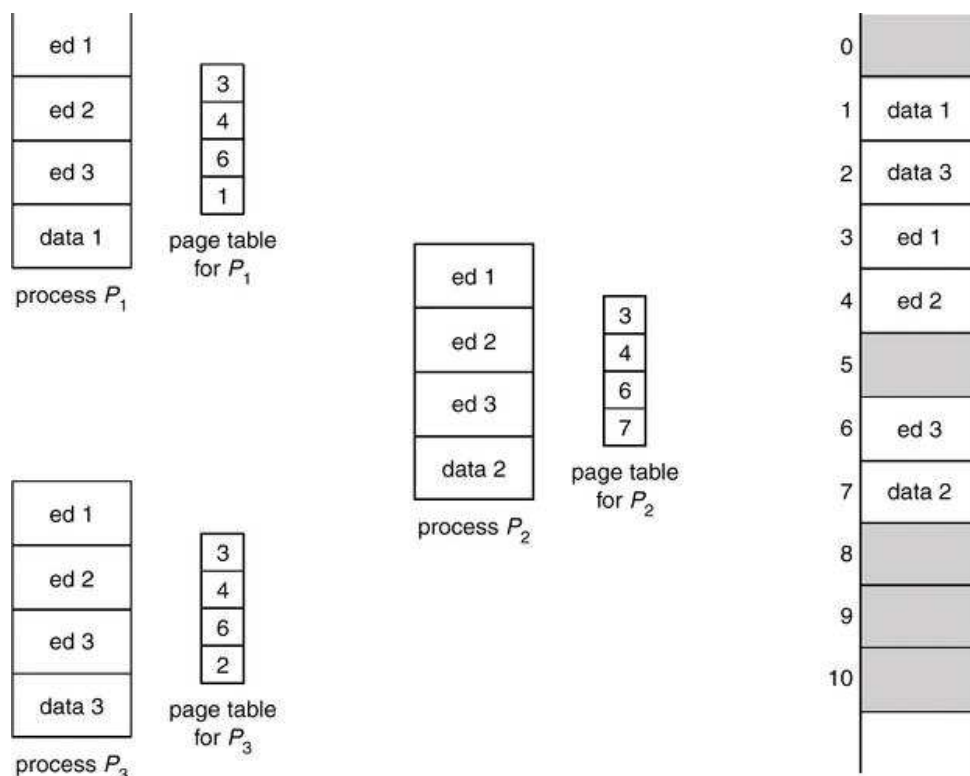
- Tablica z jedną pozycją dla każdej ramki pamięci fizycznej.
- Każda pozycja zawiera informację o adresie wirtualnym strony, która jest w tej ramce oraz o właścicielu tej strony.
- Zmniejsza zapotrzebowanie na pamięć potrzebną na tablice stron kosztem wzrostu czasu dostępu do pamięci.
- Zastosowanie tablicy hashującej ogranicza czas przeszukiwania odwrotnej tablicy stron.



## Strony dzielone

- Kod wspólny.
  - Jeden egzemplarz kodu (nie modyfikującego sam siebie), np. edytora albo kompilatora.
  - Zwykle musi występować w logicznych przestrzeniach adresowych kilku różnych procesów w tych samych miejscach (adresacja w obrębie programu).
  - Trudności implementacyjne przy odwrotnej tablicy stron.
- Prywatny kod i dane.
  - Każdy proces utrzymuje prywatną kopię.
  - Może występować w dowolnym miejscu przestrzeni adresowej.






## Segmentacja

Schemat zarządzania pamięcią uwzględniający punkt widzenia programisty.

Program jest zbiorem segmentów — elementów logicznych takich jak

- program główny,
- procedura,
- funkcja,
- obiekt,
- metoda,
- zmienne lokalne, zmienne globalne,
- bloki wspólne,
- stos,

- tablice symboli, tablice danych.



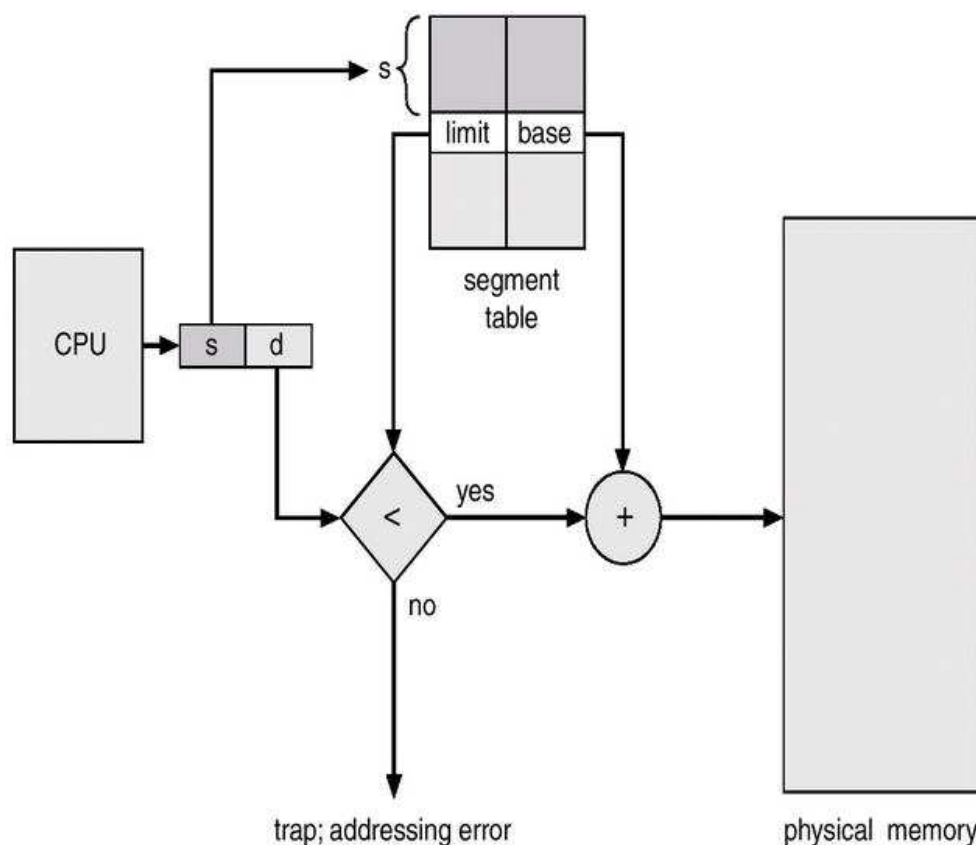
## Architektura

- Adres logiczny jest parą:

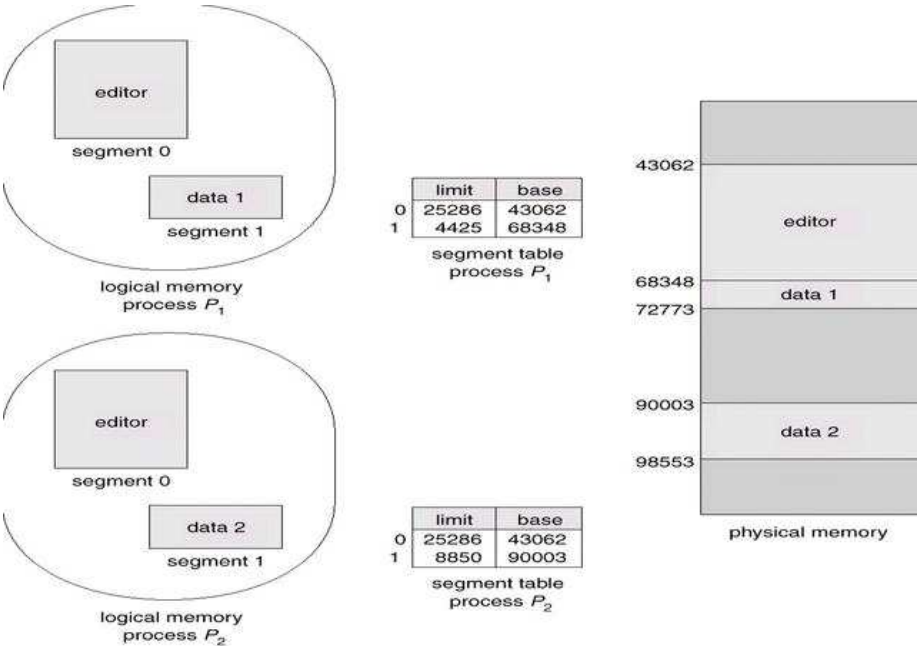
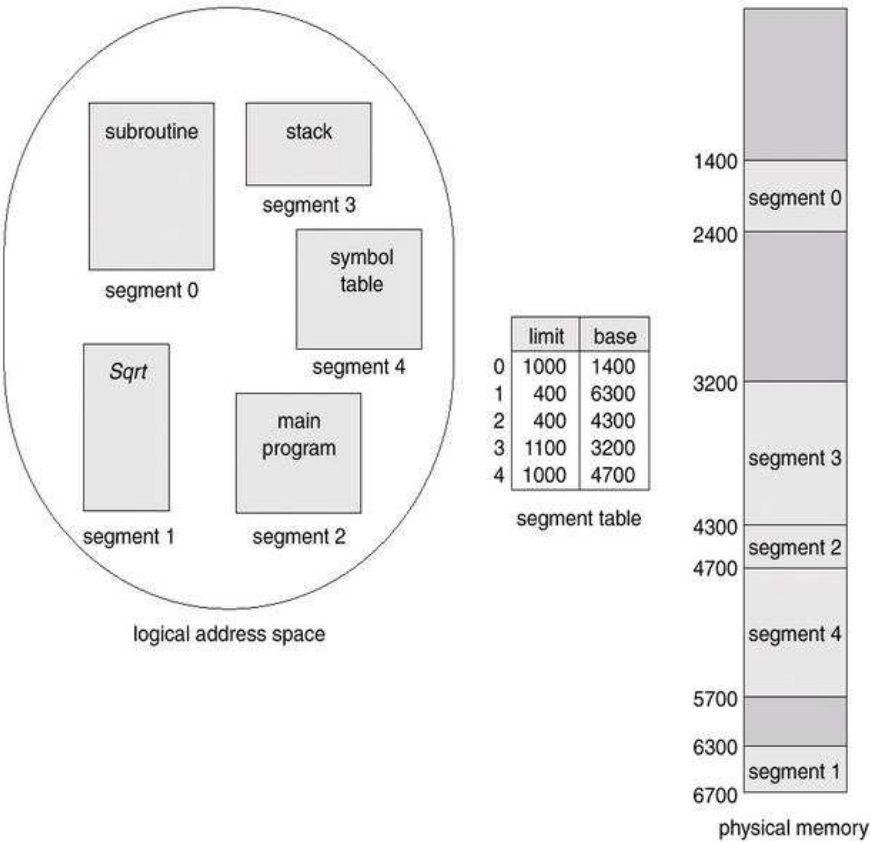
$$\langle numer\_segmentu, offset \rangle$$

- Tablica segmentów odwzorowuje logiczny adres dwuwymiarowy na jednowymiarową pamięć fizyczną. Każda pozycja zawiera:
  - bazę — adres początku segmentu w pamięci,
  - granicę segmentu — długość segmentu.
- STBR — rejestr początku tablicy segmentów zawierający adres początku tablicy segmentów.

- STL<sub>R</sub> — rejestr zawierający długość tablicy segmentów. Numer segmentu  $s$  jest legalny, jeśli  $s < STL_R$ .



- Ochrona.
  - bit poprawności — jeśli wartość 0, segment nielegalny.
  - bity dostępu — czytanie/pisanie/wykonywanie.
- Dzielenie kodu występuje na poziomie segmentu.
  - numeracja segmentów
- Segmenty różnej długości — dynamiczna alokacja.
  - best fit/first fit,
  - fragmentacja.



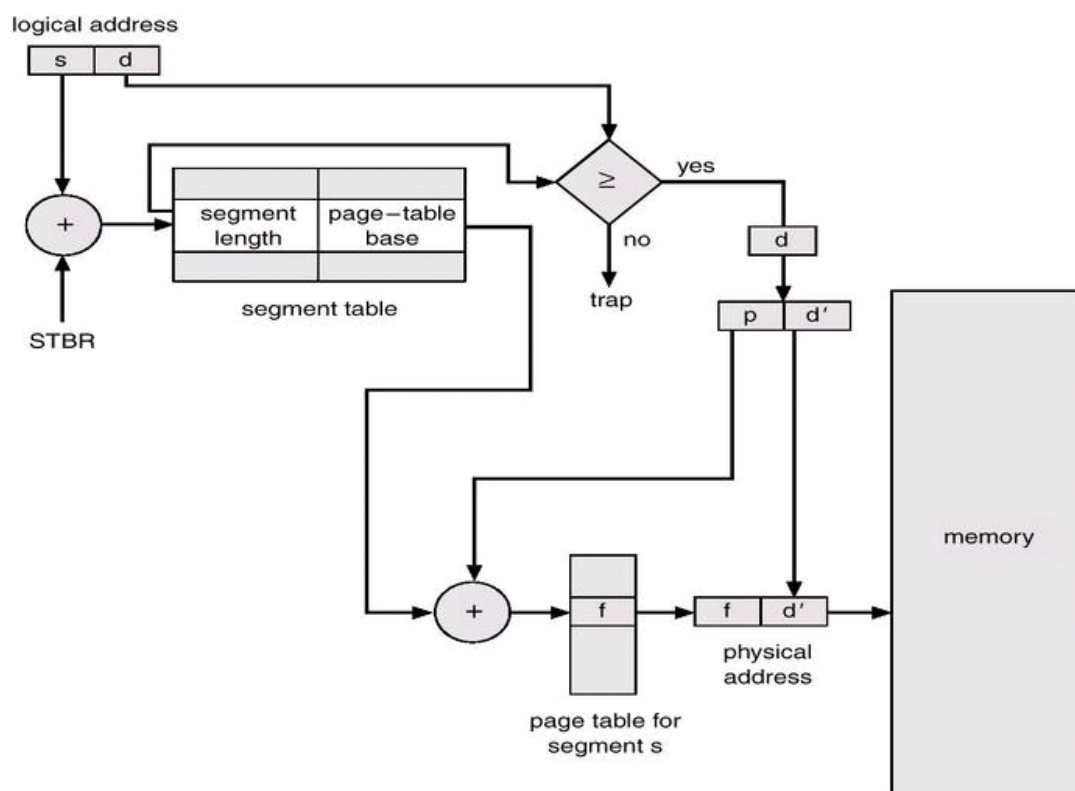
## Segmentacja ze stronicowaniem — MULTICS

Problem fragmentacji oraz wyszukiwania w strategii przydziału obszaru rozwiązano dokonując stronicowania segmentów.

Pozycja tablicy segmentów zawiera zamiast adresu początku segmentu adres początkowy tablicy stron segmentu.

Dla każdego segmentu konieczna jest oddzielna tablica stron.

W rzeczywistości schemat ten jest bardziej skomplikowany — adres jest czteroczęściowy.



## Schemat adresacji procesora intel 386

