Routing

część 3: wewnątrz routera

Sieci komputerowe

Wykład 4

Marcin Bieńkowski

Dygresja: gniazda UDP

Jedna warstwa sieci i globalne adresowanie

- Każde urządzenie w sieci posługuje się tym samym protokołem warstwy sieci. W Internecie: protokół IP.
- Każde urządzenie ma unikatowy adres. W Internecie: adresy IP.

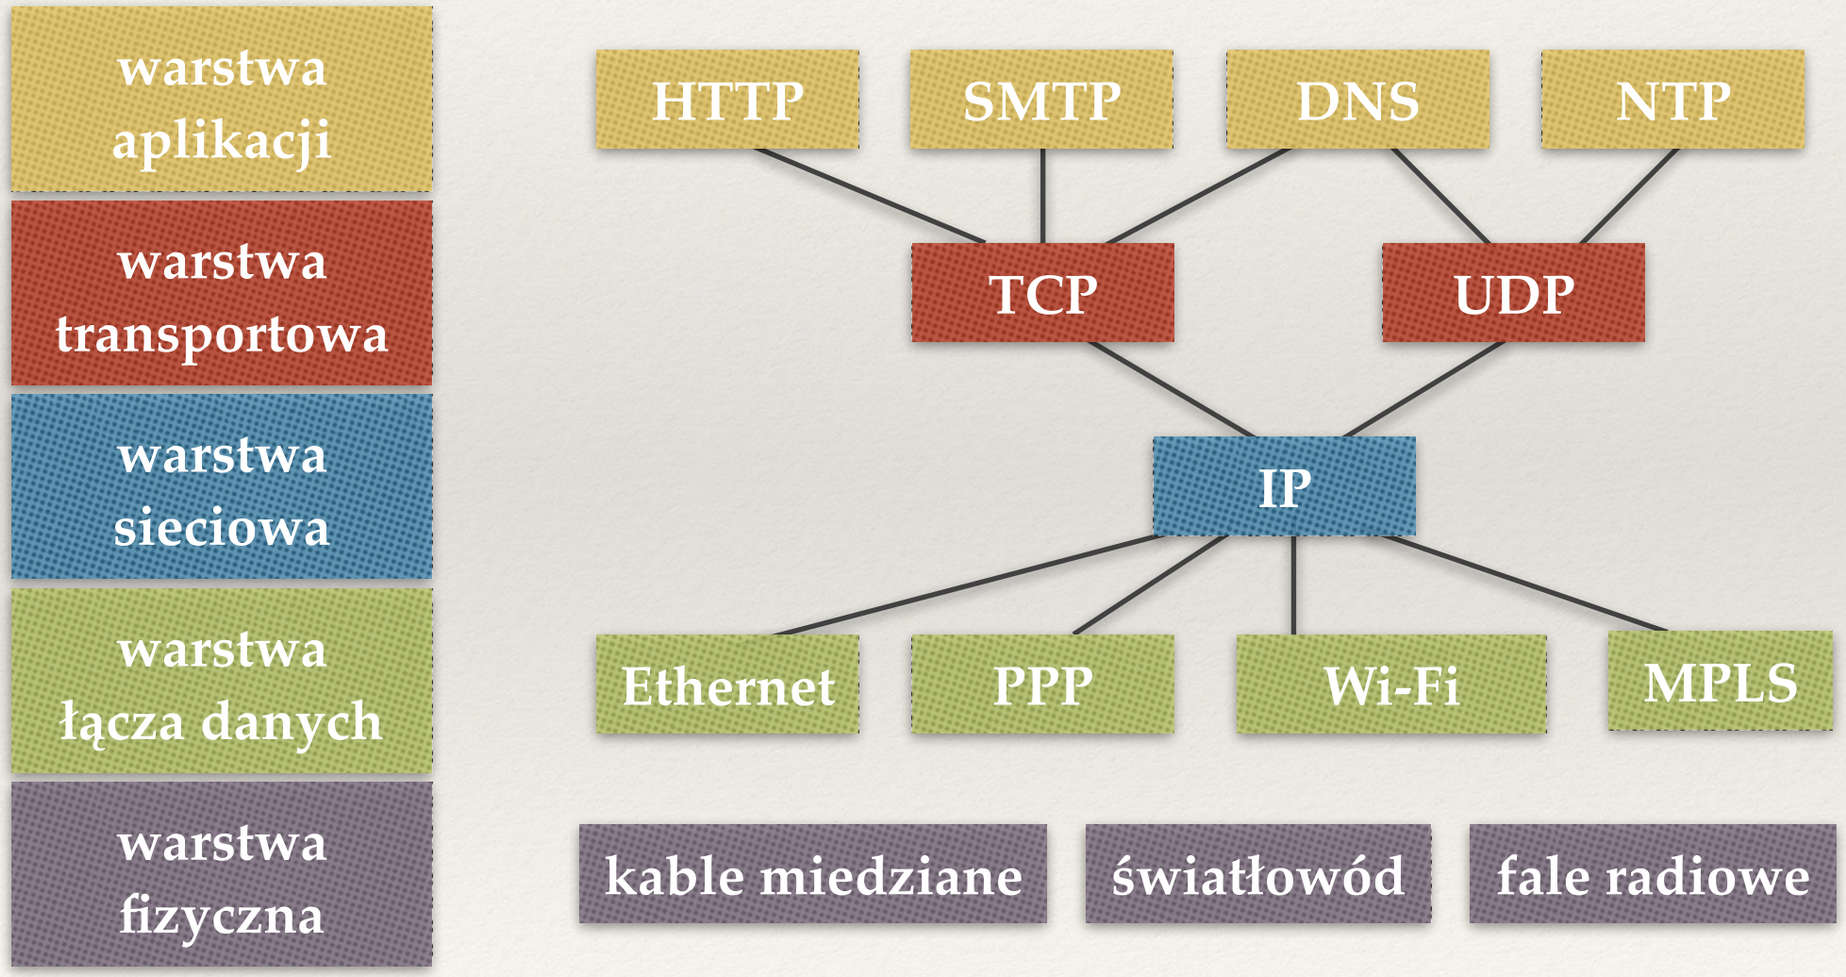

Gniazda

Interfejs programistyczny do nadawania i odbierania pakietów.

- Umożliwiają podawanie danych do umieszczenia w datagramach UDP lub segmentach TCP.

dostęp do niektórych pól za pomocą funkcji gniazd

- Gniazda surowe: umożliwiają podawanie danych do umieszczenia bezpośrednio w danych pakietu IP.

Nagłówek pakietu IP

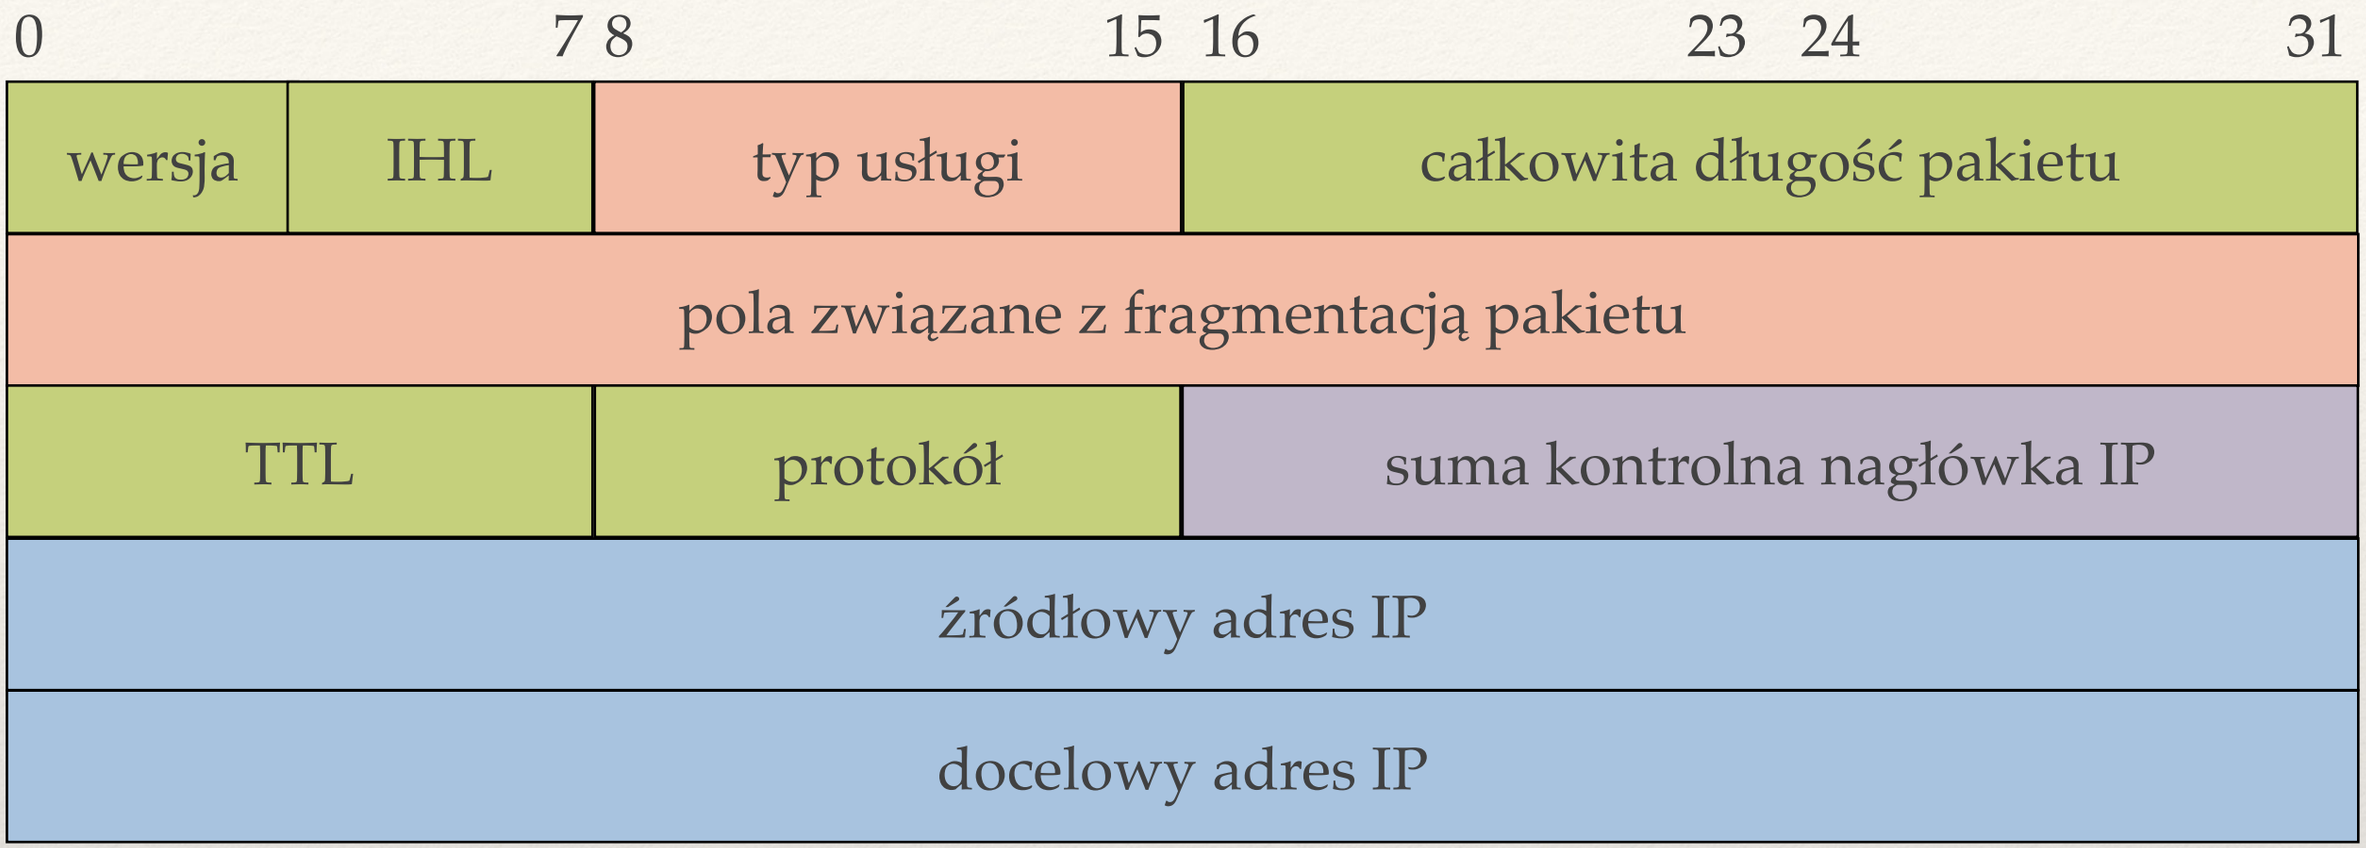

- Protokół = co jest przechowywane w danych pakietu (np. 1 = ICMP, 6 = TCP, 17 = UDP).

Nagłówek UDP (User Data Protocol)

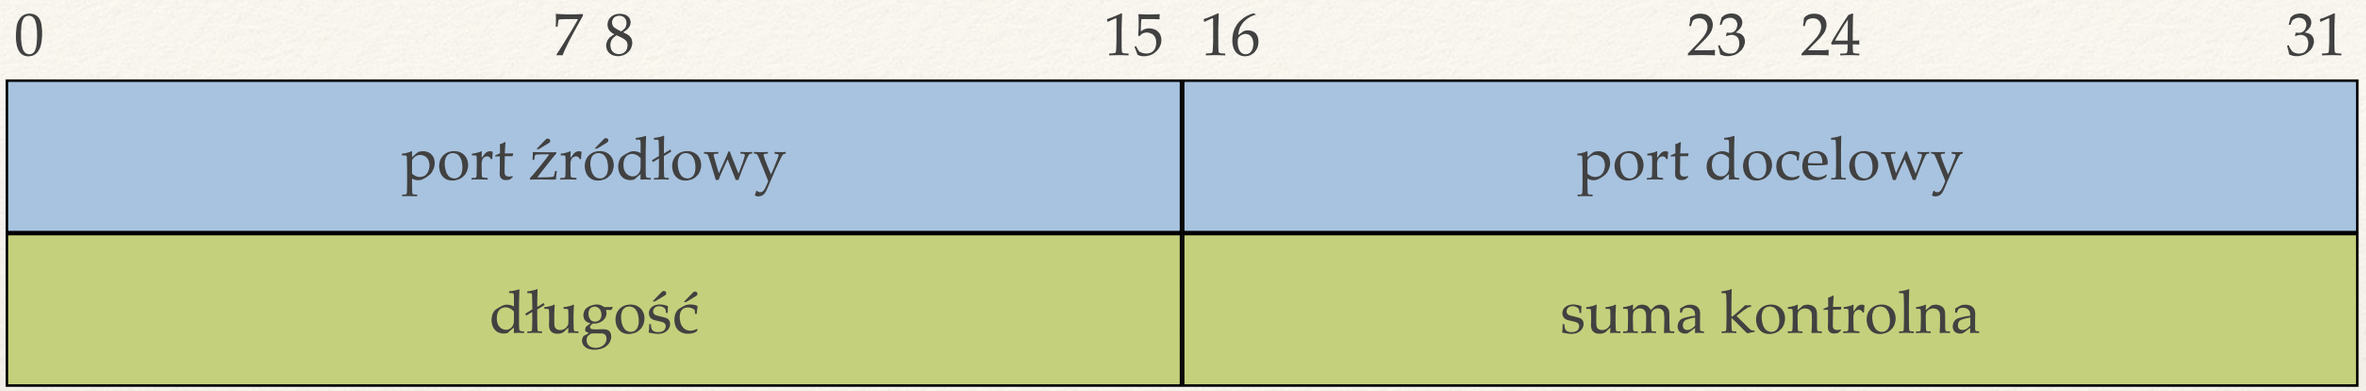

- Port:
  - liczba 16-bitowa;
  - identyfikuje aplikację wewnątrz danego komputera.

- Warstwa sieciowa zapewnia dostarczanie pakietów pomiędzy komputerami, warstwa transportowa pomiędzy aplikacjami.

Enkapsulacja i dekapsulacja

przesyłany pakiet

67.32.41.23

port 55245

router

34.37.235.21

port 53

Gniazdo UDP

- Identyfikuje jeden koniec komunikacji UDP.
- Opisywane przez parę (lokalny adres IP, lokalny port).
- Związane z konkretnym procesem.

Tworzenie gniazda

```c
#include <arpa/inet.h>

int sockfd = socket(AF_INET, SOCK_DGRAM, 0);
```

Wiązanie gniazda z adresem i portem

Jak w przypadku gniazda surowego, ale wypełniamy też port.

```
struct sockaddr_in server_address = {0};
server_address.sin_family      = AF_INET;
server_address.sin_port        = htons(32345);
server_address.sin_addr.s_addr = htonl(INADDR_ANY);


bind (
  sockfd,
  (struct sockaddr*)&server_address,
  sizeof(server_address)
);
```

Wiązanie gniazda z adresem i portem

Jak w przypadku gniazda surowego, ale wypełniamy też port.

```
struct sockaddr_in server_address = {0};
server_address.sin_family      = AF_INET;
server_address.sin_port        = htons(32345);
server_address.sin_addr.s_addr = htonl(INADDR_ANY);


bind (
  sockfd,
  (struct sockaddr*)&server_address,
  sizeof(server_address)
);
```

demonstracja

Odbieranie pakietu z gniazda

Jak w gniazdach surowych.

```
struct sockaddr_in    sender;
socklen_t             sender_len = sizeof(sender);
uint8_t               buffer[IP_MAXPACKET+1];
```

```
ssize_t packet_len = recvfrom(
  sockfd,
  buffer,                                  pakiet jako ciąg bajtów
  IP_MAXPACKET,
  0,
  (struct sockaddr*)&sender,               } adres nadawcy
  &sender_len
);
```

Wysyłanie pakietu przez gniazdo

Jak w gniazdach surowych, ale adres odbiorcy zawiera również port.

```
char* reply = "Thank you!";
size_t reply_len = strlen(reply);

ssize_t bytes_sent = sendto(
    sockfd,
    reply,
    reply_len,
    0,
    (struct sockaddr*)&recipient,
    sizeof(recipient)
);
```

dowolny ciąg bajtów, niekoniecznie napis

adres odbiorcy

Zamykanie gniazda

Zwalnia zasoby związane z gniazdem.

```
close(sockfd);
```

Kod serwera UDP (przetwarzanie pakietów)

```
bind(sockfd, (struct sockaddr*)&server_address, sizeof(server_address));

for (;;) {
  struct sockaddr_in sender;
  socklen_t          sender_len = sizeof(sender);
  uint8_t            buffer[IP_MAXPACKET+1];
  ssize_t datagram_len = recvfrom(sockfd, buffer, IP_MAXPACKET, 0,
                                  (struct sockaddr*)&sender, &sender_len);
  char sender_ip_str[INET_ADDRSTRLEN];
  inet_ntop(AF_INET, &(sender.sin_addr), sender_ip_str, sizeof(sender_ip_str));
  printf("Received UDP packet from IP address: %s, port: %u\n”,
          sender_ip_str, ntohs(sender.sin_port));
  buffer[datagram_len] = 0;
  printf("%zd-byte message: +%s+\n", datagram_len, buffer);
  char* reply = "Thank you!";
  size_t reply_len = strlen(reply);
  sendto(sockfd, reply, reply_len, 0, (struct sockaddr*)&sender, sender_len);
}

close(sockfd);
```

Kod serwera UDP (przetwarzanie pakietów)

```
bind(sockfd, (struct sockaddr*)&server_address, sizeof(server_address));

for (;;) {
  struct sockaddr_in sender;
  socklen_t          sender_len = sizeof(sender);
  uint8_t            buffer[IP_MAXPACKET+1];
  ssize_t datagram_len = recvfrom(sockfd, buffer, IP_MAXPACKET, 0,
                                  (struct sockaddr*)&sender, &sender_len);
  char sender_ip_str[INET_ADDRSTRLEN];
  inet_ntop(AF_INET, &(sender.sin_addr), sender_ip_str, sizeof(sender_ip_str));
  printf("Received UDP packet from IP address: %s, port: %u\n”,
          sender_ip_str, ntohs(sender.sin_port));
  buffer[datagram_len] = 0;
  printf("%zd-byte message: +%s+\n", datagram_len, buffer);
  char* reply = "Thank you!";
  size_t reply_len = strlen(reply);
  sendto(sockfd, reply, reply_len, 0, (struct sockaddr*)&sender, sender_len);
}

close(sockfd);
```

udp_server.c
kod (z obsługą błędów) na stronie wykładu

demonstracja

Wiązanie z portem

- Serwer związuje się z danym portem funkcją `bind()`.
  - Do związania z portem ≤ 1024 potrzebne uprawnienia administratora.

- Wysyłka przez gniazdo bez portu → gniazdo dostanie port wybrany przez jądro.
  - Port tymczasowy (zazwyczaj ≥ 32768).
  - Tak działa większość klientów (np. program `nc`).

Kod klienta UDP

```
int sockfd = socket(AF_INET, SOCK_DGRAM, 0);

struct sockaddr_in server_addr = {0};
server_address.sin_family      = AF_INET;
server_address.sin_port        = htons(32345);
inet_pton(AF_INET, "127.0.0.1", &server_addr.sin_addr);
const char* message = "Hello server!";
sendto(sockfd, message, strlen(message), 0,
       (struct sockaddr*) &server_addr, sizeof(server_addr));

close(sockfd);
```

Kod klienta UDP

```
int sockfd = socket(AF_INET, SOCK_DGRAM, 0);

struct sockaddr_in server_addr = {0};
server_address.sin_family      = AF_INET;
server_address.sin_port        = htons(32345);
inet_pton(AF_INET, "127.0.0.1", &server_addr.sin_addr);
const char* message = "Hello server!";
sendto(sockfd, message, strlen(message), 0,
       (struct sockaddr*) &server_addr, sizeof(server_addr));

close(sockfd);
```

udp_client.c
kod (z obsługą błędów) na stronie wykładu

demonstracja

Wysyłanie pakietu UDP na adres rozgłoszeniowy

Trzeba włączyć odpowiednią opcję gniazda.

```
int so_value = 1;
setsockopt(sockfd, SOL_SOCKET, SO_BROADCAST,
           (void*)&so_value, sizeof(so_value));
```

Wewnątrz routera

Przełączanie pakietów: przez RAM

Wczesne generacje routerów (jak PC):

- Brak struktury przełączającej.
- Tablica przekazywania w części sterującej.

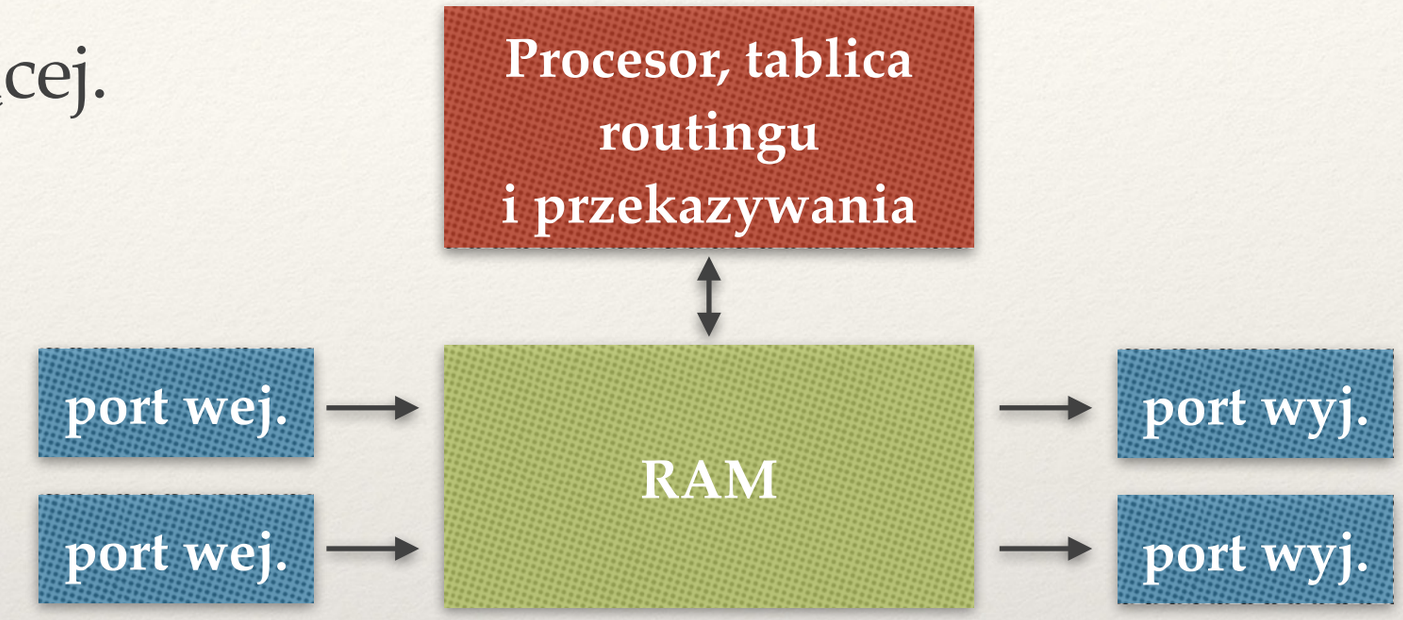

Działanie:

- Port wejściowy odbiera pakiet i zgłasza przerwanie.
- Procesor kopiuje pakiet do RAM.
- Wolny port wyjściowy zgłasza przerwanie.
- Procesor kopiuje pakiet z RAM.

Budowa współczesnego routera (1)

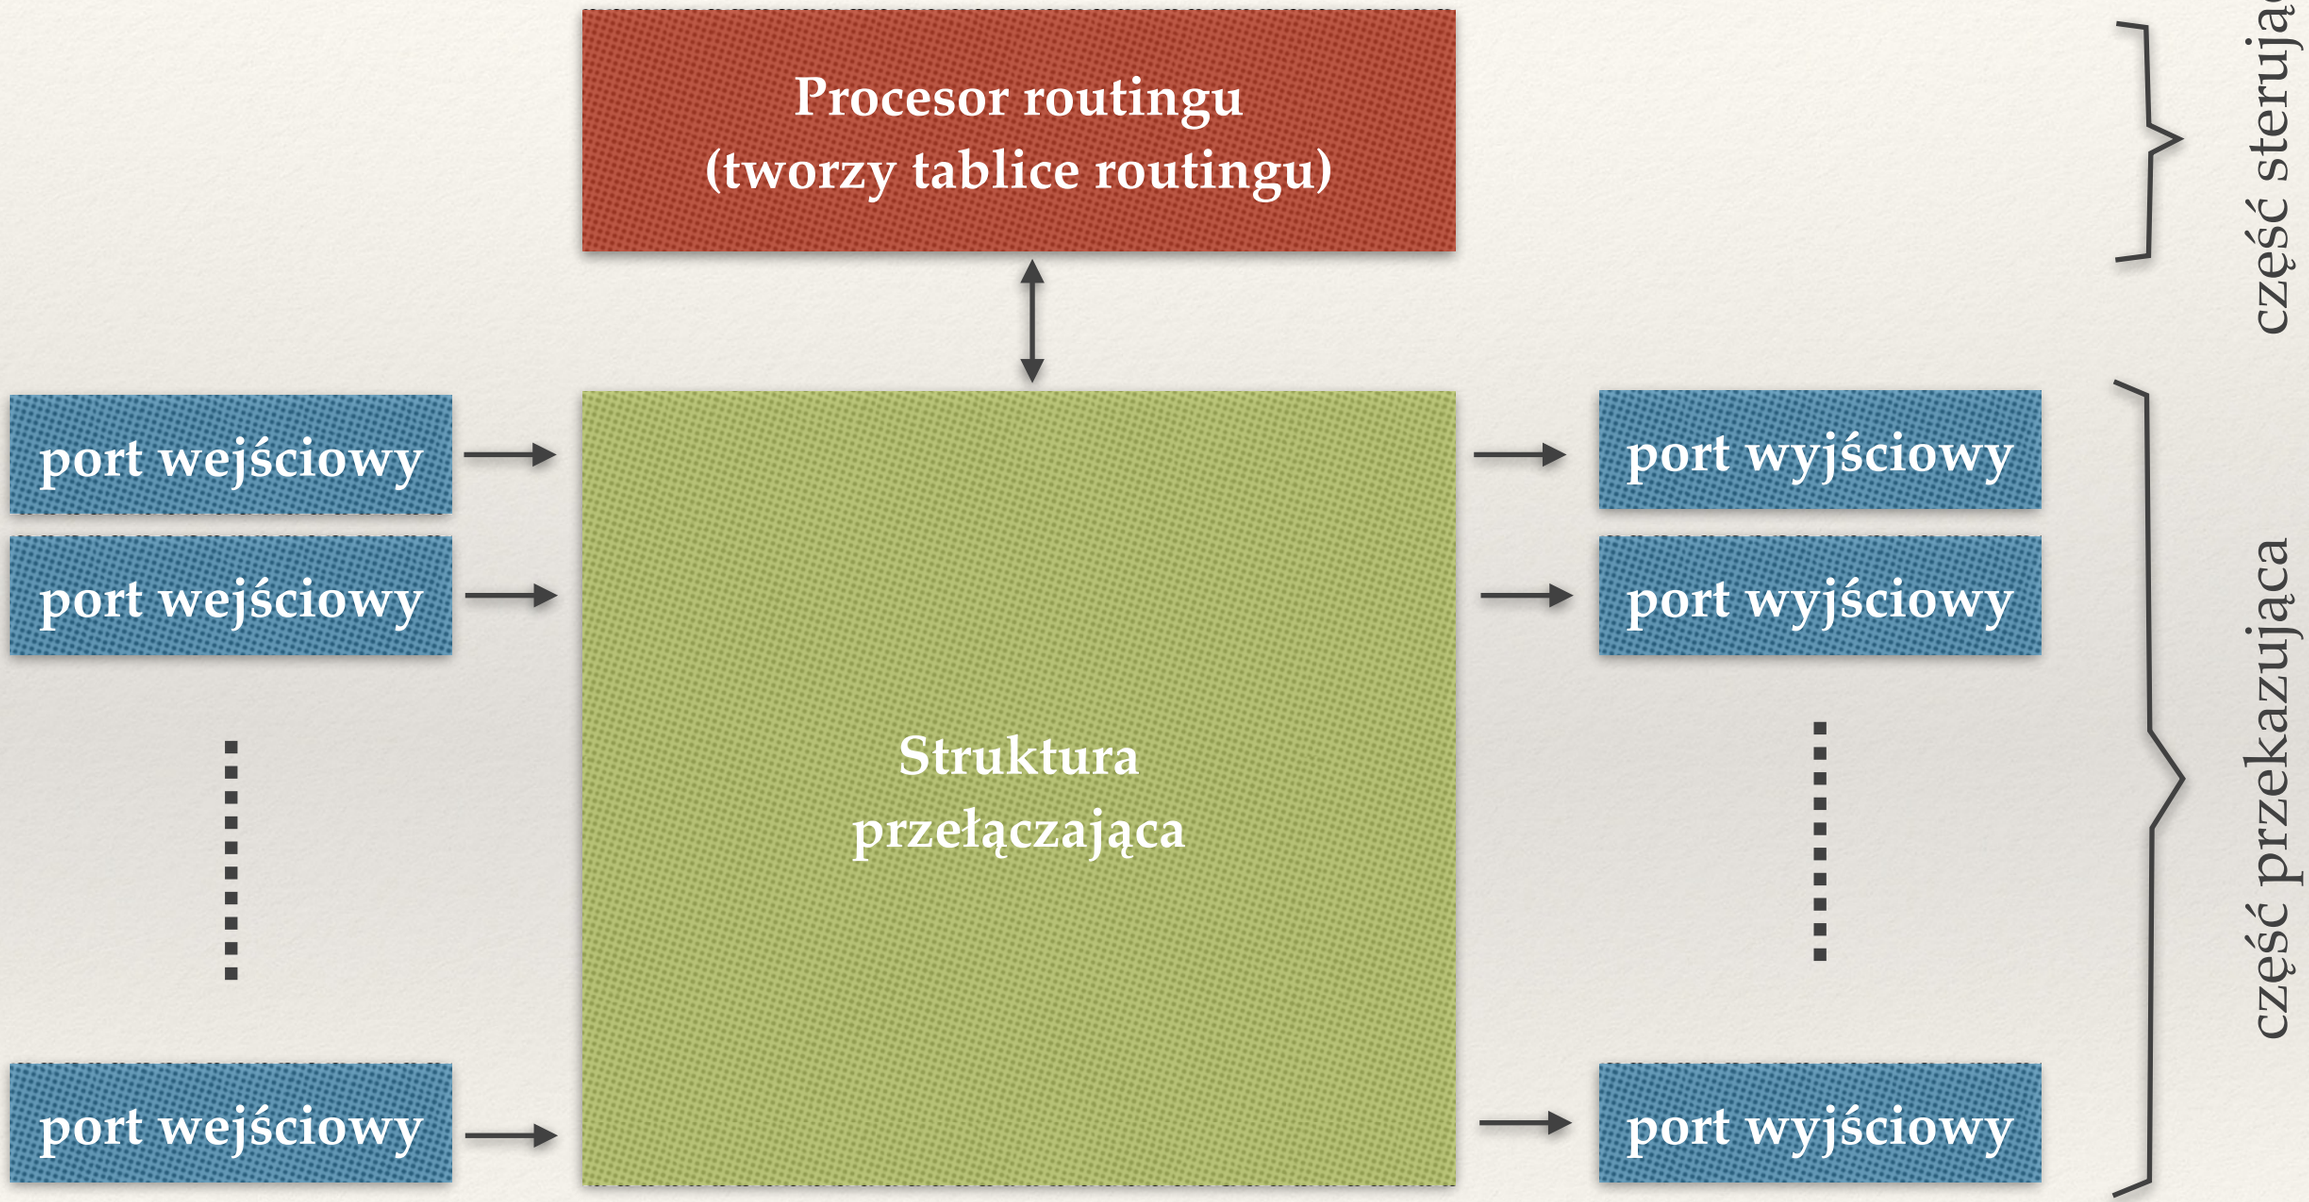

Budowa współczesnego routera (2)

- **Procesor:**
  - Otrzymuje niektóre pakiety (RIP, OSPF, BGP).
  - Tworzy tablice przekazywania i wysyła je do portów wejściowych.

- **Port wejściowy:**
  - Odbiera pakiet z łącza.
  - Uaktualnia nagłówek IP (TTL, suma kontrolna).
  - Sprawdza, do którego portu wyjściowego go przesłać.

Struktura przełączająca

- Chcemy przekazywać pakiety z prędkością łącza.
- Dla n portów wejściowych o prędkości R → chcemy przepustowość n x R (typowe wartości to 10 Gbit/s - 1 Tbit/s).
- Stosowane sieci połączeń:
  - każdy z każdym: $O(n^2)$ połączeń (niepraktyczne dla dużych n);
  - sieci Beneša i pochodne: $O(n \log n)$ połączeń (potrafią bezkolizyjnie przesłać dowolną permutację).

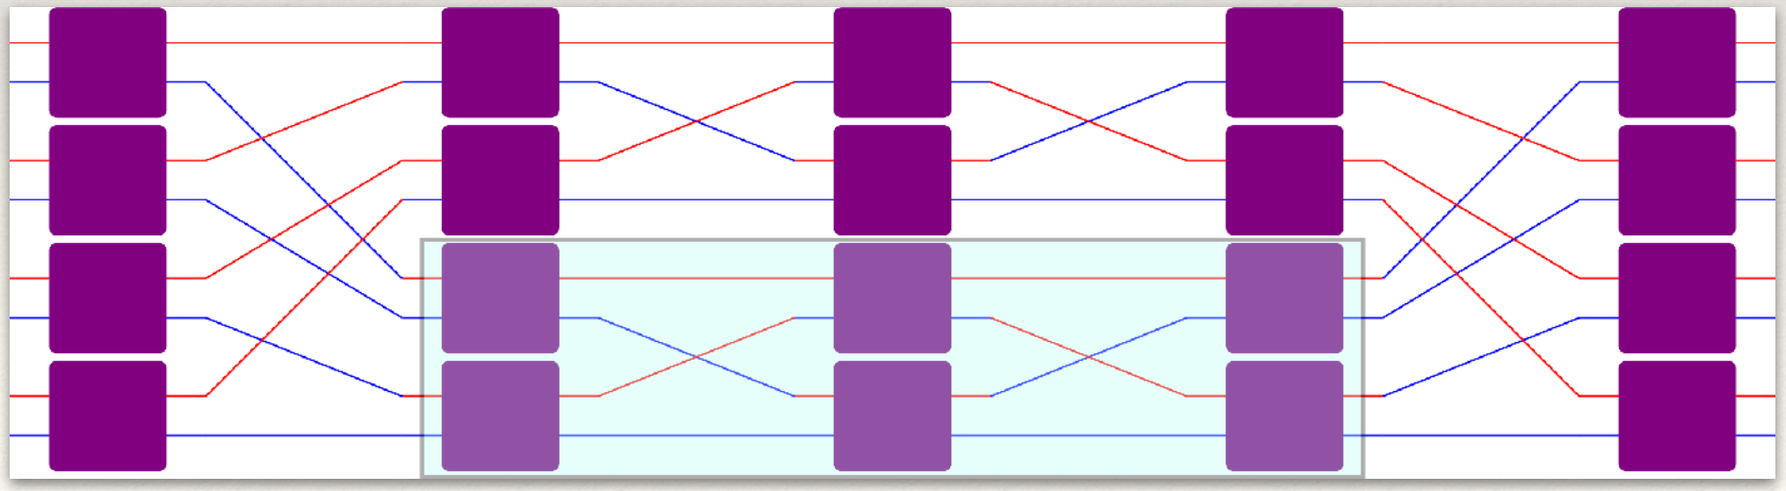

Obrazek ze strony https://en.wikipedia.org/wiki/Clos_network

Bufory z kolejkami pakietów

- **Przy portach wyjściowych.**
  - Zapobiegają utracie pakietów przy czasowym zwiększeniu liczby pakietów.

- **Przy portach wejściowych.**
  - Jeśli przepustowość struktury przełączającej jest za mała.
  - Pakiety kierowane do zajętych łącz wyjściowych są blokowane.
  - Problem blokowania przodu kolejki.

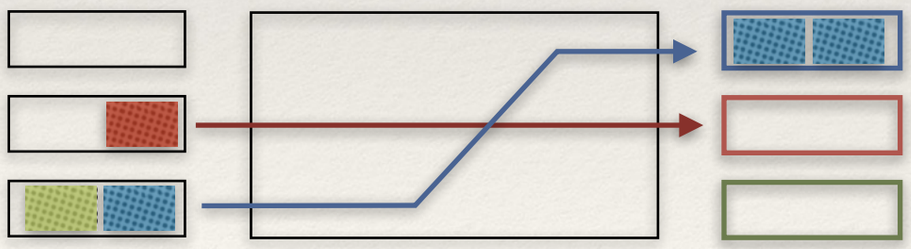

Niebieski pakiet musi czekać
i blokuje wysłanie pakietu zielonego.

Rozwiązywane przez wirtualne kolejki pakietów: jedna kolejka dla każdego portu wyjściowego.

Porty wejściowe

Reguła najdłuższego pasującego prefiksu

prefiks CIDR	akcja
`0.0.0.0/0`	do routera A
`156.17.4.0/24`	do routera B
`156.17.4.128/25`	do routera C
`156.17.4.128/26`	do routera B

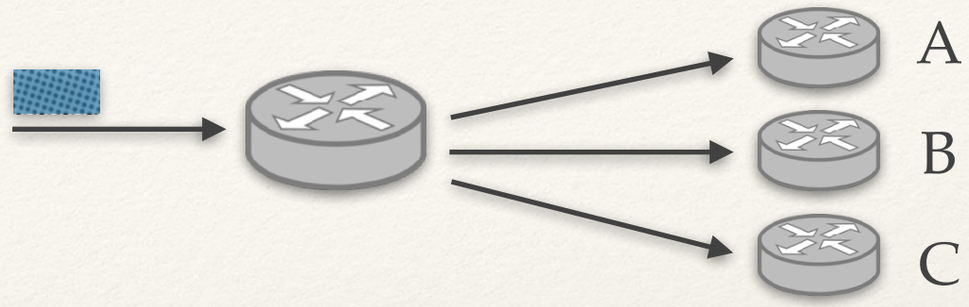

- **LPM** (*longest prefix match*): z pasujących reguł wybierana jest najdłuższa.

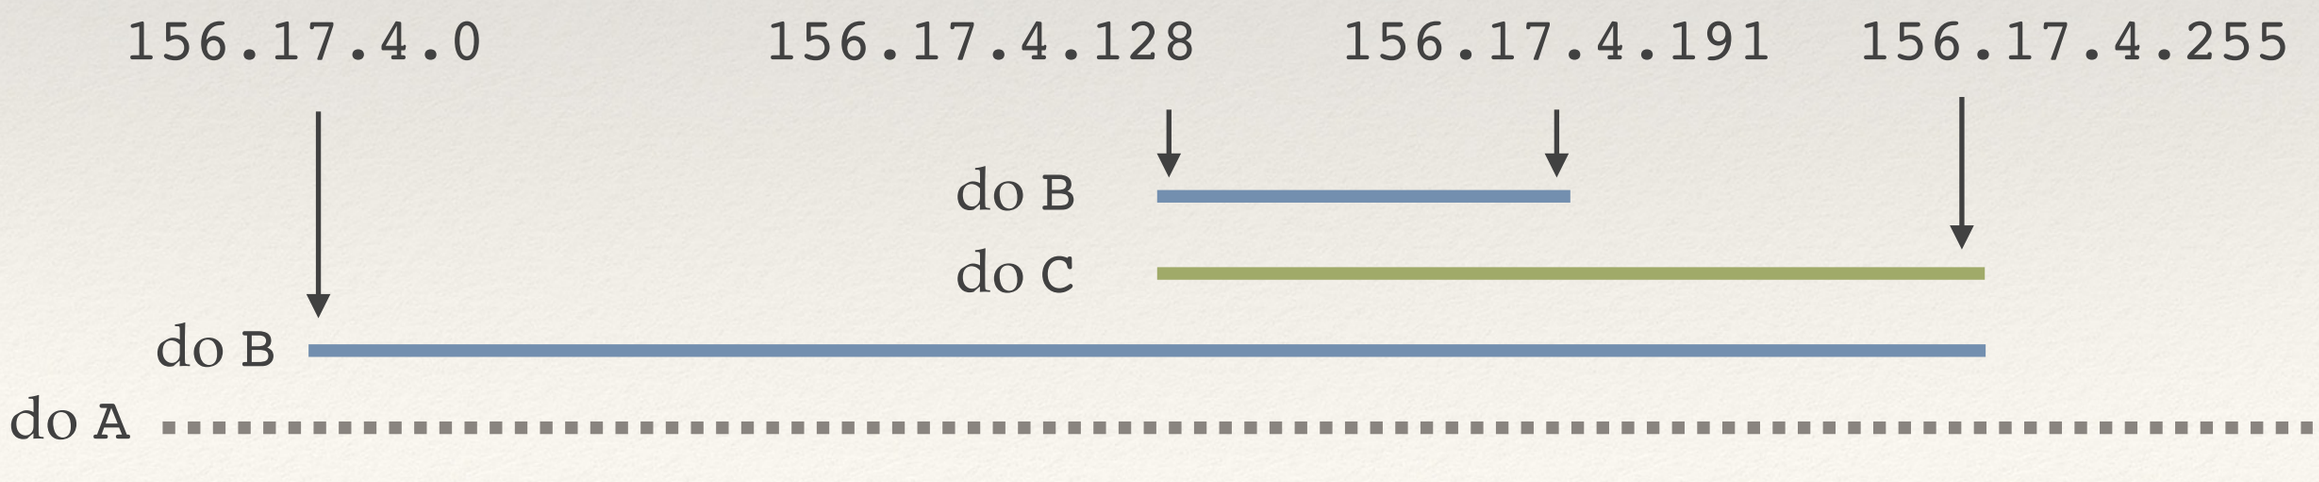

Struktura danych dla LPM

- Musi obsługiwać:
  - **lookup (adres)** — dziesiątki milionów razy / sek.
  - **insert (prefix)** / **delete (prefix)** — setki razy / sek.

- Notacja:
  - n - liczba prefiksów w tablicy;
  - w - rozmiar adresu (adres mieści się w słowie maszyny).

Ile prefiksów w routerach

- ~ 1060 tys na początku 2026.
- Mogłoby być ~600 tys, gdyby każdy ISP agregował rozgłaszane prefiksy CIDR.

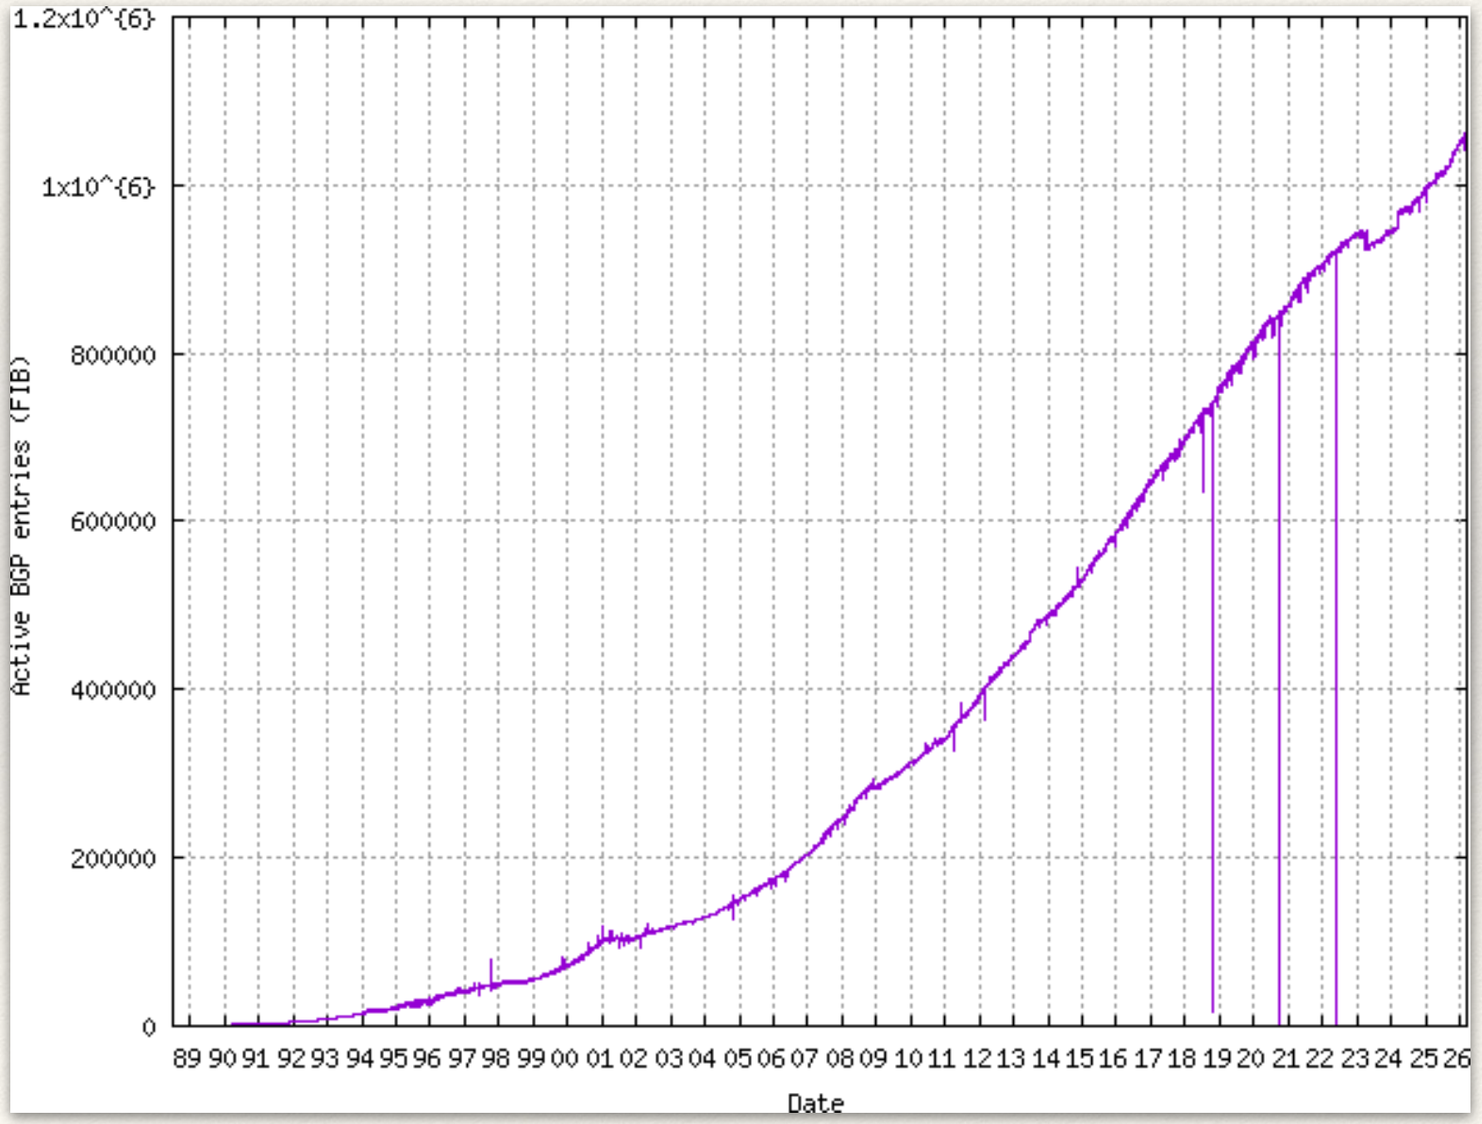

Obrazek ze strony https://www.cidr-report.org/as2.0/

Implementacja LPM (1)

Lista prefiksów:

- pamięć: *O(n)*,
- lookup: *O(n)*,
- insert: *O(1)*, delete: *O(n)*.

Implementacja LPM (2)

Tablice haszujące (starsze systemy uniksowe):

- *w+1* tablic (dla każdej możliwej długości prefiksu; w czasach klas adresów IP wystarczało 5 tablic);
- pamięć: *O(n)*,
- lookup: *O(w)* (oczekiwany),
- insert, delete: *O(1)* (oczekiwany).

Implementacja LPM (3)

Drzewa trie (nowsze systemy uniksowe, routery sprzętowe):

- pamięć: $O(n \cdot w)$,
- lookup: $O(w)$,
- insert, delete: $O(w)$.

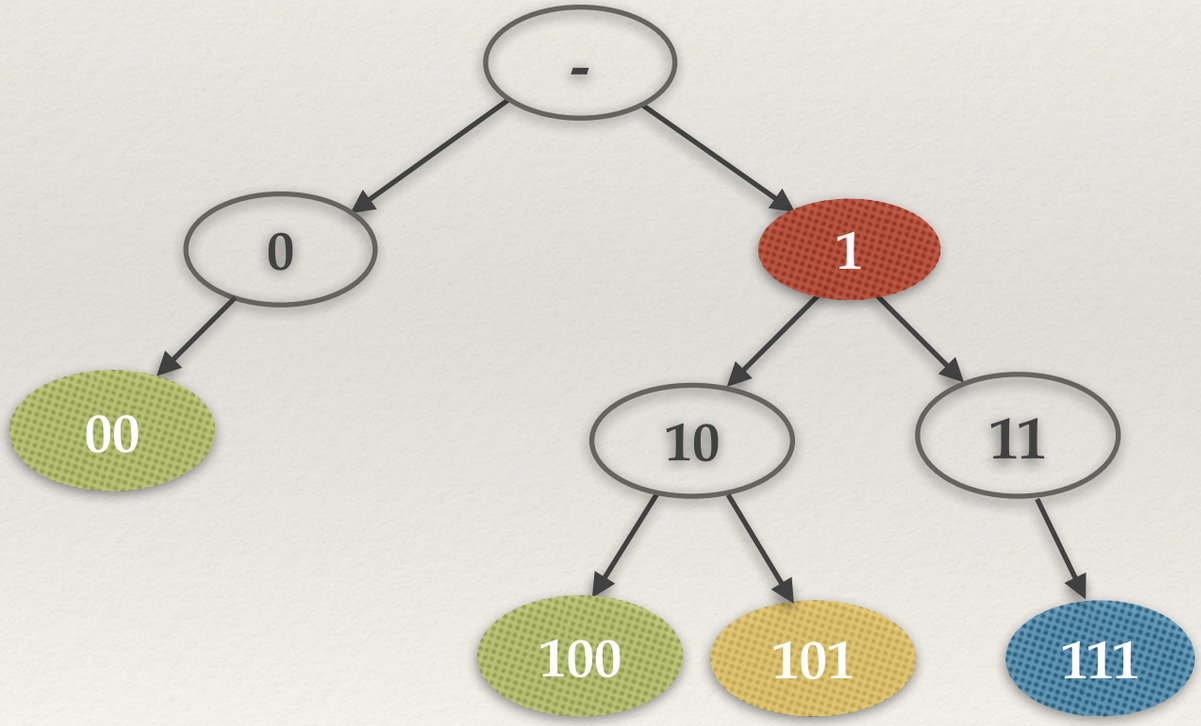

Przechodzimy drzewo w dół i zwracamy ostatnią pasującą regułę:

- dla adresu `10000`… → port zielony;
- dla adresu `11000`… → port czerwony.

Implementacja LPM (3)

Drzewa trie (nowsze systemy uniksowe, routery sprzętowe):

- pamięć: $O(n \cdot w)$,
- lookup: $O(w)$,
- insert, delete: $O(w)$.

O(n) z kompresją ścieżek bez rozgałęzień

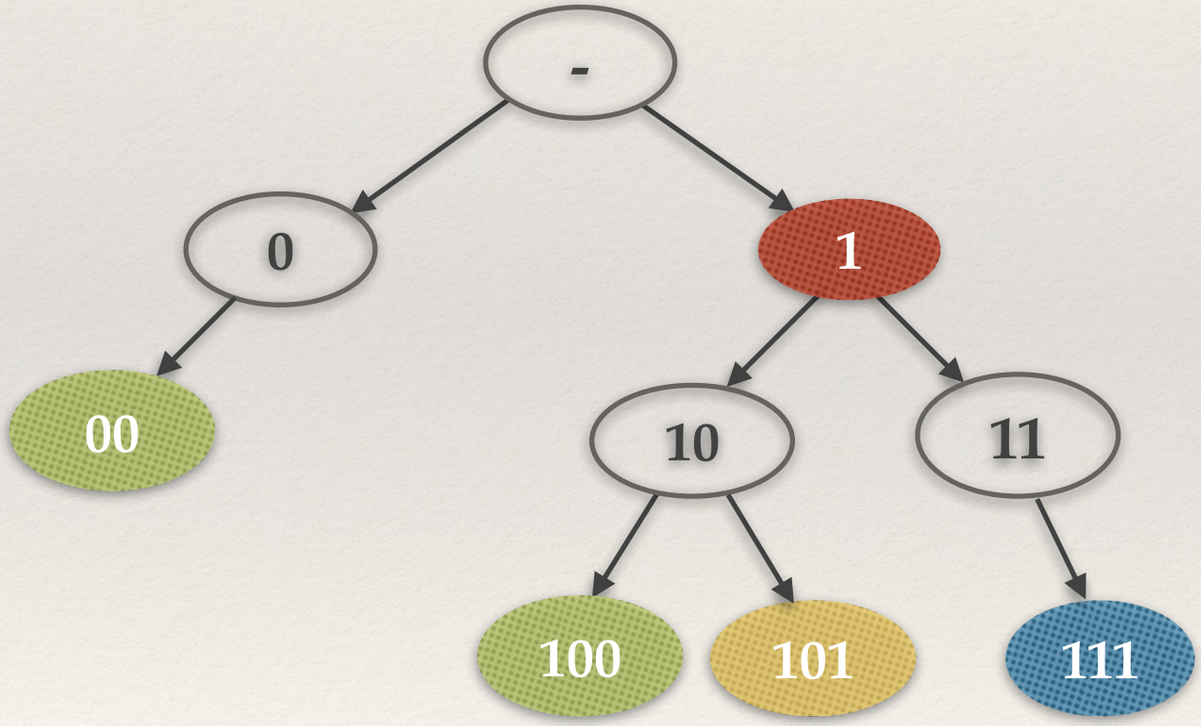

Przechodzimy drzewo w dół i zwracamy ostatnią pasującą regułę:

- dla adresu `10000…` → port zielony;
- dla adresu `11000…` → port czerwony.

Implementacja LPM (4)

Trie ze dodatkowymi krawędziami skracającymi:

- lookup: $O(\log w)$,
- insert, delete: $O(n)$.
- Można zrobić operacje insert/delete w $O(\log w)$, ale stała w notacji O jest niepraktyczna.

Implementacja LPM (5)

- **TCAM (nowsze routery sprzętowe):**
  - TCAM = *ternary content addressable memory.*
  - Przechowuje pary (p, m) = (prefix, maska).
  - Dla adresu w można **równolegle** znaleźć wszystkie pary takie, że $w \,\&\, m = p \,\&\, m$, tj. wszystkie pasujące prefiksy.
  - Sprzętowo wybieramy najdłuższy z nich.

Porty wyjściowe

MTU (maximum transmission unit)

Własność warstwy łącza danych i fizycznej łącza wyjściowego.

- Maksymalny rozmiar pakietu IP (wraz z nagłówkiem).
- MTU Ethernetu: 1500 bajtów.
- (Teoretyczne) MTU sieci bezprzewodowej Wi-Fi: 7981 bajtów.

Fragmentacja

Jeśli rozmiar pakietu ≥ MTU łącza wyjściowego → pakiet jest dzielony na fragmenty.

- Dzielenie może nastąpić na dowolnym routerze na trasie.
- Łączenie fragmentów dopiero na komputerze docelowym.

Fragmentacja a nagłówek IP

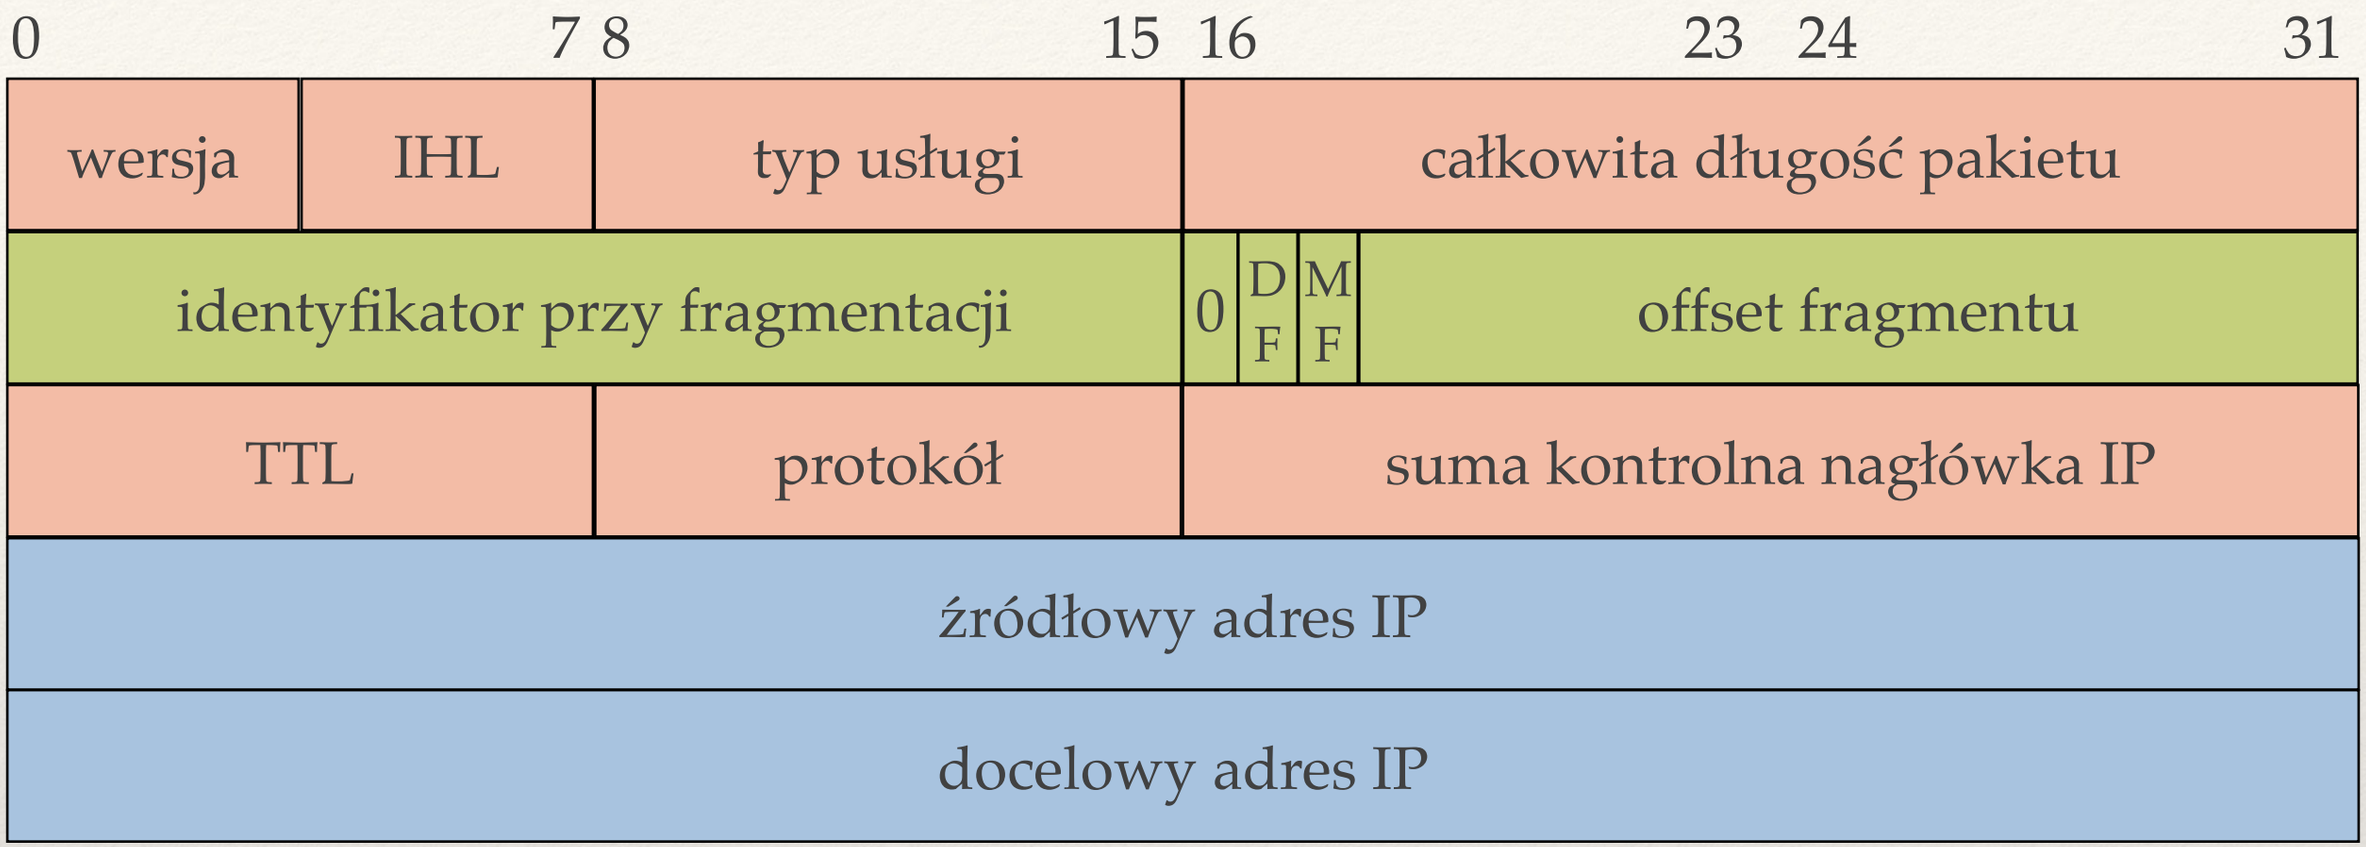

- Fragmenty dostają identyczny identyfikator.
- MF = czy jest więcej fragmentów?
- Offset = numer pierwszego bajtu w oryginalnym pakiecie.

Fragmentacja jest nieefektywna

- Dodatkowa praca dla routerów.
- Dodatkowy narzut, przykładowo:
  - Wysyłamy 140 000 bajtów.
  - MTU pierwszego łącza = 1400.
  - MTU drugiego łącza = 1250.
  - Bez fragmentacji: 140 000 / 1250 = 112 pakietów.
  - Z fragmentacją: wysyłamy 140 000 / 1400 = 100 pakietów, ale każdy dzielony później na dwa.

Fragmentacja jest nieefektywna

- Dodatkowa praca dla routerów.
- Dodatkowy narzut, przykładowo:
  - Wysyłamy 140 000 bajtów.
  - MTU pierwszego łącza = 1400.
  - MTU drugiego łącza = 1250.
  - Bez fragmentacji: 140 000 / 1250 = 112 pakietów.
  - Z fragmentacją: wysyłamy 140 000 / 1400 = 100 pakietów, ale każdy dzielony później na dwa.

- **Jak poznać najmniejsze MTU na trasie?**

Wykrywanie minimalnego MTU na ścieżce

- Ustaw bit DF (*don't fragment*) w nagłówku IP.
- Jeśli konieczna fragmentacja na routerze:
  - pakiet wyrzucony;
  - router odsyła komunikat ICMP (*destination unreachable, can't fragment*) z rozmiarem MTU kolejnego łącza.
- Zmniejsz odpowiednio rozmiar pakietu i ponów wysyłanie.

Co się dzieje w kolejce wyjściowej?

- **Kolejka FIFO:** pakiety wysyłane w takiej kolejności jak nadeszły.
- **Szeregowanie pakietów:** Przypisujemy pakiety do strumieni (na podstawie adresu i portu źródłowego + docelowego). Pakiety szeregowane w zależności od strumienia.

kolejka wyjściowa

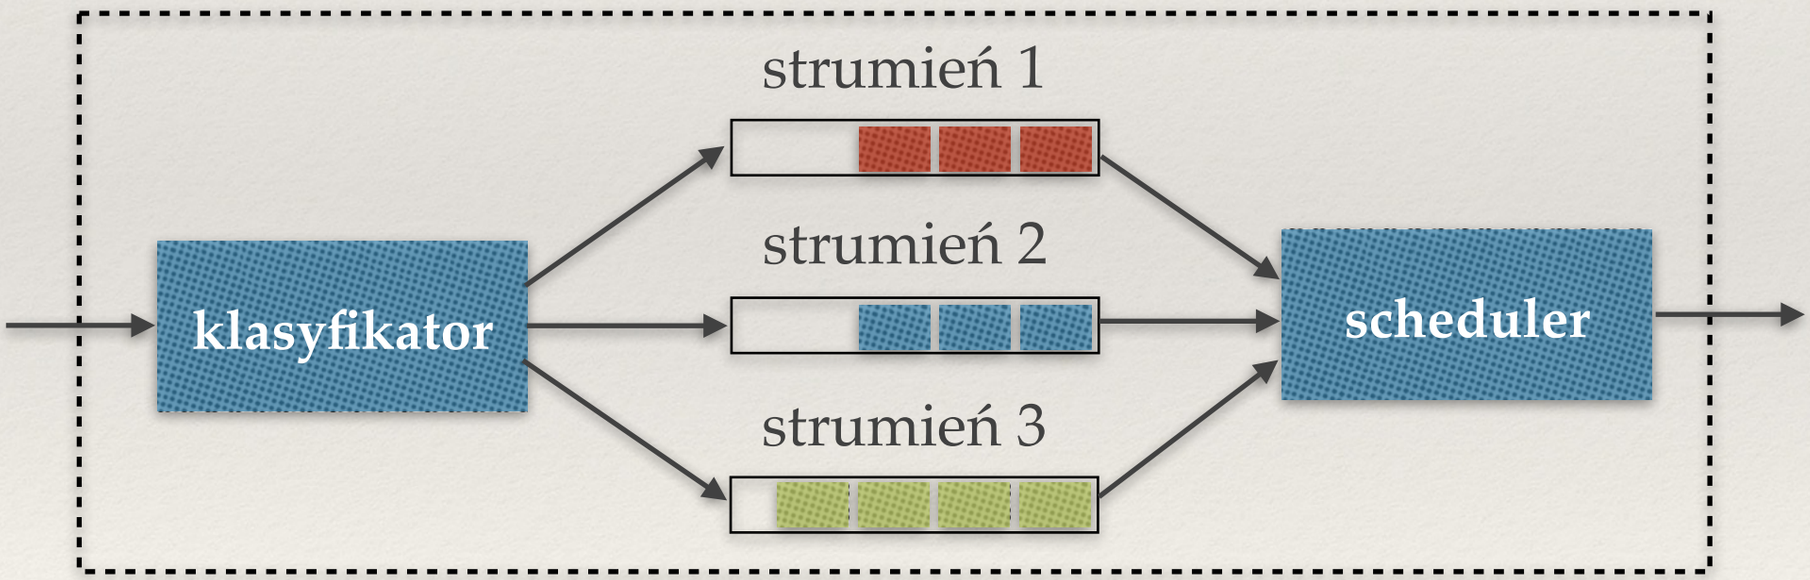

Szeregowanie pakietów w buforze

- **Względem priorytetów strumieni**

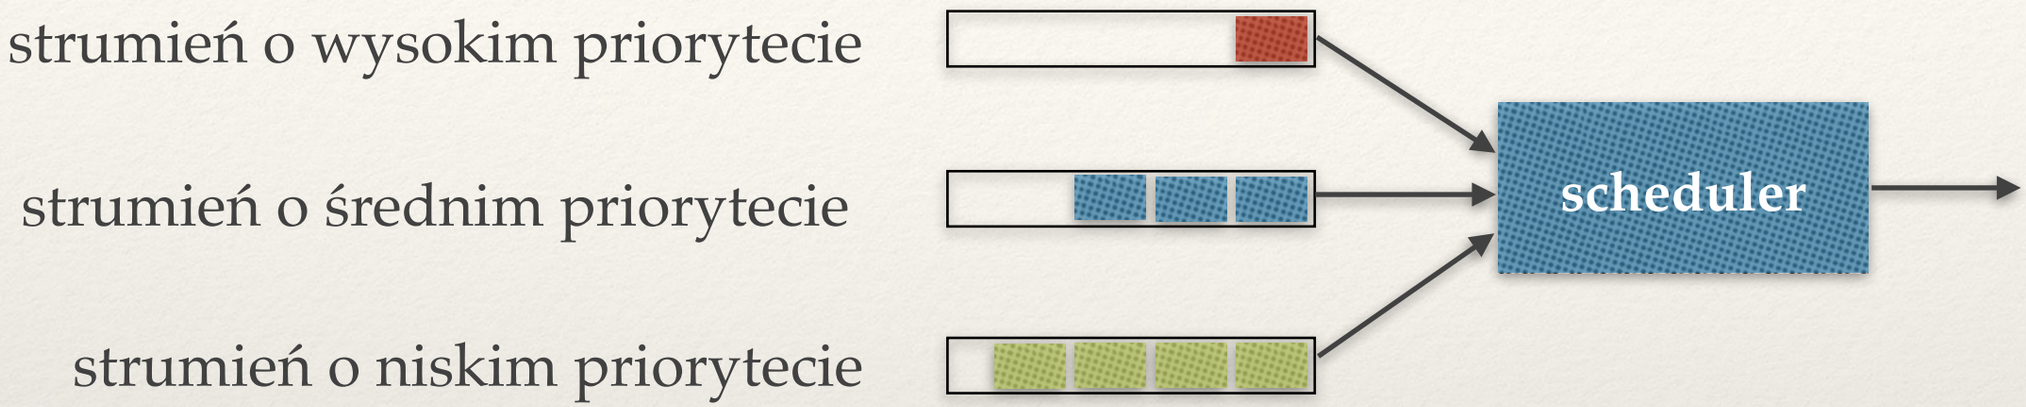

- **Cykliczne (*round-robin*): po tyle samo pakietów z każdego strumienia.**

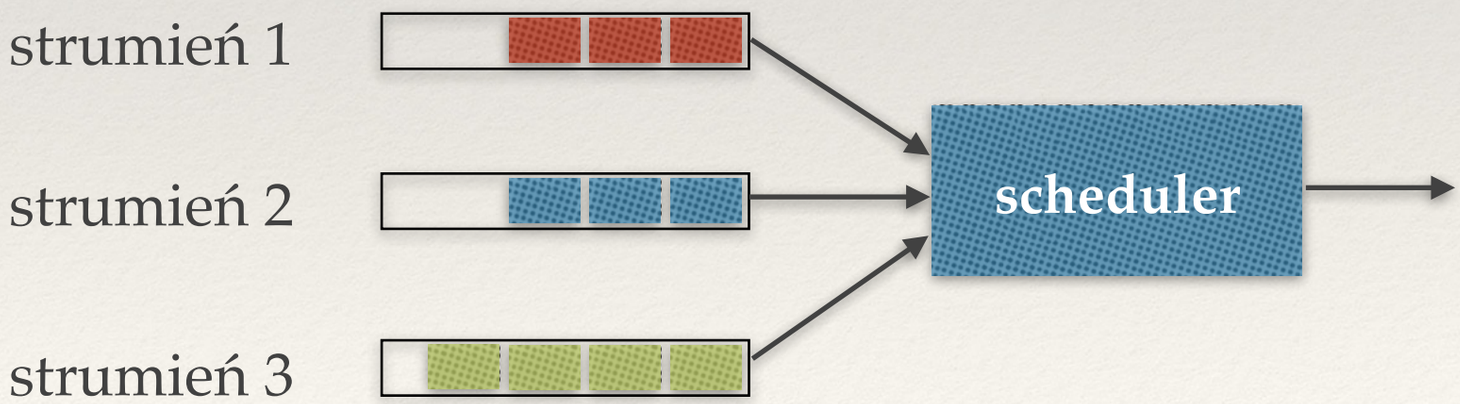

Anycast

Rodzaje adresów IP

- Adresy zwykłe (**unicast**).
- Adresy **broadcast**: pakiet wysłany na taki adres dociera do wszystkich z danej sieci.
- Adresy **multicast**: pakiet wysłany na taki adres dociera do zdefiniowanej grupy.
- Adresy **anycast**: wiele serwerów ma taki sam adres IP.

Adresy anycast

- Obsługa przez standardowe protokoły routingu dynamicznego → routery poznają trasę do **najbliższego** serwera z danym adresem.

- Potencjalny problem: wszystkie pakiety z jednego strumienia danych powinny być do jednego serwera.
  - To nie problem w przypadku protokołu DNS, bo pytanie i odpowiedź mieszczą się w jednym pakiecie UDP.
  - Istnieje ~1000 serwerów o adresach `8.8.8.8` i `1.1.1.1`.
  - W praktyce problem występuje rzadko. → Anycast stosowany też np. w HTTP.

NAT

Coraz większe zapotrzebowanie na adresy IP

- Adresy IPv4 wyczerpują się.
- Wdrożenie IPv6 wciąż trwa.
- Adresy IP są dość kosztowne → pojedyncze IP dla całych firm.

NAT

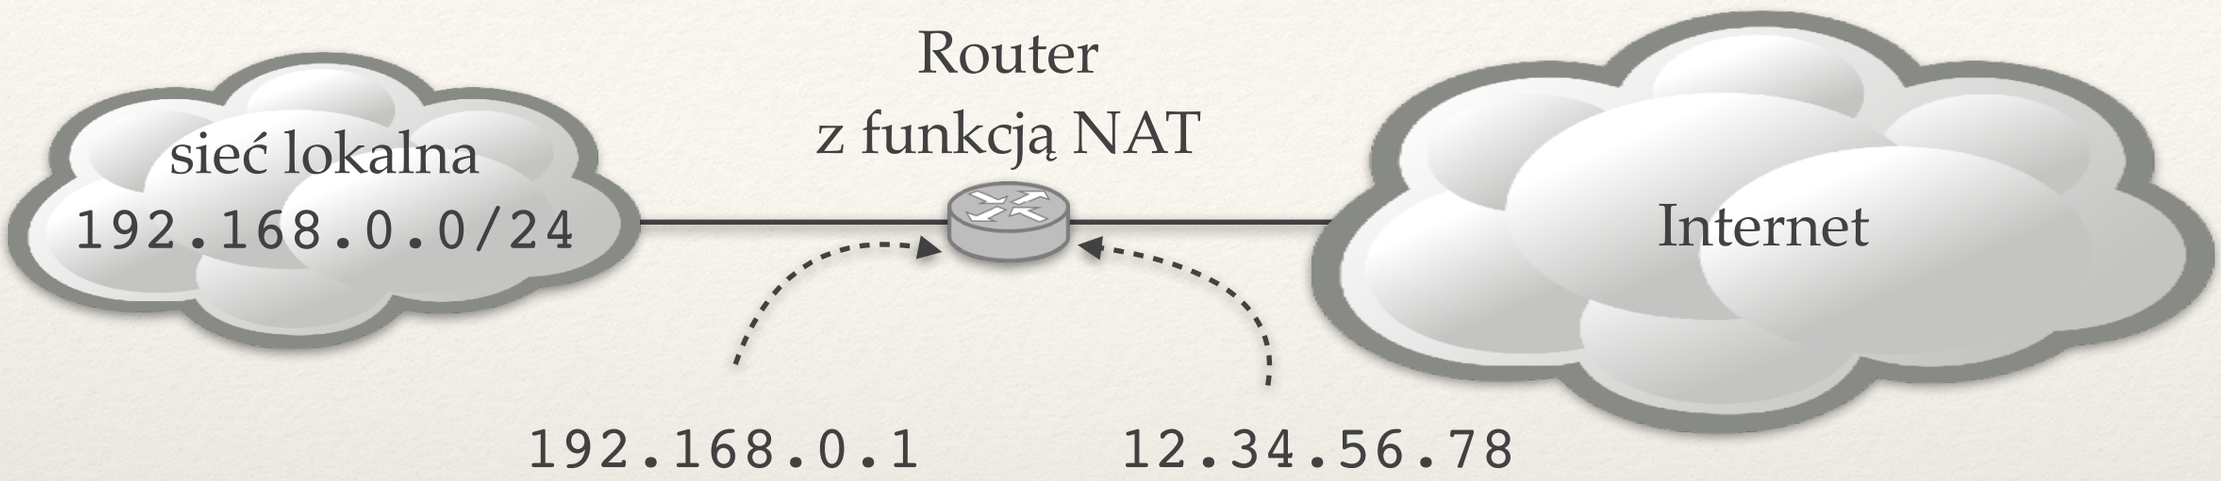

- Z reszty Internetu cała sieć lokalna wygląda tak samo, jak pojedynczy komputer z adresem `12.34.56.78`.
- Nie można (w normalny sposób) dostać się z Internetu do komputerów z LAN.

Co robi router z funkcją NAT?

- **Pakiet**
  - Z adresu i portu (A, P_A).
  - Do adresu i portu (C, P_C).
  - NAT na podstawie krotki (A, P_A, C, P_C) wybiera port P_B.
  - Adres i port źródłowy pakietu podmienione na (B, P_B).

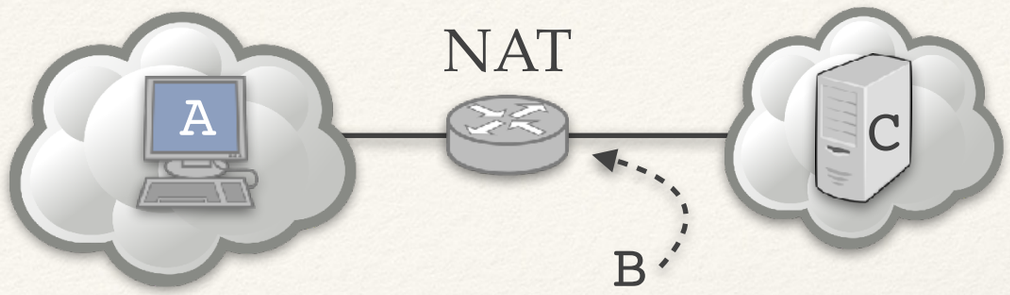

- **Tablica NAT:**
  - Przechowuje przez pewien czas przypisanie (A, P_A, C, P_C) → P_B.
  - Dla kolejnych podobnych pakietów przypisanie będzie takie samo.
  - Jeśli przychodzi odpowiedź do (B, P_B) to jej adres i port docelowy zostanie podmieniony na (A, P_A).

Adresy prywatne

Adresy przeznaczone do sieci lokalnych.

- Pakiety z takimi adresami nie są przekazywane przez routery.
- W różnych sieciach mogą być te same adresy.
- Pule adresów:
  - `10.0.0.0/8` (jedna sieć klasy A);
  - `172.16.0.0/12` (16 sieci klasy B);
  - `192.168.0.0/16` (256 sieci klasy C).
  - `fd00::/8` (dla IPv6).

Zalety i wady NAT

Zalety:

- Rozwiązuje problem braku adresów IP.
- Można zmienić adresy IP wewnątrz sieci bez powiadamiania Internetu.
- Można zmienić ISP pozostawiając adresowanie IP wewnątrz sieci.

Wady:

- Nieosiągalność komputerów z Internetu (aplikacje P2P).
- Psucie modelu warstwowego (router modyfikuje treść pakietu).

IPv6

Dlaczego nowa wersja IP?

- Adresy IPv4 wyczerpują się (IANA oddała ostatnią pulę regionalnym rejestratorom w 2011 r.).
- W 1994 rozpoczęto pracę nad nową wersją (IPv6).
- 128-bitowe adresy.

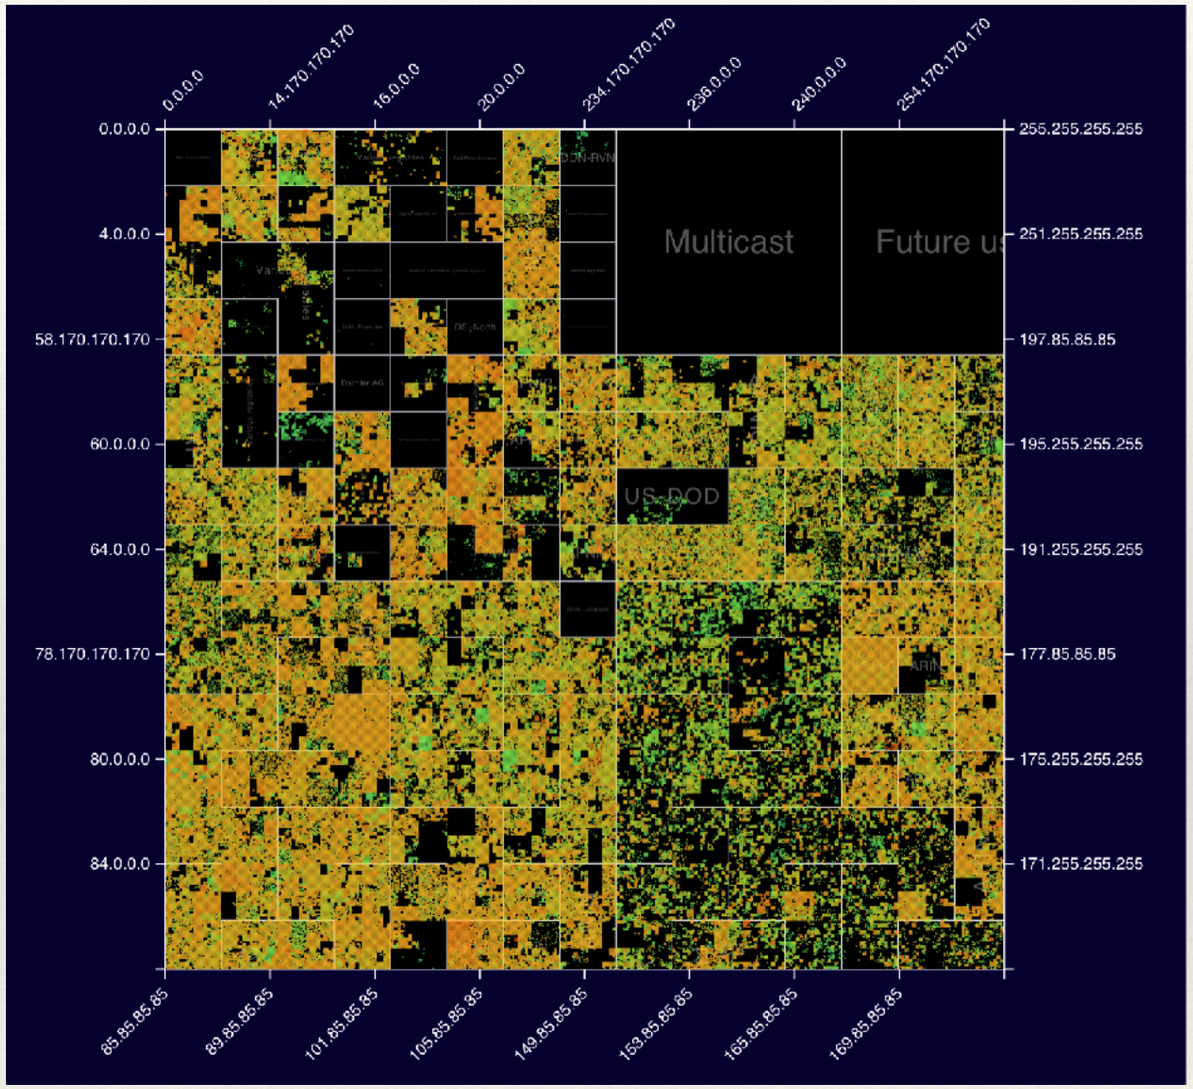

Obrazek ze strony: https://radar.cloudflare.com/year-in-review/2025#ipv4-traffic-distribution

Nagłówek IPv6

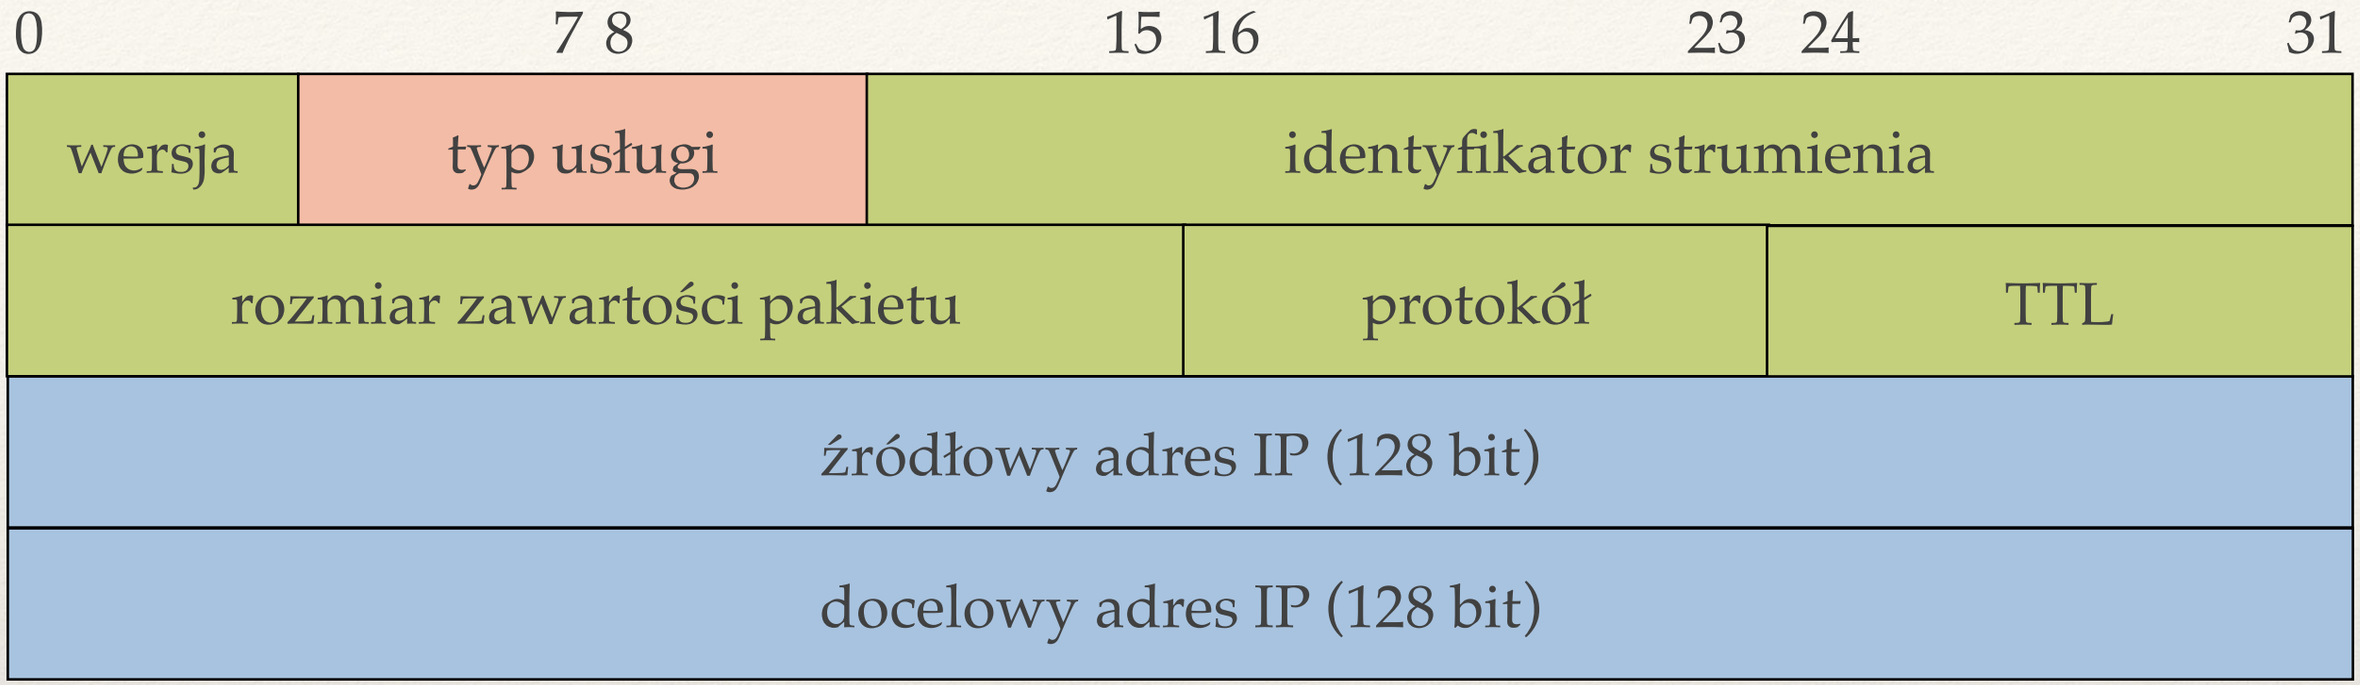

Mniejszy koszt dla routerów:

- nagłówki stałej długości;
- brak fragmentacji;
- brak sumy kontrolnej;
- etykieta strumienia (nie trzeba patrzeć na porty).

Adresy IPv6

- **Notacja:**
  - 8 bloków po 4 cyfry szesnastkowe, rozdzielonych przez dwukropek.
  - Przykładowo A = `2001:0db8:0000:0000:0000:0000:1428:0000`.
  - Localhost = `0000:0000:0000:0000:0000:0000:0000:0001/128`.

- **Uproszczenia zapisu:**
  - Można opuszczać wiodące zera w każdym bloku (do niepustego ciągu).
  - **Jeden** ciąg zerowych bloków zer można zastąpić przez `::`
  - Przykłady:
    - A = `2001:db8::1428:0`,
    - localhost = `::1/128`,
    - Pula adresów prywatnych dla IPv6: `fd00::/8`.

Sieci IPv6

- Typowy prefix dla sieci lokalnej w IPv6 to `/64`.
- Prywatni odbiorcy zazwyczaj dostają prefix `/56` lub `/60`.
- Organizacje zazwyczaj dostają prefix `/48`.

- Brak adresu rozgłoszeniowego (broadcast).
- Zdefiniowane wiele specjalnych adresów multicastowych, np:
  - `ff02::1` - wszystkie adresy w sieci lokalnej (jak broadcast);
  - `ff02::2` - wszystkie routery w sieci lokalnej.

ICMPv6

- Oferuje funkcje analogiczne do ICMPv4.
- Może zastępować DHCP.
- Zastępuje ARP.
- ARP i DHCP poznamy na kolejnych wykładach.

Migracja do IPv6

- Większość dużych serwisów (Google, Facebook, …) ma swoje wersje IPv6.
  - Osobne serwery lub serwery z podwójnym stosem (potrafią interpretować pakiety IPv4 i IPv6).
- Duża część routerów w rdzeniu Internetu potrafi przesyłać pakiety IPv6.

Migracja do IPv6

- Większość dużych serwisów (Google, Facebook, …) ma swoje wersje IPv6.
  - Osobne serwery lub serwery z podwójnym stosem (potrafią interpretować pakiety IPv4 i IPv6).

- Duża część routerów w rdzeniu Internetu potrafi przesyłać pakiety IPv6.

- **Co zrobić, jeśli router naszego ISP nie ma adresu IPv6?**

Mechanizmy migracji: tunelowanie 6in4

- Pakiety IPv6 przesyłane jako dane pakietów IPv4.
- Pomiędzy komputerem a brokerem tworzony jest logiczny kanał (1 hop z punktu widzenia IPv6).

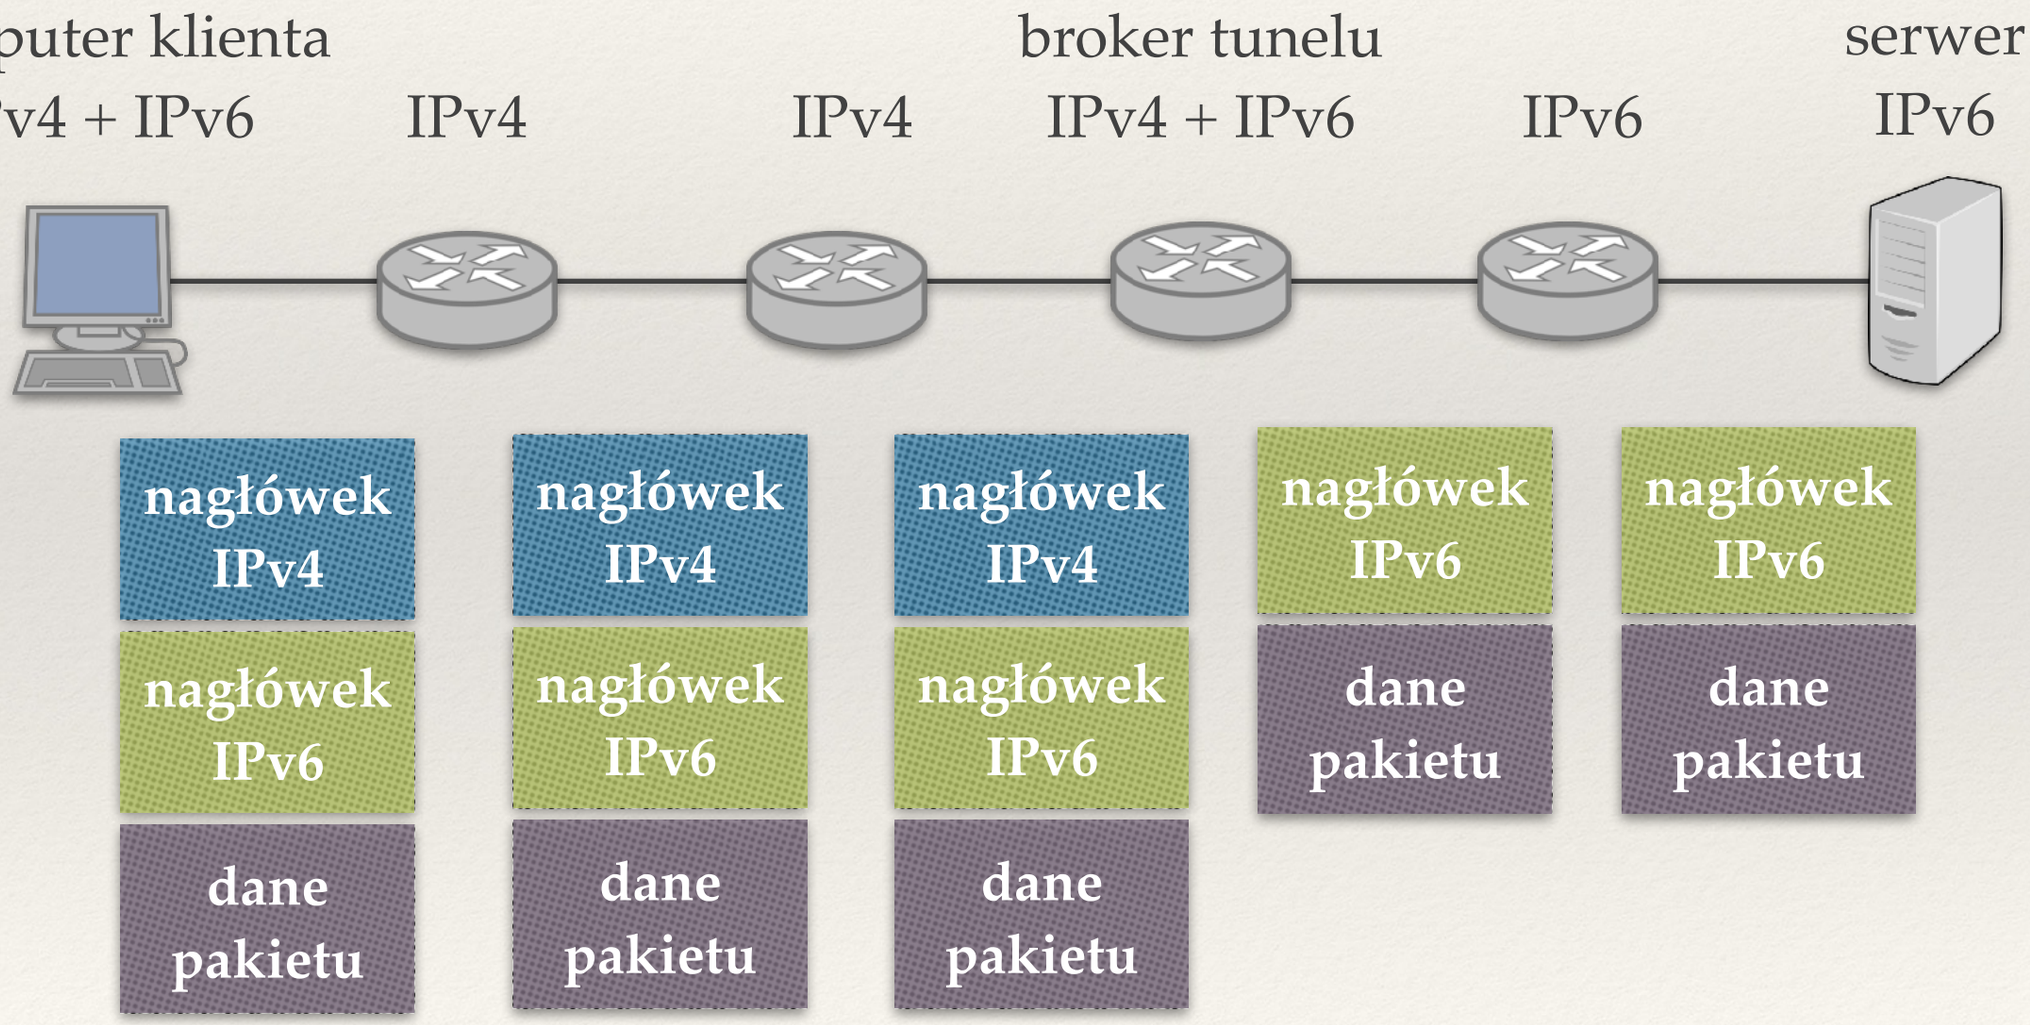

Lektura dodatkowa

- Kurose & Ross: rozdział 4.
- Tanenbaum: rozdział 5.
- Stevens: rozdział 8.

- Dokumentacja IPv6 i UDP:
  - https://web.archive.org/web/20211130063606/http://networksorcery.com/enp/Protocol/ipv6.htm
  - https://web.archive.org/web/20211206051320/http://networksorcery.com/enp/Protocol/udp.htm

- Raporty CIDR: https://www.cidr-report.org/as2.0/
- Beej's Guide to Network Programming: http://beej.us/guide/bgnet/

Zagadnienia

- Co to są prywatne adresy IP? Jakie pule adresów są zarezerwowane na takie adresy?
- Co robi funkcja `bind()`?
- Czym różnią się porty o numerach mniejszych niż 1024 od innych?
- Jakie są zadania procesora routingu, portu wejściowego, portu wyjściowego i struktury przełączającej?
- Czym się różni przełączanie pakietów w routerze za pomocą RAM od przełączania za pomocą struktury przełączającej?
- Jakie są pożądane cechy struktury przełączającej w routerze?
- Gdzie w routerze stosuje się buforowanie? Po co?
- Po co w portach wyjściowych klasyfikuje się pakiety?
- Co to jest blokowanie początku kolejki? Gdzie występuje? Jak się go rozwiązuje?
- Rozwiń skrót LPM.
- Jakie znasz struktury danych implementujące LPM? Porównaj je.
- Co to jest pamięć TCAM? Jak można ją zastosować do implementacji LPM?
- Na czym polega fragmentacja IP? Gdzie się ją stosuje i dlaczego? Gdzie łączy się fragmenty?
- Co to jest MTU? Na czym polega technika wykrywania wartości MTU dla ścieżki?
- Jak działa szeregowanie pakietów w buforze wyjściowym routera?
- Na czym polega NAT i po co się go stosuje? Jakie są jego zalety i wady?
- Jaki stan musi przechowywać router z funkcją NAT?
- Jakie są różnice pomiędzy nagłówkami IPv4 i IPv6?
- Zapisz adres IPv6 `0321:0000:0000:0123:0000:0000:0000:0001` w najkrótszej możliwej postaci.
- Co to jest tunelowanie 6in4?