

# Ezoteryczne Kartki

## Operacje bitowe

Jakub Bachurski

wersja 1.2.0.3

### 1 Podstawy

*Operacje bitowe* to operacje działające na reprezentacjach bitowych liczb. Obsługują je wszystkie typy liczbowe.<sup>1</sup>

Binarne operacje (tzn. z dwoma parametrami) bitowe działają jak odpowiednie operacje logiczne na każdej parze odpowiadających bitów obu liczb.

Operator	Operator logiczny	Warunek 1
<code>&amp;</code>	<code>&amp;&amp;</code> , <code>and</code>	oba bity to 1
<code> </code>	<code>  </code> , <code>or</code>	co najmniej jeden z bitów to 1
<code>^</code>	<code>(xor)</code>	dokładnie jeden z bitów to 1

Przykłady (liczymy  $155 \& 25$ ,  $100 | 172$ ,  $87 \wedge 248$ ):

1001 1011		0110 0100		0101 0111
<code>&amp;</code> 0001 1001		1010 1100		<code>^</code> 1111 1000
0001 1001		1110 1100		1010 1111

Do tego dochodzą przesunięcia bitowe (*bitshifty*), które działają na trochę innej zasadzie:

- $x \ll s$  to liczba  $x$  przesunięta o  $s$  bitów w lewo.  $5 \ll 2 = 20$
- $x \gg s$  to liczba  $x$  przesunięta o  $s$  bitów w prawo.  $42 \gg 3 = 5$

Jeżeli jakiś bit „wyjdzie” poza wielkość typu (np. 32 bity `unsigned`), to przepada.  $(3 \gg 1) \ll 1 = 2$ .

Jest jeden operator unarny (tzn. z jednym parametrem): `~` (operator negacji, czyli `not`), odpowiadający `!`: neguje *wszystkie* bity.

*Uwaga.* Operacje bitowe mają bardzo niski priorytet w kolejności operatorów, więc warto opatrzyć je nawiasami. Więcej o priorytetach tutaj: [operator precedence].

<sup>1</sup>W tej kartce „typy liczbowe” rozumiane są jako typy reprezentujące liczby całkowite: `int`, `unsigned`, `long` itd.

## 2 Dodatkowe operacje – rozszerzenia g++

g++ udostępnia nam jeszcze trochę dodatkowych operacji, dostępnych jako funkcje. Nie wszystkie procesory je obsługują, ale w razie czego g++ zapewni własną, szybką implementację.

Funkcja	Działanie
<code>__builtin_clz(x)</code>	<code>count leading zeroes</code> . Liczba zer wiodących.
<code>__builtin_ctz(x)</code>	<code>count trailing zeroes</code> . Liczba zer kończących.
<code>__builtin_popcount(x)</code>	Liczba bitów zapalonych (czyli 1).

Każda z funkcji działa domyślnie na `unsigned int`, ale ma odpowiedniki działające na `unsigned long` i `unsigned long long` – mają one dodatkowy sufix `l` lub `ll`. Przykładowo, rodzina `clz` to `__builtin_clz`, `__builtin_clzl`, `__builtin_clzll`. Wszystkie funkcje zwracają `int`-a. Zachowanie `clz` i `ctz` na 0 jest niezdefiniowane.

## 3 Ciekawe własności

- Bitshifty o  $k$  odpowiadają pomnożeniu/podzieleniu (z podłogą) przez  $2^k$ . Zatem potęgi dwójki można liczyć przez  $1 \ll k$ . *Uwaga.* Jeżeli kompilator ma wyłączone optymalizacje (-O0) to bitshifty są szybsze od operacji arytmetycznych. To znaczy, że w takich dziwnych warunkach  $x \gg 1$  jest szybsze od  $x / 2$ . Dotyczy to tylko dzielenia/mnożenia przez stałe.
- W drzewie binarnym, w którym indeksujemy dzieci wierzchołka  $x$  jako  $2x$  oraz  $2x + 1$ , aby dostać dziecko o takim samym ojcu jak  $y$  można użyć  $y^{\wedge} 1$ .
- `xor` ma ciekawe własności z tego względu, że jeżeli rzucamy w niego losowymi liczbami to wyniki też są całkiem losowe. Zatem ma zastosowanie w pewnych odmianach hashowania.
- `and` oraz `or` są idempotentne ( $x \mid y \mid y = x \mid y$ ) i nie mają odwrotności. `xor` jest swoją własną odwrotnością ( $x \wedge x = 0$ ).
- Liczba  $x$  jest potęgą dwójki jeżeli  $x \& (x - 1) == 0$ .
- Ponieważ `int`-y w dzisiejszych czasach używają U2 ([two's complement]), aby implementować ujemne liczby, można korzystać z takiej tożsamości:  $-x == \sim x + 1$ .
- Żeby sprawdzić czy  $k$ -ty bit liczby  $x$  jest włączony, można użyć formułki  $(x \gg k) \& 1$ . Dostaniemy 0 lub 1. Jeżeli wystarczy nam 0 i pewna niezerowa wartość, można napisać  $x \& (1 \ll k)$  (otrzymamy 0 lub  $2^k$ ).

- Podłoga z logarytmu dwójkowego to jednocześnie pozycja najbardziej znaczącej jedynek. Umieemy policzyć liczbę zer bardziej znaczących niż najbardziej znacząca jedynka za pomocą `__builtin_clz`, zatem
 

```
floor(log2(x)) == (W-1) - __builtin_clz(x)
```

 gdzie  $W$  to wielkość typu – 32 dla `int`-a. Funkcja licząca podłogę z logarytmu dwójkowego jest także dostępna jako `std::_lg(x)` w `<algorithm>` i działa dokładnie w ten sposób. Implementuje ona overloady dla każdego typu liczbowego.
- Ostatni bit liczby określa jej parzystość. Można go odzyskać za pomocą `x & 1` – działa to również dla liczb ujemnych (otrzymamy 0 lub 1, a operator modulo może zwrócić 0, 1 albo -1).

## 4 Bitmaski – liczby jako zbiory

Możemy przyjąć, że liczba o  $w$  bitach reprezentuje pewien podzbiór zbioru  $\{0, 1, 2, \dots, w - 1\}$ . Jeżeli  $k$ -ty bit (reprezentujący  $2^k$ ) jest zapalony, to  $k$  należy do zbioru reprezentowanego przez bitmaskę. Wtedy operacje bitowe można traktować jak operacje na zbiorach:

Operacja bitowa	Operacja na zbiorach
<code>x &amp; y</code>	$X \cap Y$
<code>x   y</code>	$X \cup Y$
<code>x ^ y</code>	$X \Delta Y$
<code>~x</code>	$\overline{X}$
<code>x &amp; ~y</code>	$X \setminus Y$
<code>__builtin_popcount(x)</code>	$ X $

W charakterze mniej konwencjonalnych operacji można dorzucić `__lg(x)` jako  $\max X$  oraz `__builtin_ctz(x)` jako  $\min X$ .

W ten sposób będziemy mogli pisać dynamiki po podzbiorach w o wiele prostszy sposób i rozwiązać np. problem komiwojażera. Poza tym bitmaski przydają się w pisaniu backtracków i brutów.

Bardzo przydatną własnością bitmask jest to, że odwiedzając liczby w kolejności rosnącej od 0 nigdy nie odwiedzimy pewnego zbioru *po zbiorze który go zawiera*. Dzięki temu pisanie dynamików na bitmaskach jest jeszcze prostsze!

## 5 Bitsety

`bitset` to struktura udająca tablicę `bool`-i wykorzystująca fakt, że wiele `bool`-i można upakować do jednego machine worda<sup>2</sup>. (np. `int`-a). (Nawiasem mówiąc, `bool` zajmuje tyle co najmniejsza adresowalna jednostka pamięci – czyli zwykle 1 bajt).

<sup>2</sup>W rozumieniu jako typu standardowej wielkości na danym procesorze. Uprościmy sobie i powiedzmy, że w architekturze 32-bitowej są to 32 bity, a 64-bitowej: 64 bity.

Za pomocą `bitset`-ów zużywamy 8 razy mniej pamięci<sup>3</sup>, i możemy wygodnie hurtowo wykonywać operacje bitowe, co pomaga w pewnych konkretnych optymalizacjach. Typ wykorzystywany przez `bitset` to `unsigned long`, i od jego wielkości zależy, ile naraz wykonujemy porównań.

Konkretniej, `bitset` jest strukturą znaną jako `std::bitset<size_t N>` w `<bitset>`. Jako parametr szablonu podajemy ilość bitów – niestety, musi być ona stała (a operacje zawsze są wykonywane na wszystkich bitach). Przykład wykorzystania:

```
bitset<16> A, B;
A[3] = A[6] = A[8] = 1;
B[3] = B[6] = B[7] = B[10] = 1;
cout << A << " " << B << endl;
cout << (A & B) << " " << (A | B) << " " << (A ^ B) << endl;
```

[Dokumentacja `bitset`ów].

## 6 Zadanka

### 6.1 Minimalna odległość Hamminga

**Treść** Masz dane  $n$  ciągów binarnych (czyli na alfabecie dwuznakowym) o długości  $k$ . Znajdź wśród nich parę o minimalnej odległości Hamminga (zdefiniowanej jako liczba pozycji, na której dwa ciągi różnią się).

**Rozwiązanie** Najprostszy brut zadziała w  $O(n^2k)$ . Możemy to w prosty sposób zoptymalizować wrzucając stringi do `bitset`ów (ręcznie zaimplementowanych bądź standardowych). Odległość Hamminga dwóch ciągów  $A$  i  $B$  jest wtedy równa  $(A \oplus B).count()$  (analogicznie na liczbach: `__builtin_popcount(a ^ b)`). Otrzymamy w ten sposób rozwiązanie około 32 razy szybsze, bo naraz wykonujemy 32 porównania (lub tyle, ile wynosi wielkość `machine word`). Złożoność tak zoptymalizowanego programu można zapisać jako  $O(\frac{n^2k}{W})$ , gdzie  $W = 32$ .

### 6.2 Macierze czarnorożne

**Treść** Masz daną macierz  $n \times n$  wypełnioną zerami i jedynkami. Policz liczbę macierzy, w której narożnikach są tylko jedynki.

**Rozwiązanie** Możemy to rozwiązać prostym podejściem w  $O(n^3)$  przechodząc wszystkie pary rzędów i zliczając, ile jest takich kolumn, że w obu rzędach jest tam jedynka. Oznaczmy tę wartość przez  $c$  – wtedy dla tej pary rzędów do wyniku dodajemy  $\frac{c(c-1)}{2}$ . Fazę zliczania kolumn można ulepszyć: wrzucmy rzędy macierzy do `bitset`ów. Liczba zapalonych bitów `and`-a pary rzędów to poszukiwana wartość  $c$ . Otrzymaliśmy rozwiązanie w  $O(\frac{n^3}{W})$ .

<sup>3</sup>W porównaniu do tablicy `bool` tej samej wielkości.

### 6.3 Problem wydawania reszty

**Treść** W klasycznym problemie wydawania reszty mamy dany zbiór nominałów i chcemy policzyć, dla jakich wartości można wybrać taki podzbiór nominałów, który sumuje się do tej wartości.

**Rozwiązanie** Można utrzymywać dotychczas otrzymane wartości w bitsecie. Wtedy, gdy napotykamy nowy nominał, odpowiednio przesuwamy i or-ujemy nasz bitset. *Uwaga.* Ponieważ wyrażenie `b << a[i]` może trafić na stos, to możliwe jest przekroczenie limitu stosu<sup>4</sup>. Aby temu zapobiec, należy zrobić tymczasowy bitset.

```
// Problem wydawania reszty dla jednorazowych nominałów a[]
bitset<M> b;
b[0] = true;
for(int i = 0; i < n; i++)
    b |= (b << a[i]);
```

W ten sposób upraszczamy implementację i znacząco zmniejszamy stałą.

### 6.4 Problem komiwojażera

**Treść** Dla odmiany dynamik na bitmaskach. Chcemy rozwiązać problem komiwojażera: dla danego zbioru miast i odległości pomiędzy nimi chcemy znaleźć najkrótszą ścieżkę która przechodzi przez każde z nich dokładnie raz.

**Rozwiązanie** Opisujemy dynamikę o stanie  $T(V, c)$ , gdzie  $V$  to zbiór odwiedzonych miast, a  $c$  to miasto w którym się znajdujemy. Poszukiwana wartość to długość ścieżki odwiedzającej każde z miast w  $V$  i kończącej się w  $c$ . Przejście jest dosyć intuicyjne (niech  $d$  oznacza odległość między miastami):

$$T(V, c) = \min_{c_1 \in V \setminus \{c\}} T(V \setminus \{c\}, c_1) + d(c_1, c)$$

W prosty sposób przekłada się to na kod, jeżeli skorzystamy z bitmask:

---

<sup>4</sup>np. testując rozwiązanie lokalnie, lub na dziwnej sprawdzarce.

```

// Komiwojażer dla n wierzchołków i tablicy odległości d[][]
int T[1 << N][N];
for(int v = 1; v < (1 << n); v++)
{
    if(__builtin_popcount(v) == 1)
    {
        T[v][__lg(v)] = 0; continue;
    }
    for(int c = 0; c < n; c++)
    {
        T[v][c] = INT_MAX;
        for(int c1 = 0; c1 < n; c1++)
            if((v & (1 << c1)) and c1 != c)
                T[v][c] = min(T[v][c], T[v ^ (1 << c)][c1] + d[c1][c]);
    }
}

```

## 7 Triki

*Bit tricks* zwykle się nie pamięta, kiedy są najbardziej potrzebne, ale warto je kojarzyć.

### 7.1 Podzbiory bitmaski

Okazuje się, że mając pewną maskę  $m$  oraz podmaskę  $c$ , kolejno biorąc  $c' = (c - 1) \& m$  będziemy okresowo dostawać bitmaski reprezentujące wszystkie podzbiory zbioru reprezentowanego przez  $m$ . Najlepiej widać to na przykładzie (kolejne komórki to kolejne  $c$ , po dekrementacji i wyandowaniu):

```

          0010 0011
          -----
          0010 0011
          0010 0010
          0010 0001
          0010 0000
          0000 0011
          0000 0010
          0000 0001
          0000 0000
          0010 0011
          ...

```

Formułka w C++, zaczyna od pustego i przerywa, gdy napotka pusty (0):

```

int c = 0;
do {
    process(c);
} while(c = (c - 1) & m);

```

## 7.2 Cache, cache, cache

Gdybyśmy chcieli implementować rzeczy pokroju `popcount` samodzielnie, bardzo często korzysta się z cache, które przechowują wyniki np. dla liczb 8 czy 16 bitowych. Przykładowo:

```
int byte_pop[1 << 8];

void prepare_cache()
{
    for(int i = 0; i < (1 << 8); i++)
        for(int j = 0; j < 8; j++)
            byte_pop[i] += (i >> j) & 1;
}

int popcount(int x)
{
    // 0xFF to szesnastkowo 255 = 1111 1111_2
    return byte_pop[x & 0xFF] + byte_pop[(x >> 8) & 0xFF]
        + byte_pop[(x >> 16) & 0xFF] + byte_pop[(x >> 24) & 0xFF];
}
```

W tym wypadku pewnie lepiej jest przechować dla liczb 16-bitowych, ale gwoli przykładu pokazuję 8-bitowe.

## 7.3 Upraszczenie warunków

Trudno sformalizować ten sposób. Czasami mamy dużo brzydkich `if`-ów, albo coś tego pokroju. Możemy spróbować przerzucić logikę do bitmask. Pokażę to na dwóch przykładach.

### 7.3.1 Samogłoska

Powiedzmy że chcemy mieć funkcję `bool is_vowel(char c)` stwierdzającą czy znak jest samogłoską. Mamy założenie, że `c` będzie wielką literą alfabetu łacińskiego. Ponieważ znaków jest mniej niż 32, możemy powrzucać do bitmaski 1 jeżeli litera na odpowiedniej pozycji jest samogłoską.

```
// 17842449 = 0b001000100000100000100010001
bool is_vowel(char c)
{
    return (17842449 >> (c - 'A')) & 1;
}
```

Najlepiej po prostu jest wrzucić to do tablicy `bool`, ale jest to dobry przykład tej techniki. Kolejny przykład jest bardziej użyteczny.

### 7.3.2 Unikaty

Mamy trzy zmienne:  $x$ ,  $y$  i  $z$ . Każda z nich może mieć wartości 0, 1 albo 2. Chcemy powiedzieć ile unikatowych wartości jest wśród zmiennych. Na przykład, dla  $x = 0$ ,  $y = 2$ ,  $z = 0$  mamy 2.

Pomysł jest taki, żeby powrzucać do bitmaski  $1 \ll k$ , jeżeli wśród liczb mamy wartość  $k$ , i policzyć `popcount`.

```
int count_unique(int x, int y, int z)
{
    return __builtin_popcount((1 << x) | (1 << y) | (1 << z));
}
```

