

Semantyka przenoszenia obiektów

dr inż. Ireneusz Szcześniak

jesień 2018 roku

Problem: kopiowanie obiektów

- Obiekt może być kopiowany, kiedy:
 - jest przekazywany przez wartość do funkcji,
 - jest zwracany przez wartość z funkcji,
 - jest wsadzany do kontenera,
 - jego wartość jest zamieniana z wartością innego obiektu.
- Jeżeli obiekty są duże, to częste kopiowanie obiektu doprowadza do spowolnienia programu.
- Kopiowanie obiektów jest realizowane przez konstruktor kopiujący lub kopiujący operator przypisania.
- Przy kopiowaniu, obiekt źródłowy i obiekt docelowy mogą znajdować się w różnych miejscach na stosie albo stercie.
- Obiekty lokalne tworzone są na stosie, ponieważ alokacja pamięci na stosie jest znacznie szybsza niż alokacja pamięci na stercie.

Semantyka przenoszenia obiektów

- Cecha języka C++11, która pozwala na *uniknięcie kopiowania obiektów* poprzez przenoszenie obiektów.
- Kopiowanie nie jest potrzebne i może być uniknione, jeżeli obiekt źródłowy nie będzie potem potrzebny.
- Przenoszenie obiektów jest realizowane przez konstruktor przenoszący lub przenoszący operator przypisania.
- Obiekt może być przeniesiony tylko wtedy, jeżeli:
 - jest użyty w wyrażeniu kategorii r-wartość,
 - ma zaimplementowaną semantykę przeniesienia.
- Implementacja semantyki przenoszenia obiektów danej klasy może być domyślna (dostarczona przez kompilator) albo dostarczona przez programistę.

Jak to działa?

- Nic magicznego się nie dzieje! Obiekty nie są przenoszone bit-po-bicie między różnymi miejscami pamięci!
- Przenoszenie obiektu polega na przenoszeniu danych z obiektu źródłowego do obiektu docelowego. Obiekt źródłowy i obiekt docelowy pozostają w pamięci tam, gdzie były i będą w normalny sposób niszczone.
- Programista może zaimplementować przenoszenie obiektów danej klasy przez zdefiniowanie:
 - **konstruktora przenoszącego**,
 - **przenoszącego operatora przypisania**.
- Obiekt, który jest źródłem przeniesienia, po przeniesieniu ma być **spójny** (bo obiekt będzie potem normalnie niszczone), ale jego stan nie musi być **zdefiniowany**.

Konstruktor: kopiujący i przenoszący

```
struct T
{
    // Konstruktor kopiujący.
    T(const T &t)
    {
        // Skopiuj dane z obiektu t do *this.
    }

    // Konstruktor przenoszący.
    T(T &&t)
    {
        // Przenieś dane z obiektu t do *this.
    }
};
```

Operator przypisania: kopiujący i przenoszący

```
struct T
{
    // Kopiujący operator przypisania.
    T &operator = (const T &t)
    {
        // Skopiuj dane z obiektu t do *this.
        return *this;
    }
    // Przenoszący operator przypisania.
    T &operator = (T &&t)
    {
        // Przenieś dane z obiektu t do *this.
        return *this;
    }
};
```

Przenoszący operator przypisania: zwracany typ

Przenoszący operator przypisania powinien zwracać l-referencję, a nie r-referencję, ponieważ wyrażenie $a = b = T()$ powinno przenieść obiekt tymczasowy $T()$ do b , a następnie skopiować obiekt b do a .

Jeżeli operator przypisania zwracałby r-referencję, to wyrażenie $a = b = T()$ przeniósłoby obiekty tymczasowy $T()$ do b , a następnie obiekt b zostałby przeniesiony do a .

Ciekawostka: ponieważ przenoszący operator przypisania zwraca l-referencję, to jego wynikiem możemy zainicjalizować l-referencję: $T \&l = T() = T();$, mimo że $T \&l = T();$; oczywiście się nie kompiluje.

Wybór przeciężenia

Wybór przeciężenia (kopiującego lub przenoszącego) konstruktora czy operatora przypisania zależy od kategorii wartości wyrażenia, które jest argumentem wywołania i także od dostępności przeciężenia.

Jeżeli dostępne są oba przeciężenia, kompilator wybierze przeciężenie kopiujące dla l-wartości i przeciężenie przenoszące dla r-wartości.

Jeżeli dostępne jest tylko przeciężenie kopiujące, kompilator wybierze przeciężenie kopiujące także dla r-wartości, bo stała l-referencja może wskazać r-wartość.

Jeżeli dostępne jest tylko przeciężenie przenoszące, kompilator zgłosi błąd dla l-wartości, bo r-referencja nie może wskazać l-wartości.

Domyślne implementacje składowych specjalnych

Kompilator dołączy domyślne implementacje:

- konstruktora: kopiującego i przenoszącego,
- operatora przypisania: kopiującego i przenoszącego,
- destruktor,

jeżeli programista nie dostarczył żadnej z nich. W przeciwnym razie kompilator ich nie dołączy, ale możemy jakąś jawnie dołączyć:

```
struct A
{
    ~A() {}
    A(const A &) = default;
};
```

Implementacja konstruktora przenoszącego

W liście inicjalizacji argumentami konstruktorów obiektów bazowych i składowych powinny być r-wartości, żeby zostały wybrane konstruktory przenoszące obiektów bazowych i składowych, dlatego używamy funkcji `std::move`.

```
#include <string>
#include <utility>

struct A {};

struct B: A
{
    std::string m_s;

    B(B &&b): A(std::move(b)), m_s(std::move(b.m_s))
    {
    }
};
```

Implementacja przenoszącego operatora przypisania

Żeby kompilator wybrał przenoszące (a nie kopiujące) operatory przypisania (jeżeli istnieją) dla obiektów bazowych i składowych, używamy funkcji `std::move`.

```
#include <string>
#include <utility>

struct A {};

struct B: A
{
    std::string m_s;

    B & operator=(B &&b)
    {
        A::operator=(std::move(b));
        m_s = std::move(b.m_s);
        return *this;
    }
};
```

Usuwanie składowych

Możemy usunąć składowe przez zadeklarowanie ich jako **delete**:

```
struct A
{
    // Konstruktor kopiujący.
    A(const A &) = delete;

    // Kopiujący operator przypisania.
    A &
    operator =(const A &) = delete;
};
```

W ten sposób usunęliśmy konstruktor kopiujący i kopiujący operator przypisania, jak robi się to w typach danych tylko do przenoszenia (ang. move-only type), którego przykładem jest **std::unique_ptr**.

Inicjalizacja parametrów funkcji

Parametr funkcji inicjalizowany jest na podstawie wyrażenia, które jest argumentem wywołania funkcji. Dla parametru typu niereferencyjnego będzie wywołany:

- **konstruktor kopiujący**, jeżeli argumentem jest **l-wartość**,
- **konstruktor przenoszący**, jeżeli argumentem jest **r-wartość**.

Jeżeli konstruktor kopiujący nie jest dostępny, a argumentem jest l-wartość, to będzie zgłoszony błąd kompilacji.

Jeżeli konstruktor przenoszący nie jest dostępny, a argumentem jest r-wartość, to będzie użyty konstruktor kopiujący.

Zwracanie wyniku funkcji przez wartość

Jeżeli wartość zwracana przez funkcję nie jest typu referencyjnego, to mówimy, że funkcja zwraca wynik przez wartość. Na przykład:

```
struct T;  
  
T foo();
```

Od C++03 zezwala się na optymalizację wartości powrotu (ang. return value optimization, RVO), której celem jest uniknięcie wywołania konstruktora (ang. constructor elision) kopiującego lub przenoszącego przy zwracaniu wartości funkcji.

Jeżeli nie można zastosować RVO, to C++11 wymaga, aby kompilator stosował niejawne przeniesienie (ang. implicit move) zwracanego obiektu lokalnego.

Optymalizacja wartości powrotu

Miejsce dla zwracanego obiektu jest alokowane na stosie przez kod wywołujący funkcję przed wywołaniem funkcji. Funkcja stworzy obiekt w już zaalokowanym miejscu i jeżeli może, to bez wywoływania konstruktora kopiującego czy przenoszącego.

W ten sposób funkcja tworzy obiekt w miejscu, do którego zwracany obiekt musiałby być skopiowany albo przeniesiony, gdyby był stworzony w miejscu na stosie zaalokowanym przez funkcję.

Niejawne przeniesienie

Przy zwracaniu przez wartość niestatycznego obiektu lokalnego t funkcji, jeżeli nie można zastosować RVO, lub zwracaniu parametru t funkcji, wyrażenie instrukcji `return` niejawnie traktowane jest jako r-wartość, żeby pozwolić na przeniesienie zwracanego obiektu. Wtedy instrukcja `return t;` działa jak `return std::move(t);`.

Standard C++ pozwala na jawne przeniesienie tylko w przypadku `return t;`. Inne, bardziej złożone, wyrażenia nie są uwzględnione.

Nie powinniśmy sami używać funkcji `std::move` dla argumentu instrukcji `return`, bo wtedy wymusimy przenoszenie obiektu nawet w sytuacjach, kiedy może być zastosowana RVO.

Kiedy RVO nie działa: przypadek 1

Kiedy w momencie tworzenia obiektów lokalnych funkcji nie wiadomo, który z nich zostanie zwrócony, wtedy RVO nie może być zastosowana.

```
struct A {};  
  
A foo(bool flag)  
{  
    A a1, a2;  
    return flag ? a1 : a2;  
}
```

Zwracana wartość będzie kopiowana, a nie przenoszona niejawnie, bo wyrażeniem instrukcji **return** nie jest nazwa zmiennej, a operator warunkowy.

Kiedy RVO nie działa: przypadek 2

Kiedy zwracany jest parametr funkcji. Parametr funkcji jest alokowany i inicjowany w osobnym miejscu na stosie, a nie w miejscu zaalokowanym dla zwracanej wartości.

```
struct A {};  
  
A foo(A a)  
{  
    return a;  
}
```

Ponieważ wyrażeniem instrukcji `return` jest nazwa parametru `t` funkcji, to obiekt `t` zostanie niejawnie przeniesiony.

Kiedy RVO nie działa: przypadek 3

Kiedy funkcja zwraca obiekt globalny albo statyczny, bo one nie są alokowane na stosie, gdzie jest alokowane miejsce dla wracanego obiektu.

```
struct A {};  
  
A foo()  
{  
    static A a;  
    return a;  
}
```

Ponieważ wyrażeniem instrukcji **return** jest nazwa statycznej zmiennej lokalnej **t** funkcji, to obiekt **t** nie zostanie niejawnie przeniesiony. Tego obiektu **t** będziemy potrzebować przy następnym wywołaniu funkcji, skoro jest statyczny.

Kiedy RVO nie działa: przypadek 4

Kiedy zwracany obiekt jest obiektem bazowym lokalnego obiektu. Lokalny obiekt był za duży, żeby można było go stworzyć w miejscu dla zwracanej wartości.

```
struct A {};  
struct B: A {};  
  
A foo()  
{  
    B b;  
    return b;  
}
```

Tylko obiekt bazowy zmiennej lokalnej **b** zostanie niejawnie przeniesiony (ang. object slicing) do zwracanego obiektu, bo i tak **b** będzie zniszczony. Jeżeli obiekt **b** byłby statyczny, to obiekt bazowy zostałby skopiowany.

Funkcja `std::swap`

Funkcja `std::swap` była jednym z powodów, dla którego zaczęto pracować nad semantyką przeniesienia w języku C++. Ta funkcja pokazała, że wydajniej jest przenosić obiekty niż je kopiować.

Funkcja `std::swap(x, y)` przyjmuje przez referencję dwa obiekty `x` i `y`, których wartości zamienia. Przykładowa implementacja:

```
#include <utility>

template <typename T>
void swap(T &a, T &b)
{
    T tmp = std::move(a);
    a = std::move(b);
    b = std::move(tmp);
}
```

Podsumowanie

- Przenoszenie obiektów wprowadzono w C++11.
- Przenoszenie obiektów pozwala na uniknięcie kopiowania.
- Tylko obiekty r-wartości mogą być przenoszone.
- Kompilator może dołączyć domyślne przeciążenia przenoszące.
- Wybór przeciążenia (kopiującego lub przenoszącego) konstruktora czy operatora przypisania zależy od kategorii wartości wyrażenia, które jest argumentem wywołania i także od dostępności przeciążenia.

Dziękuję za uwagę.