Teoretyczne podstawy informatyki

Wykład 5a
Modele Danych – Wprowadzenie

Abstrakcja

Abstrakcja:

Oznacza uproszczenie, zastąpienie skomplikowanych i szczegółowych okoliczności występujących w świecie rzeczywistym zrozumiałym modelem umożliwiającym rozwiązanie naszego problemu.
Oznacza to, że „abstrahujemy” od szczegółów, które nie mają wpływu lub mają minimalny wpływ na rozwiązanie problemu.
Opracowanie odpowiedniego modelu umożliwia zajęcie się istotą problemu.

Modele danych

Modele danych są to abstrakcje wykorzystywane do opisywania problemów

Każdą koncepcje matematyczną można opisać za pomocą modelu danych. W informatyce wyróżniamy zazwyczaj dwa aspekty:

1. Wartości które nasz obiekt może przyjmować. Przykładowo wiele modeli danych zawiera obiekty przechowujące wartości całkowitoliczbowe. Ten aspekt modelu jest statyczny; określa bowiem wyłącznie grupę wartości przyjmowanych przez obiekt.
2. Operacje na danych. Przykładowo stosujemy zazwyczaj operacje dodawania liczb całkowitych. Ten aspekt modelu nazywamy dynamicznym; określa bowiem metody wykorzystywane do operowania wartościami oraz tworzenia nowych wartości.

- Badanie modeli danych, ich właściwości oraz sposobów właściwego ich wykorzystania stanowi jedno z podstawowych zagadnień informatyki.

Modele danych a struktury danych

- ***Modele danych*** **to abstrakcje** wykorzystywane do opisywania problemów.
- ***Struktury danych*** **to reprezentacja danego modelu danych**, którą musimy skonstruować w sytuacji gdy język programowania nie ma wbudowanej tej reprezentacji.
  Konstruujemy strukturę danych za pomocą abstrakcji obsługiwanych przez ten język.

Modele danych języków programowania

Każdy język programowania zawiera własny model danych, który zazwyczaj istotnie różni się od modeli oferowanych przez inne języki.

Podstawowa zasada realizowana przez większość języków programowania w odniesieniu do modeli danych określa, że każdy program ma dostęp do „pudelek", które traktujemy jako obszary pamięci. Każde „pudełko" ma swój typ, np. int lub char. Wartości przechowywane w pudełkach nazywamy często obiektami danych. Możemy teraz nadawać nazwy wykorzystywanym pudełkom. W ogólności nazwa jest dowolnym wyrażeniem wskazującym na pudełko.

Modele danych języków programowania

Podstawowe typy danych w języku programowania C to: liczby całkowite, liczby zmiennoprzecinkowe, znaki, tablice, struktury czy wskaźniki.
Wszystkie te pojęcia to ***statyczne elementy modelu danych.***

Dopuszczalne operacje na tych danych to typowe operacje arytmetyczne na liczbach całkowitych i zmiennoprzecinkowych, operacje dostępu do elementów tablic i struktur oraz deferencje wskaźników czyli znajdywanie obiektów przez nie wskazywanych. Te operacje to ***dynamiczne elementy modelu danych.***

Modele danych języków programowania

Bardzo ważne są też modele danych, które nie są częścią języka programowania, takie jak listy, drzewa, grafy, zbiory.

Np. w języku matematycznym, lista jest ciągiem n elementów, który zapisujemy jako $(a_1,a_2,...,a_n)$. Do zbioru operacji wykonywanych na listach należy wstawianie nowych elementów, usuwanie elementów, łączenie list.

Modele danych a struktury danych

- Lista jest to abstrakcja matematyczna lub model danych
- Lista jednokierunkowa to struktura danych

Lista jednokierunkowa

```
Typedef struct CELL *LIST;
struct CELL{
   int element;
   LIST next;
}
```

W niektórych językach (Lisp, Prolog) nie ma potrzeby stosowania (konstruowania) struktur danych do reprezentowania abstrakcyjnych list.

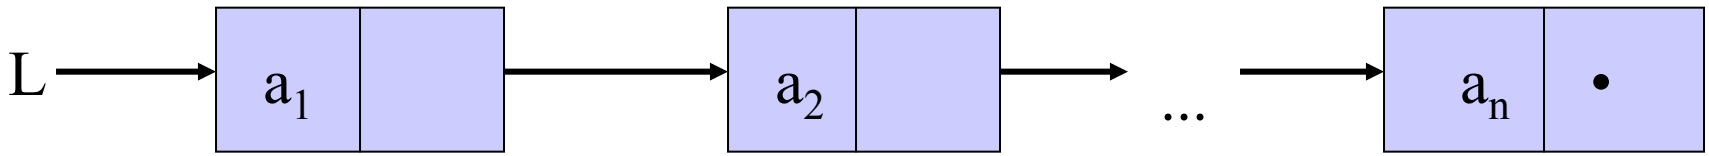

Modele danych w oprogramowaniu systemowym

Modele danych możemy też spotkać w systemach operacyjnych i w aplikacjach. Zadaniem systemu operacyjnego jest zarządzanie i szeregowanie zasobów komputera. Model danych systemów operacyjnych Unix składa się z takich Pojęć jak ***pliki, katalogi*** oraz **procesy.**

- ⇒ Dane jako takie są przechowywane w ***plikach*** (ang. files), które w systemie Unix reprezentowane są przez ciągi znaków.
- ⇒ Pliki są grupowane w ramach ***katalogów*** (ang. directories), będących zbiorami plików i (lub) innych katalogów.
- ⇒ Katalogi i pliki tworzą ***drzewo*** w którym pliki są liśćmi.

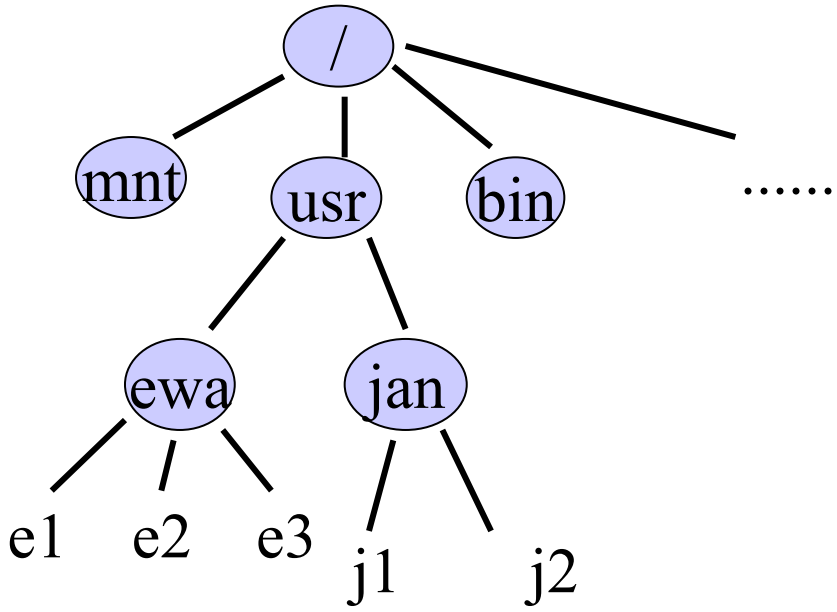

Modele danych w oprogramowaniu systemowym

⇒ ***Procesy*** są pojedynczymi wykonaniami programów.
Procesy pobierają zero lub więcej strumieni wejściowych i produkują zero lub więcej procesów wyjściowych. W systemach Unix procesy mogą składać się z ***potoków*** (ang. pipes), kiedy to wynik jednego procesu może zasilać wejście kolejnego procesu. Efekt takiego połączenia procesów można traktować jako jeden duży proces z własnym wejściem i wyjściem.

⇒ Mówiący kalkulator:

```
bc | word | speak
```

⇒ Istnieje wiele innych aspektów działania systemu operacyjnego, np. sposób zarządzania bezpieczeństwem danych oraz interakcja z użytkownikiem.

➢ *Dość łatwo można zauważyć że model danych systemu operacyjnego różni się od modeli danych języków programowania.*

Model danych w edytorach tekstu

Każdy model danych wbudowany w taki edytor wiąże się z pojęciami ciągów tekstowych oraz operacjami charakterystycznymi dla redagowania tekstu.

Model zawiera więc zazwyczaj pojęcie ***wierszy*** (ang. lines), które podobnie jak większość plików są ciągami znaków. Jednak w przeciwieństwie do plików wiersze mogą się wiązać ze swoimi numerami. Mogą być także grupowane w większe jednostki zwane ***akapitami*****.**

Operacje na wierszach można zazwyczaj stosować dla wszystkich zawartych w nich elementów, nie tylko dla ich początku, jak w przypadku najbardziej powszechnych operacji na plikach.

Typowy edytor wykorzystuje również pojęcie wiersza bieżącego oraz bieżącej pozycji w danym wierszu. Wykonywane przez edytor operacje zawierają rozmaite modyfikacje wierszy, takie jak usuwanie i wstawianie znaków, usuwanie lub tworzenie nowych wierszy, poszukiwanie określonych ciągów znaków, itd.

Modele danych układów komputerowych

Model danych opisujący układy komputerowe, zwany *logiką wnioskowania*, jest najbardziej przydatnym narzędziem w projektowaniu komputerów.

Komputery składają się z komponentów elementarnych zwanych bramkami (ang. gates). Każda bramka ma jedno lub więcej wejść i jedno wyjście; na wejściu i wyjściu dopuszczalne są tylko dwie wartości: 0 lub 1. Bramka wykonuje prostą funkcje – np. koniunkcje (bramka AND). Na pewnym poziomie abstrakcji projektowanie komputera jest procesem, w którym decyduje się o sposobie połączenia bramek tak, by możliwe było efektywne wykonywanie na nim prostych operacji.

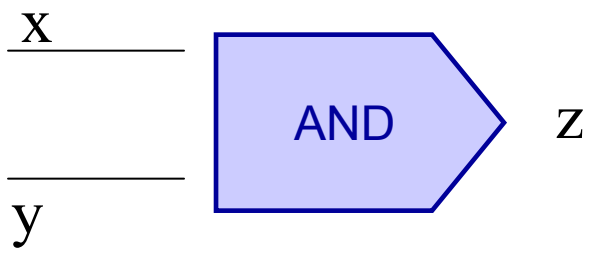

x	y	z
0	0	0
0	1	0
1	0	0
1	1	1

Sumator jednobitowy

Aby wykonać instrukcje przypisania a = b + c w języku C, komputer wykonuje dodawanie za pomocą układu zwanego sumatorem (*ang. adder*). W komputerze wszystkie liczby są zapisywane w notacji binarnej wykorzystującej dwie cyfry,0 i 1. (zwane *cyframi binarnymi* lub *bitami*). Mając kilka bramek możemy zbudować układ zwany *sumatorem jednobitowym* (ang. *one bit adder*). Dwa bity wejściowe, x i y, oraz wejściowy bit przeniesienia, c , są sumowane. Efektem tej operacji jest bit sumy oraz wyjściowy bit przeniesienia (ang. *carry out*) d.

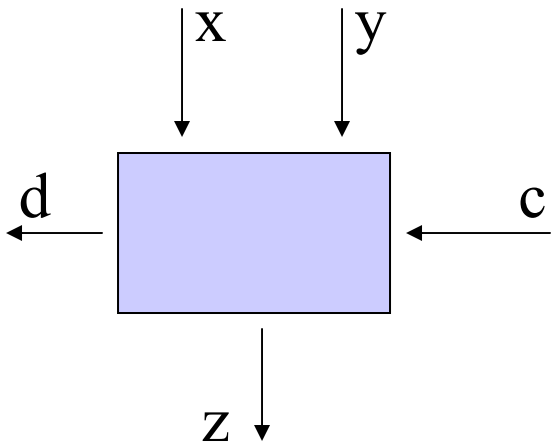

d = bit przeniesienia
z = bit sumy

x	y	z	d	z
0	0	0	0	0
0	0	1	0	1
0	1	0	0	1
0	1	1	1	0
1	0	0	0	1
1	0	1	1	0
1	1	0	1	0
1	1	1	1	1

Tabela prawdy

dz to łącznie dwubitowa liczba binarna wyrażający łączną liczbę danych wejściowych (x,y,c) mających wartość 1

Modele danych języka C

Statyczna część modelu danych w języku C – system typów opisujący wartości, które mogą być przyjmowane przez określone dane.

System typów zawiera typy proste, np. liczby całkowite, oraz zbiór zasad formowania typów, dzięki którym możemy konstruować coraz bardziej skomplikowane typy na bazie typów już znanych.

Typy podstawowe:

1. Znaki (*char, signed char, unsigned char*)
2. Liczby całkowite (*int, short, long int, unsigned*)
3. Liczby zmiennoprzecinkowe (*float, double, long double*)
4. Wyliczenia (*enum*)

Liczby całkowite i zmiennoprzecinkowe traktowane są jako typy arytmetyczne.

Modele danych języka C

Reguły formowania typów wymagają istnienia pewnych typów które mogą być albo typami podstawowymi; albo typami wcześniej skonstruowanymi za pomocą takich reguł.

Typy tablicowe:

Możemy stworzyć tablice, której elementy są typu T: T A[n];
Powyższa instrukcja deklaruje tablice n elementów, każdy typu T.
W języku C indeksy tablic rozpoczynają się od 0, zatem pierwszym elementem jest A[0], ostatnim A[n-1].
Tablice mogą być skonstruowane ze znaków, typów arytmetycznych, wskaźników, struktur, unii lub innych tablic.

Modele danych języka C

Struktury:

Struktura jest grupowaniem zmiennych zwanych *składnikami* (ang. *members*) lub *polami* (ang. *fields*). Różne składniki struktur mogą być różnych typów, jednak każdy musi zawierać elementy jednego określonego typu.

Jeśli T_1, T_2, ...T_n są typami oraz M_1, M_2,...M_n są nazwami składników, to deklaracja

```
struct S {
    T1 M1;
    ....
    Tn Mn;
}
```

definiuje strukturę której wyróżnik (nazwa jej typu) to S, zaś n to liczba jej składników. i-ty składnik nosi nazwę M_i i jest typu T_i.

Wyróżnik struktury S jest opcjonalny, udostępnia jednak wygodny skrót podczas odwoływania się do tego typu w późniejszych deklaracjach.

Modele danych języka C

Unie:

Unia pozwala na przechowywanie zmiennych przyjmujących wartości różnych typów w różnych momentach wykonywania programu.

Deklaracja:

```
union {
    T1 M1;
    T2 M2;
    ....
    Tn Mn;
} x;
```

definiuje zmienną x, która może przechowywać wartość dowolnego typu z grupy $T1_1$, T_2, ..., T_n. Nazwy składników M_1, M_2, ..., M_n pomagają wyróżnić typ aktualnej wartości zmiennej. Oznacza to ze $x.M_i$ wskazuje na wartość zmiennej x traktowanej jako wartość typu T_i.

Modele danych języka C

Wskaźniki:

Język C wyróżnia się znaczeniem jaki mają w nim wskaźniki. Zmienna typu wskaźnikowego zawiera adres obszaru pamięci. Za pomocą wskaźnika możemy uzyskać dostęp do wartości innej zmiennej.
Deklaracja: T•p;
definiuje zmienną p, jako wskaźnik do zmiennej typu T.
Zmienna p nazywa więc pudełko typu wskaźnikowego do T, wartością w pudełku p jest wskaźnik. Tym co „naprawdę" znajduje się w pudełku jest adres (lokacja), pod którym obiekt typu T jest przechowywany w komputerze.

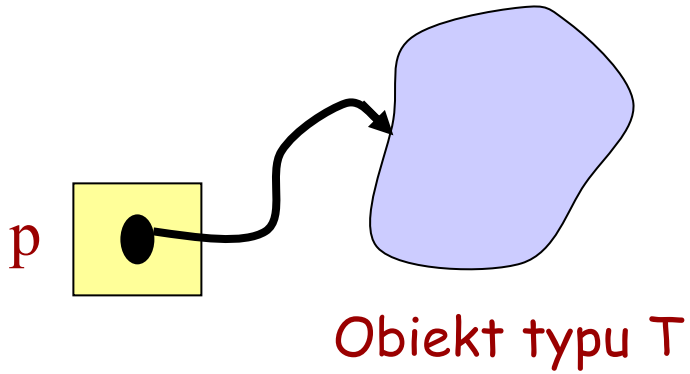

Modele danych języka C

Typedef:

Język C udostępnia instrukcje typedef, która umożliwia tworzenie synonimów dla nazw typów. Deklaracja: typedef int Odległość; pozwala na późniejsze używanie nazwy Odległość zamiast typu int.

Funkcje

Funkcje także posiadają związane ze sobą typy, mimo że nie łączymy z nimi pudełek ani wartości. Dla dowolnej listy typów T1, T2,....,Tn możemy zdefiniować funkcje pobierającą odpowiednio n parametrów tych typów. Taka listę typów poprzedzającą typ wartości zwracanych przez funkcje nazywamy typem funkcji. Jeżeli funkcja nie zwraca żadnej wartości wykorzystujemy typ void.

- W ogólności możemy budować typy dowolnie, stosując reguły ich konstrukcji, istnieje jednak kilka ograniczeń. Przykładowo nie możemy konstruować tablicy funkcji mimo że możemy zbudować tablice wskaźników do funkcji.

Operacje w modelu danych języka C

Operacje na danych przewidywane w modelu języka C możemy podzielić na trzy kategorie:

1. operacje tworzące i usuwające obiekt danych
2. operacje dostępu i modyfikacji części obiektu danych
3. operacje łączące części obiektu danych w celu sformowania nowej wartości obiektu danych.

Operacje w modelu danych języka C

Tworzenie i usuwanie obiektu danych

Język C udostępnia wiele elementarnych mechanizmów przeznaczonych do tworzenia danych.

W momencie wywołania funkcji tworzone są pudełka dla wszystkich jej lokalnych argumentów (parametrów). Pozwala to na przechowywanie wartości tych parametrów.

Innym mechanizmem jest procedura biblioteczna *malloc(n),* która zwraca wskaźnik do n kolejnych pozycji znaków w niewykorzystanej pamięci. Obiekty danych mogą być wówczas utworzone właśnie w tych obszarach pamięci.

Metody usuwania obiektów danych są analogiczne. Procedura biblioteczna *free* zwalnia pamięć zarezerwowaną przez *malloc*.

Operacje w modelu danych języka C

Dostęp do danych i ich modyfikacja

Język C zawiera mechanizm umożliwiający dostęp do komponentów składających się na obiekty. Wykorzystujemy zapis a[i] do uzyskania dostępu do i-tego elementu tablicy a, zapis x.m do uzyskania dostępu do składnika m struktury o nazwie x oraz zapis *p do uzyskania dostępu do obiektu wskazanego przez wskaźnik p.

Modyfikowanie (przypisywanie) wartości w języku C realizujemy za pomocą operatorów przypisania, które umożliwiają zmianę wartości obiektu

a[0].(*pole2[3]) = 99;

Łączenie danych

Język C zawiera bogaty zbiór operatorów umożliwiających manipulowanie danymi i łączenie ich wartości. Oto podstawowe operatory:

1. **Operatory arytmetyczne**:
   dwuargumentowe +, -, •, /
   jednoargumentowe +,-
   modulo %
   zwiększania i zmniejszania o jednostkę ++, --
2. **Operatory logiczne**:
   Język C nie zawiera typu Boolean, wykorzystuje 0 do reprezentowania wartości logicznej fałszu oraz liczby różnej od zera do reprezentowania prawdy.
   Język C udostępnia: koniunkcje && (dwuargumentowy)
   alternatywę || (dwuargumentowy)
   negacje ! (jednoargumentowy)
   operator warunkowy x ? y : z

Łączenie danych

1. **Operatory porównania:** (==, !=, <, >, ≤, ≥)
   Dla liczb całkowitych i zmiennoprzecinkowych. Wynikiem jest prawda lub fałsz.
2. **Operatory działań na poziomie bitowym**
3. **Operatory przypisania**
4. **Operatory koercji**
   (przekształcenie wartości jednego typu na odpowiadającą jej wartość innego typu).

- **Często uzupełnia się podstawowe typy przez identyfikatory zdefiniowane w pliku nagłówkowym stdio.h : NULL, TRUE, FALSE, BOOLEAN, EOF.**

Bazy danych

W wielu zastosowaniach komputerów same struktury danych nie wystarczają. Nie zawsze jest to bowiem tylko kwestia rozważenia zadania algorytmicznego i zdefiniowania dobrych i użytecznych do jego rozwiązania struktur danych. Czasem potrzeba bardzo obszernych zasobów danych, stanowiących dla wielu algorytmów potencjalne dane wejściowe, a wiec mające ustalona strukturę i nadające się do odszukiwania i manipulowania nimi.

Przykładami takich danych mogą być finansowe i osobowe dane przedsiębiorstwa, rezerwacje miejsc i informacje o lotach towarzystwa lotniczego, dane katalogowe biblioteki, itd.....

Bazy danych

Bazy danych są zazwyczaj bardzo obszerne i zawierają wiele różnych rodzajów danych, począwszy od nazwisk i adresów po specjalne kody i symbole, a czasami nawet zwykły tekst. Zgromadzone dane są zazwyczaj przedmiotem licznych rodzajów operacji wstawiania, usuwania i wyszukiwania, wykorzystywanych w różnych celach przez różnych ludzi.

O ile dodanie nowej informacji do bazy danych lub usuniecie już istniejącej są zadaniami stosunkowo łatwymi, o tyle ***zapytanie*** bazy danych z zamiarem wydobycia z niej informacji zazwyczaj jest dużo bardziej skomplikowane.

Bazy danych

Ogromne znaczenie ma dobra organizacja bazy danych. Tak jak w przypadku struktur danych, dobry projekt bazy danych – to projekt przejrzysty, łatwy do zapisania, najważniejsza zaleta to duża sprawność działania i wykonalność opartego na tym projekcie systemu zarządzania bazą danych który potrafi odpowiedzieć na zapytania w krótkim czasie.

Stosuje się różne modele organizacji baz danych. Modele, zaprojektowane do obsługi dużych ilości danych, jednocześnie wiernie i sprawnie wychwytują związki zachodzące miedzy obiektami danych. Istnieje wiele metod i języków manipulacji danymi i zapytań baz danych.

Bazy danych

Jeden z najpopularniejszych, ***model relacyjny***, zaspokaja potrzeby związane z układami danych w postaci ogromnych tabel, przypominających tablicowe struktury danych. Inny model, ***model hierarchiczny***, wymaga pewnych rodzajów układów drzewiastych albo sieciowych. Ten model organizuje dane w drzewiastej formie o wielu poziomach.

Na niektóre rodzaje danych lepiej patrzeć jak na fragmenty ***wiedzy*** niż tylko jako na liczby, nazwiska czy kody.

Oprócz dużej bazy danych opisującej inwentarz przedsiębiorstwa produkcyjnego moglibyśmy chcieć mieć dużą bazę informacji dotyczących prowadzenia tego przedsiębiorstwa. Tego rodzaju fragmenty wiedzy wymagają organizacji bardziej złożonej niż obiekty danych o mniej więcej ustalonym formacie, zwłaszcza wówczas gdy zależy nam na sprawnym wyszukiwaniu.

Bazy wiedzy

Bazy wiedzy stają się następnym naturalnym stopniem po ***bazach danych*** i są bogatym źródłem ciekawych pytań związanych z reprezentowaniem, organizacją i wyszukiwaniem algorytmicznym.

Problem ***reprezentacji wiedzy*** jest faktycznie jednym z podstawowych zagadnień ***sztucznej inteligencji***. Trudność wynika z tego, że wiedza składa się nie tylko z wielkiego zbioru faktów, ale także wielu zawiłych związków miedzy nimi. Te związki implikują inne, wyższego poziomu związki z innymi elementami wiedzy.

Bazy wiedzy

Zaproponowano wiele ***modeli wiedzy*** które można by wykorzystać w inteligentnych programach. Niektóre opierają się na pojęciach czysto informatycznych, takich jak relacyjne czy hierarchiczne bazy danych. Inne na logicznych formalizmach takich jak rachunek predykatów czy logika modalna.

Pewne języki programowania, jak Lisp czy Prolog, łatwiej nadają się do manipulowania wiedzą niż inne. Np. Prolog wydaje się trafnie dobrany jeżeli chodzi o fragmenty wiedzy dotyczące prostych relacji.

Wymagane związki stają się coraz bardziej zagmatwane gdy wyjdziemy poza małą dobrze określoną dziedzinę dyskusji. Sięganie do wiedzy wiążącej się z pewna decyzją, którą program musi podjąć, staje się ogromnym zadaniem.

Bazy wiedzy

„Efektywny" model algorytmicznej reprezentacji wiedzy wciąż czeka na odkrycie...