Regularni izrazi - dva primjera

Objektno programiranje - 5. vježbe

dr. sc. Sebastijan Horvat

Prirodoslovno-matematički fakultet,
Sveučilište u Zagrebu

3. travnja 2024. godine

Prvi primjer: Popis najpopularnijih filmova

- popis se nalazi na stranici: www.imdb.com/chart/moviemeter
- spremiti stranicu kao `filmovi.html` datoteku (u istu mapu s `.cpp` datotekom koja će sadržavati kod koji ćemo napisati)

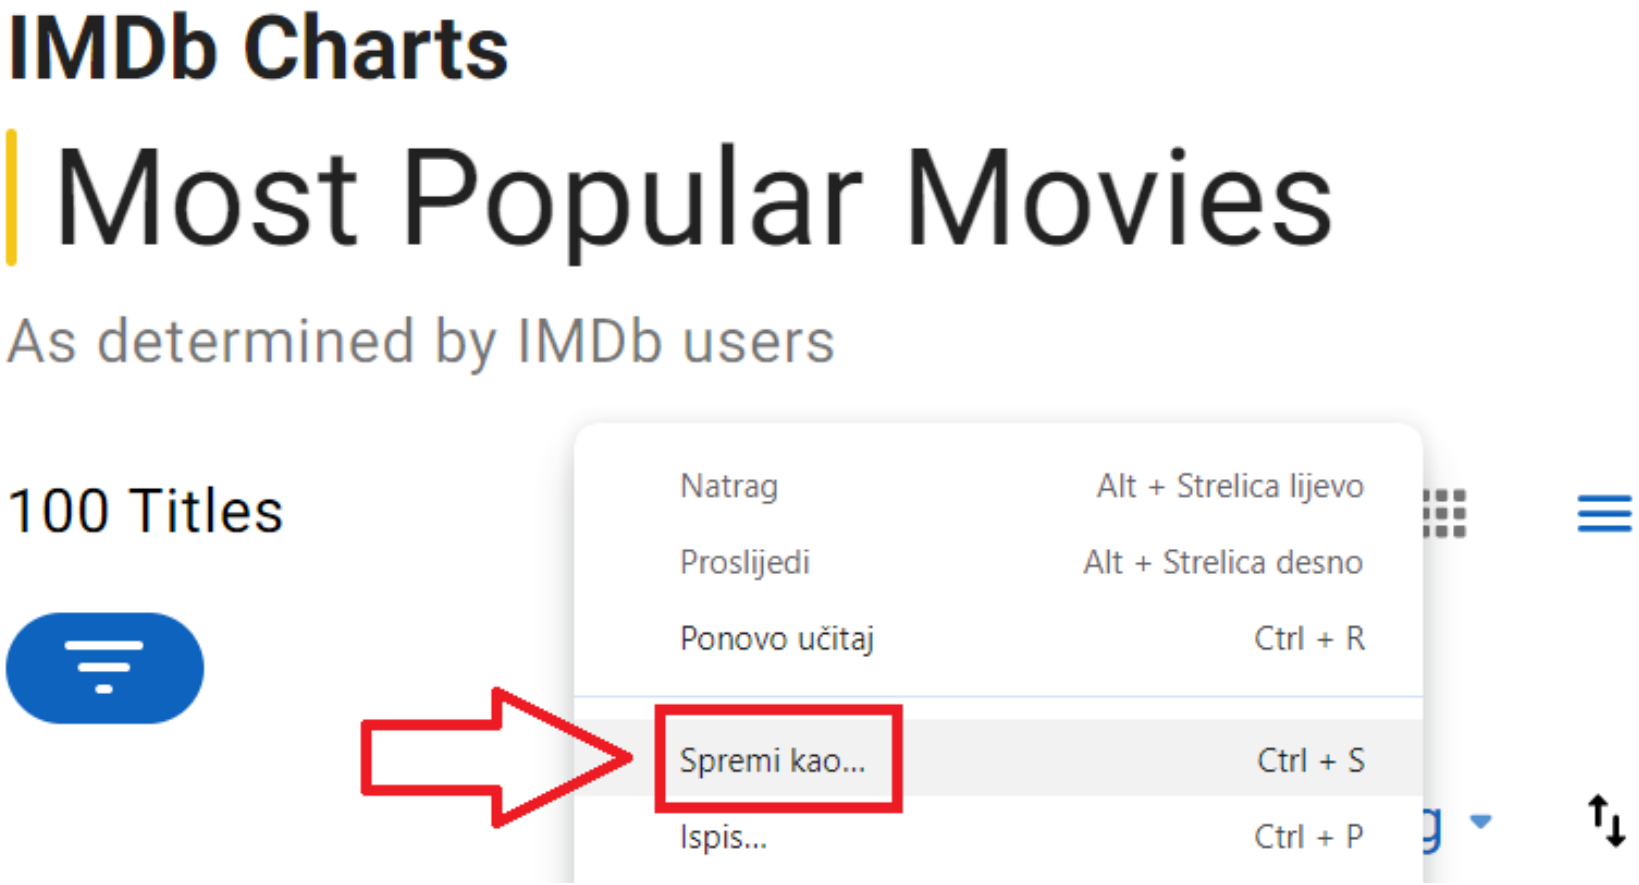

Gdje se nalaze imena filmova s popisa?

- u datoteci `filmovi.html` (ako ju otvorimo s nekim uređivačem teksta), možemo pronaći da se svaki naziv filma s popisa nalazi ovako:

`"titleText":{"text":"` NAZIV FILMA `"`

- primjerice, u datoteci[1] imamo:

```
... "titleText":{"text":"Kung Fu Panda 4", ...
```

[1] Za stranicu preuzetu na dan 2. travnja 2024. godine.

Učitavanje sadržaja datoteke `filmovi.html` u string

```
#include <iostream>
#include <fstream>
#include <string>

using namespace std;

int main() {
    ifstream dat("filmovi.html");
    string ulaz, linija;
    while(getline(dat,linija))
        ulaz += linija + '\n';
    dat.close();

    // ...tu ide kod sa sljedećih slajdova...

    return 0;
}
```

Regularni izrazi

- grubo govoreći, to je način opisa niza znakova koji nas zanima
- korisimo klasu **regex** - treba nam **`regex`** zaglavlje:

```
#include<regex>
```

- regularni izraz koji tražimo spremit ćemo u string kojim zatim inicijaliziramo **`regex`** objekt:

```
string obrazac =
  "\"titleText\":\\{\"text\":\"([^\"]*)\"";
regex regIzraz(obrazac);
```

- po *defaultu*, za regularne izraze koristi se **ECMAScript** jezik[2]

[2] ECMA = *European Computer Manufacturers Association*

Ukratko o prethodnom regularnom izrazu

- želimo prepoznati:

  `"titleText":{"text":"` NAZIV FILMA `"`

- no, ne možemo napisati ovako:

  `"titleText":{"text":"`NAZIV FILMA`"`

- kao prvo, zagrada { ima drugu ulogu, pa za prepoznavanje znaka { moramo ispred dodati \
- zatim, ne želimo doslovno prepoznati tekst NAZIV FILMA, nego bilo što nakon čega slijedi znak "
- za bilo koji znak osim " koristimo `[^"]` - ako želimo proizvoljan broj takvih znakova (možda i niti jedan takav), koristimo `*`
- dobili smo: `"titleText":\{"text":"([^"]*)"`
- kako bi u C++ stringu koristili znakove \i " moramo ispred njih dodati (još jedan) znak \
- time konačno dobivamo:

```
\"titleText\":\\{\"text\":\"([^\"]*)\"
```

`regex_search` za traženje podudaranja

- **`regex_search`** vraća podataka tipa `bool` - je li regularni izraz prepoznao neki podniz u danom stringu (za podudaranje s cijelim stringom se na isti način koristi `regex_match`)
- dajemo i jedan objekt tipa **`smatch`** - sadrži detalje o (**prvom!**) podudaranju (duljinu, poziciju, prefiks i sufiks, tj. sve prije i poslije podudaranja u stringu itd.)
- **`str`** metoda objekta vraća podudaranje kao string

```
smatch rezultat;
if(regex_search(ulaz, rezultat, regIzraz))
  cout << rezultat.str() << endl;
```

- ovdje u stringu `ulaz` tražimo podudaranje s `regIzraz` i, ako ga pronađemo, ispišemo ga (kao string)
- primjer ispisa:

```
"titleText":{"text":"Road House"
```

Opcije za `regex` objekt

- ako u stringu `obrazac` umjesto `title` stavimo `Title`, neće doći do ispisa
- ako želimo ignorirati razliku velikih i malih slova, možemo iskoristiti zastavicu (*flag*) **`regex::icase`**
- uz sljedeću promjenu ponovo dobivamo ispis:

```
regex regIzraz(obrazac, regex::icase);
```

Što ako u regularnom izrazu napravimo grešku?

- C++ kompajler neće provjeriti sintaksu regularnog izraza
- ukoliko imamo sintaksnu grešku u izrazu, pri pokretanju će se baciti iznimka tipa **`regex_error`** (pomoću `what` metode, kao i kod ostalih iznimaka, dobivamo opis nastale greške)

- primjer - iz našeg izraza uklonimo znak ')':

```
"\"TitleText\":\\{\"text\":\"([^\"]*\""
```

(nastavak primjera je na idućem slajdu...)

Nastavak primjera s prethodnog slajda

- sljedeći kod daje ispis `Parenthesis is not closed.`

```
try {
  regex regIzraz(obrazac, regex::icase);
  smatch rezultat;
  if (regex_search(ulaz,rezultat,regIzraz))
    cout << rezultat.str() << endl;
} catch (regex_error e) {
  cout << e.what() << endl;
}
```

VAŽNO: Kako bi daljnji kod ispravno radio, potrebno je vratiti znak zagrade ’)’ koji smo maloprije uklonili iz našeg regularnog izraza!

Kako pronaći sva podudaranja za naš regularni izraz?

- pomoću trenutnog koda možemo naći samo prvo podudaranje
- sva podudaranja nalazimo pomoću **`sregex_iterator`** adaptera za iterator
  - za dani tekst i izraz, nalazi prvo podudaranje
  - dereferenciranjem dobivamo odgovarajući `smatch` objekt
  - inkrementiranjem pronalazimo iduće podudaranje
  - „prazan” iterator (`end_it` u sljedećem primjeru) ponaša se kao „jedan-iza-zadnjeg” iterator

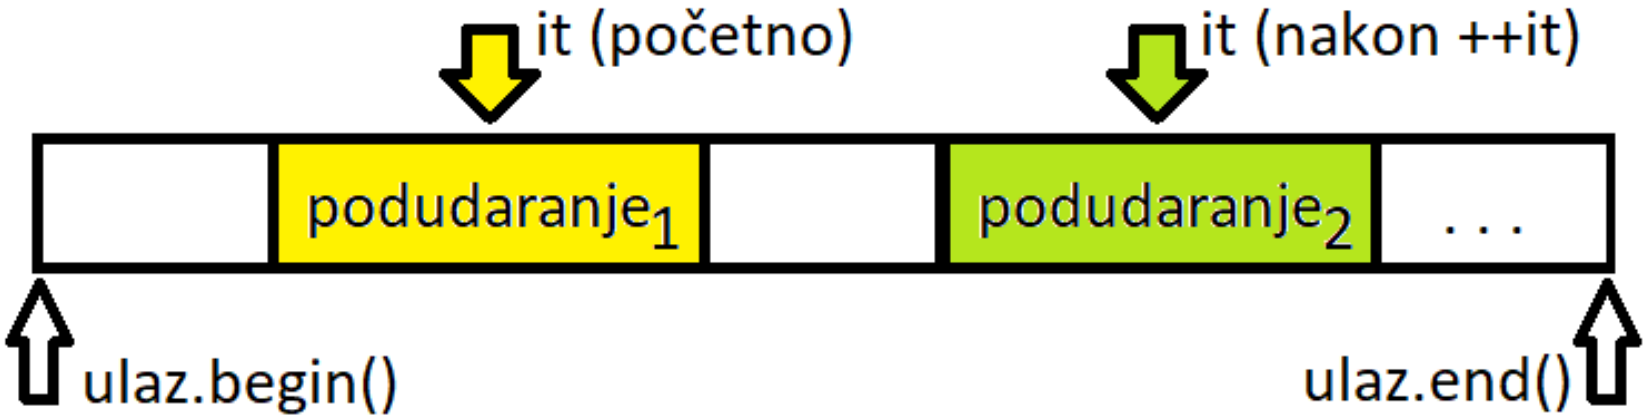

Ilustracija za `sregex_iterator`

```
it(ulaz.begin(),ulaz.end(),regIzraz);
```

Pronalaz svih podudaranja u našem primjeru

- u našem primjeru zamijenimo if(...) ... - dio koji smo imali sa sljedećim kodom:

```
sregex_iterator end_it;
for(sregex_iterator it(ulaz.begin(),
  ulaz.end(),regIzraz); it != end_it; ++it)
     cout << it->str() << endl;
```

Primjer ispisa dobiven prethodnim kodom

```
"titleText":{"text":"Road House"
"titleText":{"text":"Dina: Drugi dio"
"titleText":{"text":"Uboga stvorenja"
"titleText":{"text":"Damsel"
"titleText":{"text":"Dina"
"titleText":{"text":"Ghostbusters: Frozen Empire"
"titleText":{"text":"Alien: Romulus"
"titleText":{"text":"Beetlejuice Beetlejuice"
"titleText":{"text":"Oppenheimer"
"titleText":{"text":"Madame Web"
```

- želimo „izvaditi” iz tih podudaranja samo nazive filmova, tj. sljedeće dijelove između dvostrukih navodnika: `Road House`, `Dina: Drugi dio`, `Uboga stvorenja`, `Damsel` itd.

Upotreba podizraza (*subexpressions*)

- podizrazi predstavljaju dijelove regularnog izraza u zagradama ()
- u našem regularnom izrazu:

  `"\"TitleText\":\\{\"text\":\"([^\"]*)\""`

  imamo sljedeći podizraz:

  `[^\"]*`

- ukoliko je bilo podudaranja, dobiveni `smatch` objekt daje pristup i svakom podizrazu za to podudaranje - to dobivamo pomoću `str` i nekog od brojeva 1, 2, 3, ... za prvi, drugi, treći, ... podizraz (`str(0)` je isto kao `str()`)
- podizraz koji odgovara nazivu filma koji tražimo je prvi po redu pa koristimo `str(1)`

Konačno rješenje

- također smo dodali ispis rednog broja filma i malo poravnanja (pa trebamo #include <iomanip>):

```
int br = 0;
for(...  kao prije ...)
    cout << setw(3) << ++br << ".  "
         << it->str(1) << endl;
```

Dobiven ispis

```
  1. Road House
  2. Dina: Drugi dio
  3. Uboga stvorenja
  4. Damsel
  5. Dina
  6. Ghostbusters: Frozen Empire
  7. Alien: Romulus
  8. Beetlejuice Beetlejuice
  9. Oppenheimer
 10. Madame Web
...
100. Kungfu panda
```

Drugi primjer: Datumi u vremenskoj prognozi

- otići na www.yr.no/en
- pronaći prognozu za odabrani grad (primjerice, Zagreb) i spremiti tu stranicu kao `prognoza.html` (odabrati spremanje potpune web-stranice)

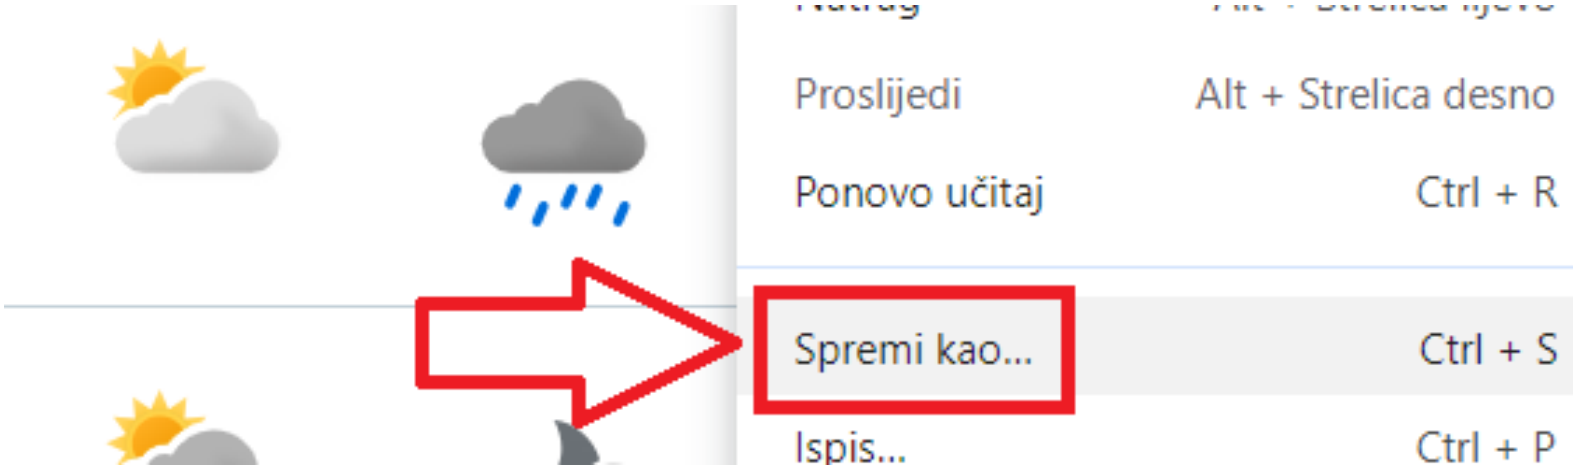

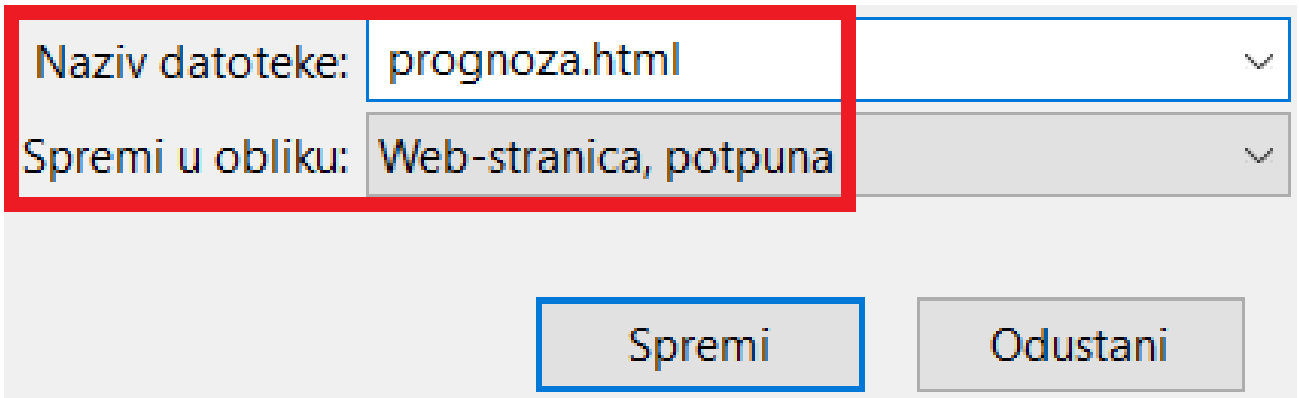

Što želimo napraviti?

- želimo datume poput `Today 1 Apr.` zamijeniti datumima poput `01.04.2024.`
- primjer - iz sljedećeg:

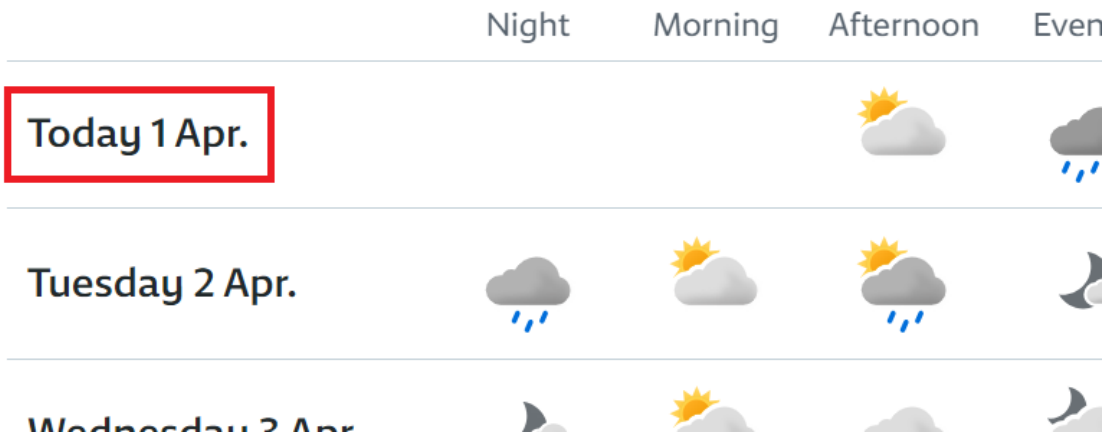

želimo dobiti:

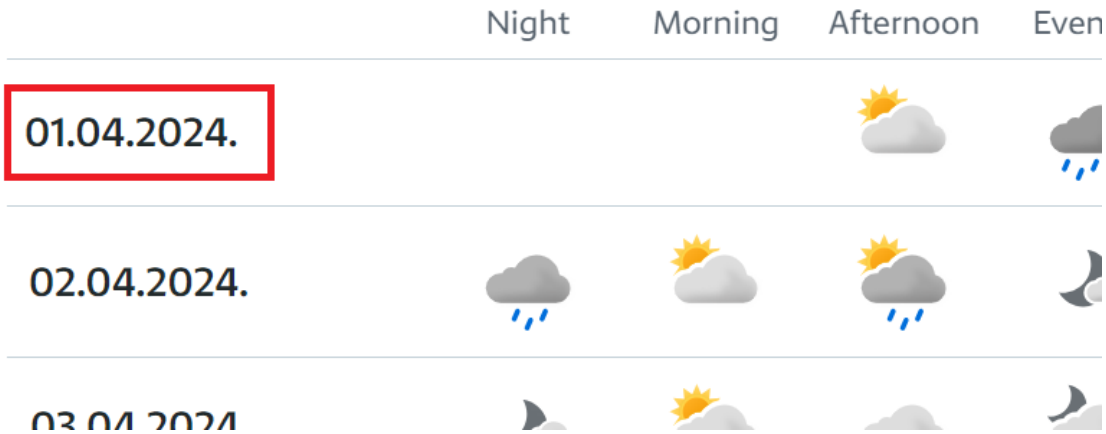

Gdje se nalaze datumi koji nas zanimaju?

- pregledom datoteke `prognoza.html` možemo uočiti da datumima na web-stranici poput `Today 1 Apr.`

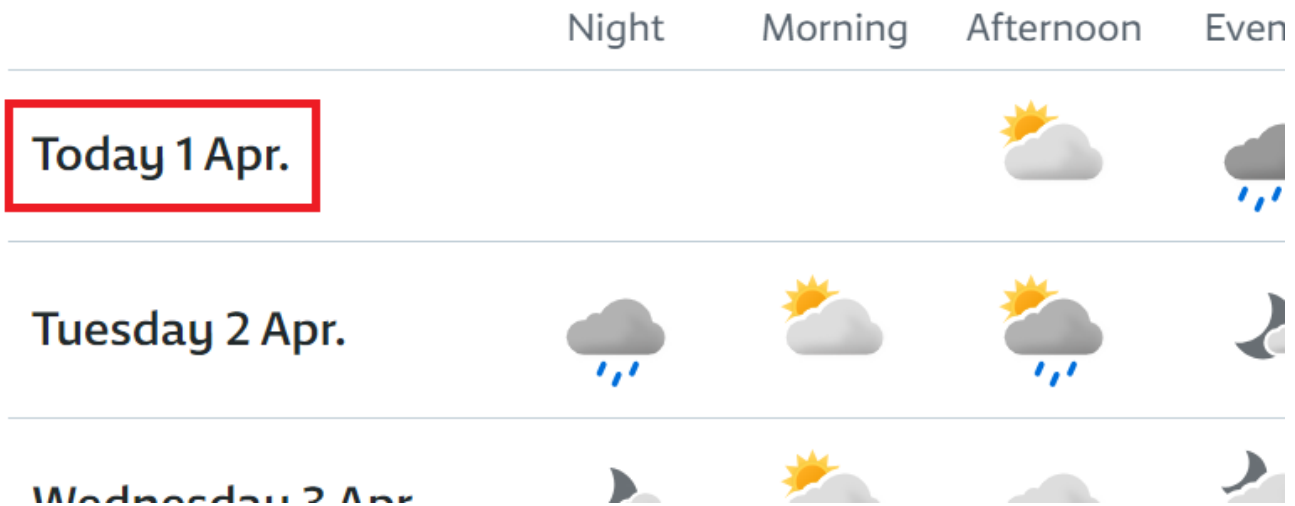

odgovaraju dijelovi u `.html` datoteci poput

```
<time datetime="2024-04-01">Today 1 Apr.</time>
```

- plan: napraviti novu datoteku u kojoj je tekst kao u datoteci `prognoza.html`, ali tako da je tekst unutar tzv. `time` *taga* (oznake) **zamijenjen** datumom koji je dobiven iz vrijednosti atributa `datetime`

Prvi dio koda

- iz datoteke `prognoza.html` prebacivat ćemo sadržaj u (novu) datoteku `prognoza-hr.html` (uz poneku zamjenu)

```
#include <iostream>
#include <fstream>
#include <string>
#include <regex>

using namespace std;

int main() {
    ifstream ulaz("prognoza.html");
    ofstream izlaz("prognoza-hr.html");

    // ...  nastavak na sljedećim slajdovima ...

    ulaz.close();
    izlaz.close();
    return 0;
}
```

Kako izgleda naš regularni izraz?

```
<time datetime="2024-04-01">Today 1 Apr.</time>
```

- regularni izraz koji ćemo koristiti:

  (<time datetime="(\d{4})-(\d{2})-(\d{2})">)([^<]*)(</time>)

- string (dodani su potrebni znakovi '\') kojim ćemo ga zapisati u kodu (kako bi stao na ekran, razlomljen je u dva dijela):

```
"(<time datetime=\"(\\d{4})"
"-(\\d{2})-(\\d{2})\">)([^<]*)(</time>)"
```

regex_replace

- kao i `regex_search` prima ulazni niz znakova i regularni izraz (`regex` objekt)
- navodimo i `string` koji predstavlja izraz kojim želimo zamijeniti **svako** pronađeno podudaranje
- u tom „zamjenskom” izrazu možemo navesti i podizraze iz pronađenog podudaranja - na određeni podizraz referiramo se navođenjem broja (nakon simbola $) koji predstavlja njegov redni broj u podudaranju
- u našem slučaju tražni „zamjenski” izraz je sljedeći:

```
$1$4.$3.$2.$6
```

- objašnjenje se nalazi na sljedećem slajdu...

Objašnjenje za izraz s prethodnog slajda

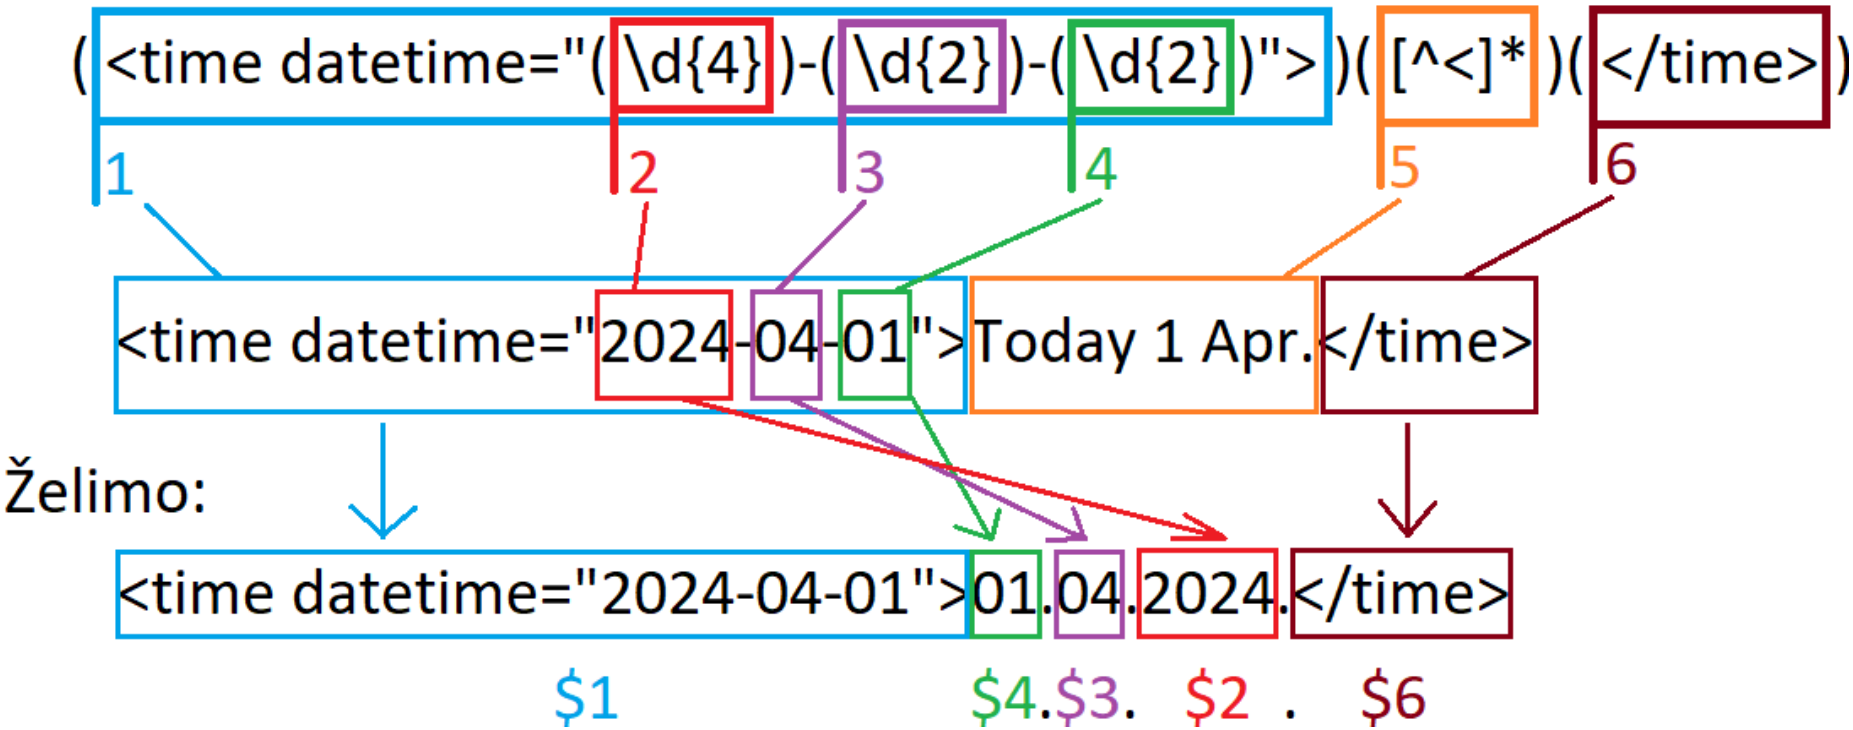

Drugi dio koda

```
string obrazac = "(<time datetime=\"(\\d{4})"
    "-(\\d{2})-(\\d{2})\">)([^<]*)(</time>)";
regex regIzraz(obrazac);
string format = "$1$4.$3.$2.$6";

string linija;
while(getline(ulaz,linija)) {
    izlaz << regex_replace(linija,regIzraz,format)
        << "\n";
}
```

Testiranje napisanog koda

- nakon kompiliranja i pokretanja našeg programa, pronaći u istoj mapi upravo stvorenu datoteku **`prognoza-hr.html`** (ta datoteka mora biti u istoj mapi kao i datoteka `prognoza.html` s obzirom da smo s njom, zbog odabira spremanja potpune web-stranice, preuzeli još i hrpu datoteka koje utječu na izgled pri otvaranju te datoteke s nekim web-preglednikom poput *Chromea*, *Firefoxa* i sl.)
- primjer (otvoreno pomoću programa *Chrome*):

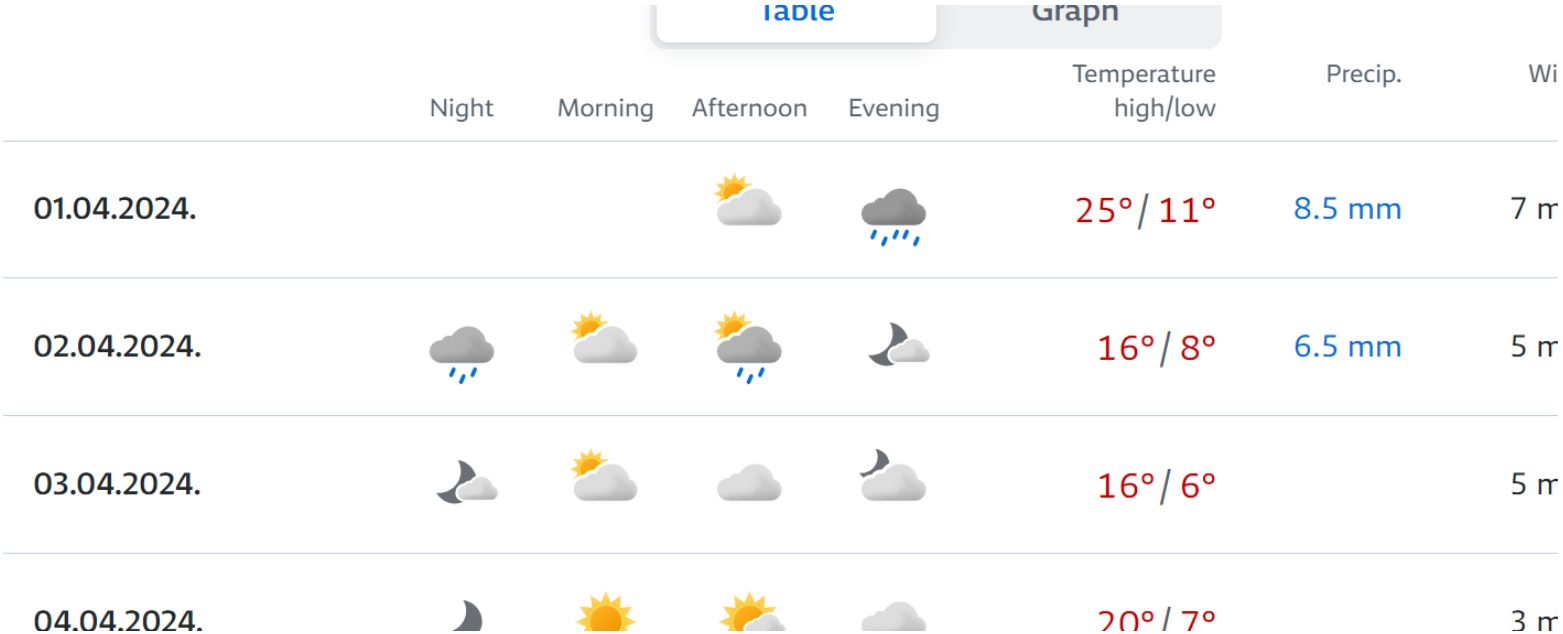

Preusmjeravanje `clog`-a

- u prethodni kod bismo mogli dodati poruke o tome što pokrenuti program trenutno radi, poput:

```
clog << "Otvaranje datoteke \"prognoza.html\"..."
     << endl;
```

- tako dobivamo ispis na ekran:

```
...$ ./prog
Otvaranje datoteke "prognoza.html"...
Otvaranje datoteke "prognoza-hr.html"...
Zamjena datuma iz datoteke...
Zatvaranje datoteka...
Kraj programa.
```

Upotreba `rdbuf`

- `rdbuf` metoda *streama* bez argumenata vraća pokazivač na *stream buffer* objekt povezan s tim *streamom*
- `rdbuf` metoda s jednim argumentom čisti *error* zastavice tog *streama* i postavlja njegov *stream buffer* na onaj na koji pokazuje dani argument
- možemo u kodu otvoriti neku datoteku (npr. "`log.txt`"), spremiti pokazivač na *buffer* koji `clog` ima, zatim postaviti da `clog` upisuje u tu otvorenu datoteku, a onda na kraju `clog`-u vratiti *buffer* koji je imao na početku (i naravno zatvoriti datoteku koju smo otvorili) $\rightarrow$ kod je na sljedećem slajdu...

Promjene u `prognoza.cpp` (unutar `main` funkcije)

```
ofstream novilog("log.txt");
streambuf *backup = clog.rdbuf();
clog.rdbuf(novilog.rdbuf());

clog << "Otvaranje datoteke \"prognoza.html\"..."
     << endl;  // ispis u datoteku log.txt

...

clog.rdbuf(backup);
novilog.close();

return 0;
```