

Zapis teksta, zvuka i videa

Danijela Simić

2024 | Matematički fakultet, Univerzitet u Beogradu


Uvod u digitalni zapis podataka

- Današnji računari su **digitalni**. To znači da su svi podaci koji su u njima zapisani – zapisani kao nizovi brojeva.
- Gubitak dela polaznih informacija.
- Većina podataka koje računari koriste nastaje zapisivanjem *prirodnih signala*.
- **Kontinualna priroda signala** – prirodno se mogu predstaviti *neprekidnim funkcijama*.
- Primer: Zvučni signal predstavlja promenu pritiska vazduha u zadatoj tački i to kao neprekidnu funkciju vremena.

Analogni zapis

- Analogni zapis uspostavlja **analogiju** između **signala** koji je zapisan i određenog **svojstva medijuma** na kome je signal zapisan.
- **Prednost:** jednostavno
- **Mane:**
 - nizak kvalitet,
 - teško je napraviti veran zapis,
 - nestalnost medijuma,
 - komplikovana obrada...

Digitalni zapis



- Vrednost signala se izmeri u **određenim vremenskim trenucima** i onda se na medijumu zapišu izmerene vrednosti.
- **Semplovi** – niz brojeva kojim je signal zapisan.
- Koliko često je potrebno vršiti merenje?
- **Najkvist-Šenonova teorema:** *signal je dovoljno meriti dva puta češće od najviše frekvencije koja se u njemu javlja.*
- Na primer: čovekovo uho čuje frekvenciju 20kHz, pa je dovoljno meriti frekvencijom 40kHz.

Prednosti:

- Kvalitet reprodukcije digitalnog zapisa ne zavisi od toga kakav je kvalitet medija na kome su podaci zapisani;
- Kvarljivost medijuma tokom vremena postaje nebitna;
- Omogućava kreiranje apsolutno identičnih kopija što dalje omogućava prenos podataka na daljinu;
- Obrada digitalno zapisanih podataka se svodi na matematičku manipulaciju brojevima i ne zahteva korišćenje specijalizovanih mašina.

Problemi:

- **Neophodno imati veoma razvijenu tehnologiju** da bi se uopšte stiglo do iole upotrebljivog zapisa.
- Na primer, izuzetno je komplikovano napraviti uređaj koji je u stanju da 40 hiljada puta u sekundi izvrši merenje intenziteta zvuka. A onda negde treba čuvati tih 40 hiljada brojeva.
- Zato je digitalni zapis dosta kasnio.

Zapis teksta u računarima

- **Tekst:** „informaciju namenjenu ljudskom sporazumevanju koja može biti prikazana u dvodimenzionalnom obliku.”
- U računarima se tekst predstavlja kao **jednodimenzioni (linearni)** niz karaktera koji pripadaju određenom unapred fiksiranom skupu karaktera.
- U zapisu teksta, koriste se specijalni karakteri koji označavaju prelazak u novi red, tabulator, kraj teksta i slično.
- Osnovna ideja koja omogućava zapis teksta u računarima je da se svakom karakteru pridruži određen (neoznačeni) ceo broj i to na unapred dogovoreni način.
- Ovi brojevi se nazivaju **kodovima karaktera**.

Zapis teksta u računar

- Tehnička ograničenja ranih računara kao i neravnomeran razvoj računarstva između različitih zemalja, doveli su do toga da postoji više različitih standardnih tabela.
- U zavisnosti od broja bitova potrebnih za kodiranje karaktera, razlikuju se 7-bitni kodovi, 8-bitni kodovi, 16-bitni kodovi, 32-bitni kodovi, kao i kodiranja promenljive dužine.
- Tabele koje sadrže karaktere i njima pridružene kodove obično se nazivaju **kodne strane**.

Zapis teksta u računar

- Tehnička ograničenja ranih računara kao i neravnomeran razvoj računarstva između različitih zemalja, doveli su do toga da postoji više različitih standardnih tabela.
- U zavisnosti od broja bitova potrebnih za kodiranje karaktera, razlikuju se 7-bitni kodovi, 8-bitni kodovi, 16-bitni kodovi, 32-bitni kodovi, kao i kodiranja promenljive dužine.
- Tabele koje sadrže karaktere i njima pridružene kodove obično se nazivaju **kodne strane**.

Zapis teksta u računar

- Postoji veoma jasna razlika između karaktera i njihove grafičke reprezentacije.
- **Glifovi** – Grafičke reprezentacije pojedinih karaktera
- **Skupovi glifova** – Fontovi
- Korespondencija između karaktera i glifova ne mora biti jednoznačna.
- Fontovi koji se obično instaliraju uz operativni sistem sadrže glifove za karaktere koji su popisani na takozvanoj **WGL4 listi (Windows Glyph List 4)** koja sadrži uglavnom karaktere korišćene u evropskim jezicima, dok je za ispravan prikaz, na primer, kineskih karaktera, potrebno instalirati dodatne fontove.

ASCII

- Mala slova engleskog alfabeta: a, b, ... , z
- Velika slova engleskog alfabeta: A, B, ... , Z
- Cifre 0, 1, ..., 9
- interpunkcijske znake: , . : ; + * - _ () [] { } . . .
- Specijalne znake: kraj reda, tabulator, . . .

ASCII

	0	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F
0	NUL	STX	SOT	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2		!	"	#	\$	%	&	'	(	)	*	+	,	-	.	/
3	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5	P	Q	R	S	T	U	V	W	X	Y	Z	[	\	]	^	_
6	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7	p	q	r	s	t	u	v	w	x	y	z	{		}	~	DEL

- 7 bita
- Prva 32 karaktera – od $(00)_{16}$ do $(1F)_{16}$ – su specijalni kontrolni karakteri.
- Ukupno 95 karaktera ima pridružene grafičke likove.
- Kodovi velikih i malih slova se razlikuju u samo jednom bitu u binarnoj reprezentaciji.

- Cifre 0–9 predstavljene su kodovima $(30)_{16}$ do $(39)_{16}$, tako da se njihov ASCII zapis jednostavno dobija dodavanjem prefiksa 011 na njihov binarni zapis.
- Slova su poređana u kolacionu sekvencu, u skladu sa engleskim alfabetom.

YUSCII	ASCII	kôd	YUSCII	ASCII	kôd
Ž	@	$(40)_{16}$	ž	'	$(60)_{16}$
Š	[	$(5B)_{16}$	š	{	$(7B)_{16}$
Đ	\	$(5C)_{16}$	đ		$(7C)_{16}$
Ć	]	$(5D)_{16}$	ć	}	$(7D)_{16}$
Č	^	$(5E)_{16}$	č	~	$(7E)_{16}$

8 bitna proširenja ASCII tabele

ISO-8859-1	Latin 1	većina zapadnoevropskih jezika
ISO-8859-2	Latin 2	centralno i istočnoevropski jezici
ISO-8859-3	Latin 3	južnoevropski jezici
ISO-8859-4	Latin 4	severnoevropski jezici
ISO-8859-5	Latin/Cyrillic	ćirilica većine slovenskih jezika
ISO-8859-6	Latin/Arabic	najčešće korišćeni arapski
ISO-8859-7	Latin/Greek	moderni grčki alfabet
ISO-8859-8	Latin/Hebrew	moderni hebrejski alfabet

Windows-1250	centralnoevropski i istočnoevropski jezici
Windows-1251	ćirilica većine slovenskih jezika
Windows-1252	(često se neispravno naziva i ANSI) zapadnoevropski jezici

Problemi sa 8-bitnim kodnim stranama

- Nije moguće u istom tekstu koristiti i ćirilicu i latinicu
- Za azijske jezike nije dovoljno 256 mesta za zapis svih karaktera
- Nije moguće u istom tekstu koristiti specijalne karaktere (recimo za zapis matematičkih simbola) i pisati tekst na nekom istočnoevropskom jeziku
- ...

Problemi sa 8-bitnim kodnim stranama i novi standardi

- Nije moguće u istom tekstu koristiti i ćirilicu i latinicu
- Za azijske jezike nije dovoljno 256 mesta za zapis svih karaktera
- Nije moguće u istom tekstu koristiti specijalne karaktere (recimo za zapis matematičkih simbola) i pisati tekst na nekom istočnoevropskom jeziku
- Universal Character Set — UCS
- *ISO 10646* i projekat *Unicode* (Xerox Parc, Apple, Sun Microsystems, Microsoft, . . .)
- ISO 10646
 - 4 bajta
 - prvih 65536 karaktera koristi se kao osnovni višejezički skup karaktera
 - preostali prostor ostavljen kao proširenje za drevne jezike, naučnu notaciju i slično.

Unicode

- Unicode je za cilj imao da bude:
 - univerzalan (UNiversal) — sadrži sve savremene jezike sa pismom;
 - jedinstven (UNIque) — bez dupliranja karaktera - kodiraju se pisma, a ne jezici;
 - uniforman (UNIform) — svaki karakter sa istim brojem bitova.
- 3 bajta:
 - $(000000)_{16} - (10F\ F\ F\ F)_{16}$

0020-007E	ASCII printable
00A0-00FF	Latin-1
0100-017F	Latin extended A (osnovno proširenje latinice, sadrži sve naše dijakritike)
0180-027F	Latin extended B
...	
0370-03FF	grčki alfabet
0400-04FF	ćirilica
...	
2000-2FFF	specijalni karakteri
3000-3FFF	CJK (Chinese-Japanese-Korean) simboli
...	

- **Basic multilingual plane** –
 - u najčešćoj upotrebi
 - sadrži većinu danas korišćenih karaktera (uključujući i CJK — Chinese, Japanese, Korean — karaktere koji se najčešće koriste) čiji su kodovi između $(0000)_{16}$ i $(FFFF)_{16}$.
- **UCS-2**: svaki Unicode karakter osnovne višejezičke ravni jednostavno zapisuje sa odgovarajuća dva bajta.
- **UTF-8**

raspon	binarno zapisan Unicode kôd	binarno zapisan UTF-8 kôd
0000-007F	00000000 0xxxxxxx	0xxxxxxx
0080-07FF	00000yyy yyxxxxxx	110yyyyy 10xxxxxx
0800-FFFF	zzzzyyyy yyxxxxxx	1110zzzz 10yyyyyy 10xxxxxx

- Napraviti procenu: Koliko memorije je potrebno za mrežu X (bivši Twitter)?



- 
- Napraviti procenu: Koliko memorije je potrebno za mrežu X (bivši Twitter)?

- Analizirati i uprostiti zadatak.
- **Funkcionalni zahtevi:**
 - Kreirati nalog i mogućnost logovanja
 - Kreirati, menjati i brisati objave (eng. *tweets*)
 - Pratiti druge korisnike
 - Pratiti objave prema vremenu kada su postavljene
 - Pretraga objava
 - Mogućnost da se na objavu odgovori ili da se označi pozitivno (eng. *like*)

- 
- Napraviti procenu: Koliko memorije je potrebno za mrežu X (bivši Twitter)?

- **Nefunkcionalni zahtevi:**

- Svaka objava može imati najviše **280 karaktera**
- Omogućiti da sistem može da ima **1 milijardu korisnika (10^9 korisnika)**
- I neka u proseku svaki korisnik ima **200 pratilaca**
- U proseku neka imamo **100 miliona objava dnevno**
- Da je uvek dostupan (ili barem 99.99% vremena)
- Da može da istovremeno u toku dana da radi sa velikim brojem objava
- Obezbediti privatnost korisnika i njihovih podataka
- Da brzo radi – korisnik ne treba da čeka dugo na prikaz/učitavanje objava

- 
- Napraviti procenu: Koliko memorije je potrebno za mrežu X (bivši Twitter)?

- Jedna objava 200 karaktera. U proseku 1 karakter je 2 bajta (UTF-8 koristimo):
 $2B * 280 = 560B \sim 1KB \sim 10^3 B$
- 100M objava dnevno ($100 * 10^6 * 10^3 B$) = $10^{11} \sim 10^{12} = 1TB$ za objave dnevno
- Na godišnjem nivou: $365 * 1 TB \sim 400TB$
- Procene:
 - 1 PB $\sim 10^{15}$
 - 1 TB $\sim 10^{12}$
 - 1 GB $\sim 10^9$
 - 1 MB $\sim 10^6$
 - 1 KB $\sim 10^3$

- Napraviti procenu: Koliko memorije je potrebno za mrežu X (bivši Twitter)?

- Hajde malo da popravimo procenu.
- Trebaju nam i neki podaci o objavama:
 - vreme objave
 - **Kao UNIX timestamp:** U formi broja koji predstavlja sekunde od početka epohe (1. januar 1970.). Timestamp koristi **4 bajta** (32-bitni `int`), ali može biti i **8 bajtova** za `int64` (što omogućava širi opseg datuma).
 - jedinstvena oznaka korisnika koji je objavu napisao: koristimo opet 32-bitni `int`, odnosno 4B
 - jedinstvena oznaka objave (isto kao i prethodno) ~ 4B
 - Broj “sviđanja” ~ 32-bitni `int`, odnosno 4B
- Ovo je 20B koje je potrebno dodati na ona 560B za tekst. Praktično ništa ne menja, ne utiče previše.
- Na kraju, možemo reći (još malo proširiti) da je za *objave* potrebno 1PB

- Napraviti procenu: Koliko memorije je potrebno za mrežu X (bivši Twitter)?

- Imamo i meta podatke koje čuvamo za svakog korisnika:
 - ime i prezime korisnika
 - neka je ukupno ime + prezime = 20 karaktera
 - opet koristimo UTF-8, 2 bajta
 - 40B za ime i prezime
 - jedinstvena oznaka korisnika (kao jmbg)
 - dovoljan je **int** (32-bitni, odnosno 4B)
 - Ukupno: $44B * 10^9$ korisnika ~ 44 GB podataka
- Ali, svaki korisnik ima 200 pratilaca. Ove veze između korisnika je potrebno pamtit:

- Uzmimo da pamtimo kao parove (kodKorisnika, kodKorisnikaKogPrati)
- $200 * 10^9$ korisnika $* 8B = 1.6 * 10^{12} \sim 1.6TB$ podataka

- 
- Napraviti procenu: Koliko memorije je potrebno za mrežu X (bivši Twitter)?

Ukupni rezultat:

- Twitter postoji od 2006. ~ 20 godina
- $20 * 1\text{PB} + 44\text{ GB podataka} + 1.6\text{TB} = 21\text{ PB prostora}$
- Javni podatak je da kompanija koristi oko 300PB prostora
- Naša procena nije loša!
- Diskutovati zašto postoji razlika u proceni.


Zapis zvuka

- Zvučni talas predstavlja oscilaciju pritiska koja se prenosi kroz vazduh
- Digitalizacija zvuka se vrši merenjem i zapisivanjem vazdušnog pritiska u kratkim vremenskim intervalima
- Osnovni parametri:
 - **amplituda** (koja odgovara „glasnoći“)
 - **frekvencija** (koja odgovara „visini“).
- Ljudsko uho obično čuje raspon frekvencija od 20Hz do 20kHz — dovoljno je koristiti frekvenciju odabiranja 40kHz.
- AudioCD standard — 44.1kHz
- miniDV, DVD, digital TV — 48kHz
- U mobilnoj telefoniji — frekvencije odabiranja mogu biti i znatno manje.
- **Broj bitova** — 2 bajta, 65536 različitih nivoa amplitude

Zapis zvuka

- Višekanalnog snimanja zvuka
- **Stereo zvuk** — snimanje zvuka sa dva kanala
- **Surround sistemi** — snimanje sa više od dva kanala (od 3 pa čak i do 10)
- Najpoznatiji takvi sistemi su 5+1 gde se koristi 5 regularnih i jedan bas kanal.
- Jedan minut stereo zvuka u AudioCD formatu zauzima:
 - $2 \cdot 44100 \text{ sample/sec} \cdot 60 \text{ sec} \cdot 2 \text{ B/sample} = 10584000 \text{ B} \approx 10.1 \text{ M B.}$
- Tehnike kompresije: **MP3 (MPEG-1 Audio-Layer 3)**.

- Napraviti procenu: Koliko memorije je potrebno za Spotify?



Služi za skladištenje i puštanje muzike uživo. Čuva podatke o korisnicima, ali i izvođačima, albumima, pesmama itd...

Zapis video sadržaja

- Video zapis u računarima predstavlja kompleksan proces koji uključuje **efikasno povezivanje slike i zvuka** uz primenu različitih **tehnika kompresije i sinhronizacije**.
- Video se sastoji od **niza pojedinačnih frejmova**, pri čemu je svaki frejm digitalna slika koja se kombinuje sa odgovarajućim segmentom zvučnog zapisa.
- **Koderi i dekoderi** (eng. codecs)
- **Redundacija podataka** — odnosi na višak podataka koji nisu neophodni za reprodukciju

Zapis video sadržaja – koderi i dekoderi

- **Koderi** — H.264, H.265 (HEVC), AV1 — su algoritmi koji **vrše kompresiju** video i audio podataka tokom snimanja.
- vremenskog (eng. inter–frame) i prostornog (eng. intra–frame) kodiranje
- **Diskretne kosinusne transformacije** (eng. Discrete Cosine Transform):
 - podaci rastave na različite frekvencije
 - niske frekvencije - zadržati, visoke frekvencije - delimično ili potpuno ukloniti,
- **Kompenzacije pokreta** (eng. Motion Compensation):
 - umesto da se kompletan frejm kodira iznova, kodira se samo razlika između trenutnog i prethodnog frejma, koristeći vektore pokreta za opisivanje kretanja objekata H.265, poznat i kao HEVC, koristi naprednije
- AV1 – kao projekat otvorenog koda

Zapis video sadržaja – koderi i dekoderi

- **Reprodukcija** video sadržaja – **dekoder razdvaja podatke i rekonstruiše originalne frejmove** slike zajedno sa odgovarajućim audio segmentima.
- Sinhronizacija između zvuka i slike postiže se pomoću vremenskih oznaka (eng. timestamp)
- Kompenzacija kretanja zasnova na blokovima (eng. Block-based Motion Compensation) i
- Inverzna kosinusna transformacija (eng. Inverse Discrete Cosine Transform, IDCT)

Zapis video sadržaja – kontejneri sadržaja

- **MP4, MKV, ili MOV**
- Integrišu video i audio, ali i druge, meta podatke (npr. prevode, title)
- **MP4** – široko podržan format; često se koristi za uživo puštanje sadržaja zbog balansa između kvaliteta i veličine fajla.
- **MKV** — pruža veću fleksibilnost i može integrisati više tokova
- **MOV** — razvijen od strane kompanije Apple, nudi visok nivo kvaliteta i često se koristi u profesionalnim okruženjima za uređivanje videa


Zapis video sadržaja

- **HD (High Definition)** — odnosi na rezoluciju od 1280×720 piksela
- **Full HD** — rezolucija 1920×1080 piksela (često kao 1080*p*)
- **p** označava progresivno skeniranje, što znači da se svaki frejm prikazuje u celosti. U manjim formatima ili u slučaju upletenog (eng. interlaced) skeniranja, frejmovi se ne prikazuju svi odjednom, već se deli na polja, gde se prvo prikazuje polovina slike, a zatim druga polovina, što može dovesti do smanjenja kvaliteta slike ili povećanja **treperenja**.
- **4K** — 3840×2160 piksela

Zapis video sadržaja - bitrate

- **Brzina bita (brzina protoka, eng. bitrate)** — megabiti po sekundi (Mbps), količina podataka koja se prenosi ili obrađuje u jedinici vremena tokom reprodukcije videa.
- Viša brzina bita – bolji kvalitetom slike, veći kapacitet, šira mrežna propusnost
- Niža brzina bita – gubitak detalja, pojavu vizuelnih nepravilnosti
- Veće rezolucije zahtevaju veću brzinu
- Full HD (1080p) – 8-12 Mbps
- 4K – 35-45 Mbps
- *Moderniji kodeci, H.265 i AV1, omogućavaju bolju kompresiju i kvalitet slike pri nižoj brzini bita u odnosu na starije kodeke*
- H.264 za Full HD (1080p) – 8-12 Mbps
- H.265 za Full HD (1080p) – 4-6 Mbps
- AV1 za Full HD (1080p) – 3-5 Mbps

- Napraviti procenu: Koliko memorije je potrebno za YouTube platformu?



- Napraviti procenu: Koliko memorije je potrebno za YouTube platformu?

- Kolika je cena jednog videa?
 - **1080p (Full HD)**, prosek je 5-10 Mbps, za 5 minuta, veličina videa je **3 GB**.
 - **720p (HD)**, prosek je 2.5-6 Mbps, za 5 minuta, veličina videa je **1 GB**.
 - **480p (SD)**, prosek je 1-2 Mbps, za 5 minuta, veličina je **300 MB**.
 - Prema samom servisu, dozvoljena veličina videa je 256GB
- Neka imamo 1 milijardu korisnika, 10^9
- Neka se dnevno objavi 1 milion videa $\sim 10^6$
- Ukupno za video dnevno: $10^6 * 1\text{GB} \sim 1\text{PB}$ (godišnje je 300PB)
- Prema statističkim podacima, 500 sati videa se postavlja na YouTube svakog minuta:
 - prosek - 7.5 Mbps = $7.7 * 10^6$ bita $\sim 9 * 10^5$ B
 - $9 * 10^5 * 500 * 60$ minuta * 60 sekundi $\sim 1\text{TB}$ podataka svakog minuta
 - Godišnje: $1\text{TB} * 24 * 60 * 365 \sim 100\text{PB}$ podataka

- Napraviti procenu: Koliko memorije je potrebno za YouTube platformu?

- Procena za meta podatke za korisnike je ista kao i kod Twittera.
- Par interesantnih činjenica:
 - svaki video se čuva u više formata i rezolucija
 - video je podeljen na delove (chunk) (paralelizacija, ušteda, brzina, lako menjanje nivoa kvaliteta itd...)
 - Čuvaju se kopije