

# Laboratorul 1

## Semnale discrete

### 1.1 Tema

Însușirea modului de lucru cu semnale în Matlab. Studiul operațiilor cu semnale. Proprietăți ale semnalelor deterministe și aleatoare.

### 1.2 Semnale utilizate

Majoritatea semnalelor vor fi generate în Matlab, după cum se explică mai jos. Semnale vocale sau audio pot fi găsite în fișierele descrise în tabelul de mai jos.

Nume fișier	Conținut	Frecv. eșantionare
sunet_a	semnal vocal, sunetul 'a'	8 kHz
sunet_i	semnal vocal, sunetul 'i'	8 kHz
sunet_s	semnal vocal, sunetul 's'	8 kHz
xilo	semnal audio, xilofon	44.1 kHz

### 1.3 Suport teoretic

**Definiția 1.1** *Un semnal discret  $x$  este o funcție definită pe mulțimea numerelor întregi,  $x : \mathbb{Z} \rightarrow \mathbb{R}$ .*

*Eșantionare.* Fie  $x_a(t)$ ,  $t \in \mathbb{R}$ , un semnal analogic. Prin eșantionare (uniformă) cu perioada  $T_e$  se obține semnalul discret

$$x[n] = x_a(nT_e). \quad (1.1)$$

**Definiția 1.2** *Un semnal  $x[n]$  este periodic de perioadă  $N$  sau  $N$ -periodic, dacă  $x[n] = x[n + kN]$ , pentru orice  $n, k \in \mathbb{Z}$ . În general, numim perioadă a semnalului cel mai mic  $N$  pozitiv cu proprietatea de mai sus.*

*Suportul unui semnal.* Spunem că semnalul  $x[n]$  are suport  $\mathcal{T} \in \mathbb{Z}$  dacă  $x[n] = 0$ ,  $\forall n \in \mathbb{Z} \setminus \mathcal{T}$ , adică semnalul este nul în afara mulțimii suport. În Matlab se pot utiliza semnale cu suport finit, ca în cazul  $\mathcal{T} = 0 : M - 1$ , unde  $M$  este un întreg pozitiv. Aceste semnale se memorează în variabile de tip vector; adoptăm convenția ca vectorii respectivi să fie de tip linie.

### 1.3.1 Semnale deterministe

Prezentăm în continuare câteva semnale extrem de folosite.

*Impuls unitate:*

$$\delta[n] = \begin{cases} 1, & \text{dacă } n = 0, \\ 0, & \text{altfel.} \end{cases} \quad (1.2)$$

*Treaptă unitate:*

$$u[n] = \begin{cases} 1, & \text{dacă } n \geq 0, \\ 0, & \text{altfel.} \end{cases} \quad (1.3)$$

*Semnale sinusoidale.* Un semnal sinusoidal discret real, cu frecvența  $\omega$  și defazajul  $\varphi$ , are forma

$$x[n] = \sin(\omega n + \varphi). \quad (1.4)$$

Atenție, riguros ar fi să numim  $\omega$  pulsație, dar acesta este un abuz comun în prelucrarea semnalelor. Un semnal sinusoidal discret *complex* are forma

$$x[n] = e^{j(\omega n + \varphi)} = \cos(\omega n + \varphi) + j \sin(\omega n + \varphi). \quad (1.5)$$

*Semnale exponențiale:*

$$x[n] = \alpha^n u[n], \quad \alpha \in \mathbb{C}. \quad (1.6)$$

*Proprietăți ale semnalelor sinusoidale.* Sinusoida discretă (1.4) este periodică doar dacă există un întreg  $k$  astfel încât

$$N = \frac{2\pi k}{\omega} \quad (1.7)$$

să fie întreg. În acest caz, perioada este cel mai mic întreg pozitiv  $N$  care satisface (1.7). O proprietate esențială a semnalelor sinusoidale discrete este că semnale cu frecvențe diferite pot fi identice.

**Propoziția 1.1** Două sinusoidale de forma (1.4), cu frecvențele  $\omega$  și  $\omega + 2k\pi$ , unde  $k$  este un întreg arbitrar, sunt identice.

Așadar, doar semnalele sinusoidale cu frecvențe  $\omega \in [-\pi, \pi]$  sunt distincte.

### 1.3.2 Operații cu semnale

Fie  $x[n]$ ,  $y[n]$  două semnale. Având în vedere că un semnal este o funcție, produsul unui semnal cu un scalar, i.e.  $\alpha x[n]$ ,  $\alpha \in \mathbb{R}$ , sau suma a două semnale, i.e.  $x[n] + y[n]$ , au definiții evidente. Alte operații de interes în prelucrarea semnalelor sunt următoarele.

**Definiția 1.3** *Convoluția semnalelor*  $x[n]$ ,  $y[n]$  este semnalul

$$x[n] * y[n] \stackrel{\text{def}}{=} \sum_{k=-\infty}^{\infty} x[k]y[n-k]. \quad (1.8)$$

**Definiția 1.4** *Modulația în timp a semnalelor*  $x[n]$ ,  $y[n]$  este semnalul  $x[n]y[n]$  obținut prin înmulțirea eșantioanelor corespunzătoare aceluiași moment de timp.

### 1.3.3 Semnale aleatoare

O variabilă aleatoare reală  $\xi$  este caracterizată de funcția de densitate de probabilitate  $p: \mathbb{R} \rightarrow [0, 1]$ , cu proprietatea

$$\int_{-\infty}^{\infty} p(\xi) d\xi = 1. \quad (1.9)$$

Probabilitatea ca valoarea variabilei aleatoare să se afle într-un interval precizat  $[\xi_1, \xi_2]$  este

$$\text{Prob}(\xi_1 \leq \xi \leq \xi_2) = \int_{\xi_1}^{\xi_2} p(\xi) d\xi.$$

*Speranța matematică (expectația).* Fie  $\xi$  și  $\eta$  două variabile aleatoare legate prin relația  $\eta = f(\xi)$ , unde  $f$  este o funcție precizată. Atunci speranța matematică (expectația) a variabilei  $\eta$  este

$$E\{\eta\} = \int_{-\infty}^{\infty} f(\xi) p(\xi) d\xi. \quad (1.10)$$

Aceasta are semnificația de medie a valorilor variabilei  $\eta$  peste toate valorile posibile ale variabilei  $\xi$ , luând în considerare probabilitățile asociate acestor valori. Operatorul  $E\{\cdot\}$  se mai numește și operator de mediere.

*Media*  $\mu$  a variabilei aleatoare  $\xi$  se obține punând  $\eta = \xi$  în (1.10), adică este definită prin

$$\mu = E\{\xi\} = \int_{-\infty}^{\infty} \xi p(\xi) d\xi. \quad (1.11)$$

*Varianța*  $\sigma^2$  a variabilei aleatoare  $\xi$  este definită prin

$$\sigma^2 = E\{(\xi - \mu)^2\} = \int_{-\infty}^{\infty} (\xi - \mu)^2 p(\xi) d\xi. \quad (1.12)$$

**Definiția 1.5** O variabilă aleatoare cu distribuție uniformă în intervalul  $[0, 1]$  are densitatea de probabilitate

$$p(\xi) = \begin{cases} 1, & \text{pentru } \xi \in [0, 1], \\ 0, & \text{altfel.} \end{cases} \quad (1.13)$$

**Definiția 1.6** O variabilă aleatoare cu distribuție gaussiană (sau normală) de medie  $\mu$  și varianță  $\sigma^2$  are densitatea de probabilitate

$$p(\xi) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(\xi-\mu)^2}{2\sigma^2}}. \quad (1.14)$$

De obicei, această distribuție este notată  $\mathcal{N}(\mu, \sigma^2)$ .

Graficele densităților de probabilitate ale variabilelor uniformă și gaussiană sunt prezentate în figura 1.1.

**Definiția 1.7** Un proces aleator  $x[n]$ ,  $n \in \mathbb{Z}$ , este un șir de variabile aleatoare. Un semnal aleator, notat tot  $x[n]$ , este o realizare a procesului aleator, în sensul că, la fiecare moment de timp  $n$ , se consideră o singură valoare a variabilei aleatoare corespunzătoare.

**Definiția 1.8** Un proces aleator  $x[n]$  este staționar (în sens larg) dacă variabilele aleatoare  $x[n]$  au aceeași medie, i.e.

$$E\{x[n]\} = \mu, \quad \forall n \in \mathbb{Z}, \quad (1.15)$$

iar autocorelațiile

$$E\{x[n]x[n-k]\} = r[k], \quad \forall n \in \mathbb{Z}, \quad (1.16)$$

depind doar de "distanța"  $k$  între momentele de timp. (Evident, avem  $r[k] = r[-k]$ .)




Figura 1.1: Densități de probabilitate uniformă (stânga) și gaussiană  $\mathcal{N}(0, 1)$  (dreapta).

Autocovarianțele unui proces aleator staționar sunt autocorelațiile procesului  $x[n] - \mu$ , i.e.

$$E\{(x[n] - \mu)(x[n - k] - \mu)\} = \rho[k].$$

Pentru procese cu medie nulă, avem  $r[k] = \rho[k]$ .

**Definiția 1.9** Un zgomot alb de medie nulă și varianță  $\sigma^2$  este un proces aleator  $w[n]$  pentru care

$$\begin{aligned} E\{w[n]\} &= 0, \\ E\{w[n]w[n - k]\} &= \sigma^2\delta[k]. \end{aligned} \quad (1.17)$$

*Estimarea mediei și a autocorelațiilor.* În aplicațiile practice, dispunem de o realizare finită a unui proces aleator, adică de un semnal aleator cu suport finit  $x[n]$ ,  $n = 0 : M - 1$ . Media (1.15) se estimează cu

$$\hat{\mu} = \frac{1}{M} \sum_{n=0}^{M-1} x[n]. \quad (1.18)$$

Pentru autocorelațiile (1.16) se folosesc estimăția nedeviată

$$\hat{r}[k] = \frac{1}{M - k} \sum_{n=k}^{M-1} x[n]x[n - k], \quad 0 \leq k \leq M - 1, \quad (1.19)$$

dar mai ales cea deviată

$$\hat{r}[k] = \frac{1}{M} \sum_{n=k}^{M-1} x[n]x[n - k], \quad 0 \leq k \leq M - 1. \quad (1.20)$$

Pentru  $k < 0$ , în (1.19) și (1.20) se ia  $\hat{r}[k] = \hat{r}[-k]$ .

## 1.4 Ghid Matlab

### 1.4.1 Semnale deterministe

Pentru exemplificare vom considera suportul

```
>> n = 0:M-1
```

de lungime  $M$ . Semnalele definite mai sus, i.e. impuls unitate (1.2), treaptă unitate (1.3), sinusoidă reală (1.4), exponențial (1.6) se introduc simplu astfel

```

>> imp_unit = eye(1,M)           % impuls unitate
>> tr_unit  = ones(1,M)         % treapta unitate
>> sin_real = sin(w*n + phi)    % sinusoida reala
>> j = sqrt(-1)
>> sin_compl = exp( j*(w*n + phi)) % sinusoida complexa
>> e = ones(1,M)
>> e(2:end) = alfa
>> e = cumprod(e)               % semnal exponential

```

Desigur, înainte de executarea instrucțiunilor de mai sus, variabilele `w`, `phi`, `alfa` trebuie să primească valori numerice adecvate. Graficul unui semnal real se poate face cu funcția `plot`; tipică pentru semnale discrete este însă funcția `stem`, apelată e.g. astfel

```
>> stem(n, sin_real)
```

Pentru a ilustra operațiile cu semnale, considerăm că `x1` și `x2` conțin două semnale cu același suport. Atunci, suma lor se scrie

```
>> xs = x1 + x2
```

modulația în timp (produsul la nivel de element) este

```
>> xm = x1 .* x2
```

iar convoluția lor este

```
>> xc = conv(x1,x2)
```

Atenție, semnalul `xc` obținut prin convoluție are alt suport decât `x1` și `x2`; de exemplu, dacă `x1` și `x2` au suport  $0 : M - 1$ , atunci `xc` are suport  $0 : 2M - 2$ .

### 1.4.2 Semnale aleatoare

Matlab posedă generatoare de numere (aproximativ) aleatoare. Un semnal aleator cu distribuție uniformă în intervalul  $[0, 1]$ , de lungime `M`, se poate genera cu

```
>> x = rand(1,M)
```

Un semnal aleator cu distribuție gaussiană de medie nulă și varianță egală cu 1 se poate genera cu

```
>> x = randn(1,M)
```

Media (1.18) a unui semnal aleator se calculează cu

```
>> mean(x)
```

Autocorelațiile nedeviate (1.19) se calculează cu

```
>> r = xcorr(x, 'unbiased')
```

iar cele deviate (1.20) cu

```
>> r = xcorr(x, 'biased')
```

În ambele cazuri, vectorul de autocorelații `r` are lungimea  $2M - 1$ ; de altfel, aceasta este lungimea maximă permisă de suportul finit al semnalului, după cum se vede din (1.19) și (1.20).

Autocovarianțele se estimează cu funcția `xcov`. Atenție, în această funcție nu se folosește media exactă a procesului (care este necunoscută), ci estimăția ei (1.18).




Figura 1.2: Semnalul  $\sin(\pi n/3)$ , de perioadă 6. Punctat, sinusoida continuă  $\sin(\pi t/3)$ .

### 1.4.3 Sunete

Pentru a asculta un sunet, acesta trebuie salvat cu funcția `auwrite`. De exemplu, semnalul `xilo`, aflat în variabila `yx`, se salvează cu

```
>> auwrite(yx, 44100, 16, 'linear', 'numefisier.au')
```

Frecvența de eșantionare este o informație esențială. Modificarea ei produce alterarea semnalului audio. Ascultați în căști (dacă vor fi disponibile) semnalul audio selectând fișierul `.au` în Windows Explorer și acționând butonul `play` din meniul asociat. Citirea unui fișier `.au` într-o variabilă Matlab se face cu funcția `auread`.

Fișiere în format `wave` se pot manipula cu funcțiile `wavwrite` și `wavread`.

## 1.5 Sarcini de lucru

### Tema 1.1 ("Acomodare")

Executați comenzile Matlab descrise în secțiunea "Ghid Matlab" și desenați graficele semnalelor prezentate în partea teoretică a lucrării.

### Tema 1.2 (Eșantionare)

**a.** Încărcați cu comanda `load` fișierele audio descrise la începutul lucrării. Care este durata reală a fiecărui semnal? (Țineți seama de frecvența de eșantionare cu care au fost obținute semnalele.)

**b.** Scrieți o funcție Matlab care calculează semnalul obținut prin eșantionarea cu relația (1.1) a sinusoidii continue  $x_a(t) = \sin(\Omega t)$ . Argumentele de intrare sunt pulsația  $\Omega$  a sinusoidii continue (frecvența fiind  $\Omega/2\pi$ ), perioada de eșantionare  $T_e$  (sau frecvența de eșantionare  $f_e = 1/T_e$ ) și lungimea  $M$  a suportului semnalului discretizat. Argumentul de ieșire este un vector  $x$  de lungime  $M$  conținând eșantioanele sinusoidii discrete pe suportul  $0 : M - 1$ .

**c.** Scrieți o funcție Matlab care desenează pe același grafic sinusoida continuă  $x_a(t) = \sin(\Omega t)$  și pe cea discretizată  $x[n] = \sin(\Omega n T_e)$ , pentru un suport precizat (de exemplu  $0 : M - 1$ ). Un exemplu de grafic este prezentat în figura 1.2, unde, e.g.  $\Omega = \pi/3$  și  $T_e = 1$ , iar suportul este  $0 : 12$ .

**Tema 1.3 (Sinusoide discrete)**

Folosind funcțiile realizate, desenați graficele următoarelor sinusoide discrete, împreună cu sinusoidele continue din care sunt obținute. Luați  $T_e = 1$  pentru comoditate, caz în care  $\Omega = \omega$ .

a. Sinusoida discretă periodică cu frecvența  $\omega = \pi/5$ . Care este perioada acesteia ? Observați că în (1.7) avem  $k = 1$ .

b. Sinusoida discretă periodică cu frecvența  $\omega = 3\pi/5$ . Care este perioada acesteia ? Observați că în (1.7) avem  $k = 3$ . Deduceți că numărul  $k$  reprezintă numărul de perioade ale semnalului sinusoidal continuu  $x(t) = \sin(\omega t)$  care corespund unei perioade a semnalului discret  $x[n] = \sin(\omega n)$ . Alegeți frecvențe  $\omega$  astfel încât să obțineți și alte valori ale lui  $k$ .

c. O sinusoidă discretă aperiodică, de exemplu luând  $\omega = 1$ .

d. Două sinusoide discrete identice, dar cu frecvențe diferite (care provin din eșantionarea unor sinusoide continue diferite). Luați de exemplu  $\omega_1 = \pi/3$  și  $\omega_2 = 2\pi + \pi/3$ . Observați diferența dintre sinusoidele continue.

**Tema 1.4 (Ce ne arată autocorelațiile)**

a. Verificați că generatorul de numere aleatoare `randn` produce într-adevăr zgomot alb de medie nulă și varianță 1. Pentru aceasta, generați cu `randn` un semnal pseudoaleator  $x$  de lungime  $M$ . Cu ajutorul funcției `mean`, calculați media semnalului. Cu ajutorul funcției `xcorr`, calculați primele  $L < M$  autocorelații  $r[k]$ . Apelul

```
>> r = xcorr(x, L, 'biased')
```

produce secvența  $r[k]$ ,  $k = -L : L$ ; așadar,  $r[0]$  se află în poziția  $L+1$  în vectorul `r`. Desenați graficul secvenței de autocorelații și interpretați rezultatul.

Ținând  $L$  fix, măriți  $M$  și constatați că mai multe eșantioane ale unui semnal aleator dau o imagine mai bună a caracteristicilor procesului aleator care generează semnalul.

b. Generați un semnal sinusoidal cu suport  $0 : M - 1$ , astfel încât acesta să conțină mai multe perioade ale sinusoidei (minimum 5). Calculați autocorelațiile  $r[k]$  ale acestui semnal. Observați care sunt valorile  $k$  pentru care  $r[k]$  este un maxim sau un minim local. Care este legătura cu perioada sinusoidei ? Explicați.

c. Semnalul `xilo` este aproape periodic în partea lui finală. Extrageți eșantioanele de la 8000 la 10000 și calculați autocorelațiile acestui subsemnal. Observați din nou legătura între "perioada" semnalului și maximele secvenței de autocorelații.

Faceți același lucru pentru semnalele vocale. Observați forma cvasi-periodică a vocalelor și forma aproape de zgomot alb a sunetului 's'.

**Tema 1.5 (Supliment: este randn un semnal gaussian ?)**

Considerând că valorile furnizate de funcția `randn` sunt realizări ale unei variabile aleatoare cu distribuție gaussiană, ne punem problema să verificăm dacă distribuția "experimentală" a valorilor coincide cu (1.14). Pentru aceasta, generați cu `randn` un vector suficient de lung și "desenați" distribuția sa cu ajutorul funcției `hist`. Suprapuneți peste distribuția experimentală graficul densității de probabilitate (1.14). (Atenție, aceasta va trebui înmulțită cu numărul de valori din vector, pentru a avea aceeași scară.)