

Τηλεπικοινωνιακά Συστήματα

Διάλεξη 3η

Θωμάς Καμαλάκης

Χαροκόπειο Πανεπιστήμιο Αθηνών

Οκτώβριος 2020

Περιεχόμενα

- 1 Ισχύς και Ενέργεια
- 2 Ενέργεια στο πεδίο των συχνοτήτων
- 3 Τυχαίες Μεταβλητές

Τι είναι η ισχύς και η ενέργεια;

- Στις επικοινωνίες μας ενδιαφέρει πόση ισχύ εκπέμπουμε
 - για λόγους οικονομικούς.
 - για λόγους ασφάλειας.
- η ενέργεια E ενός σήματος $x(t)$ ορίζεται ως:

$$E = \int_{-\infty}^{+\infty} |x(t)|^2 dt \quad (1)$$

- η ενέργεια $E(t_a, t_b)$ ενός σήματος $x(t)$ στο χρονικό διάστημα $[t_a, t_b]$ ορίζεται ως:

$$E(t_a, t_b) = \int_{t_a}^{t_b} |x(t)|^2 dt \quad (2)$$

Ισχύς

- η στιγμιαία ισχύς $p(t)$ του σήματος ορίζεται ως:

$$p(t) = |x(t)|^2 \tag{3}$$

- η μέση ισχύς στο διάστημα $[t_a, t_b]$ ορίζεται ως:

$$P(t_a, t_b) = \frac{1}{t_b - t_a} \int_{t_a}^{t_b} |x(t)|^2 dt \tag{4}$$

- η μέση ισχύς P του σήματος ορίζεται ως:

$$P = \lim_{\tau \rightarrow \infty} \frac{1}{\tau} \int_{-\frac{\tau}{2}}^{+\frac{\tau}{2}} |x(t)|^2 dt \tag{5}$$

Ένα παράδειγμα

$$x(t) = A \cos(2\pi f_0 t) \quad (6)$$

Ας υπολογίσουμε την ενέργεια στο διάστημα $[0, T]$ όπου $T = \frac{1}{f_0}$ είναι η περίοδος του σήματος.

$$E(0, T) = \int_0^T |x(t)|^2 dt = A^2 \int_0^T \cos^2(2\pi f_0 t) dt = \frac{A^2}{2} \int_0^T (1 + \cos(4\pi f_0 t)) dt = \frac{A^2 T}{2} \quad (7)$$

Η μέση ισχύς του σήματος είναι

$$P(0, T) = \frac{1}{T} \int_0^T |x(t)|^2 dt = \frac{E(0, T)}{T} = \frac{A^2}{2} \quad (8)$$

Υπολογισμός με Python



- Πρώτα κάνουμε μερικές προσθήκες στην `comm_lib`

```
1
2 # Calculate energy
3 def energy(t, x):
4     return np.trapz( np.abs(x) ** 2.0, t)
5
6 # Calculate average power
7 def average_power(t, x):
8     ta = np.min(t)
9     tb = np.max(t)
10    return energy( t , x ) / ( tb - ta )
11
12 # Calculate a simple cosine signal
13 def cos_signal(A, f0, t, phi = 0.0 ):
```

- προσέξτε την τελευταία συνάρτηση `cos_signal`.
- ορίζει ένα προαιρετικό argument το `phi`
- στην ουσία φτιάχνουμε το $A \cos(2\pi f_0 t + \phi)$ αλλά αν δεν δώσουμε τιμή για το `phi` τότε θεωρεί $\phi = 0$.
- για αν δώσουμε τιμή την καλούμε π.χ. ως `cos_signal(..., phi = 2)`

Ο κανόνας του τραpezίου: trapz

- προσεγγίζει ένα ολοκλήρωμα με το άθροισμα πολλών μικρών τραpezίων



By Intégration_num_trapèzes.svg: Scalerderivative work: Cdang (talk) - Intégration_num_trapèzes.svg, CC BY-SA 3.0, <https://commons.wikimedia.org/w/index.php?curid=8541370>

Μαθηματικά vs Python

Τα μαθηματικά λένε $A^2/2 = 0.5$

```

1 import commlib as cl
2 import matplotlib.pyplot as plt
3
4 f0 = 50
5 T = 1 / f0
6 Tmin = -T / 2
7 Tmax = +T / 2
8 N = 1000
9 A = 1
10
11 t = cl.time_axis(Tmin, Tmax, N)
12 x = cl.cos_signal(A, f0, t)
13
14 # Plot results
15 plt.close('all')
16 plt.figure(1)
17 plt.xlabel('t/T')
18 plt.ylabel('x(t)')
19 plt.plot( t/T , x )
20
21 print('Power computed using trapezium rule: ', cl.average_power(t, x) )

```

```

In [8]: runfile('/home/thkam/python/teleconsystems/lecture3/
powerexamples.py', wdir='/home/thkam/python/teleconsystems/
lecture3')
Reloaded modules: commlib
Power computed using trapezium rule: 0.49949951925820724

```


Ένα παράδειγμα σύγκλισης

Τι συμβαίνει αν μεταβάλλουμε τον αριθμό των σημείων που χρησιμοποιούμε στον κανόνα του τραπεζίου;

```
1 import commlib as cl
2 import matplotlib.pyplot as plt
3 import numpy as np
4
5 f0 = 50
6 T = 1 / f0
7 Tmin = -T / 2
8 Tmax = +T / 2
9 A = 1
10
11 # number of points considered in each simulation
12 Ns = np.arange(10, 1000, 10)
13 Ps = np.zeros( Ns.size )
14
15 for i, N in enumerate(Ns):
16     t = cl.time_axis(Tmin, Tmax, N)
17     x = cl.cos_signal(A, f0, t)
18     Ps[ i ] = cl.average_power(t, x)
19     print('Power computed using trapezium rule using ',
20           N, ' points is : ', Ps[ i ] )
21
22 plt.close('all')
23 plt.plot(Ns, Ps)
24 plt.xlabel('N')
25 plt.ylabel('P')
```

Ένα παράδειγμα σύγκλισης

Τι συμβαίνει αν μεταβάλλουμε τον αριθμό των σημείων που χρησιμοποιούμε στον κανόνα του τραπεζίου;



Περιοδικά σήματα

- Ένα σήμα είναι περιοδικό όταν $x(t + T) = x(t)$.
- Το T ονομάζεται περίοδος του σήματος.
- Μπορούμε να δείξουμε ότι για ένα περιοδικό σήμα, η μέση ισχύς στην βασική περίοδο ισούται με την μέση ισχύ, δηλαδή:

$$P(0, T) = \frac{1}{T} \int_0^T |x(t)|^2 dt = \lim_{\tau \rightarrow \infty} \frac{1}{\tau} \int_{-\frac{\tau}{2}}^{+\frac{\tau}{2}} |x(t)|^2 dt = P \quad (9)$$

Ισχύς περιοδικού σήματος

- Δεν είναι και τόσο δύσκολη η απόδειξη.
- Αν θέσουμε $\tau = 2nT$ όπου n ένας ακέραιος έχουμε:

$$\frac{1}{\tau} \int_{-\frac{\tau}{2}}^{+\frac{\tau}{2}} |x(t)|^2 dt = \frac{1}{2nT} \int_{-nT}^{+nT} |x(t)|^2 dt =$$

$$\frac{1}{2nT} 2n \int_0^T |x(t)|^2 dt = P(0, T) \quad (10)$$

- επομένως και:

$$P = \lim_{\tau \rightarrow \infty} \frac{1}{\tau} \int_{-\frac{\tau}{2}}^{+\frac{\tau}{2}} |x(t)|^2 dt = P(0, T) \quad (11)$$

Το θεώρημα του Parseval

- Ενέργεια στο πεδίο των συχνοτήτων = ενέργεια στο πεδίο του χρόνου.

$$E = \int_{-\infty}^{+\infty} |x(t)|^2 dt = \int_{-\infty}^{+\infty} |X(f)|^2 df \quad (12)$$

- Παραλείπουμε την απόδειξη αλλά δεν είναι και τόσο δύσκολη.



Ας το επαληθεύσουμε με λίγη Python (parseval.py):

```

1 import commlib as cl
2 import matplotlib.pyplot as plt
3
4 T = 10
5 T1 = 1
6 N = 1000
7
8 t = cl.time_axis(-T, T, N)
9 x = cl.square(t, T1)
10 f = cl.frequency_axis(t)
11 X = cl.spectrum(t, x)
12
13 plt.close('all')
14 cl.plot_signal(t, x, xlabel = 't',
15               ylabel = 'x', figure_no = 1)
16
17 cl.plot_signal(f, X, xlabel = 'f',
18               ylabel = 'X', figure_no = 2)
19
20 Et = cl.energy(t, x)
21 Ef = cl.energy(f, X)
22
23 print('Energy in the time domain :', Et)
24 print('Energy in the frequency domain :', Ef)

```

Το θεώρημα του Parseval



```
Energy in the time domain : 1.02  
Energy in the frequency domain : 1.0199802544230687
```

Πυκνότητα Ισχύος

- ας υποθέσουμε ότι παρατηρούμε ένα σήμα $x(t)$ μέσα στην διάρκεια $t \in [-T/2, T/2]$.
- δεν μας ενδιαφέρει τι συμβαίνει εκτός αυτού του διαστήματος.
- φτιάχνουμε δηλαδή μία «παραθυρωμένη» έκδοση του σήματος $x(t)$,

$$x_T(t) = \begin{cases} x(t), & \text{εάν } t \in [-T/2, T/2] \\ 0, & \text{διαφορετικά} \end{cases} \quad (13)$$

- η ενέργεια που καταγράφουμε στο διάστημα αυτό είναι:

$$E(-T/2, T/2) = \int_{-T/2}^{T/2} |x(t)|^2 dt = \int_{-\infty}^{\infty} |x_T(t)|^2 dt = \int_{-\infty}^{\infty} |X_T(f)|^2 df \quad (14)$$

- όπου $X_T(f)$ είναι το φάσμα του $x_T(t)$.

Πυκνότητα Ισχύος

- Η μέση ισχύς στο διάστημα $[-T/2, T/2]$ είναι

$$P(-T/2, T/2) = \frac{1}{T} E(-T/2, T/2) = \int_{-\infty}^{\infty} \frac{|X_T(f)|^2}{T} df \quad (15)$$

- Η μέση ισχύς δίνεται από την σχέση:

$$P = \lim_{T \rightarrow \infty} \frac{1}{T} E(-T/2, T/2) = \int_{-\infty}^{\infty} \lim_{T \rightarrow \infty} \frac{|X_T(f)|^2}{T} df \quad (16)$$

- επομένως το $S_x(f)$ όπως ορίζεται παρακάτω είναι η πυκνότητα ισχύος. Μετριέται σε $W \times Hz^{-1}$.

$$S_x(f) = \lim_{T \rightarrow \infty} \frac{|X_T(f)|^2}{T} \quad (17)$$

Μερικές αλλαγές στην commlib.py



```
1 # power spectral density
2 def power_density(t, x):
3     T = np.max(t) - np.min(t)
```

- Στην περίπτωση μας περιοριζόμαστε ούτως ή άλλως σε σήματα πεπερασμένης διάρκειας.
- έχουμε έναν συγκεκριμένο άξονα t του οποίου τα όρια καθορίζονται από τον πίνακα t της numpy.
- το τι συμβαίνει έξω από το χρονικό αυτό παράθυρο δεν μας ενδιαφέρει.
- θεωρούμε ότι το σήμα εκεί είναι μηδέν.

Παράδειγμα : powerdensity.py

```
1 import complib as cl
2 import matplotlib.pyplot as plt
3 import numpy as np
4
5 T = 10
6 T1 = 1
7 N = 1000
8
9 t = cl.time_axis(-T, T, N)
10 x = cl.square(t, T1)
11 f = cl.frequency_axis(t)
12 Sx = cl.power_density(t, x)
13
14 plt.close('all')
15 cl.plot_signal(t, x, xlabel = 't',
16               ylabel = 'x', figure_no = 1)
17
18 cl.plot_signal(f, Sx, xlabel = 'f',
19               ylabel = 'Sx', figure_no = 2)
20
21 # calculate average power
22 T = np.max(t) - np.min(t)
23 Et = cl.energy(t, x) / T
24 Ef = np.trapz(Sx, f)
25
26 print('Average power :', Et)
27 print('Average power from power density :', Ef)
```

Παράδειγμα : powerdensity.py




```
Reloaded modules: commlib  
Average power : 0.05105105105105105  
Average power from power density : 0.05105006278393736
```

Τυχαίες Μεταβλητές

- Μία *τυχαία μεταβλητή* είναι ένα μέγεθος X το οποίο δεν γνωρίζουμε με βεβαιότητα.
- Μπορούμε όμως να υπολογίσουμε την πιθανότητα το X να πάρει μία τιμή x .
- Πάρτε για παράδειγμα το αποτέλεσμα που φέρνει η ρίψη ενός ζαριού.
- Αν το X είναι αυτό το αποτέλεσμα τότε οι τιμές x που μπορεί να πάρει είναι $\{1, 2, 3, 4, 5, 6\}$.
- Αν το ζάρι είναι δίκαιο, τότε θα πρέπει αυτές οι τιμές να συμβαίνουν με πιθανότητα εμφάνισης $\frac{1}{6}$.

$$P\{x = 1\} = \dots = P\{x = 6\} = \frac{1}{6} \quad (18)$$

Διακριτές και συνεχείς μεταβλητές



- Μία διακριτή τυχαία μεταβλητή λαμβάνει μόνο ένα σύνολο από διακριτές τιμές.
- Το ζάρι είναι ένα τέτοιο παράδειγμα.
- Μία συνεχής τυχαία μεταβλητή μπορεί να λάβει οποιαδήποτε τιμή μέσα σε ένα διάστημα $[a, b]$.
- Ο θόρυβος των καναλιών των παλμογράφων είναι ένα τέτοιο παράδειγμα.

Συνεχείς τυχαίες μεταβλητές

- Για μία συνεχή τυχαία μεταβλητή X δεν έχει νόημα να υπολογίσουμε την πιθανότητα $P\{X = x\}$. Αυτή θα τείνει στο μηδέν!
- Έχει περισσότερο νόημα να υπολογίζουμε την πιθανότητα η X να βρεθεί εντός ενός διαστήματος τιμών, $P\{a \leq X < b\}$
- Ορίζουμε την πυκνότητα πιθανότητας $f_X(x)$ ως την συνάρτηση της οποίας το ολοκλήρωμα (εμβαδό) μας δίνει αυτή την πιθανότητα.

$$P\{a \leq X < b\} = \int_a^b f_X(x) dx \quad (19)$$

- Δεδομένου ότι μία μεταβλητή πάντα θα είναι μεταξύ του $(-\infty, +\infty)$ θα πρέπει να έχουμε:

$$\int_{-\infty}^{+\infty} f_X(x) dx = 1 \quad (20)$$

- θα πρέπει πάντα να έχουμε $f_X(x) \geq 0$.

Παραδείγματα

- ομοιόμορφη κατανομή:

$$f_X(x) = \begin{cases} \frac{1}{b-a} & , a \leq x \leq b \\ 0 & , \text{διαφορετικά} \end{cases} \quad (21)$$

- Gaussian (κανονική) κατανομή:

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(\frac{-(x-\mu)^2}{2\sigma^2}\right) \quad (22)$$



- Η `numpy.random.uniform` παράγει τυχαία δείγματα από ομοιόμορφη κατανομή.
- Η `numpy.random.normal` παράγει δείγματα από κανονική κατανομή.

Ένα παράδειγμα Python: randomnessamples.py

```

1 from numpy.random import normal, uniform
2 import matplotlib.pyplot as plt
3
4 save_path = '/home/thkam/Documents/Presentations/TelecomSystems/lecture3/'
5 mu = 1
6 sigma = 2
7 a = 1
8 b = 2
9
10 Nsamples = 1000
11
12 # normal distribution
13 xn = normal(mu, sigma, Nsamples)
14
15 # uniform distribution
16 xu = uniform(a, b, Nsamples)
17
18 # Plot samples
19 plt.close('all')
20
21 plt.figure(1)
22 plt.plot(xn, 's')
23 plt.title('Normal distribution')
24 plt.savefig(save_path + 'normalsamples.png')
25
26 plt.figure(2)
27 plt.plot(xu, 's')
28 plt.title('Uniform distribution')
29 plt.savefig(save_path + 'uniformsamples.png')
    
```

Ένα παράδειγμα Python: randomsamples.py



Αναμενόμενες τιμές

- Ας υποθέσουμε ότι έχουμε μία τυχαία μεταβλητή την X .
- Υπολογίζουμε πολλά δείγματα της $\{x_1, \dots, x_N\}$
- Πολλές φορές είναι χρήσιμο να υπολογίζουμε το μέσο όρο των δειγμάτων αυτών:

$$\frac{x_1 + \dots + x_N}{N} \quad (23)$$

- Επίσης μπορούμε να υπολογίσουμε το μέσο μίας συνάρτησης πάνω στην τυχαία μεταβλητή $g(X)$:

$$\frac{g(x_1) + \dots + g(x_N)}{N} \quad (24)$$


- Είναι διαισθητικά εμφανές ότι όσο αυξάνουμε το N τόσο πιο καλό υπολογισμό των παραπάνω μέσων τιμών θα έχουμε!

Αναμενόμενες τιμές: expectedvalues.py


```

1  from numpy.random import normal
2  import numpy as np
3  import matplotlib.pyplot as plt
4
5  save_path = '/home/thkam/Documents/Presentations/TelecomSystems/lecture3/'
6  mu = 1
7  sigma = 2
8
9  Nsamples = np.arange(100, 10000, 100)
10 expectations = np.zeros( Nsamples.size )
11
12 func = lambda x : x ** 2.0
13
14 # iterate over different N values
15 for i, N in enumerate(Nsamples):
16     xn = normal(mu, sigma, N)
17     expectations[i] = np.mean( func(xn) )
18
19
20 # Plot expectations
21 plt.close('all')
22
23 plt.figure(1)
24 plt.plot(Nsamples, expectations)
25 plt.title('Expectations vs Nsamples')
26 plt.xlabel('Nsamples')
27 plt.ylabel('Expected Value')
28 plt.savefig(save_path + 'convsquare.png')
    
```

Αναμενόμενες τιμές: expectedvalues.py



$$(\alpha') g(x) = x$$



$$(\beta') g(x) = x^2$$

Σημαντικές παράμετροι τυχαίων μεταβλητών

- Μέση τιμή

$$\mu_X = \mathbb{E} \{X\} \quad (25)$$

- Διακύμανση

$$\sigma_X^2 = \mathbb{E} \{(X - \mu_X)^2\} \quad (26)$$

- Τυπική απόκλιση

$$\sigma_X = \left(\mathbb{E} \{(X - \mu_X)^2\} \right)^{\frac{1}{2}} \quad (27)$$

Υπολογισμός αναμενόμενων τιμών

- Αν ξέρουμε την πυκνότητα πιθανότητας $f_X(x)$ τότε

$$\mu_X = \mathbb{E}\{g(X)\} = \int_{-\infty}^{+\infty} g(x)f_X(x)dx \quad (28)$$

- Παράδειγμα: Για την ομοιόμορφη κατανομή έχουμε:

$$\begin{aligned} \mathbb{E}\{X\} &= \int_{-\infty}^{+\infty} x f_X(x) dx = \frac{1}{b-a} \int_a^b x dx = \\ &= \frac{1}{b-a} \left(\frac{b^2}{2} - \frac{a^2}{2} \right) = \frac{b+a}{2} \end{aligned} \quad (29)$$

Υπολογισμός αναμενόμενων τιμών

- Παράδειγμα: Για την ομοιόμορφη κατανομή έχουμε:

$$\begin{aligned}\mathbb{E}\{X^2\} &= \int_{-\infty}^{+\infty} x^2 f_X(x) dx = \frac{1}{b-a} \int_a^b x^2 dx = \\ &= \frac{1}{b-a} \left(\frac{b^3}{3} - \frac{a^3}{3} \right) = \frac{b^2 + ab + a^2}{3} \quad (30)\end{aligned}$$

Υπολογισμός αναμενόμενων τιμών

- Παράδειγμα: Για την ομοιόμορφη κατανομή έχουμε:

$$\begin{aligned}\mathbb{E}\{X^2\} &= \int_{-\infty}^{+\infty} x^2 f_X(x) dx = \frac{1}{b-a} \int_a^b x^2 dx = \\ &= \frac{1}{b-a} \left(\frac{b^3}{3} - \frac{a^3}{3} \right) = \frac{b^2 + ab + a^2}{3} \quad (31)\end{aligned}$$

$$\begin{aligned}\sigma_X^2 &= \mathbb{E}\{(X - \mu_X)^2\} = \mathbb{E}\{X^2 - 2\mu_X X + \mu_X^2\} = \\ &= \mathbb{E}\{X^2\} - 2\mu_X \mathbb{E}\{X\} + \mu_X^2 = \mathbb{E}\{X^2\} - \mu_X^2 = \frac{(b-a)^2}{12} \quad (32)\end{aligned}$$

Υπολογισμός αναμενόμενων τιμών

- Για την κανονική κατανομή έχουμε:

$$\mu_X = \mathbb{E} \{X\} = \mu \quad (33)$$

$$\sigma_X^2 = \mathbb{E} \{(X - \mu_X)^2\} = \sigma^2 \quad (34)$$

- Παραλείπουμε εδώ την απόδειξη (δεν είναι και πολύ δύσκολη όμως).

Η σημασία του σ_X^2

```
1 from numpy.random import normal
2 import numpy as np
3 import matplotlib.pyplot as plt
4
5 save_path = '/home/thkam/Documents/Presentations/TelecomSystems/lecture3/'
6 mu = 1
7 sigma1 = 2
8 sigma2 = 6
9 Nsamples = 1000
10
11 xn1 = normal(mu, sigma1, Nsamples)
12 xn2 = normal(mu, sigma2, Nsamples)
13
14 plt.close('all')
15
16 plt.figure(1)
17 plt.plot(xn2, 's', label = 'sigma=6')
18 plt.plot(xn1, 's', label = 'sigma=2')
19
20 plt.xlabel('index')
21 plt.ylabel('sample')
22 plt.legend()
23 plt.savefig(save_path + 'demostd.png')
```


Αθροιστική πυκνότητα πιθανότητας

- Η αθροιστική πυκνότητα πιθανότητας $F_X(\gamma)$ θα δούμε ότι είναι αρκετά χρήσιμη στις επικοινωνίες.
- Ορίζεται ως η πιθανότητα η τυχαία μεταβλητή X να είναι μικρότερη ή ίση από μία τιμή γ .
- $F_X(\gamma) = \Pr \{X \leq \gamma\}$.
- Για την ομοίμορφη κατανομή:

$$F(\gamma) = \Pr \{X \leq \gamma\} = \int_{-\infty}^{\gamma} f_X(x) dx = \int_a^{\gamma} f_X(x) dx = \frac{\gamma - a}{b - a} \quad (35)$$

- Η παραπάνω σχέση ισχύει όταν $a \leq \gamma \leq b$.

Αθροιστική πυκνότητα πιθανότητας

- Στην περίπτωση της κανονικής κατανομής, δεν μπορούμε να δώσουμε μία απλή σχέση για την $F_X(\gamma)$.
- Εκφράζουμε όμως την $F_X(\gamma)$ μέσω μίας συνάρτησης την οποία υπολογίζουμε με την βοήθεια υπολογιστή.
- Αν ορίσουμε την $Q(x)$ ως:

$$Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^{\infty} \exp\left(-\frac{y^2}{2}\right) dy \quad (36)$$

- τότε έχουμε:

$$F_X(\gamma) = 1 - Q\left(\frac{\gamma - \mu}{\sigma\sqrt{2}}\right) \quad (37)$$