

Slučajni procesi

Regresiona analiza (nastavak). Osnovni pojmovi iz teorije vjerovatnoće. Statistika prvog reda.

Ljubiša Stanković, Miloš Brajović

Univerzitet Crne Gore
Elektrotehnički fakultet

Prezentacija 2

Regresiona analiza. *Ridge regresija*

Ljubiša Stanković, Miloš Brajović

Univerzitet Crne Gore
Elektrotehnički fakultet

Prezentacija 2

Ridge regresija

- Regresija može biti generalizovana na **multivarijabilni slučaj**, kada postoji više od jedne nezavisne promjenljive.
- U ovom slučaju, odbirak signala koji se razmatra, $x(n)$, predstavlja funkciju od slučajnih promjenljivih $t_1(n), t_2(n), \dots, t_M(n)$, odnosno,
$$x(n) = x(t_1(n), t_2(n), \dots, t_M(n)).$$
- Regresija može biti zapisana u obliku **višedimenzionog linearog modela**,

$$x(n) = a_1 t_1(n) + a_2 t_2(n) + \dots + a_M t_M(n) + \varepsilon(n), \quad n = 1, 2, \dots, N$$

gdje su $t_i(n)$, $i = 1, 2, \dots, M$, nezavisne varijable odbirka $x(n)$.

- Ovaj sistem jednačina može biti zapisan u matrično-vektorskoj formi kao

$\mathbf{x} = \mathbf{T}\mathbf{a} + \boldsymbol{\Xi}$, gdje su:

$$\mathbf{x} = \begin{bmatrix} x(1) \\ x(2) \\ \vdots \\ x(N) \end{bmatrix}, \quad \mathbf{T} = \begin{bmatrix} t_1(1) & t_2(1) & \dots & t_M(1) \\ t_1(2) & t_2(2) & \dots & t_M(2) \\ \vdots & \vdots & \ddots & \vdots \\ t_1(N) & t_2(N) & \dots & t_M(N) \end{bmatrix}, \quad \mathbf{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_M \end{bmatrix}, \quad \text{i} \quad \boldsymbol{\Xi} = \begin{bmatrix} \varepsilon(1) \\ \varepsilon(2) \\ \vdots \\ \varepsilon(N) \end{bmatrix}.$$

Ridge regresija

- Uobičajeni cilj je minimizacija kvadrata greške između podataka \mathbf{x} i modela $\mathbf{T}\mathbf{a}$, odnosno:

$$J(\mathbf{a}) = \|\mathbf{x} - \mathbf{T}\mathbf{a}\|_2^2 = (\mathbf{x} - \mathbf{T}\mathbf{a})^T (\mathbf{x} - \mathbf{T}\mathbf{a}) = (\mathbf{x}^T - \mathbf{a}^T \mathbf{T}^T)(\mathbf{x} - \mathbf{T}\mathbf{a}).$$

- Rješenje ovog problema minimizacije u smislu najmanjih kvadrata se dobija iz $\partial J(\mathbf{a}) / \partial \mathbf{a}^T = \mathbf{0}$, u obliku:

$$-2\mathbf{T}^T(\mathbf{x} - \mathbf{T}\hat{\mathbf{a}}) = \mathbf{0} \quad \text{ili} \quad \mathbf{T}^T \mathbf{x} = \mathbf{T}^T \mathbf{T}\hat{\mathbf{a}}.$$

- Estimacija regresionih parametara $\mathbf{a} = [a_1, a_2, \dots, a_N]^T$ koji minimizuju funkciju cijene $J(\mathbf{a})$, dobija se iz:

$$\hat{\mathbf{a}} = (\mathbf{T}^T \mathbf{T})^{-1} \mathbf{T}^T \mathbf{x} = \text{pinv}\{\mathbf{T}\} \mathbf{x}, \quad (1)$$

gdje $\text{pinv}\{\mathbf{T}\} = (\mathbf{T}^T \mathbf{T})^{-1} \mathbf{T}^T$ predstavlja tzv. **pseudo-inverziju matrice \mathbf{T}** .

- Osjetljivost rekonstruisanih koeficijenata na slučajne varijacije u podacima $x(n)$, uzrokovane šumom $\epsilon(n)$, u velikoj mjeri zavisi od kondicionog broja matrice $\mathbf{T}^T \mathbf{T}$, čija se inverzija vrši.

Ridge regresija

- Po definiciji, **kondicioni broj** proizvoljne normalne matrice \mathbf{A} definiše se kao:

$$\text{cond}\{\mathbf{A}\} = \frac{|\lambda_{\max}|}{|\lambda_{\min}|},$$

gdje su λ_{\max} i λ_{\min} najveća i najmanja vrijednost matrice \mathbf{A} .

- Matrica \mathbf{A} je normalna ako važi $\mathbf{A}^H \mathbf{A} = \mathbf{A} \mathbf{A}^H$, gdje je $(\cdot)^H$ Hermitsko transponovanje, odnosno, transponovanje i konjugovanje matrice.
- Za velike vrijednosti kondicionog broja posmatrane matrice $\mathbf{T}^T \mathbf{T}$, koji odgovara relativno maloj vrijednosti determinante $\det\{\mathbf{T}^T \mathbf{T}\}$, mali šum $\varepsilon(n)$ u ulaznim podacima izaziva *veoma velike varijacije* rezultujućih parametara $\hat{\mathbf{a}} = [\hat{a}_1, \hat{a}_2, \dots, \hat{a}_M]^T$ u posmatranom modelu (tzv. **ill-posed problem**).
- U cilju **regularizacije inverzije** (ali i ograničavanja vrijednosti potencijalno ekstremno velikih elemenata u inverznoj matrici), dodaje se mala vrijednost λ prije inverzije, dok se vektor parametara računa korišćenjem

$$\hat{\mathbf{a}} = (\mathbf{T}^T \mathbf{T} + \lambda \mathbf{I})^{-1} \mathbf{T}^T \mathbf{x}. \quad (2)$$

- Može se lako pokazati da je ova forma vektora \mathbf{a} rješenje minimizacije funkcije cijene $J(\mathbf{a}) = \|\mathbf{x} - \mathbf{T}\mathbf{a}\|_2^2$, kada se za koeficijente $\mathbf{a} = [a_1, a_2, \dots, a_M]^T$, postavi tzv. ograničenje energije.

Ridge regresija

- Ograničenje energije u minimizaciji obezbjeđuje da energija vektora $\mathbf{a} = [a_1, a_2, \dots, a_M]^T$ bude najmanja moguća (kako bi se izbjegla pojava velikih vrijednosti u elementima ovog vektora uslijed moguće nestabilnosti inverzije matrice $\mathbf{T}^T \mathbf{T}$).
- Ovo je razlog zbog kojeg se regresiona estimacija naziva i *estimacija skupljanja* (engl. **shrinkage estimation**).
- Ograničena funkcija cijene data je sljedećim izrazom:

$$J(\mathbf{a}) = \|\mathbf{x} - \mathbf{T}\mathbf{a}\|_2^2 + \lambda \|\mathbf{a}\|_2^2,$$

gdje $\|\mathbf{a}\|_2^2$ predstavlja L_2 -normu vektora \mathbf{a} .

- Minimalna vrijednost ove funkcije cijene se dobija iz:

$$\frac{\partial J(\mathbf{a})}{\partial \mathbf{a}^T} = -2\mathbf{T}^T (\mathbf{x} - \mathbf{T}\mathbf{a}) + 2\lambda\mathbf{a} = \mathbf{0}$$

u obliku datom izrazom (2).

- Ukoliko je ograničenje definisano kao **L_1 -norma koeficijenata** $\mathbf{a} = [a_1, a_2, \dots, a_M]^T$, funkcija cijene postaje

$$J(\mathbf{a}) = \|\mathbf{x} - \mathbf{T}\mathbf{a}\|_2^2 + \lambda \|\mathbf{a}\|_1.$$

Ridge regresija

- Za razliku od ograničenja definisanog L_2 -normom, koja nameće male vrijednosti (energiju) vektora $\mathbf{a} = [a_1, a_2, \dots, a_M]^T$, ograničenje L_1 -normom nameće **rijetko (engl. sparse)** rješenje za $\mathbf{a} = [a_1, a_2, \dots, a_M]^T$ (rješenje sa najvećim mogućim brojem elemenata u vektoru $\mathbf{a} = [a_1, a_2, \dots, a_M]^T$ koji su jednaki nuli).
- Minimizacija ove funkcije cijene je poznata kao *operator najmanjeg apsolutnog skupljanja i selekcije* (engl. *Least Absolute Shrinkage and Selection Operator – LASSO*). LASSO rješenje se ne može dobiti u zatvorenoj formi.
- Ovaj minimizacioni problem je od ključnog značaja u oblastima kompresivnog odabiranja i mašinskog učenja.

Primjer 4

- Vrši se $N = 10$ mjerjenja slučajne varijable $\mathbf{x} = [x(1), x(2), \dots, x(N)]^T$.
- Poznato je da je slučajna varijabla $x(n)$ linearna funkcija od $M = 7$ nezavisnih promjenljivih $\mathbf{t}(n) = [t_1(n), t_2(n), \dots, t_M(n)]$.
- Vrijednosti nezavisnih promjenljivih su date u matrici \mathbf{T} , gdje $\mathbf{t}(n)$ označava vrste matrice, dok je slučajna varijabla $x(n)$ data u vektoru \mathbf{x} .
- Odrediti parametre $\mathbf{a} = [a_1, a_2, \dots, a_M]^T$ linearног modela korišćenjem *ridge* regresije i $\lambda = 0.01$.

Ridge regresija – primjer 4

Primjer 4 – nastavak

$$\mathbf{T} = \begin{bmatrix} 1.1661 & 1.1607 & 0.5404 & 0.1656 & -0.8154 & -0.7506 & 0.4005 \\ 0.0884 & 0.3245 & 0.4657 & 0.0397 & 1.1129 & -0.1554 & 1.1253 \\ 0.2168 & 0.6992 & -0.2677 & 0.9177 & -0.4409 & -0.5107 & -0.4384 \\ -0.5292 & 0.9924 & 0.8458 & -0.7220 & -0.0592 & 0.9896 & 1.1560 \\ 0.2099 & 0.8470 & -0.5224 & 0.6903 & 0.2075 & 0.1795 & 0.5974 \\ -0.3515 & -1.2374 & 0.1422 & 1.0570 & -0.5864 & 0.2041 & 0.2922 \\ 0.6215 & 1.4229 & 0.5253 & 0.6104 & 0.3214 & -1.1383 & 0.3013 \\ 0.7764 & 0.9572 & 0.5978 & -0.3710 & 1.0122 & -1.2106 & -0.7862 \\ -1.3638 & -0.6115 & -0.1246 & 0.1535 & -0.0534 & 0.6406 & 0.3441 \\ -0.4296 & -0.7374 & 0.6755 & 0.3165 & -0.3022 & 0.4979 & -0.9710 \end{bmatrix}^T$$

$$\mathbf{x} = [3.1399, -0.9308, 0.8620, -0.9898, 0.2084, -0.1228, 0.9128, 0.5337, -2.6691, -0.5552]^T$$

- Estimirani parametri linearog modela, koji se dobijaju primjenom *ridge* regresije (2), su:

$$\begin{aligned}\hat{\mathbf{a}} &= (\mathbf{T}^T \mathbf{T} + 0.01 \mathbf{I})^{-1} \mathbf{T}^T \mathbf{x} \\ &= [1.9787, -0.0023, -0.0047, -0.0186, -1.0095, -0.0208, 0.006]^T.\end{aligned}$$

Primjer 4

- LASSO minimizacija, sa istim $\lambda = 0.01$, daje sljedeći rezultat estimacije:

$$\hat{\mathbf{a}} = \text{lasso}(\mathbf{x}, \mathbf{T}, 0.01) = [1.9767, 0, 0, 0, -0.9776, 0, 0]^T,$$

namećući pritom da je najveći mogući broj elemenata u vektoru \mathbf{a} jednak nuli.

- Zbog ovog svojstva, koje je ključno u kontekstu obrade rijetkih signala i kompresivnog odabiranja, LASSO minimizacija može dati rješenje čak i kada je broj opservacija manji od ukupnog broja elemenata u vektoru \mathbf{a} .
- Ako zadržimo prvih $N = 6 < M = 7$ vrsta u \mathbf{T} i \mathbf{x} , dobijamo

$$\hat{\mathbf{a}} = \text{lasso}(\mathbf{x}, \mathbf{T}, 0.01) = [1.9931, 0, 0.0004, 0, -0.9772, 0, 0]^T.$$

- U ovom slučaju važi $\det\{\mathbf{T}^T \mathbf{T}\} = 0$, budući da je $N < M$.
- LASSO minimizaciona procedura za L_1 -normu je implementirana u Octave/MATLAB-u.
- U našim razmatranjima, navedeni optimizacioni pristup ćemo koristiti ne zalazeći u njegovu implementaciju.

Polinomijalna aproksimacija

- Specifična forma linearne regresije je **polinomijalna aproksimacija** (engl. **polynomial fitting**):

$$x(t_n) = a_0 + a_1 t_n + a_2 t_n^2 + \cdots + a_M t_n^M + \varepsilon(t_n), \quad n = 1, 2, \dots, N.$$

- Ovakav oblik regresije je i dalje linearan, zato što linearnost važi u odnosu na parametre modela a_0, a_1, \dots, a_M .
- Matrica nezavisnih varijabli je data u sljedećem obliku:

$$\mathbf{T} = \begin{bmatrix} 1 & t_1 & t_1^2 & \cdots & t_1^M \\ 1 & t_2 & t_2^2 & \cdots & t_2^M \\ \vdots & & & & \\ 1 & t_N & t_N^2 & \cdots & t_N^M \end{bmatrix},$$

pri čemu su svi drugi vektori, rezultati i komentari identični kao u multivarijabilnom slučaju.

- U kontekstu polinomijalnih aproksimacija, regularizaciona ograničenja nad rješenjem sprečavaju „preprilagođavanje“ (engl. **overfitting**) modela i održavaju niske vrijednosti parametara.

Metod kros-validacije

- U praksi, određivanje najbolje vrijednosti parametra λ predstavlja složen problem. Jedan pristup određivanju najbolje vrijednosti λ je poznat pod nazivom **metod kros-validacije**.
- Navedeni metod se sastoji od sljedećih koraka:
 1. Estimacija parametara modela se radi sa unaprijed odabranim skupom vrijednosti λ , gdje se jedna ili više tačaka $(t_n, x(n))$ *isključuje* iz razmatranja.
 2. Estimacija se ponavlja, ali uz isključivanje ostalih tačaka, jedne po jedne.
 3. Računa se ukupna kvadratna greška vrijednosti predviđenih modelom u odnosu na izostavljene vrijednosti, za svaku razmatranu vrijednost λ .
 4. Najbolja vrijednost λ je ona koja daje najmanju ukupnu kvadratnu grešku predikcije.

Osnovni pojmovi iz teorije vjerovatnoće. Statistika prvog reda.

Ljubiša Stanković, Miloš Brajović

Univerzitet Crne Gore
Elektrotehnički fakultet

Prezentacija 2

- Teorija vjerovatnoće je naučna disciplina koja se bavi analizom slučajnih fenomena na bazi skupa aksioma.
- Vjerovatnoća je veličina kojom se kvantificuje u kolikoj mjeri je ishod određenog slučajnog događaja vjerovatan, odnosno, vjerovatnoća predstavlja kvantifikaciju očekivanja da će se neki događaj desiti.
- Za računanje parametara *statistike prvog reda*, dovoljno je kao osnovnu probabilističku deskripciju poznavati **vjerovatnoću ili funkciju gustine vjerovatnoće** slučajne promjenljive.
- Prepostavimo da slučajni signal $x(n)$ može uzeti jednu od diskretnih vrijednosti (amplituda) ξ_i iz skupa $\mathbb{A} = \{\xi_1, \xi_2, \dots, \xi_N\}$.
- U posmatranom kontekstu, govorimo o vjerovatnoćama da slučajni signal $x(n)$ u trenutku n uzima specifičnu vrijednost ξ_i iz skupa svih mogućih vrijednosti

$$P\{x(n) = \xi_i\} = P_{x(n)}(\xi_i).$$

gdje operator $P\{\cdot\}$ označava vjerovatnoću odgovarajućeg događaja.

Vjerovatnoća

- Funkcija vjerovatnoće $P_{x(n)}(\xi)$ zadovoljava sljedeće uslove (*aksiome teorije vjerovatnoće*):
 1. $0 \leq P_{x(n)}(\xi) \leq 1$ za bilo koje ξ .
 2. Za događaje $x(n) = \xi_i$ i $x(n) = \xi_j$, $i \neq j$, koji su međusobno **isključivi** važi:
 3. **Suma vjerovatnoća** da $x(n)$ uzima bilo koju vrijednost ξ_i iz skupa \mathbb{A} svih mogućih vrijednosti ξ je **siguran dogadaj**. Vjerovatnoća sigurnog događaja je jednaka 1, pa važi:

$$\sum_{\xi \in \mathbb{A}} P_{x(n)}(\xi) = 1.$$

- **Nemoguć dogadaj** ima vjerovatnoću jednaku nuli.
- Primjer signala kod kojeg su vjerovatnoće estimirane nakon eksperimenta (*a posteriori*) već je prezentovan u sklopu ranijih predavanja.
- **A posteriori vjerovatnoća** da signal $x(n)$ uzima vrijednost ξ_i je definisana kao odnos između broja pojavljivanja N_{ξ_i} događaja $x(n) = \xi_i$ i ukupnog broja sprovedenih eksperimenata N :

$$P_{x(n)}(\xi_i) = \frac{N_{\xi_i}}{N}.$$

za dovoljno veliko N i N_{ξ_i} .

Vjerovatnoća

- U nekim slučajevima, moguće je odrediti vjerovatnoću događaja **prije** nego što se eksperiment sprovede.
- Na primjer, ako je signal jednak broju koji se pojavljuje prilikom bacanja kocke, (gdje je pretpostavljeno da su sve strane kocke ravnopravne), tada taj signal može uzeti jednu od vrijednosti iz skupa $\xi_i \in \mathbb{A} = \{1, 2, 3, 4, 5, 6\}$.
- U ovom slučaju, vjerovatnoća svakog događaja je poznata unaprijed (**a priori**), i jednaka je $P(\xi_i) = 1/6$.
- **Nezavisnost.** Dva događaja (dva slučajna odbirka signala) su nezavisni jedan od drugog, *ukoliko vjerovatnoća da se jedan događaj desi* (da jedan odbirak uzme slučajnu vrijednost) *ne utiče na vjerovatnoću da se desi drugi događaj* (ne utiče na vrijednost drugog odbirka signala). Ako su signali $x(n)$ i $x(m)$ **statistički nezavisne slučajne varijable**, tada

$$P\{x(n) = \xi_i \text{ i } x(m) = \xi_j\} = P_{x(n)}(\xi_i)P_{x(m)}(\xi_j).$$

- **Isključivost.** Dva slučajna događaja su međusobno isključiva *ukoliko se ne mogu desiti u isto vrijeme*. Ako su vrijednosti signala $x(n) = \xi_i$ i $x(n) = \xi_j$ međusobno isključivi događaji, tada, prema osobini (2) važi:

$$P\{x(n) = \xi_i \text{ ili } x(n) = \xi_j\} = P_{x(n)}(\xi_i) + P_{x(n)}(\xi_j).$$

Vjerovatnoća – primjer

Primjer 1

Razmatra se slučajni signal čije su vrijednosti jednake broju koji se pojavljuje pri bacanju kocke. Skup mogućih vrijednosti signala je $\xi_i \in \mathbb{A} = \{1, 2, 3, 4, 5, 6\}$.

- Odrediti vjerovatnoću da odbirak signala uzme vrijednost $x(n) = 2$ ili vrijednost $x(n) = 5$, odnosno $P\{x(n) = 2 \text{ ili } x(n) = 5\}$.
- Odrediti vjerovatnoću da odbirak signala u trenutku n uzme vrijednost $x(n) = 2$ i da pri sljedećem bacanju signal uzme vrijednost $x(n+1) = 5$, odnosno

$$P\{x(n) = 2 \text{ i } x(n+1) = 5\}.$$

- Događaji da $x(n) = 2$ i $x(n) = 5$ su međusobno isključivi. Stoga, vjerovatnoća dva isključiva događaja jednaka je sumi njihovih pojedinačnih vjerovatnoća,

$$P\{x(n) = 2 \text{ ili } x(n) = 5\} = P_{x(n)}(2) + P_{x(n)}(5) = \frac{1}{6} + \frac{1}{6} = \frac{1}{3}.$$

- Događaji da $x(n) = 2$ i $x(n+1) = 5$ predstavljaju statistički nezavisne događaje. U ovom slučaju važi:

$$P\{x(n) = 2 \text{ i } x(n+1) = 5\} = P_{x(n)}(2)P_{x(n)}(5) = \frac{1}{6} \cdot \frac{1}{6} = \frac{1}{36}.$$

Uslovna vjerovatnoća

- Uslovna vjerovatnoća je vjerovatnoća da se događaj A desi, pod uslovom da se drugi događaj B već desio. Vjerovatnoća događaja A , pod uslovom da se desio događaj B se kratko zapisuje u formi $P(A|B)$.
- Vjerovatnoća da su se desila oba događaja A i B je:

$$P\{A \text{ i } B\} = P(A|B)P(B),$$

gdje je $P(B)$ vjerovatnoća da se desio događaj B , dok $P(A|B)$ označava vjerovatnoću da se događaj A desio pod uslovom da se događaj B već desio.

Primjer 2

Pretpostaviti da je dužina slučajnog signala $x(n)$ jednaka N , a da je I odbiraka oštećeno ekstremno jakim šumom. Neka se kao skup mjerenja (opservacija) uzima podskup od $M < N$ slučajno pozicioniranih odbiraka signala.

- Koja je vjerovatnoća da u skupu od M slučajno pozicioniranih odbiraka signala nema odbiraka koji su oštećeni jakim šumom?
- Ako je $N = 128$, $I = 16$, i $M = 32$, odrediti koliko se skupova od M odbiraka, koji ne sadrže nijedan odbirak koji je oštećen jakim šumom, može očekivati u 1000 realizacija (pokušaja).

Primjer 2 – rješenje

- Vjerovatnoća da prvi slučajno odabrani odbirak nije oštećen jakim šumom može biti izračunata kao *a priori* vjerovatnoća,

$$P(1) = P(B) = \frac{N-I}{N}$$

budući da postoji N odbiraka i da je njih $N - I$ neoštećeno (od strane šuma).

- Nakon što se odabere prvi odbirak bez šuma, u preostalih $N - 1$ odbiraka, postoji tačno $N - 1 - I$ odbiraka koji su neoštećeni šumom. Vjerovatnoća da se odabere odbirak bez šuma je sada $P(A|B) = (N - 1 - I)/(N - 1)$.
- Vjerovatnoća da drugi slučajno odabrani odbirak nije oštećen jakim šumom, pod uslovom da prvi odabrani odbirak nije oštećen, jednaka je proizvodu vjerovatnoća

$$P(2) = P(A) = P(A|B)P(B) = \frac{N-1-I}{N-1} \frac{N-I}{N}.$$

Ovdje se koristi svojstvo uslovne vjerovatnoće.

- Dalje se nastavlja proces slučajne selekcije odbiraka. Na isti način se može odrediti vjerovatnoća da svih M slučajno odabranih odbiraka nijesu pod uticajem jakog šuma kao:

$$P(M) = \frac{N-I}{N} \frac{N-1-I}{N-1} \cdots \frac{N-(M-1)-I}{N-(M-1)} = \prod_{i=0}^{M-1} \frac{N-I-i}{N-i}.$$

- Za $N = 128$ odbiraka signalna, sa $I = 16$ odbiraka oštećenih šumom, vjerovatnoća da $M = 32$ slučajno selektovanih odbiraka nije oštećeno šumom jednaka je $P(32) = 0.0071$.

Primjer 2 – rješenje

- Ako se ista procedura sa selekcijom $M = 32$ odbirka ponovi 1000 puta, možemo očekivati

$$P(32) \times 1000 = 7.1,$$

što je oko 7 realizacija u kojima nijedan od M odbiraka signala nije zahvaćeno šumom. Jedna realizacija bez oštećenja šumom se očekuje na svakih 140 realizacija.

- U literaturi, može se naći na sljedeći **proračun očekivanog broja iteracija** neophodnih da bi se došlo do realizacije bez šuma.
- Vjerovatnoća da je jedan odbirak bez šuma (*inlier*) jednaka je $(N - I)/N$. Zatim se pretpostavlja da ova vjerovatnoća može da se iskoristi za M odbiraka (odbirak se vraća i može se opet birati).
- Vjerovatnoća da je najmanje jedan odbirak oštećen jakim šumom u ukupno M odbiraka je $[1 - ((N - I)/N))^M]$.
- Najzad, vjerovatnoća da se dobije realizacija bez jakog šuma u ukupno N_{it} takvih pokušaja je

$$P = 1 - [1 - ((N - I)/N))^M]^{N_{it}} \quad \text{gdje je} \quad N_{it} = \frac{\ln(1 - P)}{\ln(1 - ((N - I)/N))^M}.$$

- Navedeni proračun je tačan ako je $(N - I - M)/(N - M) \sim (N - I)/N$, inače se umjesto $((N - I)/N))^M$ mora koristiti

$$P(M) = \prod_{i=0}^{M-1} \frac{N - I - i}{N - i}.$$

Bajesova teorema

- Razmatraju se dva događaja A i B . **Bajesova relacija** se dobija iz vjerovatnoće da se dese oba događaja:

$$P\{A \text{ i } B\} = P(A|B)P(B) = P\{B \text{ i } A\} = P(B|A)P(A).$$

kao:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}.$$

- Prepostavimo sada da se posmatra N mogućih događaja A_i , $i = 1, 2, \dots, N$. Tada važi:

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{P(B)}.$$

- Prepostavimo dalje da su događaji A_i , $i = 1, 2, \dots, N$ **nezavisni i iscrpni**.
- Navedeno znači da dva događaja A_i i A_j , $i \neq j$, ne mogu da se dese istovremeno (nezavisnost) i da jedan od događaja A_i , $i = 1, 2, \dots, N$, mora da se desi (iscrpnost). U tom slučaju, može se pisati

$$\begin{aligned} P(B) &= P\{B \text{ i (siguran događaj)}\} = P\{B \text{ i } (A_1 \text{ ili } A_2 \text{ ili } \dots \text{ ili } A_N)\} \\ &= P(B|A_1)P(A_1) + P(B|A_2)P(A_2) + \dots + P(B|A_N)P(A_N). \end{aligned}$$

Bajesova teorema

- **Bajesova teorema** je data izrazom:

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{P(B|A_1)P(A_1) + P(B|A_2)P(A_2) + \cdots + P(B|A_N)P(A_N)}.$$

- Pošto je Bajesovski pristup od velikog značaja u savremenoj obradi podataka, u nastavku će mu biti posvećeno više detalja.
1. Događaj B je **prepostavljen** (**dokaz** se desio). Vjerovatnoća $P(B)$ pokazuje koliko je vjerovatan prepostavljeni događaj (dokaz) pod uslovom svih mogućih događaja (hipoteza) A_i . Navedeno se može zapisati u obliku
$$P(B) = P(B|A_1)P(A_1) + P(B|A_2)P(A_2) + \cdots + P(B|A_N)P(A_N)$$
 2. Specifični događaj A_i se naziva **hipoteza**, prepostavljajući da se događaj B desio. Vjerovatnoća $P(A_i)$ pokazuje koliko je vjerovatan događaj A_i (hipoteza), nezavisno od toga da li se događaj B desio.
 3. Vjerovatnoća $P(B|A_i)$ pokazuje koliko je vjerovatan događaj B (dokaz), pod uslovom da se događaj A_i desio (tj. pod uslovom da je hipoteza tačna).
 4. Rezultat $P(A_i|B)$ je vjerovatnoća događaja A_i (koliko je vjerovatna hipoteza A_i) uz činjenicu da se dokaz B desio.

Bajesova teorema – primjer

Primjer 3

Razmatraju se četiri slike, označene sa A_1, A_2, A_3 , i A_4 . U dvije slike (A_1 i A_2) postoji 20% crvenih piksela, u trećoj slici (A_3) postoji 30% crvenih piksela, dok u četvrtoj slici (A_4) postoji 50% crvenih piksela. Bira se slučajno jedna slika i posmatra se jedan njen piksel. Odabrani piksel je crvene boje (dokaz B). Koja je vjerovatnoća da je odabrana slika A_4 ?

- Vjerovatnoća da je slika A_4 odabrana (hipoteza A_4) kada se crveni piksel dobija kao dokaz (označeno kao B) jednaka je:

$$P(A_4|B) = \frac{P(B|A_4)P(A_4)}{P(B|A_1)P(A_1)+P(B|A_2)P(A_2)+P(B|A_3)P(A_3)+P(B|A_4)P(A_4)}.$$

- Vjerovatnoća da je dobijen crveni piksel, u oznaci $P(B)$, pod uslovom da su se desili svi mogući događaji (hipoteze) A_i , $i = 1, 2, 3, 4$, data je izrazom:

$$\begin{aligned} P(B) &= P(B|A_1)P(A_1)+P(B|A_2)P(A_2)+P(B|A_3)P(A_3)+P(B|A_4)P(A_4) \\ &= \frac{20}{100} \frac{1}{4} + \frac{20}{100} \frac{1}{4} + \frac{30}{100} \frac{1}{4} + \frac{50}{100} \frac{1}{4} = 0.3. \end{aligned}$$

Primjer 3 – rješenje

- Ova vjerovatnoća je dobijena kao suma po svim događajima A_i , i poznata je kao **marginalna vjerovatnoća**.
- Vjerovatnoća da se desila hipoteza A_4 , nezavisno od boje piksela (nezavisno od događaja B) je

$$P(A_4) = 1/4 = 0.25,$$

budući da postoje četiri slike, čiji je izbor jednak vjerovatan, $P(A_1) = P(A_2) = P(A_3) = P(A_4) = 1/4$.

- Vjerovatnoća $P(B|A_4)$ govori koliko je vjerovatan događaj B (dokaz u vidu crvenog piksela), pod uslovom da se događaj A_4 desio (hipoteza da je četvrta slika već odabrana). Njena vrijednost je

$$P(B|A_4) = \frac{50}{100} = 0.5,$$

budući da je 50% crvenih piskela u slici A_4 .

- Rezultujuća vjerovatnoća da je slika A_4 odabrana, pod uslovom da se događaj B desio (crveni piksel se pojavio) je jednaka:

$$P(A_4|B) = \frac{0.5 \times 0.25}{0.3} = 0.4167.$$

Primjer 4

Razvijen je sistem za testiranje virusa, za koji je poznata očekivana pouzdanost. Vjerovatnoća korektnih pozitivnih ili negativnih rezultata za testiranu osobu je veoma visoka, i jednaka je 0.978. Vjerovatnoća pogrešno pozitivnog (engl. *false-positive*) rezultata (testirana osoba nema virus, ali je test pozitivan) iznosi $P_{F+} = 0.018$. Vjerovatnoća pogrešno negativnog (engl. *false-negative*) rezultata (testirana osoba ima specificirani virus, ali je rezultat negativan) je $P_{F-} = 0.004$.

- Koliki je očekivani broj pozitivnih rezultata na 1000 testiranih osoba iz zemlje u kojoj je očekivani broj osoba zaraženih virusom:
 - ① 1 na 1000 osoba ($p = P(V) = 10^{-3}$);
 - ② 1 na 10,000 osoba ($p = P(V) = 10^{-4}$);
 - ③ 1.75 na 100 osoba ($p = P(V) = 0.0175$); i
 - ④ 25 na 100 osoba iz odabranog skupa za testiranje (koji je formiran na bazi prethodne evaluacije drugih simptoma)?
- Slučajno odabrana osoba se testirala na virus i rezultat je pozitivan. Odrediti vjerovatnoću da je ova osoba zaražena virusom u sva četiri prethodna slučaja.

Primjer 4 – rješenje

- Vjerovatnoća pozitivnog rezultata je jednaka sumi vjerovatnoće da testirana osoba nema virus i da je rezultat pozitivan, $(1 - P(V))P_{F+}$, i vjerovatnoće da osoba ima virus i da je rezultat pozitivan, $P(V)(1 - P_{F-})$.

- Navedeno znači da je test slučano odabrane osobe pozitivan sa vjerovatnoćom

$$P(+) = (1 - P(V))P_{F+} + P(V)(1 - P_{F-}) = (1 - p)P_{F+} + p(1 - P_{F-}).$$

- Za dati očekivani broj osoba zaraženih virusom, $p = P(V)$, dobijamo:

- ① $P(+) = 0.019$, što znači da će biti 10 pozitivnih rezultata na 1000 testiranih osoba, iako je očekivani odnos 1 na 1000, u ovom slučaju. Stoga, većina rezultata testa će biti pogrešno pozitivna.
- ② $P(+) = 0.0181$ potvrđuje da pogrešno pozitivni rezultati ponovo dominiraju u testu.
- ③ U ovom slučaju, dobija se $P(+) = 0.035$, što znači da polovina pozitivnih rezultata odgovara osobama koje su kontaminirane virusom, budući da bi ova vjerovatnoća, sa idealnim testom, značila da je 3.5 od 100 osoba kontaminirano.
- ④ Za odabranu grupu osoba sa simptomima, sa relativno visokom vjerovatnoćom da su zaraženi virusom, dobija se vjerovatnoća $P(+) = 0.2625$, što znači da je poklapanje sa očekivanim brojem kontaminiranih osoba visoko.

- Zaključak je da nasumično testiranje (engl. *random screening*) populacije ne može dati zadovoljavajuće rezultate ukoliko je vjerovatnoća pojave virusa mala a test nije idealan (ako test ne daje nula pogrešno pozitivnih i negativnih ishoda).

Primjer 4 – rješenje

- Testiranje treba raditi na prethodno odabrani skup ljudi. Ovaj zaključak je još jasniji u kontekstu Bajesove analize, date u nastavku.
- Kada se slučajno odabrana osoba testira, i rezultat je pozitivan, tada je *a posteriori* vjerovatnoća događaja da je osoba kontaminirana virusom, ukoliko je test pozitivan, $P(V|+)$, jednaka:

$$P(V|+) = \frac{P(+|V)P(V)}{P(+)} = \frac{(1 - P_{F-})P(V)}{(1 - P(V))P_{F+} + P(V)(1 - P_{F-})} = \frac{(1 - P_{F-})p}{(1 - p)P_{F+} + p(1 - P_{F-})},$$

gdje je $P(+|V)$ vjerovatnoća pozitivnog testa, ako je osoba kontaminirana virusom, $p = P(V)$ je vjerovatnoća da slučajna osoba ima virus, dok je $P(+)$ vjerovatnoća da je rezultat testa pozitivan, uključujući oba slučaja da osoba ima i da osoba nema virus.

- Za tri razmatrana slučaja, vrijednosti vjerovatnoće $P(V|+)$ su: (a) $P(V|+) = 0.0525$, (b) $P(V|+) = 0.0055$, i (c) $P(V|+) = 0.4964$.
- (d) Za odabrani skup osoba sa značajnom vjerovatnoćom da su kontaminirani virusom, dobija se $P(V|+) = 0.9486$, što znači visoku pouzdanost testa (ako je test pozitivan osoba je kontaminirana).
- Ovi rezultati potvrđuju zaključaka da *slučajno testiranje osoba ne treba raditi*, osim ukoliko je vjerovatnoća pojave virusa kod testiranih osoba povećana uslijed drugih simptoma, što znači da će skup testiranih osoba imati virus sa značajnom vjerovatnoćom.

Srednja vrijednost i varijansa

- Vidjeli smo da se **srednja (prosječna) vrijednost** računa za skup dostupnih uzoraka eksperimenta, te da je kao takva **slučajna po svojoj prirodi**.
- Ukoliko je dostupan probabilistički opis slučajne varijable (signala), tada je moguće predvidjeti srednju (prosječnu) vrijednost signala *bez korišćenja njegovih specifičnih realizacija*, odnosno, bez eksperimenata sa slučajnim pokušajima.
- Ovakva, **analitički dobijena**, srednja vrijednost, poznata je pod nazivom **očekivana vrijednost** i predstavlja pravu srednju vrijednost, koja bi se dobila na osnovu velikog broja eksperimenata. Ona je **deterministička veličina**.
- **Očekivana vrijednost** signala $x(n)$ se računa kao suma po skupu dostupnih amplituda, $\xi \in \mathbb{A} = \{\xi_1, \xi_2, \dots, \xi_N\}$, sa odgovarajućim vjerovatnoćama kao težinskim koeficijentima te sume, odnosno:

$$\mu_x(n) = E\{x(n)\} = \sum_{\xi \in \mathbb{A}} \xi P_{x(n)}(\xi).$$

- **Varijansa** odbirka slučajnog signala $x(n)$ koja uzima vrijednosti ξ iz slučajnog skupa $\mathbb{A} = \{\xi_1, \xi_2, \dots, \xi_N\}$, sa poznatim vjerovatnoćama, $P_{x(n)}(\xi_i)$, definiše se kao

$$\sigma_x^2(n) = E\{|x(n) - \mu_x(n)|^2\} = \sum_{\xi \in \mathbb{A}} |\xi - \mu_x(n)|^2 P_{x(n)}(\xi).$$

Srednja vrijednost i varijansa – primjer

Primjer 5

Slučajni signal $x(n)$ može uzeti vrijednosti iz skupa $\xi \in \mathbb{A} = \{0, 1, 2, 3, 4, 5\}$. Poznato je da je za $k = 0, 1, 2, 3, 4$ vjerovatnoća da je $x(n) = k$ dva puta veća od vjerovatnoće da je $x(n) = k + 1$.

Odrediti vjerovatnoće $P_{x(n)}(\xi_k) = P\{x(n) = k\}$. Odrediti očekivanu vrijednost i varijansu posmatranog slučajnog signala.

- Pretpostavimo da je $P\{x(n) = 5\} = A$ za $k = 5$. Tada su vjerovatnoće da $x(n)$ uzima vrijednosti k predstavljene u donjoj tabeli:

$\xi_k = k$	0	1	2	3	4	5
$P_{x(n)}(\xi_k) = P\{x(n) = k\}$	$32A$	$16A$	$8A$	$4A$	$2A$	A

- Konstanta A se može odrediti iz

$$\sum_{k=0}^5 P_{x(n)}(\xi_k) = 1.$$

Njena vrijednost je $A = 1/63$. Sada imamo:

$$\mu_x(n) = \mu_x = \sum_{k=0}^5 kP_{x(n)}(\xi_k) = \frac{19}{21} \quad \text{i} \quad \sigma_x^2(n) = \sigma_x^2 = \sum_{k=0}^5 \left(k - \frac{19}{21}\right)^2 P_{x(n)}(\xi_k) = \frac{626}{441}.$$

Funkcija gustine vjerovatnoće

- Ako slučajni signal može uzeti **kontinualne vrijednosti** po amplitudi, tada se ne može definisati vjerovatnoća da odbirak signala $x(n)$ može uzeti jednu egzaktnu vrijednost amplitude ξ .
- U ovom slučaju, koristi se **funkcija gustine vjerovatnoće** $p_{x(n)}(\xi)$ (engl. *probability density function*).
- Ova funkcija definiše vjerovatnoću da n -ti odbirak signala $x(n)$ uzima vrijednost unutar infinitezimalno malog intervala $d\xi$ oko ξ ,

$$P\{\xi \leq x(n) < \xi + d\xi\} = p_{x(n)}(\xi)d\xi.$$

- Funkcija gustine vjerovatnoće $p_{x(n)}(\xi)$ posjeduje sljedeća svojstva:
 1. Nenegativnost, $p_{x(n)}(\xi) \geq 0$ za bilo koje ξ
 2. Pošto je $P\{-\infty < x(n) < \infty\} = 1$, to mora važiti:

$$\int_{-\infty}^{\infty} p_{x(n)}(\xi)d\xi = 1.$$

- Vjerovatnoća da je vrijednost signala $x(n)$ unutar intervala $a < x(n) \leq b$ je data izrazom:

$$P\{a < x(n) \leq b\} = \int_a^b p_{x(n)}(\xi)d\xi.$$

Funkcija gustine vjerovatnoće

- **Kumulativna funkcija raspodjele** (engl. *cumulative probability distribution – CDF*) $F_x(\chi)$ se definiše kao vjerovatnoća da je vrijednost signala $x(n)$ manja od χ ,

$$F_x(\chi) = \text{P}\{x(n) \leq \chi\} = \int_{-\infty}^{\chi} p_{x(n)}(\xi) d\xi.$$

- Očigledno, važi $\lim_{\chi \rightarrow -\infty} F_x(\chi) = 0$, $\lim_{\chi \rightarrow +\infty} F_x(\chi) = 1$, kao i:

$$\text{P}\{a < x(n) \leq b\} = \int_a^b p_{x(n)}(\xi) d\xi = F_x(b) - F_x(a),$$

gdje je $F_x(b) \geq F_x(a)$ za $b > a$.

- Kumulativna funkcija raspodjele je **neopadajuća funkcija**.
- Funkcija gustine vjerovatnoće $p_{x(n)}(\xi)$ je jednaka izvodu funkcije raspodjele $F_x(\xi)$:

$$p_{x(n)}(\xi) = \frac{dF_x(\xi)}{d\xi}.$$

- **Očekivana vrijednost** slučajne varijable $x(n)$, čiji odbirci uzimaju kontinualne vrijednosti amplitude, može se izraziti preko funkcije gustine vjerovatnoće:

$$\mu_x(n) = \text{E}\{x(n)\} = \int_{-\infty}^{\infty} \xi p_{x(n)}(\xi) d\xi.$$

Funkcija gustine vjerovatnoće

- Za slučajne signale čiji odbirci uzimaju kontinualne vrijednosti amplitude **varijansa** se definiše izrazom:

$$\sigma_x^2(n) = \int_{-\infty}^{\infty} |\xi - \mu_x(n)|^2 p_{x(n)}(\xi) d\xi,$$

gdje je $p_{x(n)}(\xi)$ funkcija gustine raspodjele.

Primjer 6

Razmatra se realni slučajni signal $x(n)$, čiji su odbirci uniformno distribuirani na intervalu $-1 \leq x(n) < 1$.

- Odrediti očekivanu vrijednost i varijansu odbiraka signala $x(n)$.
 - Signal $y(n)$ se dobija kao $y(n) = x^2(n)$. Odrediti očekivanu vrijednost i varijansu signala $y(n)$.
- Budući da je slučajni signal $x(n)$ uniformno distribuiran na intervalu $-1 \leq x(n) < 1$, njegova funkcija gustine vjerovatnoće je data izrazom:

$$p_{x(n)}(\xi) = \begin{cases} A & \text{za } -1 \leq \xi < 1 \\ 0 & \text{drugdje.} \end{cases}$$

Primjer 6 – rješenje

- Vrijednost konstante A , $A = 1/2$, se može jednostavno dobiti iz $\int_{-\infty}^{\infty} p_{x(n)}(\xi) d\xi = 1$.
- Očekivana vrijednost i varijansa su date izrazima:

$$\mu_x(n) = \int_{-\infty}^{\infty} \xi p_{x(n)}(\xi) d\xi = \int_{-1}^1 \frac{1}{2} \xi d\xi = 0,$$

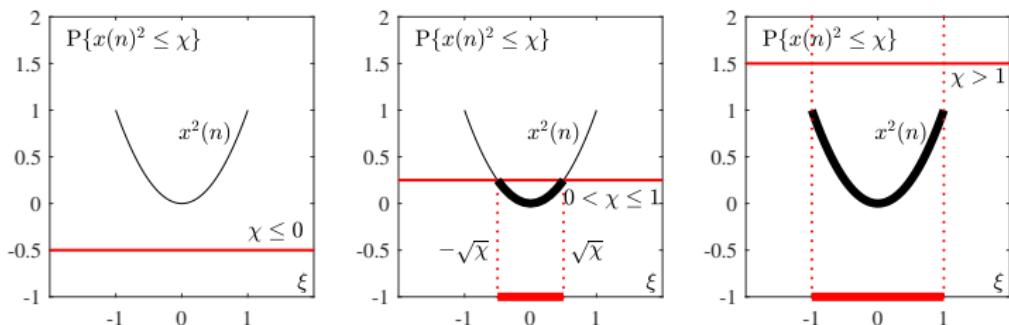
$$\sigma_x^2(n) = \int_{-\infty}^{\infty} (\xi - \mu_x(n))^2 p_{x(n)}(\xi) d\xi = \int_{-1}^1 \frac{1}{2} \xi^2 d\xi = \frac{1}{3}.$$

- Vjerovatnoća da amplituda signala $y(n)$ nije veća od prepostavljene vrijednosti χ predstavlja, po definiciji, distribuciju vjerovatnoće za $y(n)$. Ona je data sljedećim izrazom:

$$F_y(\chi) = P\{y(n) \leq \chi\} = P\{x^2(n) \leq \chi\} = P\{-\sqrt{\chi} \leq x(n) \leq \sqrt{\chi}\}$$
$$= \begin{cases} 0 & \text{za } \chi \leq 0 \\ \int_{-\sqrt{\chi}}^{\sqrt{\chi}} p_{x(n)}(\xi) d\xi & \text{za } 0 < \chi \leq 1 \\ 1 & \text{za } \chi > 1 \end{cases} = \begin{cases} 0 & \text{za } \chi \leq 0 \\ \sqrt{\chi} & \text{za } 0 < \chi \leq 1 \\ 1 & \text{za } \chi > 1, \end{cases}$$

pošto je $y(n) \leq \chi$, kada $x^2(n) \leq \chi$, kao što je ilustrovano na slici (naredni slajd).

Primjer 6 – rješenje



Slika: Ilustracija računanja distribucije vjerovatnoće $F_y(\chi)$ za $y(n) = x^2(n)$ i $-1 \leq x(n) \leq 1$.

- Funkcija gustine vjerovatnoće se dobija kao izvod od funkcije raspodjele $F_y(\chi)$, odnosno:

$$p_{y(n)}(\xi) = \frac{dF(\xi)}{d\xi} = \begin{cases} \frac{1}{2\sqrt{\xi}} & \text{za } 0 < \xi \leq 1 \\ 0 & \text{inače.} \end{cases}$$

- Očekivana vrijednost i varijansa signala $y(n)$ je:

$$\mu_y(n) = \mu_y = \int_0^1 \xi \frac{1}{2\sqrt{\xi}} d\xi = \frac{1}{3}, \quad \sigma_y^2(n) = \sigma_y^2 = \int_0^1 (\xi - \frac{1}{3})^2 \frac{1}{2\sqrt{\xi}} d\xi = \frac{4}{45}.$$

Funkcija gustine vjerovatnoće – primjer

Primjer 7

- Odrediti funkciju gustine vjerovatnoće za $y(n)$ u slučaju proizvoljne monotone funkcije $y(n) = f(x(n))$ čija je inverzna funkcija $f^{-1}(y(n)) = x(n)$, pri čemu je funkcija gustine vjerovatnoće od $x(n)$ jednaka $p_{x(n)}(\xi)$.
- Odrediti izraz za funkciju gustine vjerovatnoće $p_{y(n)}(\xi)$, ako je $x(n)$ slučajna varijabla sa uniformnom funkcijom raspodjele unutar intervala $[-\pi/2, \pi/2]$ dok je $y(n) = \tan(x(n))$, dok je odgovarajuća inverzna funkcija $x(n) = \arctan(y(n))$?
- Distribucija vjerovatnoće slučajnog signala $y(n)$ data je sljedećim izrazom:

$$F_y(\chi) = P\{y(n) \leq \chi\} = P\{f(x(n)) \leq \chi\} = P\{x(n) \leq f^{-1}(\chi)\} = \int_{-\infty}^{f^{-1}(\chi)} p_{x(n)}(\xi) d\xi,$$

odnosno

$$F_y(\chi) = F_x(f^{-1}(\chi)).$$

- Funkcija gustine vjerovatnoće je:

$$p_{y(n)}(\xi) = \frac{dF_y(\xi)}{d\xi} = \frac{dF_x(f^{-1}(\xi))}{d\xi} = p_{x(n)}(f^{-1}(\xi)) \left| \frac{df^{-1}(\xi)}{d\xi} \right|.$$

Primjer 7 – rješenje

- Ova relacija se može takođe dobiti na osnovu činjenice da vjerovatnoća u diferencijalno maloj površini mora biti invarijantna na smjenu varijabli, tj.

$$|p_{y(n)}(\xi)d\xi| = |p_{x(n)}(f^{-1}(\xi))df^{-1}(\xi)|.$$

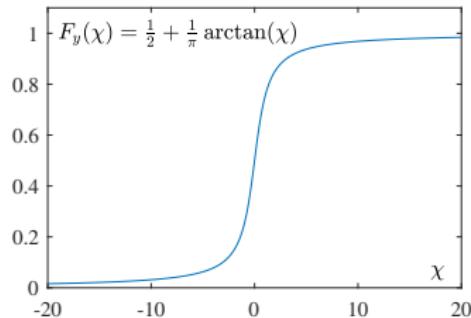
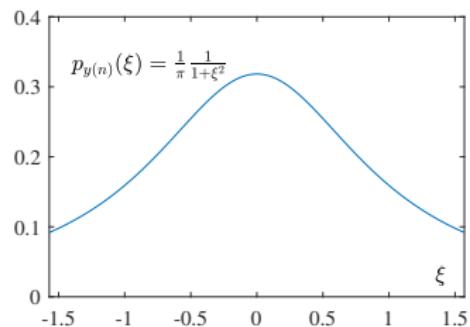
- Za slučajni signal $x(n)$, sa uniformnom funkcijom gustine vjerovatnoće unutar intervala $[-\pi/2, \pi/2]$, slučajna varijabla $y(n) = \tan(x(n))$ je distribuirana od $-\infty$ do ∞ . Njena funkcija gustine vjerovatnoće je:

$$p_{y(n)}(\xi) = p_{x(n)}(\arctan(\xi)) \left| \frac{d(\arctan(\xi))}{d\xi} \right| = \frac{1}{\pi} \frac{1}{1+\xi^2},$$

pošto je $p_{x(n)}(\xi) = 1/\pi$, za $-\pi/2 \leq \xi < \pi/2$.

- Slučajni signal $y(n)$ može uzeti velike vrijednosti sa značajnom vjerovatnoćom, pošto je funkcija raspodjele: $F_y(\chi) = (1/2 + \arctan(\chi)/\pi)$.
- Slučajni signali čija raspodjela vjerovatnoće (CDF) nije eksponencijalno ograničena, odnosno, koji imaju teže (veće) vrijednosti tzv. "repova" (engl. *heavy tails*), poznati su kao signali sa **heavy-tailed funkcijom gustine vjerovatnoće**.
- U ovom slučaju, zadovoljen je uslov za *heavy-tailed* funkciju $\lim_{\chi \rightarrow \infty} (F_y(\infty) - F_y(\chi)) e^{a\chi} = \infty$ za svako $a > 0$.

Heavy-tailed distribucije



Slika: Ilustracija *heavy-tailed* funkcije gustine vjerovatnoće $p_{y(n)}(\xi)$ i kumulativne funkcije raspodjele $F_y(\chi)$, gdje je $y(n) = \tan(x(n))$ i $x(n) = \arctan(y(n))$.

- Po definiciji, *heavy-tailed* distribucija ima „rep“ koji je veći od eksponencijalne funkcije, odnosno, ovakva distribucija teži nuli sporije od one koja je eksponencijalna.
- *Heavy-tailed* distribucije tipično imaju više *outlier*-a sa velikim vrijednostima, što je proporcionalno „težini“ repa, i za njih ne postoje neki momenti.
- Neki predstavnici *heavy-tailed* distribucija su: Košijeva, Studentova, LogNormal distribucija, i druge.
- Nasuprot njima, postoje i *light-tailed* distribucije, koje imaju „rep“ koji je „lakši“, odnosno, niži, od eksponencijalne. Primjeri su normalna i *t*-distribucija.

Združena funkcija gustine vjerovatnoće

- Kao uvod u statistiku drugog reda, posmatrajmo dva signala, $x(n)$ i $y(m)$, sa kontinualnim vrijednostima amplituda.
- Vjerovatnoća da n -ti odbirak signala $x(n)$ uzima vrijednost unutar intervala $\xi \leq x(n) < \xi + d\xi$ i da $y(m)$ uzima vrijednost unutar $\zeta \leq y(m) < \zeta + d\zeta$ je:

$$P\{\xi \leq x(n) < \xi + d\xi, \zeta \leq y(m) < \zeta + d\zeta\} = p_{x(n),y(m)}(\xi, \zeta)d\xi d\zeta,$$

gdje je $p_{x(n),y(m)}(\xi, \zeta)$ **združena funkcija gustine vjerovatnoće**.

- Vjerovatnoća događaja $a < x(n) \leq b$ i $c < y(m) \leq d$ je:

$$P\{a < x(n) \leq b, c < y(m) \leq d\} = \int_a^b \int_c^d p_{x(n),y(m)}(\xi, \zeta)d\xi d\zeta.$$

- Za **međusobno nezavisne** signale važi: $p_{x(n),y(m)}(\xi, \zeta) = p_{x(n)}(\xi)p_{y(m)}(\zeta)$. Specijalni slučaj prethodnih relacija se dobija za $y(m) = x(m)$.

Primjer 8

Signal $x(n)$ je definisan kao $x(n) = a(n) + b(n) + c(n)$, gdje su $a(n)$, $b(n)$, i $c(n)$ međusobno nezavisni slučajni signali sa uniformnom funkcijom gustine vjerovatnoće na intervalu $[-1, 1]$. Odrediti funkciju gustine vjerovatnoće signala $x(n)$, njegovu srednju vrijednost μ_x i varijansu σ_x^2 .

Primjer 8 – rješenje

- Posmatrajmo prvo sumu dva nezavisna slučajna signala $s(n) = a(n) + b(n)$.
- Vjerovatnoća da važi $s(n) = a(n) + b(n) \leq \chi$ može biti izračunata na osnovu združene funkcije raspodjele slučajnih signala $a(n)$ i $b(n)$:

$$\begin{aligned} F_s(\chi) &= P\{s(n) \leq \chi\} = P\{-\infty < a(n) < \infty \text{ i } -\infty < b(n) \leq \chi\} \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\chi-\xi} p_{a(n), b(n)}(\xi, \zeta) d\xi d\zeta = \int_{-\infty}^{\infty} \left(p_{a(n)}(\xi) \int_{-\infty}^{\chi-\xi} p_{b(n)}(\zeta) d\zeta \right) d\xi. \end{aligned}$$

- Sada se može izračunati funkcija gustine raspodjele za $s(n)$, kao izvod od $F_s(\chi)$, odnosno:

$$\begin{aligned} p_{s(n)}(\chi) &= \frac{dF_s(\chi)}{d\chi} = \int_{-\infty}^{\infty} \left(p_{a(n)}(\xi) \frac{d}{d\chi} \left(\int_{-\infty}^{\chi-\xi} p_{b(n)}(\zeta) d\zeta \right) \right) d\xi \\ &= \int_{-\infty}^{\infty} p_{a(n)}(\xi) p_{b(n)}(\chi - \xi) d\xi = p_{a(n)}(\chi) *_{\chi} p_{b(n)}(\chi), \end{aligned}$$

što znači da je funkcija gustine raspodjele zbira dvije nezavisne slučajne varijable jednaka konvoluciji pojedinačnih funkcija raspodjele.

Primjer 8 – rješenje

- Na sličan način, u slučaju tri signala se dobija da se funkcija gustine raspodjele može izračunati kao konvolucija:

$$p_{x(n)}(\chi) = p_{a(n)}(\chi) *_{\chi} p_{b(n)}(\chi) *_{\chi} p_{c(n)}(\chi),$$

$$p_{x(n)}(\chi) = \begin{cases} \frac{(\chi+3)^2}{16} & \text{for } -3 \leq \chi \leq -1 \\ \frac{3-\chi^2}{8} & \text{za } -1 < \chi \leq 1 \\ \frac{(\chi-3)^2}{16} & \text{za } 1 < \chi \leq 3 \\ 0 & \text{za } |\chi| > 3. \end{cases}$$

- Srednja vrijednost i varijansa se mogu izračunati pomoću funkcije gustine raspodjele $p_{x(n)}(\chi)$, ili direktnim putem, uz korišćenje svojstva linarnosti:

$$\mu_x = E\{x(n)\} = E\{a(n)\} + E\{b(n)\} + E\{c(n)\} = 0$$

$$\begin{aligned}\sigma_x^2 &= E\{(x(n) - \mu_x)^2\} = E\{(a(n) + b(n) + c(n))^2\} \\ &= E\{a^2(n)\} + E\{b^2(n)\} + E\{c^2(n)\} + 2(\mu_a\mu_b + \mu_a\mu_c + \mu_b\mu_c) \\ &= \frac{1}{3} + \frac{1}{3} + \frac{1}{3} = 1.\end{aligned}$$

Združena funkcija gustine vjerovatnoće – primjer 9

Primjer 9

Razmatraju se dva nezavisna slučajna signala $x(n)$ i $y(n)$, sa funkcijama gustine vjerovatnoće $p_{x(n)}(\xi)$ i $p_{y(n)}(\xi)$. Novi slučajni signal se definiše tako da uzima manju od vrijednosti signala $x(n)$ i $y(n)$ svakom trenutku n , odnosno:

$$z(n) = \min\{x(n), y(n)\}.$$

- Odrediti raspodjelu vjerovatnoće i funkciju gustine vjerovatnoće slučajnog signala $z(n)$.
- Čemu je jednaka funkcija raspodjele signala $z(n)$ ako su:

$$p_{x(n)}(\xi) = \frac{1}{\beta_x} e^{-\xi/\beta_x} u(\xi) \quad \text{i} \quad p_{y(n)}(\xi) = \frac{1}{\beta_y} e^{-\xi/\beta_y} u(\xi)?$$

- Pošto slučajni signal $z(n)$ uzima manju od vrijednosti $x(n)$ i $y(n)$, vjerovatnoća da je $z(n) = \min\{x(n), y(n)\}$ manje ili jednako od prepostavljene vrijednosti χ jednaka je vjerovatnoći da je najmanje jedan od slučajnih odbiraka $x(n)$ i $y(n)$ ispod prepostavljene vrijednosti χ :

$$\begin{aligned} P\{z(n) \leq \chi\} &= P\{\min\{x(n), y(n)\} \leq \chi\} \\ &= 1 - P\{x(n) > \chi \text{ i } y(n) > \chi\} = 1 - P\{x(n) > \chi\}P\{y(n) > \chi\}. \end{aligned}$$

Primjer 9 – rješenje

- Pošto je

$$P\{x(n) > \chi\} = 1 - F_x(\chi) \quad \text{i} \quad P\{y(n) > \chi\} = 1 - F_y(\chi),$$

dobijamo funkciju raspodjele slučajne varijable $z(n)$ u obliku:

$$\begin{aligned}F_z(\chi) &= P\{z(n) \leq \chi\} = 1 - (1 - F_x(\chi))(1 - F_y(\chi)) \\&= F_x(\chi) + F_y(\chi) - F_x(\chi)F_y(\chi).\end{aligned}$$

- Funkcija gustine raspodjele se dobija kao izvod funkcije raspodjele vjerovatnoće:

$$\begin{aligned}p_{z(n)}(\xi) &= \frac{dF_z(\xi)}{d\xi} = p_{x(n)}(\xi) + p_{y(n)}(\xi) - p_{x(n)}(\xi)F_y(\xi) - F_x(\xi)p_{y(n)}(\xi) \\&= p_{x(n)}(\xi)(1 - F_y(\xi)) + p_{y(n)}(\xi)(1 - F_x(\xi)).\end{aligned}$$

- Za specifične funkcije gustine raspodjele iz postavke zadatka, dobija se:

$$p_{z(n)}(\xi) = \frac{1}{\beta_z} e^{-\xi/\beta_z} u(\xi)$$

sa $\frac{1}{\beta_z} = \frac{1}{\beta_x} + \frac{1}{\beta_y}$, pošto je:

$$F_x(\xi) = (1 - \exp(-\xi/\beta_x))u(\xi) \quad \text{i} \quad F_y(\xi) = (1 - \exp(-\xi/\beta_y))u(\xi)$$

Izvod integrala sa varijabilnom granicom

Napomenimo da po drugoj fundamentalnoj teoremi matematičke analize, po kojoj je $\frac{d}{dx} \int_a^x h(t)dt = h(x)$, i pravilu ulančavanja, važi sljedeće:

$$\frac{d}{dx} \int_a^{f(x)} h(t)dt = h(f(x))f'(x),$$

gdje je pretpostavljeno da su odgovarajuće funkcije neprekidne i diferencijabilne, dok a predstavlja konstantu.