TEHNIČKO MODELIRANJE DOGAĐAJIMA

Kalman Žiha
Sveučilište u Zagrebu
Fakultet strojarstva i brodogradnje
Zavod za brodogradnju i pomorsku tehniku
Ivana Lućića 5, Zagreb
E-mail: kziha@fsb.hr, Tel: (01) 6168132, Fax: (01) 6156940

SAŽETAK Rad prikazuje tehničko modeliranje primjenom vjerojatnosne sustavne analize usmjerene događajima. Djelovanja tehničkih predmeta u radu se predočavaju sa potpunim ili nepotpunim sustavima događaja, sastavljenih od raznih podsustava događaja. Sustavna analiza usmjerena događajima se odnosi na važne podsustave tehničkih predmeta kao što su djelotvorni ili nedjelotvorni događaji te na njihove međusobne odnose. Sama je analiza primjenjiva na tehničke sustave sa različitim odnosima među događajima, kao što su isključivi i neisključivi, zavisni i nezavisni događaji. Sustavi i podsustavi se nadalje podvrgavaju analizama vjerojatnosti i neizvjesnosti. Analiza neizvjesnosti se zasniva na entropiji. Opći odnosi između vjerojatnostima, neizvjesnostima sustava i podsustava se određuju na osnovi teorije informacija. Analize sustava usmjerene događajima ukazuju na moguća poboljšanja u projektiranju i korištenju tehničkih predmeta.

TECHNICAL MODELLING BY EVENTS The article presents technical modelling based on probabilistic event oriented system analysis. Operations of technical objects are represented as either complete or incomplete systems of events and as compounds of various subsystems of events. The event oriented system analysis investigates important subsystems in technical systems, such as operational modes and failure modes, and their interrelations. The analysis is also applicable to the technical systems with various relations among the sets of events, such as mutually exclusive and inclusive sets. Furthermore, the systems and subsystems are subjected to probability and uncertainty analysis. The system uncertainty analysis is based on entropy. General relations among the probabilities, uncertainties of the system and uncertainties of the subsystems are derived by using information theory. The event oriented system analysis indicates potential improvements in system design and utilisation.

1. Uvod

Svaki se tehnički predmet može izučavati inženjerskim sredstvima kao sustav sastavljen od podsustava različitih tvarnih sastavnica na više načina ali i sam kao podsustav nekog drugog nadsustava. Djelovanja predmeta koji u ponašanju iskazuju nepredvidljivosti, pogotovo u okolišu čije je djelovanje izrazito slučajne naravi, mogu se proučavati vjerojatnosnim i statističkim postupcima. Djelovanja predmeta se mogu promatrati ne samo na osnovi njihovih tvarnih i tehničkih svojstava, nego i na osnovi mogućih događaja u službi u vijeku njihova postojanja. Mnogi su zamjetni događaji vezani uz djelovanje nekog predmeta manje ili više važni za njegovu opstojnost. Mogu se zamisliti i manje zamjetni, nepoznati, neodređeni, kao i međusobno nezavisni i zavisni događaji. Poznavanje pojedinačnih slučajnih događaja je važno za primjenu teorije vjerojatnosti. Međutim, poznavanja sustava i podsustava slučajnih događaja pružaju dodatne uvide u djelovanja te osiguravaju bolje razmijevanje i sveobuhvatniju analizu, projektiranje, korištenje i održavanje tehničkih predmeta.

Svi dokučivi događaji vezani za djelovanje nekog predmeta mogu se promatrati kao sustav događaja koji opisuje moguće ishode u sudjelovanju predmeta u njegovoj okolini. Ovisno o poznavanju događaja svojstvenih nekom predmetu, sustavi se mogu promatrati kao putpuni i manje ili više nepotpuni sustavi događaja. Mnogi se događaji po svojoj naravi, važnosti, posljedicama ili nekim drugim mjerilima, mogu svrstavati u podsustave događaja na više razina. Proučavanje podsustava događaja i njihovih međusobnih veza u okviru cijelog sustava, omogućuje sagledavanje ukupnog djelovanja predmeta u svojoj okolini. Predočavanjem djelovanja predmeta sustavom događaja, obični se vjerojatnosni pristup može proširiti konceptom entropije u vjerojatnosti. Još je važnije to što se otvara mogućnost primjene teorije informacija na djelovanje tehničkih predmeta. Ovakvim se pristupom djelovanja predmeta mogu proučavati na druge načine, važnim za ocjenjivanje sposobnosti prilagodbe zahtjevima i izazovima koje pred njih postavljaju okolišni uvjeti.

U radu se opisuje postupak modeliranja djelovanja tehničkih predmeta u njihovu vijeku postojanja sustavima i podsustavima slučajnih događaja. Primjenjuju se teorija vjerojatnosti i teorija informacija za sagledavanje djelovanja predmeta ocjenom njihove redundantnosti i robustnosti u slučajnim uvjetima okoline. To se postiže na osnovi razmatranja uvjetnih entropija potpunih ili nepotpunih sustava i podsustava odgovarajućih događaja. Opisani pristup osim teoretskih razmatranja, pruža i mogućnosti za mnoga praktična rješenja i poboljšanja u projektiranju, korištenju i održavanju tehničkih predmeta.

Složeni se tehnički predmeti općenito podvrgavaju analizama načina djelovanja radi određivanja događaja koji se mogu dogoditi na razinama sastavnica, podsustava i sustava. Cilj je takvih analiza određivanje učinka zamjetljivih događaja na ukupno djelovanja sustava [1, 2, 3]. Kvantitatvnim se postupcima pokušavaju utvrditi vjerojatnosti sigurnog djelovanja ili nastupanja pogrešaka ili oštećenja sustava u radu [4, 5]. Već je ranije uočeno da su redundantnosti [6, 7] i robustnosti [8] važna svojstva sustava većine djelujućih tehničkih predmeta. Analize načina djelovanja tehničkih predmeta su bitan preduvjet za razumijevanje djelovanja složenih predmeta bez čega se ne može niti zamisliti analiza pouzdanosti i neizvjesnosti.

2. Modeliranje neizvjesnosti

Brojne se neizvjesnosti javljaju u razmatranju tehničkih predmeta i različiti su postupci za njihova proučavanja. U opće prihvaćenom pristupu modeliranju sa slučajnim varijablama, neizvjesnosti su posljedica slučajnih svojstava materijala, geometrije, izrade, opterećenja, uvjeta službovanja kao i subjektivnih slučajnosti i neznanja vezanih za projektiranje i korištenje. Sustavna analiza u tim okvirima, primjenom teorije vjerojatnosti i statistike može dati pouzdanosti ili vjerojatnosti oštećenja na osnovi slučajnih svojstava sastavnica.
Uobičajeni vjerojatnosni pristup diskretnim tehničkim sustavima (mehaničkim, strukturnim, električnim, pomorskim, nuklearnim itd.), sa neizvjesnim svojstvima i u neizvjesnim okolnostima rada, uzima u obzir slučajna tvarna i tehnička svojstva sastavnica i slučajna djelovanja okoline na opstojnost predmeta.
Pojmu neizvjesnosti se obzirom na slučajne događaje valja pridjeliti točniji, jednoznačni smisao [9]. Pod neizvjesnošću se u odnosu na brojne slučajne događaje podrazumijeva objektivna neizvjesnost zbog istinske mogućnosti da se više slučajnih događaja može ostvariti i zbog nemogućnosti predviđanja njihova ishoda, a ne subjektivna neizvjesnost u svijesti promatrača zbog ishoda nekog pokusa.
Uz značenje pojma neizvjesnosti se vezuje i pojam informacija. Neizvjesnost izčezava sagledavanjem odgovarajućih informacija. Neizvjesnost ishoda se može izjednačiti sa informacijom nakona ishoda., tako da se ova dva pojma se često koriste izmjenično. Neizvjesnost, kao i informacija se mogu mjeriti, pri čemu se koristi pojam entropije. Pojam entropije je prvo primjenjen u teoriji informacija na prijenos informacija [10, 11, 12, 13]. Potom je proširen kao entropijski koncept u vjerojatnosti dajući dobru osnovu za ocjene neizvjesnosti sustava [14]. Ustanovljena je i jaka veza između pojma entropije u teoriji informacija i u termodinamici [15]. Informacija se s jedne strane promatra kao osnovni koncept i objektivna kategorija kao materija i energija [16] a sdruge strane kao subjektivni koncept jer predmijeva postojanje svjesnog subjekta, promatrača sa sposobnošću interpretacije za kojega informacija ima značenje.
U radu se primjenjuje Shannonova entropija za ocjenu neizvjesnosti potpunih sustava i podsustava događaja. Uz osnovnu definiciju entropije koja se odnosi na potpune sustave događaja, Renyieva entropija se koristi za ocjene neizvjesnosti nepotpunih sustava događaja [17]. Teorem o mješavini razdioba i teorem o zavisnim sustavima događaja mogu se koristiti za ocjene neizvjesnosti podsustava [18]. Za tehničko modeliranje događajima može biti zornije neizvjesnosti izraziti u odnosu na najveću moguću entropiju [19].
Tehnički se predmeti mogu promatrati i na drugi način. Cilj primjene događajima usmjerene sustavne analize je u proučavanju ne samo tvarnih i tehničkih sastavnica nego i svih zamjetljivih ili barem svih važnijih događaja u djelovanju predmeta u radnom vijeku [20]. U najširem se smislu tehnički predmeti u svome djelovanju mogu promatrati kao djelotvorni i nedjelotvorni i to na različitim razinama. Većina su stanja djelotvornosti tehničkih predmeta zamjetljiva ali sigurno postoje i nezamjetljiva, neodređena, nepoznata i na koncu i manje važna stanja kao i neka stanja zajednička različitim svojstvima predmeta. Stanja tehničkih predmeta se mogu predočavati sustavima i podsustavima slučajnih događaja u različitim odnosima i na više razina. Uvjetne se entropije djelotvornih i nedjelotvornih događaja mogu interpretirati kao redundantnosti i robustnosti djelovanja predmeta u radnom vijeku [21].

3. Mjere neizvjesnosti

Neizvjesnost pojedinačnog slučajnog događaja A s vjerojatnošću $p=p(A)\neq 0$ od osnovnog je značaja u teoriji informacija i izražava se sa $E=H_1(p)=-\log_2 p(A)$ [12]. Interpretira se ili kao neizvjesnost, koliko je događaj bio neočekivan ili kao informacija koja se ostvari njegovim događanjem [22].

Mnogo je važnije od jednog događaja promatrati sustave događaja. Sami se događaji smatraju apstraktnim konceptom i pristupa im se aksiomatski. Algebarska struktura sustava događaja se može svesti na Boolovu algebru [17].
Sustav događaja: $E_1, E_2, \ldots , E_n$ se smatra potpunim sustavom ako vrijede slijedeći odnosi:

$$E_k \neq \varnothing \quad (k = 1,2,\cdots,n) \tag{1}$$

$$E_j E_k = \varnothing \quad (\mathit{for}\ j \neq k) \tag{2}$$

$$E_1 + E_2 + \cdots + E_n = I \tag{3}$$

- Znak "$\varnothing$" u (1) i (2) označava nemogući događaj.
- Činjenicu da su E_j i E_k međusobno isključivi događaji izražava (2).
- Izraz (3) označava da se mora dogoditi barem jedan događaj E_k, $k = 1, 2, \ldots, n$.

- Znak "*I*" označava siguran događaj.

Definicija potpunog i nepotpunog sustava događaja u prostoru vjerojatnosti podrazumijeva:

- Sustav događaja E_k, $k=1, 2, ...,n$, je potpun ako je za $i\neq j$, $A_i A_j = \emptyset$, i ako je događanje nekog događaja skoro sigurno, odnosno ako je $p(\sum_k E_k) = \sum_k p(E_k) = 1$. Predmijeva se da se u svakom pokusu može dogoditi samo jedan događaj.
- Ako neki ishodi nisu poznati, ili su njihove vjerojatnosti nepoznate, ili ako su samo neki događaji zamjetni i uzeti u razmatranje, govori se o nepotpunom sustavu jer je $\sum_k p(E_k) < 1$.

3.1. Neizvjesnosti potpunih sustava događaja

Za kvantitativne analize sustava događaja u matematici je dostatno prikazati ih samo sa razdiobom vjerojatnosti. Međutim za složene tehničke probleme pogodnije je sustave i podsustave događaja predstavljati oznakama događaja i pripadnim vjerojatnostima kao konačne sheme [14]. Promotrimo sustav $\mathcal{S}$ sastavljen od događaja E_i, $i=1,2,...,n$, sa pripadnim vjerojatnostima $p_i=p(E_i)$, prikazan u obliku konačne sheme:

$$\mathcal{S} = \begin{pmatrix} E_1 & E_2 & \cdots & E_n \\ p_1 & p_2 & \cdots & p_n \end{pmatrix}$$

Entropija konačnog sustava $\mathcal{S}$ predpostavljeno ovisi samo o razdiobi vjerojatnosti $\mathcal{P} = (p_1, p_2, ..., p_n)$ i može se zapisati na nekoliko načina [13]:

$$H(\mathcal{S}) = H_n(\mathcal{S}) = H_n(p_1, p_2, ..., p_n) =$$

$$= H_n(\mathcal{P}) = -\sum_{i=1}^{n} p_i \log p_i = \sum_{i=1}^{n} p_i \log \frac{1}{p_i} \qquad (4)$$

Veličina (4) se naziva entropijom potpunih razdioba ili entropijom potpunih sustava događaja i označava se kao Shannonova entropija ili Shannonova informacija.

3.2. Neizvjesnosti nepotpunih sustava događaja

Druga mjera neizvjesnosti je is Renyieva entropija reda α, koja se za $\alpha\neq 1$, definira kako slijedi:

$$H_n^{\alpha}(\mathcal{S}) = H^{\alpha}(\mathcal{S}) = \frac{1}{1-\alpha} \log_2 (\sum_{i=1}^{n} p_i^{\alpha} / \sum_{i=1}^{n} p_i) \qquad (5)$$

Entropija nepotpunog sustava $\mathcal{S}$ se može promatrati kao granični slučaj od (5) za $\alpha\to 1$ i dade se interpretirati kao aritmetička sredina (očekivanje) pojedinih entropija $-\log p_i$ s težinama p_i. Sam je Renyi ovu veličinu nazivao Shannonovom entropijom prvog reda:

$$H_n^{1}(\mathcal{S}) = H^{1}(\mathcal{S}) = (-\sum_{i=1}^{n} p_i \log p_i) / \sum_{i=1}^{n} p_i \qquad (6)$$

Veličina (6) se često označava kao Renyieva entropija prvog reda [22]. U radu se korisiti oznaka Renyi/Shannononova entropija prvog reda.

3.3. Svojstva mjera neizvjesnosti

Neka su svojstva entropije važna za tehničke probleme modeliranja navedena u nastavku.

- Odabir jedinica neizvjesnosti je proizvoljan kao i za bilo koju drugu fizikalnu veličini. Na primjer, ako je u izrazima (4, 5, i 6) primjenjen logaritam sa bazom 2, jedinica entropije se označava sa 1 bit. Jedan bit je neizvjesnost dva događaja sa istim vjerojatnostima. Ako se primjeni prirodni logaritam jedinica se naziva 1 nit.
- Ishodi s vjerojatnošću nula ne mjenjaju neizvjesnost. Po dogovoru je $0 \log 0 := 0$.
- Entropija $H_n(\mathcal{S})$ je jednaka nuli kada je stanje sustava potpuno predvidivo i ne postoji nikakva neizvjsnost. To je slučaj kada je jedna od vjerojatnosti p_i, $i=1,2,...,n$ jednaka jedan $p_k=1$, a sve ostale jednake nuli, $p_i=0$, $i\neq k$.
- Entropija postiže najveću vrijednost kada su svi događaji jednako vjerojatni a to je u slučaju da je $p_i = 1/n$, za $i=1, 2, ..., n$, i jednaka je Hartleyevoj entropiji $H_n(\mathcal{S})_{max}=\log n$, [11]. Hartleyeva entropija odgovara Renyievoj entropiji nultog reda.
- Entropija raste sa brojem događaja.
- Entropija ne ovisi o redoslijedu događaja:
- $H_n(p_1,p_2,...,p_n)=H_n(p_{k(1)},p_{k(2)},...,p_{k(n)})$, gdje je k proizvoljna permutacija od $(1,2,...,n)$.
- Entropija je jedina odgovarajuća funkcija za mjeru neizvjesnosti (teorem jedinstvenosti) [14].

Ima još nekih važnih svojstava entropije koji se odnose na složene događaje. Razmatraju se dva sustava događaja: $\mathcal{A}=(A_1, A_2,\ldots,A_m)$ i $\mathcal{B}=(B_1, B_2,\ldots,B_n)$.

- Za nezavisne sustave događaja, kod kojih je vjerojatnost pojavljivanja dva događaja definirana sa $p(A_i \cap B_j)=p(A_i)p(B_j)$, entropija sustava koji se označava kao direktni produkt sustava događaja $\mathcal{A}\mathcal{B}$, definira se kako slijedi (aditivnost entropije):

$$H(\mathcal{A}\,\mathcal{B}) = H(\mathcal{A}) + H(\mathcal{B}) \qquad (7)$$

- Za zavisne sustave događaja, kod kojih vje vjerojatnost pojavljivanja dva događaja definirana sa $p(A_i \cap B_j)=p(A_i)p(B_j/A_i)$, entropija se složenog sustava $\mathcal{A}\mathcal{B}$ definira kako slijedi:

$$H(\mathcal{A}\,\mathcal{B}) = H(\mathcal{A}) + H(\mathcal{B}/\mathcal{A}) \qquad (8)$$

$H(\mathcal{B}/\mathcal{A})$ u (8) je prosječna entropija sustava $\mathcal{B}$ u sustavu $\mathcal{A}$ i predstavlja uvjetnu entropiju sustava $\mathcal{B}$ obzirom na sustav $\mathcal{A}$:

$$H(\mathcal{B}/\mathcal{A}) = \sum_i p(A_i) \cdot H(\mathcal{B} / A_i) \qquad (9)$$

$H(\mathcal{B} / A_i)$ u (9) je uvjetna entropija sustava $\mathcal{B}$ obzirom na događaj A_i u sustavu $\mathcal{A}$.

4. Podsustavi događaja

Promatra se sustav $\mathcal{S}$ isključivih događaja E_{ij}, s pripadnim vjerojatnostima $p(E_{ij})$:

$$\mathcal{S}=\begin{pmatrix} E_{11} & \dots & E_{1m_1} & \dots & E_{i1} & \dots & E_{im_i} & \dots & E_{n1} & \dots & E_{nm_n} \\ p(E_{11}) & \dots & p(E_{1m_1}) & \dots & p(E_{i1}) & \dots & p(E_{im_i}) & \dots & p(E_{n1}) & \dots & p(E_{nm_n}) \end{pmatrix}$$

Događaji se unutar sustava $\mathcal{S}$ mogu grupirati neovisno o redoslijedu, u podsustave događaja $\mathcal{S}_i$, $i=1,2,...,n$, sa događajima E_{ij}, $j=1,2,...,m_i$, kako slijedi:

$$\mathcal{S}_i=\begin{pmatrix} E_{i1} & \dots & E_{ij} & \dots & E_{im_i} \\ p(E_{i1}) & \dots & p(E_{ij}) & \dots & p(E_{im_i}) \end{pmatrix}$$

Vjerojatnost $p(\mathcal{S}_i)$ svakog podsustava $\mathcal{S}_i$, $i=1,2,...,n$, se lako dobija na slijedeći način:

$$p(\mathcal{S}_i)=\sum_{j=1}^{m_i} p(E_{ij}) \tag{10}$$

Ni vjerojatnosti ne entropije ne ovise o redoslijedu događaja u sustavima i podsustavima.
Za strogo isključive podsustave događaje može se pojednostavljeno pisati:

$$\mathcal{S}=\left(\mathcal{S}_1+\ldots+\mathcal{S}_i+\ldots+\mathcal{S}_n\right)$$

Vjerojatnost sustava se može odrediti kako slijedi:

$$p(\mathcal{S})=p(\bigcup_{i=1}\mathcal{S}_i)=\sum_{i=1}^{n}\sum_{j=1}^{m_i} p(E_{ij}) \tag{11}$$

Razdioba vjerojatnosti događaja $p(E_{ij})$ podsustava $\mathcal{S}_i$ može se razmotriti kao djelomična razdioba cijelog sustava $\mathcal{S}$. Međutim, svakoj se djelomičnoj razdiobi može pridružiti potpuna razdioba sa zamjenom $p(E_{ij}/\mathcal{S}_i)$ umjesto of $p(E_{ij})$, koja se može shvatiti kao potpuna razdioba pod uvjetom da se dogodio podsustav $\mathcal{S}_i$ s vjerojatnošću $p(\mathcal{S}_i)$. Očito da je $p(E_{ij}/\mathcal{S}_i)\cdot p(\mathcal{S}_i)= p(E_{ij})$. Svaki se podsustav $\mathcal{S}_i$ može promotriti i pod uvjetom da se samo on dogodio unutar sustava $\mathcal{S}$. Uvjetna vjerojatnost sustava $p(\mathcal{S}/\mathcal{S}_i)$ ovisi samo o vjerojatnostima podsustava, odnosno $p(\mathcal{S}/\mathcal{S}_i)=p(\mathcal{S}_i)$. Očito je i $p(\mathcal{S}_i/\mathcal{S}_i)=1$.
Ukoliko sustav $\mathcal{S}$ nije potpuni sustav događaja, a to je onda ako je $p(\mathcal{S})<1$, neizvjesnost se sustava određuje preko Renyi/Shannonove entropije prvog reda:

$$H_N^1(\mathcal{S})=H_N(\mathcal{S})/p(\mathcal{S}) \tag{12}$$

Sustav se $\mathcal{S}$ može promotriti i pod uvjetom da su samo zamjetljivi događaji od interesa kada se uvjetna entropija može prikazati kako slijedi:

$$H_N(\mathcal{S}/\mathcal{S})=-\sum_{i=1}^{N}\frac{p(E_i)}{p(\mathcal{S})}\log\frac{p(E_i)}{p(\mathcal{S})}=H_N^1(\mathcal{S})+\log p(\mathcal{S}) \tag{13}$$

Težinski zbroj naveden u (12) se računa kako slijedi:

$$H_N(\mathcal{S})=-\sum_{i=1}^{n}\sum_{j=1}^{m_i} p(E_{ij})\log p(E_{ij})=\sum_{i=1}^{n}H_{m_i}(\mathcal{S}_i) \tag{14}$$

Najveća entropija sustava $\mathcal{S}$ za potpune i nepotpune sustave se dobiva za N jednako vjerojatna događaja:

$$H_N^1(\mathcal{S})_{\max}=\log\left(\frac{N}{p(\mathcal{S})}\right).$$

4.1. Neizvjesnosti podsustava događaja

Za ocjenu neizvjesnosi podsustava događaja može s primjeniti teorem o mješavini razdioba vjerojatnosti [17]. Djelomične se razdiobe mogu promatrati kao razdiobe podsustava događaja [18].
Neizvjesnosti podsustava $\mathcal{S}_i$, bez obzira na islkučivost događaja, mogu se prikazati preko Shannonove entropije primjenjene samo na djelomične razdiobe systava $\mathcal{S}$ pod uvjetom da su se dogodili podsustavi $\mathcal{S}_i$. Tako prikazana uvjetna entropija ne ovisi o vjerojatnosti susava $p(\mathcal{S})$ i nije ovisna o tome da li je sustav događaja potpun ili nije.

Po definiciji entropije u (4), primjenom uvjetnih vjerojatnosti događaja u podsustavima, entropija podsustava se određuje kako slijedi:

$$H_{m_i}(\mathcal{S}/\mathcal{S}_i)=-\sum_{j=1}^{m_i}\frac{p(E_{ij})}{p(\mathcal{S}_i)}\log\frac{p(E_{ij})}{p(\mathcal{S}_i)} \tag{15}$$

Entropija podsustava u (15) ovisi samo o stanjima podsustava $\mathcal{S}_i$, i ni o jednom drugom stanju sustava $\mathcal{S}$ niti o samom sustavu $\mathcal{S}$.
Gubitak entropije podsustava $\mathcal{S}_i$ promatranog kao djelomična razdioba u odnosu na isti podsustav promatran kao nepotpuni sustav, može se prikazati kao:

$$H_{m_i}(\mathcal{S}/\mathcal{S}_i)=H_{m_i}^1(\mathcal{S}_i)+\log p(\mathcal{S}_i) \tag{16}$$

Renyi/Shannonova entropija prvog reda $H^1_{mi}(\mathcal{S}_i)$ u (16), odgovara entropiji nepotpunog sustava:

$$H_{m_i}^1(\mathcal{S}_i)=H_{m_i}(\mathcal{S}_i)/p(\mathcal{S}_i) \tag{17}$$

Djelomični zbroj $H_{mi}(\mathcal{S}_i)$ u (17) u sustavu $\mathcal{S}$, odgovara djelomičnoj razdiobi vjerojatnosti podsustava $\mathcal{S}_i$:

$$H_{m_i}(\mathcal{S}_i)=-\sum_{j=1}^{m_i} p(E_{ij})\log p(E_{ij}) \tag{18}$$

Najveća postiziva uvjetna entropija podsustava $\mathcal{S}_i$ se dobiva za m_i jednako vjerojatna događaja:

$$H_{m_i}(\mathcal{S}/\mathcal{S}_i)_{\max}=\log m_i \tag{19}$$

4.2. Odnosi između sustava i podsustava

Sustav se $\mathcal{S}$ može promatrati i kao složeni sustav podsutava $\mathcal{S}_1, \mathcal{S}_2, ..., \mathcal{S}_n$, označen $\mathcal{S}'$:

$$\mathcal{S}'=\left(\mathcal{S}_1,\ldots,\mathcal{S}_i,\ldots,\mathcal{S}_n\right)=\begin{pmatrix} \mathcal{S}_1 & \dots & \mathcal{S}_i & \dots & \mathcal{S}_n \\ p(\mathcal{S}_1) & \dots & p(\mathcal{S}_i) & \dots & p(\mathcal{S}_n) \end{pmatrix}$$

Vjerojatnost sustava $\mathcal{S}'$ je

$$p(\mathcal{S}')=\sum_{i=1}^{n}p(\mathcal{S}_i)=p(\mathcal{S})=\sum_{i=1}^{n}\sum_{j=1}^{m_i}p(E_{ij}).$$

Najveća postiziva entropija sustava $\mathcal{S}'$, bilo za potpune ili nepotpune sustave, dobija se za *n* jednako vjerojatna podsustava $H_n^1(\mathcal{S}')_{\max} = \log\left(\dfrac{n}{p(\mathcal{S}')}\right)$.

Za nepotpuni sustav događaja $\mathcal{S}'$ kada je $p(\mathcal{S}') < 1$, Renyi/Shannonova entropija prvog reda se dobija kao:

$$H_n^1(\mathcal{S}') = H_n(\mathcal{S}') / p(\mathcal{S}') \tag{20}$$

Sustav $\mathcal{S}'$ se može promatrati i pod uvjetom da su samo zamjetljivi događaju od interesa:

$$H_n(\mathcal{S}'/\mathcal{S}') = -\sum_{i=1}^{n} \frac{p(\mathcal{S}_i)}{p(\mathcal{S})} \log \frac{p(\mathcal{S}_i)}{p(\mathcal{S})} = \tag{21}$$

$$= H_n^1(\mathcal{S}') + \log p(\mathcal{S})$$

Zbroj u (20) je određen kako slijedi:

$$H_n(\mathcal{S}') = -\sum_{i=1}^{n} p(\mathcal{S}_i) \log p(\mathcal{S}_i) \tag{22}$$

Općenito se odnos među vjerojatnostima i uvjetnim entropijama bilo potpunih ili nepotpunih događaja i entropije sustava, može odrediti na osnovi težinskog zbroja svih uvjetnih entropija podsustava [18]:

$$\sum_{i=1}^{n} p(\mathcal{S}_i) \cdot H_{m_i}(\mathcal{S}/\mathcal{S}_i) = p(\mathcal{S}) \cdot \left[H_N(\mathcal{S}/\mathcal{S}) - H_n(\mathcal{S}'/\mathcal{S}')\right] = \tag{23}$$

$$= p(\mathcal{S}) \cdot \left[H_N^1(\mathcal{S}) - H_n^1(\mathcal{S}')\right]$$

Odnos prikazan sa (23) može se smatrati izravnom primjenom teorema o entropiji sustava složenog iz više podsustava. Prosjek entropija podsustava $\mathcal{S}_i$, s težinama jednakim vjerojatostima podsustava $p(\mathcal{S}_i)$, jednaka je razlici entropija sustava $\mathcal{S}$ i sustava složenog od podsustava. $\mathcal{S}'$.

Smanjenje entropije sustava $\mathcal{S}$ je posljedica saznanja o podjeli na podsustave. Izraz (23) ne ovisi o tome da li su sustavi $\mathcal{S}$ i $\mathcal{S}'$ potpuni kada su $p(\mathcal{S}) = p(\mathcal{S}') = 1$, $H_N(\mathcal{S})=H^1_N(\mathcal{S})$ i $H_n(\mathcal{S}')=H^1_n(\mathcal{S}')$, ili nepotpuni kada su $p(\mathcal{S}) = p(\mathcal{S}') < 1$, $H_N(\mathcal{S})=H^1_N(\mathcal{S})+\log p(\mathcal{S})$ i $H_n(\mathcal{S}')=H^1(\mathcal{S}')+\log p(\mathcal{S}')$.

Izraz (23) se može napisati i drukčije na osnovi entropija nepotpunih podsustava:

$$\sum_{i=1}^{n} p(\mathcal{S}_i) \cdot H_{m_i}^1(\mathcal{S}_i) = p(\mathcal{S}) \cdot H_N^1(\mathcal{S}) \tag{24}$$

5. Tehnički sustavi događaja

Predpostavi li se da se neki tehnički predmet sastoji od n_c tehničkih, iženjerskih ili fizičkih sastavnica, zamjetljivi događaji svojstveni pojedinim sastavnicama se mogu smatrati osnovnim događajima. Osnovni se događaji mogu dogoditi kada ih se označava sa A_i, ili ne dogoditi, kada se označavaju sa $\overline{A}_i$, $i = 1,2,...,n_e$. Takvi se parovi koji put nazivaju jednostavnim alternativama. Ukupan broj osnovnih događaja se može označiti sa n_e i nije nužno jednak broju sastavnica n_c.

Kvantitativni postupci sustavne analize u stanju su u mnogim slučajevima odrediti vjerojatnosti djelotvornog ishoda događaja, dakle njegovu pouzdanost označenu sa $R_i = p(A_i)$ ili vjerojatnost nedjelotvornog ishoda događaja odnosne greške u radu, označene sa $P_{f,i} = p(\overline{A}_i) = 1 - p(A_i)$.

Sustav $\mathcal{E}_j$ od samo dva događaja predstavlja stanja samo jednog načina djelovanja jedne sastavnice i predstavlja se ovako: $\mathcal{E}_j = \begin{pmatrix} A_j & \overline{A}_j \\ p(A_j) & p(\overline{A}_j) \end{pmatrix}$.

Neizvjesnost da je način djelovanja sastavnice djelotvoran ili ne, izražava se entropijom dva događaja $H(\mathcal{E}_j) = -p(A_j)\log p(A_j) - p(\overline{A}_j)\log p(\overline{A}_j)$.

Najviša entropija dva događaja iste vjerojatnosti iznosi $H_2(\varepsilon_j)_{\max} = \log_2 2 = 1$, što je ujedno i jedinica mjere neizvjesnosti 1 bit.

Postupci analize događanja mogu dati odgovora o zamjetljivim i važnim događajima u djelovanju nekog tehničkog predmeta, koji se mogu označiti sa E_i. Neki se događaji označeni sa E^o_i mogu smatrati djelotvornim, povoljnim, operativnim, (status = O), a neki, označeni sa E^f_i nedjelotvornim, nepovoljnim, nefunkcinalnim (status = F). Vjerojatnosti se pojedinih načina djelovanja po svoj prilici mogu izračunati primjenom kvantitativnih postupaka i označiti sa $p(E_i)$, $i=1,2,...,N$, gdje je *N* ukupan broj svih znanih, zamjetljivih, važnih događaja u djelovanju nekog tehničkog sustava $\mathcal{S}$.

Sustav se $\mathcal{S}$ može prikazati i kao zbroj podsustava djelotvornih i nedjelotvornih događaja:

$$\mathcal{S} = \begin{pmatrix} E_1 & E_2 & ... & E_N \\ p(E_1) & p(E_2) & ... & p(E_N) \end{pmatrix} = (\mathcal{O} + \mathcal{F})$$

Od posebnog je interesa razmotriti dva važna podsustava sustava $\mathcal{S}$; podsustav djelotvornih događaja $\mathcal{O}$, koji sadrži sve povoljne događaje *E*, označene kao E^o_i, $i=1,2,...,N_o$ i podsustav nedjelotvornih događaja $\mathcal{F}$, koji sadrži nepovoljne događaje E^f_i, $i=N_o+1,...,N_o+N_f$:

$$\mathcal{O} = \begin{pmatrix} E_1^o & E_2^o & ... & E_{N_o}^o \\ p(E_1^o) & p(E_2^o) & ... & p(E_{N_o}^o) \end{pmatrix}$$

$$\mathcal{F} = \begin{pmatrix} E_{N_o+1}^f & E_{N_o+2}^f & ... & E_{N_o+N_f}^f \\ p(E_{N_o+1}^f) & p(E_{N_o+2}^f) & ... & p(E_{N_o+N_f}^f) \end{pmatrix}$$

Pri tome je ukupan broj svih događaja $N_o+N_f=N$. Valja primjetiti da redoslijedi događaja tehničkih sustava i podsustava nemaju značaja za proračune pouzdanosti i neizvjesnosti.

Pozdanost sustava je posljedica svih djelotvornih ishoda i može se odrediti kao vjerojatnost podsustava $p(\mathcal{O})$:

$$R(\mathcal{S}) = p(\mathcal{O}) = \sum_{i=1}^{N_O} p(E_i^o) \qquad (25)$$

Vjerojatnost oštečenje odgovara svim onim događajima čiji ishod dovodi do nedjelotvornosti sustava *p($\mathcal{F}$):*

$$P_f(\mathcal{S}) = p(\mathcal{F}) = \sum_{i=N_o+1}^{N_o+N_f} p(E_i^f) \qquad (26)$$

I za potpune i za nepotpune sustave svakako vrijedi:

$$p(\mathcal{S}) = p(\mathcal{O}) + p(\mathcal{F}) = \sum_{i=1}^{N} p(E_i) \qquad (27)$$

Sustav $\mathcal{S}'$ složen od podsustava djelotvornih događaja $\mathcal{O}$ i nedjelotvornih događaja $\mathcal{F}$ može se prikazati kako slijedi:

$$\mathcal{S}' = (\mathcal{O}, \mathcal{F}) = \begin{pmatrix} \mathcal{O} & \mathcal{F} \\ p(\mathcal{O}) & p(\mathcal{F}) \end{pmatrix}$$

5.1. Neizvjesnosti tehničkih sustava događaja

Sustav se događaja $\mathcal{S}$ može promatrati pod uvjetima da je djelotvoran ili nedjelotvoran kako slijedi:

$$\mathcal{S}/\mathcal{O} = \begin{pmatrix} E_1^o/\mathcal{O} & E_2^o/\mathcal{O} & \cdots & E_{N_o}^o/\mathcal{O} \\ \dfrac{p(E_1^o)}{p(\mathcal{O})} & \dfrac{p(E_2^o)}{p(\mathcal{O})} & \cdots & \dfrac{p(E_{N_o}^o)}{p(\mathcal{O})} \end{pmatrix}$$

$$\mathcal{S}/\mathcal{F} = \begin{pmatrix} E_{N_o+1}^f/\mathcal{F} & E_{N_o+2}^f/\mathcal{F} & \cdots & E_{N_o+N_f}^f/\mathcal{F} \\ \dfrac{p(E_{N_o+1}^f)}{p(\mathcal{F})} & \dfrac{p(E_{N_o+2}^f)}{p(\mathcal{F})} & \cdots & \dfrac{p(E_{N_o+N_f}^f)}{p(\mathcal{F})} \end{pmatrix}$$

Shannonova entropija sustava $\mathcal{S}$ pod uvjetom da je djelotvoran $\mathcal{O}$ je:

$$H_{N_o}(\mathcal{S}/\mathcal{O}) = -\sum_{i=1}^{N_O} \frac{p(E_i^o)}{p(\mathcal{O})} \cdot \log \frac{p(E_i^o)}{p(\mathcal{O})}, \qquad (28)$$

Shannonova entropija sustava $\mathcal{S}$ pod uvjetom da je nedjelotvoran $\mathcal{F}$ je:

$$H_{N_f}(\mathcal{S}/\mathcal{F}) = -\sum_{i=N_0+1}^{N_o+N_f} \frac{p(E_i^f)}{p(\mathcal{F})} \cdot \log \frac{p(E_i^f)}{p(\mathcal{F})} \qquad (29)$$

Entropija djelotvornih načina (28) i entropija nedjelotvornih načina (29) ovise samo o stanjima podsustava djelotvornih i nedjelotvornih načina a ne i o drugim događajima sustava.

Najveća postiziva entropija sustava $\mathcal{S}$ pod uvjetom da je djelotvoran je:

$$H_{N_o}(\mathcal{S}/\mathcal{O})_{\max} = \log N_o \qquad (30)$$

Najveća postiziva etropija sustava $\mathcal{S}$ pod uvjetom da nije djelotvoran je:

$$H_{N_f}(\mathcal{S}/\mathcal{F})_{\max} = \log N_f \qquad (31)$$

Entropija svih događaja potpunog sustava $\mathcal{S}$ iznosi:

$$H_N(\mathcal{S}) = H_N(\mathcal{O} + \mathcal{F}) = -\sum_{i=1}^{N} p(E_i) \cdot \log p(E_i) \qquad (32)$$

Maksimalno postiziva entropija sustava iznosi:

$$H_N(\mathcal{S})_{\max} = \log N \qquad (33)$$

Entropija svih događaja potpunog sustava $\mathcal{S}'$ sastavljenog od podsustava $\mathcal{O}$ and $\mathcal{F}$: iznosi:

$$H_2(\mathcal{S}') = H_2(\mathcal{O}, \mathcal{F}) = -p(\mathcal{O}) \cdot \log p(\mathcal{O}) - p(\mathcal{F}) \cdot \log p(\mathcal{F}) \qquad (34)$$

Najveća postiziva entropija iznosi:

$$H_2(\mathcal{S}')_{\max} = \log 2 \qquad (35)$$

Djelotvorni i nedjelotvorni događaji su od najvećeg značaja za projektante i korisnike tehničkih objekata. Podsustavi djelotvornih i nedjelotvornih događaja se mogu promatrati i na različitim razinama djelotvornosti ili stupnjevima nedjelotvornosti.

5.2. Odnosi vjerojatnosti i neizvjesnosti sustava

Težinski zbroj entropija podsustava djelotvornih i nedjelotvornih događaja $\mathcal{O}$ i $\mathcal{F}$ sustava $\mathcal{S}$ u smislu mješavine razdioba vjerojatnosti daje:

$$\begin{aligned} &p(\mathcal{O}) \cdot H_{N_o}(\mathcal{S}/\mathcal{O}) + p(\mathcal{F}) \cdot H_{N_f}(\mathcal{S}/\mathcal{F}) = \\ &= H_N(\mathcal{O} + \mathcal{F}) - H_2(\mathcal{O}, \mathcal{F}) \end{aligned} \qquad (36)$$

Izraz (36) povezuje vjerojatnosti i entropije podsustava sa entropijama sustava.

Promatranjem sustava $\mathcal{S}=(\mathcal{O}+\mathcal{F})$ i $\mathcal{S}'=(\mathcal{O},\mathcal{F})$ u smislu zavisnih sustava prema (8) and (9) može se dobiti entropija dva sustava:

$$H(\mathcal{S}\mathcal{S}') = H(\mathcal{S}') + H(\mathcal{S}/\mathcal{S}') \qquad (37)$$

Izraz u (37) se računa kako slijedi:

$$H(\mathcal{S}/\mathcal{S}') = p(\mathcal{O}) \cdot H(\mathcal{S}/\mathcal{O}) + p(\mathcal{F}) \cdot H(\mathcal{S}/\mathcal{F}) \qquad (38)$$

Izraz (38) predstavlja uvjetnu entropiju sustava $\mathcal{S}$ obzirom na sustav $\mathcal{S}'$.

H($\mathcal{S}/\mathcal{O}$) i *H($\mathcal{S}/\mathcal{F}$)* se nazivaju uvjetnim entropijama sustava $\mathcal{S}$ s obzirom na podsustave $\mathcal{O}$ i $\mathcal{F}$. Kada je stanje sustava $\mathcal{S}'$ potpuno određeno stanjima sustava $\mathcal{S}$ kao što je u ovom razmatranju slučaj, vrijedi:

$$H(\mathcal{S}\mathcal{S}') = H(\mathcal{S}) \qquad (39)$$

I konačno, korištenjem teorema o entropijama zavisnih sustava, dobija se isti rezultat kao i za slučaj primjene teorema o mješavinama razdioba vjerojatnosti:

$$p(\mathcal{O}) \cdot H(\mathcal{S}/\mathcal{O}) + p(\mathcal{F}) \cdot H(\mathcal{S}/\mathcal{F}) = H(\mathcal{S}) - H(\mathcal{S}')$$
(40)

Kada sustav $\mathcal{S}$ nije potpun zbog $p(\mathcal{S}) < 1$, za ocjenu neizvjesnosti sustava se može primjeniti Renyi/Shannonova entropija prvog reda *$H^1(\mathcal{S})$* u (6):

$$H_N^1(\mathcal{S}) = H_N^1(\mathcal{O} + \mathcal{F}) = \frac{H_N(\mathcal{S})}{p(\mathcal{S})} \qquad (41)$$

Renyi/Shannonova entropija prvog reda *$H^1(\mathcal{S}')$* sustava složenog od podsustava se određuje prema (6) kako slijedi:

$$H_2^1(\mathcal{S}') = H_2^1(\mathcal{O}, \mathcal{F}) = \frac{H_2(\mathcal{S}')}{p(\mathcal{S}')} \qquad (42)$$

U izrazima (39) i (40), $H(\mathscr{S})$ i $H(\mathscr{S}')$ su određeni u (32) and (34).

Sustavi $\mathscr{S}$ i $\mathscr{S}'$ se mogu promotriti i kao nepotpuni kada se uvjetne entrpije određuju prema (13) and (21).

Prema (12) se može dobiti slijedeći odnos među vjerojatnostima i entropijama sustava $\mathscr{S}$ i podsustava $\mathscr{O}$ i $\mathscr{F}$, kako slijedi:

$$\begin{aligned} & p(\mathscr{O})\cdot H_{N_o}(\mathscr{S}/\mathscr{O}) + p(\mathscr{F})\cdot H_{N_f}(\mathscr{S}/\mathscr{F}) = \\ & = p(\mathscr{S})\cdot\left[H_N^1(\mathscr{S}) - H_2^1(\mathscr{S}')\right] = \\ & = p(\mathscr{S})\cdot\left[H_N(\mathscr{S}/\mathscr{S}) - H_n(\mathscr{S}'/\mathscr{S}')\right] = \\ & = H_N(\mathscr{S}) - H_2(\mathscr{S}') = H_N(\mathscr{O}+\mathscr{F}) - H_2(\mathscr{O},\mathscr{F}) \end{aligned} \tag{43}$$

Neizvjesnosti podsustava djelotvornnih i nedjelotvornih načina i njihovi odnosi obzirom na vjerojatnosti mogu se koristiti za procjene valjanosti tehničkih objekata. Pri tome se može rukovoditi slijedećim smjernicama:

- Visoka entropija djelotvornih načina ukazuje na jednolikiju razdiobu vjerojatnosti operativnih događaja i na veću pretičnost u djelotvornosti što odgovara većoj redundanciji sustava [21].
- Visoka entropija nedjelotvornih načina ukazuje na jednolikiju razdiobu vjerojatnosti oštećenja što se može protumačiti i kao veća ujednačenost i otpornost na razne vrste oštećenja što odgovara većoj robustnosti sustava [21].

6. Zaključak

U radu se razmatra kako se tradicionalno modeliranje tehničkih predmeta na osnovi tvarnih sastavnica korištenjem tehničkih i inženjerskih znanja i iskustava, može proširiti na modeliranje događajima i primjenu teorije informacija na poboljšanje postupaka projektiranja i korištenja predmeta. Takvo modeliranje uzima u obzir razne slučajne događaje u vijeku korištenja tehničkih predmeta i racionalno sagledava njihovu djelotvornost. Prikazano se modeliranja može primjeniti i na razne odnose među događajima, kao što su isljučivi i neisključivi, zavisni i nezavisni, a na osnovi prikladne podjele prostora događaja.

Neizvjesnosti u djelovanju tehničkih predmeta potječu od nepredvidljivosti većeg broja mogućih događaja. Praktične mjere neizvjesnosti, uz druge mjere valjanosti sustava, daju uvida u značaj broja djelotvornih i nedjelotvornih događaja i razdioba njihovih vjerojatnosti za opstojnost sustava. Na taj se način omogućuje uvid u njihovu redundanciju i robustnost u djelovanju. Odnosi među vjerojatnostima i neizvjesnostima sustava i podsustava događaja mogu korisno poslužiti u raznim područjima projektiranja, korištenja i održavanja tehničkih sustava u cilju povećanja njihove djelotvornosti.

Shannonova entropija se može koristiti za ocjenu neizvjesnosti potpunih sustava događaja a Renyieva entropija za ocjene neizvjesnosti nepotpunih sustava događaja. Teoremi za mješavine razdioba vjerojatnosti kao i za entropije zavisnih sustava su korisni za dovođenje u vezu vjerojatnosti i neizvjesnosti sustava i podsustava događaja. Entropija se smatra jedinom racionalom mjerom neizvjesnosti sustava, a uz to i objektivnom mjerom budući da ne ovisi ni o čemu drugom osim o mogućim događajima.

Ocjena neizvjesnosti sustava događaja putem entropije je poznata u tehnici od ranije, ali je mogući razlog za neprimjenu na tehničke predmete u tome da entropija sustava događaja nije od posebno velikog interesa za ocjenu valjanosti sustava. Međutim, uvjetne entropije važnih podsustava događaja kao što su djelotvorni i nedjelotvorni događaji na raznim razinama i stupnjevima, kao i poznavanje odnosa među njima, mogu pružiti nove uvide u valjanosti tehničkih predmeta u njihovoj uporabi.

U mnogim je tehničkim problemima teško sagledati sve okolnosti njihova djelovanja. Neki se događaji prividjaju slučajnima obzirom na jedan određeni splet okolnosti, dok sa stajališta nekog drugog skupa okolnosti mogu biti potpuno određeni. Slučajnosti i određenosti događaja ovise o tome da li okolnosti mijenjaju ili ne mjenjaju ishode. Izbor okolnosti i načina ocjene događaja ovise o promatraču i u tome postoje mogućnosti slobode izbora u okvirima tehničkih ograničenja i iskustva.

Unutar pojedinih sustava i podsustava se mogu promatrati grupe i podgrupe događaja iste djelotvornostii ili istih stupnjeva pogrešaka, ili nekih drugih zajedničkih svojstava od interesa. Tehničko se modeliranje događajima može primjeniti na različite razine događanja vezanih za obavljanje zadataka tehničkih predmeta.

U radu se naznačuje problem razlikovanja među složenim tehničkom predmetima istovjetne namjene, uključivo njihove moguće redundancije i robustnosti, sa istim pouzdanostima i vjerojatnostima oštećenja, a koji se međusobno razlikuju po broju i razdiobama vjerojatnosti pojedinih događaja. Neizvjesnosti sustava i podsustava se mogu smatrati dodatnim značajkama tehničkih predmeta koji uzimaju u obzir brojeve raznih vrsta događaja i razdibe njihovih vjerojatnosti i izražavaju redundancije i robustnosti njihova djelovanja. Na osnovi ovih svojstava mogu se donositi odluke o valjanosti pojednih tehničkih predmeta u radnim uvjetima, uz ona uobičajena razmatranja o sigurnosti i isplativosti. Takva razmatranja o tehničkom modeliranju događajima mogu poboljšati alternativna rješenja tehničkih predmeta a povratnim se postupkom na osnovi promatranja sustava u radu može doći do saznanja o učinkovitosti sustava kao i do poboljšanja u korištenju i održavanju sustava.

Tehničko modeliranje događajima se suočava sa mogućim računskim ograničenjima pogotovo u razmatranjima velikih i složenih sustava. Za potpuno tehničko modeliranje sustava potrebno je izvršiti pobrojavanje po svim mogućim događajima. Većina kvantitativnih postupaka analize koji su danas u upotrebi u cilju uštede vremena i računskih napora oslanjaju se samo na najvažnije prepoznatljive događaje.

Na sreću, postupci tehničkog modeliranja prikazani u ovom radu omogućuju modeliranje i samo djelomično poznatih, zamjetljivih, uistinu važnih događaja, na osnovu čega se može nadati i njihovoj praktičnoj izvedivosti i u uvjetima ograničenih računarskih resursa.
Oslonac za primjen tehničkog modeliranja događajima se može potražiti u sve boljem poznavanju djelovanja tehničkih predmeta u neizvjesnim okolnostima, u brzom razvoju analitičkih i računskih postupaka te u ogromnom porastu mogućnosti obrade podataka novih generacija računskih strojeva.

Lista znakova

A_i, E_i	Slučajni događaji općenito
$H(\bullet)$	Entropije sustava događaja
$H^1(\bullet)$	Entropije sustava događaja prvog reda
N, n	Brojevi sustava i podsustava
N_O, N_f	Brojevi operativnih i neoperativnih događaja
$p(\bullet)$, p_i	Vjerojatnosti događaja, sustava i podsustava
$P_f(\bullet)$	Vjerojatnost oštećenja
$R(\bullet)$	Pouzdanost
$\mathcal{S}$	Sustavi događaja općenito
$\mathcal{S}'$	Sustavi od podsustava događaja
$\mathcal{S}_i$	Podsustavi događaja općenito
$\mathcal{O}$	Podsustavi djelotvornih događaja
$\mathcal{F}$	Podsustav nedjelotvornih događaja

Literatura

1. Barlow, R. B., Proschan, F., Mathematical Theory of Reliability, Wiley, New York, 1965.
2. Kapur, K. C., Lamberson, L. R., Reliability in Engineering Design, Wiley, New York, 1977.
3. Rao, S. S., Reliability Based Design, McGraw-Hill, New York, 1992.
4. Madsen, H. O., Krenk, S., Lind, N., C., Methods of Structural Safety, Prentice-Hall, New Jersey, 1986.
5. Ditlevsen, O., Madsen, H.O., Structural Reliability Methods, Wiley, New York, 1996.
6. Gnedenko, B., Ushakov, I., Probabilistic Reliability Engineering, Ed. Falk, J., Wiley, New York, 1995.
7. Gnedenko, B., V., Belyayev, Yu., K., Solovyev, A., D., Mathematical Methods of Reliability Theory, Eds. Birnbaum, Z., W., Lukacs, E., Academic Press, New York, 1969.
8. Ben Haim, Y., A non-probabilistic measure of reliability of linear systems based on expansion of convex models, Structural Safety, 17, 1995.
9. Tribus, M., Rational Descriptions, Decisions and Designs, Pergamon Press, New York, 1969.
10. Nyquist, H., Certain Factors Affecting Telegraph Speed, Bell System Tech. J., 3., 1924.
11. Hartley, R., V., Transmission of Information, Bell System Tech. J., 7., 1928.
12. Wiener, N., Cybernetic, or Control and Communication, Bell System Tech. J, 27.,1948.
13. Shannon C. E., Weaver W., The Mathematical Theory of Communication, University of Illinois Press, Urbana, 1949.
14. Khinchin, A., I., Mathematical Foundations of Information Theory, Dover Publications, NewYork, 1957.
15. Syilard, L., On the Decrease of Entropy in Thermodynamic System by the Intervention of Intelligent Beings, Zeitschrift fur Physic 53, 1929.
16. Stonier, T., Information and Internal Structure of the Universe. An Exploration into Information Physics, Springer, Berlin, 1990.
17. Renyi, A., Probablity Theory, North-Holland, Amsterdam, 1970.
18. Žiha. K., Entropy of subsystems of events, Proceedings of ITI'98 Conference., Pula, 1998.
19. Žiha, K., Usage of relative uncertainty measures, Proceedings of ITI'99 Conference., Pula, 1999.
20. Žiha, K., Event Oriented System Analysis, Probabilistic Engineering Mechanics, 15(3), 2000.
21. Žiha, K., Redundancy and Robustness of Systems of Events, prihvaćeno za objavljivanje Probabilistic Engineering Mechanics, 2000.
22. Aczel, J., Daroczy, Z., On Measures of Information and Their Characterization, Academic Press, New York, 1975.