



Pronicanje u budućnost

Ante Munitić*

ISSN 0469 - 6255
(289-292)

"KAOS - 2." LORENZOV "LEPTIROV UČINAK" "CHAOS - 2" LORENZ "BUTTERFLY EFFECT"

UDK 519.71/.72+530.13/.14+577.3

Znanstveni serijal
Scientific serial

6. Uredni nered *Determined chaos*

Od kada god postoji, čovjek je želio spoznati prirodne zakonitosti koje vladaju u iznimno složenom dinamičkom procesu ponašanja atmosferskih vremenskih prilika, kako bi pravodobno predviđajući, smanjio njihove, najčešće katastrofalne posljedice. Svjedoci smo kako i danas, pored razmjerno visokog stupnja razvoja automatizacije, kompjuterizacije, satelitizacije i informatizacije, čak i u najrazvijenijim zemljama svijeta, vremenske prilike, ili bolje rečeno neprilike, redovito izazivaju prave kataklizme, koje odnose mnogobrojne ljudske živote i stvaraju goleme materijalne štete. Zbog toga je bio razumljiv interes najboljih umova čovječanstva, kako u prošlosti tako i danas, da proniknu u "skrivenе" tajne prirode, koje upravljaju složenom dinamikom ponašanja "sustava atmosferskih vremenskih prilika" na našem planetu Zemlji. Da bi se shvatilo ponašanje sustava atmosferskih vremenskih prilika (SAVP), znanstvenici su morali odrediti mentalne (veoma subjektivne), verbalne, strukturne i matematičke modele, koji bi što kvalitetnije predstavljali veoma složenu, tj. nelinearnu dinamiku ponašanja SAVP-a!

Filozof i matematičar XVIII. stoljeća Laplace je, pod utjecajem njutnovskog determinizma, smatrao, da će strogo determinirani sustavi, od Svetišta pa do atoma, u skladu s Newtonovim zakonima, u potpunosti definirati put čovječanstva u "sigurnu", to jest u unaprijed poznatu budućnost! Sreća je što nam priroda nije dala život u potpuno određenom svemirskom prostoru, te je, davši nam izvjesnu dozu "kaotične neizvjesnosti", učinila život na našem planetu Zemlji mnogo ljestvijim i zanimljivijim! U stvari, ono što čini život čovjekov zanimljivim jest upravo mogućnost doživljavanja budućnosti s umjerenom dozom neizvjesnosti!

* prof. dr. sci. Ante Munitić
Redovni profesor informacijskih znanosti
Pomorski fakultet, Split

Pod utjecajem njutnovske totalne determinističke metodologije, poznati matematičar i jedan od "očeva" prvih računalnih strojeva John von Neumann je sredinom dvadesetog stoljeća mislio da je za električko računalo upravo idealan radni zadatak modeliranje SAVP-a, s mogućnošću kompjutorskoga automatiziranog prognoziranja i upravljanja SAVP-om. S obzirom da je John von Neumann bio nesumnjivi znanstveni autoritet, većina meteorologa je prihvatala njegovo mišljenje te je uporno proizvodila sve složenije kompjutorske modele SAVP-a, koje su pokušavali koristiti za davanje što kvalitetnijih dugoročnih vremenskih prognoza, ali im to nikako nije polazilo za rukom!

No ipak je Lorenz Edvard, jedan od pionira izrade kompjutorskih prognostičkih modela SAVP-a, 1961. godine, poslije niza simulacijskih eksperimenata, došao do epohalne znanstvene spoznaje:

1. Kvalitetna dugoročna prognoza SAVP-a je nemoguća, jer se radi o prirodnom dinamičkom izrazito nelinearnom sustavu, a nelinearni fizikalni dinamički sustavi su jednostavno rečeno "nepredvidljivi";

2. Uzrok je ovom prirodnom dinamičkom fenomenu, do tada nepoznata prirodna pojавa, tzv. "*leptirov učinak*", tj. *ATRAKTOR!*";

3. Tzv. prirodnji "*red*" prerašten je u "*nered*", tj. u determinirani "*KAOS*"!

7. Osjetljiva ovisnost o početnim uvjetima *Sensitive dependence of initial conditions*

Lorenz je 1963. godine predstavio javnosti veoma jednostavan model SAVP-a, sa svega tri nelinearne diferencijalne jednadžbe I. reda, koje su imale posebne veličine parametara, osjetljivih na unaprijed zadane početne uvjete. Njegov model je predstavljao

proces podizanja zagrijane atmosfere u obliku drhtavih turbulentnih valova, a pod utjecajem topline što je stvaralo sunce zračenjem zemljine površine, odnosno proces konvekcije sunčeve toplinske energije zračnim strujanjem. U matematičkom modelu varijabla $\mathbf{x}(t)$ predstavlja konvektivni zračni tok, $\mathbf{y}(t)$ horizontalnu varijaciju temperature i $\mathbf{z}(t)$ vertikalnu varijaciju temperature. Nadalje, svi parametri su pozitivni i predstavljaju: $\sigma = \text{Prandtlov broj}=10$; $r = \text{Rayleighov broj}=28$; $b = \text{veličina promatrane regije}=8/3$.

$$(dx/dt) = -\sigma x + \sigma y \quad (2)$$

$$(dy/dt) = -xz + rx - y \quad (3)$$

$$(dz/dt) = xy - bz \quad (4)$$

7.1. Sustav dinamički simulacijski model Lorenzovog modela SAVP-a System dynamic simulation model of Lorenz SAWC model

Na osnovu danog Lorenzovog matematičkog modela (jednadžbe (2),(3) i (4)), ili kako sustav-dinamičari kažu, "jednadžbi stanja" SAVP-a, moguće je determinirati tzv. **sustav-dinamički mentalno-verbalni kvalitativni simulacijski model SAVP-a**.

Iz jednadžbe (2) neposredno slijedi sistem dinamički mentalno-verbalni model:

"Ako poraste konvektivni zračni tok $x(t)$, tada će se smanjiti brzina njegove promjene (dx/dt), što ukazuje na "negativni" (-) dinamički karakter promatrane uzročno-posljedične veze (UPV)!".

"Ako raste horizontalna varijacija temperature $y(t)$, tada će porasti brzina promjene konvektivnog zračnog toka (dx/dt), što ukazuje na "pozitivan" (+) dinamički karakter promatrane uzročno-posljedične veze-UPV!".

Iz jednadžbe (3) neposredno slijedi:

"Ako poraste konvektivni zračni tok $x(t)$, tada će se povećati brzina promjene horizontalne varijacije temperature (dy/dt), što ukazuje na "pozitivni" (+) dinamički karakter promatrane uzročno-posljedične veze (UPV)!".

"Ako poraste verticalna varijacija temperature $z(t)$, tada će se smanjiti brzina promjene horizontalne varijacije temperature (dy/dt), što ukazuje na "negativni" (-) dinamički karakter promatrane uzročno-posljedične veze (UPV)!".

"Ako poraste horizontalna varijacija temperature $y(t)$, tada će se smanjiti brzina promjene horizontalne varijacije temperature (dy/dt), što ukazuje na "negativni" (-) dinamički karakter promatrane uzročno-posljedične veze (UPV)!".

Iz jednadžbe (4) neposredno slijedi:

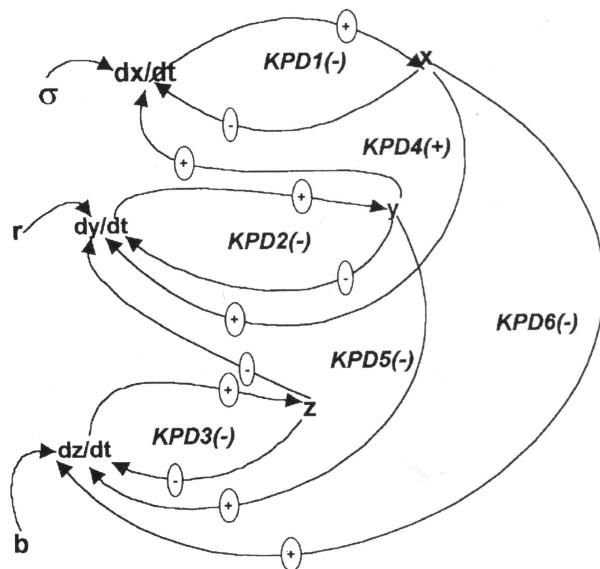
"Ako poraste horizontalna varijacija temperature $y(t)$, tada će porasti brzina promjene vertikalne vari-

jacije temperature (dz/dt), što ukazuje na "pozitivni" (+) dinamički karakter promatrane uzročno-posljedične veze (UPV)!".

"Ako poraste konvektivni zračni tok $x(t)$, tada će porasti brzina promjene vertikalne varijacije temperature (dz/dt), što ukazuje na "pozitivni" (+) dinamički karakter promatrane uzročno-posljedične veze (UPV)!".

"Ako poraste vertikalna varijacija temperature $z(t)$, tada će se smanjivati brzina promjene vertikalne varijacije temperature (dz/dt), što ukazuje na "negativni" (-) dinamički karakter promatrane uzročno-posljedične veze (UPV)!".

U skladu s metodologijom Sistemske dinamike i Lorenzovim matematičkim modelom, te sistem-dinamičkim mentalno-verbalnim kvalitativnim modelom, moguće je determinirati **sistem-dinamički kvalitativni struktturni simulacijski model SAVP-a** (Slika 1.).



Slika 1. Sustav-dinamički kvalitativni struktturni simulacijski model Lorenzovog SAVP-a

Figure 1. System dynamic qualitative structure simulation model of Lorenz SAWC model

Analizirajući Sliku 1., moguće je uočiti da Lorenzovim SAVP-om dominiraju tri jednostavna i tri složena "kruga povratnog djelovanja"-KPD-a :

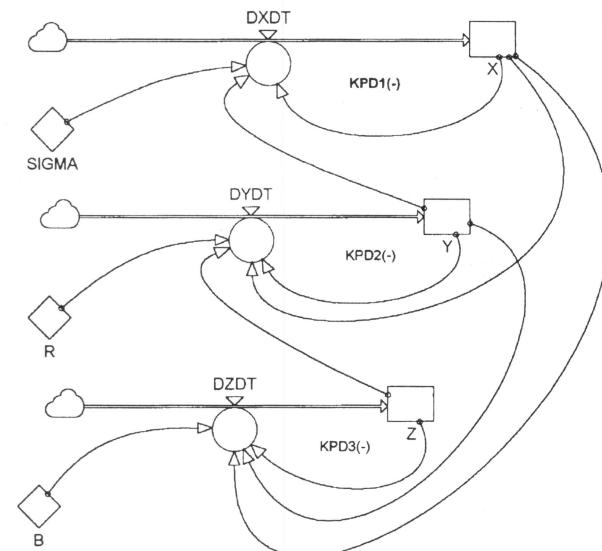
- 1.-KPD1(-), koji ima "samoregulirajući" (self-regulating) dinamički karakter;
- 2.-KPD2(-), koji ima samoregulirajući dinamički karakter;
- 3.-KPD3(-), koji ima samoregulirajući dinamički karakter,
- 4.-KPD4(+), koji ima kumulativni dinamički karakter,
- 5.-KPD5(-), koji ima samoregulirajući dinamički karakter,
- 6.-KPD6(-), koji ima samoregullirajući dinamički karakter.

^{**}SAWC = System Atmospheric Weather Conditions

U skladu s metodologijom "sistemske dinamičare", na osnovi danih sustav-dinamičkih kvalitativnih mentalno-verbalnih i struktturnih, te kvantitativnog matematičkog (jednadžbe 2., 3. i 4.) simulacijskog modela, moguće je determinirati sustav-dinamički dijagram tokova Lorenzovog SAVP-a, koristeći se pri tome simbolikom simulacijskog grafički orientiranog POWER-SIM programske paketa (Slika 2.).

Promatrujući Sliku 2., moguće je uočiti da su vremenski ovisne varijable $x(t)$, $y(t)$ i $z(t)$ predstavljene pravokutnicima, koji simbolički predstavljaju "sadašnje" stanje varijabli $x(t)$, $y(t)$ ili $z(t)$, u nekom vremenskom trenutku (t). Matematički determinirano sadašnje stanje varijable u vremenskom trenutku (t) - "sada" jest jednako sumi početne vrijednosti varijable u prethodnom vremenskom trenutku ($t-1$) - "prije" i promjeni stanja varijable u vremenskom intervalu dt , tj. od trenutka ($t-1$) - "prije" pa do trenutka (t) - "sada", u kojem se dogodila promjena stanja varijable (dx), (dy) ili (dz), što ima matematičko značenje " \int ", tj. integrala za slučaj kontinuiranih modela (skupa diferencijalnih jednadžbi), odnosno " Σ ", tj. sumatora za slučaj diskretnih modela (skupa diferencijskih jednadžbi).

Na dijagramu tokova (Slika 2.) moguće je uočiti da su promjene stanja varijabli (dx/dt), (dy/dt) i (dz/dt) predstavljene simboličnom oznakom ventila, te da su u modelu doble programske pogodniji naziv **DXDT**, **DYDT** i **DZDT**. Matematička definicija promjene stanja varijabli, koja se događa između vremenskog trenutka ($t-1$) - "prije" i vremenskog trenutka (t) - "sada", odnosno u infinitezimalnom vremenskom periodu (dt), jest i derivacija dx/dt , dy/dt i dz/dt . U fizici, promjena stanja varijabli ima naziv brzina promjene varijabli x , y i z po vremenu za kontinuirane modele, dok za



Slika 2. Sustav-dinamički dijagram tokova simulacijskog modela Lorenz-ovog SAWC-a

Figure 2. System dynamic simulation model flowing chart of Lorenz SAWC model

diskretne modele matematički naziv jest i diferencija varijabli Δx , Δy i Δz po vremenskom intervalu Δt .

Veoma osjetljivi parametri $\sigma = \text{SIGMA} = 10$ (Prandtl-ov broj), $R = 28$ (Rayleigh-ov broj) i $B = 8/3$ (veličina promatrane regije) su predstavljeni dijagonalno postavljenim kvadratom, što znači da su konstantni!

Kao rezultanta svih predstavljenih sistem dinamičkih modela (mentalno-verbalni, strukturalni, dijagramske-tokovni i matematički modeli) moguće je (u POWER-SIM 2.5 grafički orientiranom višem programskom jeziku) determinirati: kompjuterski simulacijski model Lorenzovog SAVP-a:

```

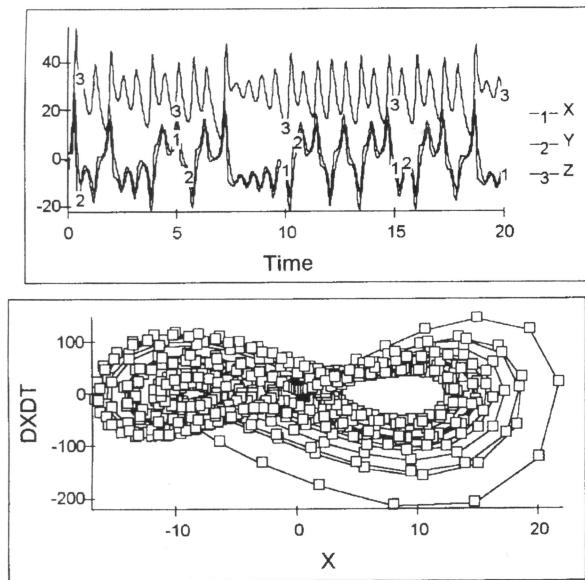
init X = 0
flow X = +dt*DXDT
doc X = KONVEKTIVNI ZRAČNI TOK
init Y = 1
flow Y = +dt*DYDT
doc Y = HORIZONTALNA TEMPERATURNAA VARIJACIJA
init Z = 0
flow Z = +dt*DZDT
doc Z = VERTIKALNA TEMPERATURNAA VARIJACIJA
aux . DXDT = -SIGMA*X+SIGMA*Y
doc . DYDT = BRZINA STRUJANJA KONVEKTIVNOG ZRAČNOG TOKA
aux . DZDT = -X*Z+R*X-Y
doc . DZDT = X*Y-B*Z
aux doc DZDT = BRZINA PROMJENE VERTIKALNE TEMPERATURNE
VARIJACIJE
const B = 8/3
doc B = VELIČINA PROMATRANE REGIJE
const R = 28
doc R = RAYLEIGH-OV BROJ
const SIGMA = 10
doc SIGMA = PRANDTL-OV BROJ

```

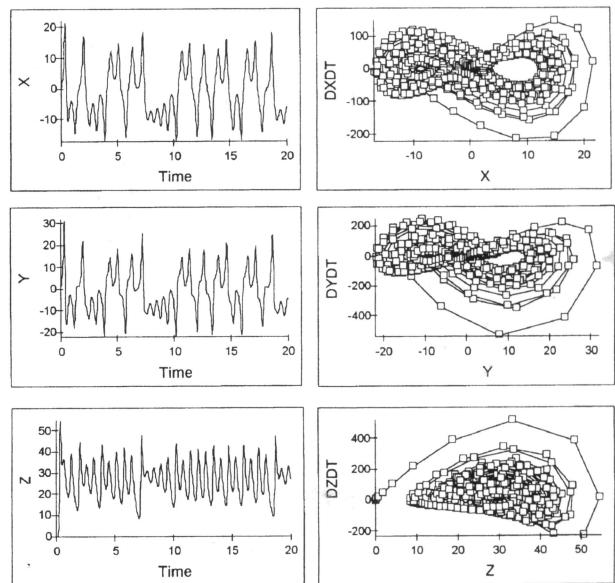
U DYNAMO programskom jeziku model Lorenzovog SAVP-a:

```

*****
* *****DR. ANTE MUNITIĆ*****23.04.1991.*****
* *****01.11.1997.*****
* *****KAOS 2.*****
*
* LORENZ-OV MODEL :
*
* (dx/dt)=sx+sy
* (dy/dt)=xz+rx-y
* (dz/dt)=xy-bz
*
* x= konvektivni zračni tok
* y= horizontalna temperaturna
* variacija
* z= vertikalna temperaturna
* varijabla
* s= Prandtl-ov parametar
* r= Rayleigh-ov parametar
* b= parametar obuhvaćene sregije
*
L X.K=X.J+DT*DX.JK
N X=0
*
R DX.KL=S*X.K+S*Y.K
*
C S=10
*
L Y.K=Y.J+DT*DY.JK
N Y=1
*
R DY.KL=-X.K*Z.K+R*X.K-Y.K
*
C R=28
*
L Z.K=Z.J+DT*DZ.JK
N Z=0
*
R DZ.KL=X.K*Y.K-B*Z.K
*
K B=8/3
*
*****
* SAVE X,Y,Z,DZ,DY,DX
*
SPEC DT=.01,LENGTH=20,SAVPER=.01
*
```



Slika 3. Vremenski dijagram ponašanja varijabli x, y i z Lorenzovog SAVP-a
Figure 3. Variables x, y and z time chart of Lorenz SAWC model



Slika 4. Vremenski i fazni dijagram-atraktor SAVP-a, tj. Lorenzov ‘leptirov učinak’
Figure 4. Time and phase chart - SAWC attractor i.e. Lorenz ‘Butterfly effect’

7.2. Rezultati simulacije Lorenzovog SAVP-a

Lorenz SAVP model simulation results

Kompjutorska simulacija Lorenzovog SAVP-a je izvedena s dva specijalizirana sustav dinamička kompjutorska programska paketa: POWERSIM i DYNAMO, čije kvalitativne rezultate predstavljaju slike 3. i 4.

Analiza dobivenih dinamičkih karakteristika vremensko ovisnih varijabli $x(t)$, $y(t)$ i $z(t)$, ukazuju na interesantnu pojavu njihove ‘kaotične’ oscilacije, čije amplitde i faze poprimaju uvijek drugu vrijednost, nikada se ne ponavljajući, te da se Lorenzov SAVP model dinamički ponaša prividno beskrajno složeno.

Rukopis primljen: 11.12.1997.

Još interesantniji grafički prikaz funkcionalne ovisnosti jest između ‘brzine promjene varijabli i njihova stanja’, ili matematički determinirano:

$$(dx/dt)=f_1(x) \quad (5)$$

$$(dy/dt)=f_2(y) \quad (6)$$

$$(dz/dt)=f_3(z) \quad (7)$$

Inženjeri upravljanja ovakav funkcionalni grafički prikaz nazivaju: ‘trajektorija fazne ravnine’, ili ‘trajektorija faznog prostora’, odnosno, u ovom slučaju ‘Lorenzov atraktor’ ili ‘Lorenzov leptirov učinak’, ili, sasvim općenito: ‘ČUDAN ATRAKTOR’ (Slika 4.)!

Lorenzov atraktor ima oblik leptirovih krila ili lica sove, po kojemu postaje lako prepoznatljiv.

Lorenzovo otkriće je bila ‘gruda snijega’ koja je izazvala pravu ‘znanstvenu lavinu’, iz koje je, krajem XX. stoljeća, započela treća znanstvena revolucija pod nazivom: **Teorija determinističkog kaosa!**

ISPRAVAK IZ PROŠLOG BROJA

U prvom dijelu ovog znanstvenog serijala objavljenog u prošlom broju časopisa potkrale su se sljedeće greške: na stranici 200, u prvom poglavlju, u drugom pasusu, treća rečenica, umjesto godine 1900., treba stajati godina 1980., te u četvrtom pasusu na kraju rečenice treba stajati ‘da je prva započela kvantnom fizikom, a druga teorijom relativnosti’, te u drugom poglavlju jednadžba (1) treba glasiti $2^n \times t_0 = 2^n / f_0$.

Molimo autora i cijenjeno čitateljstvo za ispriku.

Uredništvo