

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ANALIZA MODELA UPRAVLJANJA I REGULACIJE
U OPĆOJ TEORIJI SPOZNAJE

MAGISTARSKI RAD

ZDRAVKO CAREV

ZAGREB, 2011.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ANALIZA MODELA UPRAVLJANJA I REGULACIJE
U OPĆOJ TEORIJI SPOZNAJE

MAGISTARSKI RAD

Mentor:

dr. sc. BRANKO NOVAKOVIĆ, red. prof.

ZDRAVKO CAREV

ZAGREB, 2011.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK:	621.3.078
Ključne riječi:	Spoznaja, Spoznajna teorija, Kibernetika, Automatska regulacija, Dinamika, Prostor egzistencije, Spoznajni stupanj djelovanja, Forme vibriranja, Proces, Istina, Filozofija, Metodologija
Znanstveno područje:	Tehničke znanosti
Znanstveno polje:	Temeljne tehničke znanost
Institucija u kojoj je rad izrađen:	Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu
Mentor rada:	dr. sc. Branko Novaković, red. prof.
Broj stranica:	101
Broj slika:	95
Broj tablica:	18
Broj korištenih bibliografskih jedinica:	38
Datum obrane:	22. prosinac 2011.g.
Povjerenstvo:	dr. sc. Vranješ Božo, red. prof., FSB - predsjednik dr. sc. Branko Novaković, red. prof., FSB - mentor dr. sc. Zdenko Kovačić, red. prof., FER - član
Institucija u kojoj je rad pohranjen	Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu Nacionalna sveučilišna knjižnica Zagreb

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE
POSLIJEDIPLOMSKI STUDIJ

Zagreb, 24. studeni 1999.

ZADATAK ZA MAGISTARSKI RAD

Kandidat : **Zdravko Carev**, dipl.inž. strojarstva

Zadatak: **ANALIZA MODELA UPRAVLJANJA I REGULACIJE
U OPĆOJ TEORIJI SPOZNAJE**

Polazeći od temeljnih postavki opće teorije spoznaje pronaći zakonitosti egzistencije i strukturiranja ponašanja entiteta, odnosno sustava u procesima upravljanja. Dokazati pojam univerzalnosti procesa upravljanja. Odrediti uvjete mogućeg prijenosa spoznaja sa procesa upravljanja na procese regulacije. U tom smislu definirati model, uzorak varijabli, uzorak entiteta, te metode obrade podataka. Predložiti odgovarajuća aplikativna rješenja dobivenih zakonitosti za konkretni objekt upravljanja odnosno regulacije. Uspostaviti spoznajne korelacije između procesa upravljanja, regulacije, odnosno vođenja i umjetne inteligencije. Pritom posebnu pozornost obratiti na primjenu umjetnih neuronskih mreža i sustava neizrazite logike na procese upravljanja i regulacije. Na kraju izvesti odgovarajuće zaključke rada u smislu prednosti i nedostataka navedenog pristupa.

Zadatak zadan: 14. 12. 1999.

Rad predan: -----

Voditelj Odbora za poslijediplomski
studij i doktorate:

Dr.sc. Božo Vranješ, red. prof.

Voditelj magistarskog rada:

Dr.sc. Branko Novaković, red. prof.



ZAHVALA*Zahvala*

mentoru, prof. Branko Novaković za korisne savjete, te konstantnu potporu bez koje bi ovaj rad teško ugledao svjetlo dana.

prof. Božo Vranješ i prof. Zdenko Kovačić koji su u također dali potporu za izradu rada.

prof. Dubravko Majetić, koji je dao podršku u kritičnim trenucima kada je ovaj rad trebalo privesti kraju.

Također, prof. Dobromir Bonacin koji je uvijek bio spreman za žestoku raspravu na temu rada.

Apsolutnu potporu i podršku dali su i roditelji Dalibor i Antonieta, stoga njima posebna zahvala.

*Mnogo je staza oko nas. Koja je prava ?
Ona koju sami utabamo.*

Zdravko Carev

SADRŽAJ

PODACI ZA BIBLIOGRAFSKU KARTICU	II
ZADATAK ZA MAGISTARSKI RAD	III
ZAHVALA.....	IV
SADRŽAJ	VII
PREDGOVOR.....	X
SAŽETAK.....	XI
SUMMARY	XII
KLJUČNE RIJEČI.....	XIII
KEY WORDS	XIII
POPIS OZNAKA I VARIJABLI	XIV
POPIS SLIKA.....	XVI
POPIS TABLICA	XIX
1. UVOD.....	1
2. METODOLOGIJA.....	2
1. Pristup istraživanju	2
2. Prostor istraživanja	3
3. Model	3
4. Uzorak varijabli	4
5. Uzorak entiteta	6
6. Metode obrade podataka	6
7. Temeljni pojmovi.....	10
3. CILJEVI I HIPOTEZE	13
4. REFERENCE.....	15
1. Automatska regulacija u širem smislu.....	15
2. Filozofsko logičke postavke.....	18

5. REZULTATI.....	21
1. Identifikacija taksona.....	21
1. Taksoni 1. razine.....	21
1. Takson br. 1 – Organiziranost (Jednostavnost – Složenost)	21
2. Takson br. 2 – Stabilnost (Varijabilnost – Postojanost).....	22
3. Takson br. 3 – Cjelovitost (Kompaktnost – Raspršenost).....	23
4. Takson br. 4 – Sklad (Fleksibilnost – Krutost).....	23
5. Takson br. 5 – Ekspanzija (Prostorna – Materijalna).....	24
6. Takson br. 6 – Komunikativnost (Aktivnost – Pasivnost).....	25
2. Taksoni 2. razine.....	26
1. Takson br. 1 – Perzistencija (Osjetljivost – Robusnost).....	26
2. Takson br. 2 – Upravlјivost (Elementarnost – Sustavnost).....	27
3. Takson br. 3 – Edukatibilnost (Površnost – Sistematičnost).....	30
3. Taksoni 3. razine.....	31
1. Takson br. 1 – Determinizam (Dezintegracija (neodređenost) – Integracija (određenost)).....	31
2. Takson br. 2 – Razvoj (Zasićen – Svestran)	31
4. Razina 4 – Glavni takson - Spoznaja (Parcijalna – Globalna).....	32
5. Slike taksona i tablice sa projekcijama	33
2. Procesi spoznaje	59
6. OPĆA TEORIJA SPOZNAJE	62
1. Temelji opće teorije spoznaje – definicija.....	62
2. Ostale prepoznate razine opće teorije spoznaje	63
1. Druga razina opće teorije spoznaje.....	63
2. Treća razina opće teorije spoznaje.....	65
3. Četvrta razina opće teorije spoznaje.....	67
3. Procesi na 4. razini opće teorije spoznaje.....	69
4. Hijerarhija prepoznatih razina opće teorije spoznaje.....	72
5. Potvrda hipoteze.....	74

7. PRIMJERI	75
1. Primjer br 1.....	76
1. Rezultati	77
1. Orhoblique faktori.....	77
2. Polarni taksoni	78
3. Popis svih varijabli.....	83
2. Primjer br. 2.....	84
1. Slučaj br. 1 – nezavisne uzbude	84
1. Rezultati.....	85
1. Orhoblique faktori.....	85
2. Polarni taksoni.....	86
2. Slučaj br. 2	92
1. Rezultati: Orhoblique faktori	92
3. Kako postupati po općoj teoriji spoznaje.....	96
4. Dodatni osvrt na neke tvrdnje	97
8. ZAKLJUČAK	98
9. LITERATURA.....	100
KRATKI ŽIVOTOPIS	XX
SHORT BIOGRAPHY	XXII

PREDGOVOR

Razni interesi kao i brojni kontakti sa područjima koja po klasičnoj definiciji nemaju dodirne točke ni sa strojarstvom, a ni sa automatskom regulacijom vrlo vjerojatno su glavni razlog za nastanak ovog rada.

Uočena veza između, na prvi pogled totalno različitih područja, dovela je do toga da se u prvi plan postavi univerzalnost i kao trajna orijentacija postavi zadaća pronalaženja zajedničkog nazivnika svih dodirnutih područja.

Kao jako zahvalno područje iz kojeg se može krenuti na ovakav put, pokazala se upravo automatska regulacija u širem smislu: dovoljno je općenita tj. jako je bliska kibernetici kao općoj znanosti o upravljanju, dok je sa druge strane dovoljno konkretna da ne podnosi proizvoljna i površna tumačenja. Osim toga bliska je i matematici kao neizbježnom teorijskom alatu.

Ovime je ostavljena maksimalna sloboda kreaciji uz istodobnu mogućnost provjere dobivenih rezultata na konkretnom i u suštini širokom području.

SAŽETAK

U radu se predlaže sveopća i svezremenska *teorija*. *Teorija* proučava *sve*. *Sve* se definira kao cijeli svijet bez ikakvog ostatka u bilo kakvom pogledu. U središte *teorije* postavljena je *Spoznaja*, koja se definira kao skup *zakonitosti* kojima neki *entitet* vlada. *Entitet* se definira kao bilo koja registrabilna pojava. *Zakonitost* se definira kao opće i nepromjenjivo pravilo.

Definicija Opće teorije spoznaje:

1. Postoje opće zakonitosti koje važe uvijek i svugdje,
2. Generalna (glavna) zakonitost je *Spoznaja*,
3. Postoje hijerarhijski niže rangirane, međuovisne *Spoznaje*.

Spoznaja se uvodi kao apsolutni kriterij klasificiranja *entiteta*. Teleološki cilj svakog entiteta je maksimalna moguća spoznaja tj. spoznaja svega. S obzirom da se proučava *sve*, ne postoji slučajnost; slučaj se definira kao djelovanje trenutno nepoznatih entiteta.

Dinamički sustavi se proučavaju na isti način kao i statički. Vrijeme kao parametar je potrebno „samo“ iz razloga da se može registrirati napredovanje / nazadovanje entiteta na spoznajnoj skali. Osim glavne zakonitosti *spoznaje*, u radu su pronađene još tri razine „*spoznaja*“ unutar kojih su opisane Kibernetika i Teorija kaosa. Osim toga prikazano je kako se pomoću *teorije* definira znanstveni, a kako stručni rad.

Primjena i proširenje *teorije* je prikazano dvama primjerima.

U prvom primjeru se proučava klasični p2 član sa step ulazom. Sve varijable kojima se opisuje ponašanje p2 člana svedene su na tri neortogonalna faktora: *Prigušenje*, *Brzina* i *Amplituda*. Nadalje su izolirana 3 neortogonalna bipolarna tipa (taksona) p2 članova koji su opisani kao:

1. *Energija unutar objekta* sa polovima: *Masena (derivacijska) kontrola* i *Opružna (proporcionalna) kontrola*,
2. *Tranzicija* sa polovima: *Tvrđi prijelaz* i *Meki prijelaz* (način prijelaza iz opružne u masenu kontrolu), i
3. *Akumulirana energija* sa polovima: *Mala energija sustava* i *Velika energija sustava*.

Ovime je uspostavljena veza sa II razinom *teorije* te je identificirano da *Energija unutar sustava* predstavlja *Perzistenciju*, *Tranzicija* je predstavljena *Upravljivošću*, a *Akumulirana energija* *Edukatibilnošću*.

U drugom primjeru pronađen je ekvivalent tipovima u klasičnom smislu koji se definira kao tip ponašanja u dinamičkom smislu. Prikazani su razlozi zbog kojih se predlaže napuštanje koncepta objekt regulacije + regulator. Definirani su ekstremi spoznajnog pristupa kao ispitivanje objekta / entiteta nezavisnim uzбудama sa jedne strane te objekt / entitet kao servosustav sa druge strane. U dinamičkom smislu, spoznaje entiteta su prepoznate kao linearne kombinacije formi vibriranja. Dobijen je generalni tip (forma) ponašanja koja je identificirana sa svrhom entiteta / objekta.

Kao mjera (dinamičke) učinkovitosti projektiranog entiteta / objekta predložen je od projektanta potpuno nezavisan, spoznajni supanj djelovanja (η_{sp}). On se definira kao omjer u realnosti stvarno iskazanih i svih (ukupnih) spoznaja entiteta / objekta.

SUMMARY

In this work, it is proposed wide and all-times *Theory*. A *theory* that analyses and encloses *everything*. Term *Everything* is defined as whole World without any remainder in any sense. In the center of *Theory* it was *Comprehension* allocated and such comprehension is defined as set of rules that one entity dispose. The *Entity* is defined as any observed phenomenon. *Rule* is global and unchangeable regulation.

The Definition of Global Comprehensive Theory:

1. **There are global existing rules that exist always and everywhere,**
2. **General (main) rule is *Comprehension*,**
3. **There exist hierarchically lower inter-dependant *Comprehensions*.**

The *Comprehension* is introduced as absolute criteria of the *entity* classification. Teleological aim of any entity is the most probable cognition/comprehension i.e. of everything. Whereas we study *all*, there are no random situations. The random occurrence is defined as the activity of presently unknown entities.

The dynamic systems are analyzed in the same way as static. Time as a parameter is necessary "only" for the purpose of registering the advancement / retrogression of the entity on the comprehensive scale. Apart from the main validity of *comprehension* in the work, there have been found three more *comprehension* levels inside, and by means of theory – Cybernetics and the Theory of Chaos were described. Furthermore, it was shown, with the help of theory, how can be scientific and professional articles defined.

The appliance and the expansion of the *theory* are shown with two examples.

In the first example the classical mass-spring-damper system with step input is analyzed. All variables which describe the behavior of the mass-spring-damper system are reduced to three non-orthogonal factors: *Damping*, *Speed* and *Amplitude*. Furthermore, there are isolated 3 non-orthogonal bipolar types (clusters) of the mass-spring-damper system described as:

Pole object inner energy – *Mass (derivational) control* – *Spring (proportional) control*.

Pole transition – *Hard transition* and *Soft transition* (the mode of transition from Spring to Mass control)

Pole accumulated energy – *Little system energy* and *Big system energy*

With this, the link with the 2nd level of theory is established and it is identified that *Energy* within the system represents *Persistence*, *Transition* is represented by *Maneuverability*, and *Accumulated energy* by *Educational function*.

In the second example, there is an equivalent to the types in the most classical manner which is defined as a behavioral type in dynamic sense. Reasons for which it is suggested to abandon the concept object regulation + regulator are shown. Extremes of the comprehensive approach as analyzing object / entity by independent excitations on one side, and object / entity as servo-system on the other side are defined. In dynamic sense comprehension of an entity is recognized as linear combinations of mode shapes. It was obtained a general type (form) of behavior which is identified with the purpose of entity / object.

As a measure of (dynamic) efficiency of designed entity / object it is suggested by the designer completely independent comprehensive efficiency level of operation (η_{sp}). It is defined as ratio of really expressed entity comprehensions and its all possible comprehensions.

KLJUČNE RIJEČI

Spoznaja, Spoznajna teorija, Kibernetika, Automatska regulacija, Dinamika, Prostor egzistencije, Spoznajni stupanj djelovanja, Forme vibriranja, Proces, Istina, Filozofija, Metodologija.

KEY WORDS

Comprehension, Comprehension Theory, Cybernetics, Automatic regulation, Dynamics, Space of Existence, Comprehensive Efficiency, Mode shapes, Process, Truth, Philosophy, Methodology.

POPIS OZNAKA I VARIJABLI

Oznaka	Opis
% VAR	postotak objašnjenog varijabiliteta u odnosu na ukupni varijabilitet
amr	amplituda na rezonantnoj frekvenciji
amx	maksimalno ubrzanje
BREL	broj ukupnih direktnih relacija
BREM	broj točaka za emisiju informacija
BRLU	ukupni broj linija (=brli+brzi)
BRPR	broj točaka za prijem informacija
BRSK	broj direktnih relacija skeleta
BRSP	broj spojnica
BRTO	broj točaka
BRVR	broj zarobljenih točaka (u vreći)
ddd	prigušenje
e0	trajno regulacijsko odstupanje
Ep	potencijalna energija na kraju
fpr	faktor prigušenja
FY	projekcija sile broj Y na faktor
IMNV	minimalni broj koraka potrebnih za prijenos informacije u najnepovoljnijem slučaju
IMXV	maksimalni broj koraka potrebnih za prijenos informacije u najnepovoljnijem slučaju
JEDS	jednostavnost strukture
maxf	frekvencija na kojoj je izdizanje amplitude = 10 % maksimalnog (rezonantnog) izdizanja (viša frekvencija)
minf	frekvencija na kojoj je izdizanje amplitude = 10 % maksimalnog (rezonantnog) izdizanja (niža frekvencija)
m-mf	= maxf – minf
mmm	masa
mpa	apsolutna maksimalna amplituda (t – područje)
mpp	postotni prebačaj (t – područje)
mpt	vrijeme maksimalne amplitude (t – područje)
NSET	najudaljenija slobodna eksterna točka
NSTO	najudaljenija slobodna točka općenito
OBQY	orthoblique faktor broj Y
omb	širina pojasa
omn	neprigušena vlastita frekvencija
omp	prigušena vlastita frekvencija
omr	rezonantna frekvencija
PRAV	pravilnost

PRY	projekcija na faktor / takson broj Y
REPR	reproducibilnost
SIME	simetričnost
sss	krutost opruge
stp	stupanj prigušenja
TAXY	takson (tip) broj Y
tra	vrijeme porasta odziva sa 10% na 90%
tsmi	vrijeme smirivanja (odstupanje +/- 10%)
vmx	maksimalna brzina
WFFuk	ukupan apsolutan rad ulazne sile
WFiuk	ukupan apsolutan rad sile inercije
WFouk	ukupan apsolutan rad sile opruge
WFpuk	ukupan apsolutan rad sile prigušenja
Wukup	ukupna energija
XXXX	broj zarobljenih pozicija ukupno
ZAPO	broj praznih zarobljenih pozicija
η_{sp}	spoznajni stupanj djelovanja

POPIS SLIKA

Oznaka	Naziv	Strana
Slika 2.5.1.	Entiteti od E001 do E480 – vektorski format	7
Slika 2.5.2.	Entiteti od E481 do E700 – vektorski format	8
Slika 2.5.3.	Entiteti od E001 do E140 – rasterski format	8
Slika 2.5.4.	Entiteti od E140 do E700 – rasterski format	9
Slika 5.1.5.1.	Organiziranost (1. razina, 1. takson.); negativna strana: Jednostavnost	33
Slika 5.1.5.2.	Organiziranost (1. razina, 1. takson); pozitivna strana - Složenost	33
Slika 5.1.5.3.	Organiziranost (1. razina, 1. takson); negativna strana: Jednostavnost	34
Slika 5.1.5.4.	Organiziranost (1. razina, 1. takson); pozitivna strana - Složenost	34
Slika 5.1.5.5.	Stabilnost (1. razina, 2. takson); negativna strana - Varijabilnost	35
Slika 5.1.5.6.	Stabilnost (1. razina, 2. takson); pozitivna strana - Postojanost	35
Slika 5.1.5.7.	Stabilnost (1. razina, 2. takson); negativna strana - Varijabilnost	36
Slika 5.1.5.8.	Stabilnost (1. razina, 2. takson); pozitivna strana - Postojanost	36
Slika 5.1.5.9.	Cjelovitost (1. razina, 3. takson); negativna strana - Kompaktnost	37
Slika 5.1.5.10.	Cjelovitost (1. razina, 3. takson); pozitivna strana - Raspršenost	37
Slika 5.1.5.11.	Cjelovitost (1. razina, 3. takson); negativna strana - Kompaktnost	38
Slika 5.1.5.12.	Cjelovitost (1. razina, 3. takson); pozitivna strana - Raspršenost	38
Slika 5.1.5.13.	Sklad (1. razina, 4. takson); negativna strana - Fleksibilnost	39
Slika 5.1.5.14.	Sklad (1. razina, 4. takson); pozitivna strana - Krutost	39
Slika 5.1.5.15.	Sklad (1. razina, 4. takson); negativna strana - Fleksibilnost	40
Slika 5.1.5.16.	Sklad (1. razina, 4. takson); pozitivna strana - Krutost	40
Slika 5.1.5.17.	Ekspanzija (1. Razina, 5. Takson); negativna strana - Prostorna	41
Slika 5.1.5.18.	Ekspanzija (1. Razina, 5. Takson); pozitivna strana - Materijalna	41
Slika 5.1.5.19.	Ekspanzija (1. Razina, 5. Takson); negativna strana - Prostorna	42
Slika 5.1.5.20.	Ekspanzija (1. Razina, 5. Takson); pozitivna strana - Materijalna	42
Slika 5.1.5.21.	Komunikativnost (1. razina, 6. takson); negativna strana - Aktivnost	43
Slika 5.1.5.22.	Komunikativnost (1. razina, 6. takson); negativna strana - Pasivnost	43
Slika 5.1.5.23.	Komunikativnost (1. razina, 6. takson); negativna strana - Aktivnost	44
Slika 5.1.5.24.	Komunikativnost (1. razina, 6. takson); negativna strana - Pasivnost	44
Slika 5.1.5.25.	Perzistencija (2. razina, 1. takson); negativna strana - Osjetljivost	45
Slika 5.1.5.26.	Perzistencija (2. razina, 1. takson); negativna strana - Robusnost	45
Slika 5.1.5.27.	Perzistencija (2. razina, 1. takson); negativna strana - Osjetljivost	46
Slika 5.1.5.28.	Perzistencija (2. razina, 1. takson); negativna strana - Robusnost	46
Slika 5.1.5.29.	Upravlјivost (2. razina, 2. takson); negativna strana - Elementarnost	47
Slika 5.1.5.30.	Upravlјivost (2. razina, 2. takson); pozitivna strana - Sustavnost	47
Slika 5.1.5.31.	Upravlјivost (2. razina, 2. takson); negativna strana - Elementarnost	48
Slika 5.1.5.32.	Upravlјivost (2. razina, 2. takson); pozitivna strana - Sustavnost	48
Slika 5.1.5.33.	Edukatibilnost (2. razina, 3. takson); negativna strana - Površnost	49
Slika 5.1.5.34.	Edukatibilnost (2. razina, 3. takson); pozitivna str. - Sistematičnost	49

Slika 5.1.5.35.	Edukatibilnost (2. razina, 3. takson); negativna strana - Površnost	50
Slika 5.1.5.36.	Edukatibilnost (2. razina, 3. takson); pozitivna strana - Sistematičnost	50
Slika 5.1.5.37.	Determinizam (3. razina, 1. takson); negativna strana – Dezintegracija (neodređenost)	51
Slika 5.1.5.38.	Determinizam (3. razina, 1. takson); negativna strana – Integracija (određenost)	51
Slika 5.1.5.39.	Determinizam (3. razina, 1. takson); negativna strana – Dezintegracija (neodređenost)	52
Slika 5.1.5.40.	Determinizam (3. razina, 1. takson); negativna strana – Integracija (određenost)	52
Slika 5.1.5.41.	Razvoj (3. razina, 2. takson); negativna strana – Zasićen	53
Slika 5.1.5.42.	Razvoj (3. razina, 2. takson); negativna strana - Svestran	53
Slika 5.1.5.43.	Razvoj (3. razina, 2. takson); negativna strana – Zasićen	54
Slika 5.1.5.44.	Razvoj (3. razina, 2. takson); negativna strana - Svestran	54
Slika 5.1.5.45.	Spoznaja (4. razina, glavni takson); negativna strana - Globalna	55
Slika 5.1.5.46.	Spoznaja (4. razina, glavni takson); pozitivna strana - Parcijalna	55
Slika 5.1.5.47.	Spoznaja (4. razina, glavni takson); pozitivna strana - Parcijalna	56
Slika 5.1.5.48.	Spoznaja (4. razina, glavni takson); negativna strana - Globalna	56
Slika 5.2.1.	sortirani glavni takson	60
Slika 5.2.2.	konstruktivni procesi	61
Slika 5.2.3.	destruktivni procesi	61
Slika 6.2.3.1.	Shema spoznavanja entiteta u prostoru njegove egzistencije	68
Slika 6.3.1.	Komunikativnost (+ = pasivnost)	69
Slika 6.3.2.	Ekspanzija (+ = materijalna)	69
Slika 6.3.3.	Organiziranost (- = jednostavnost)	69
Slika 6.3.4.	Cjelovitost (+ = raspršenost)	70
Slika 6.3.5.	Stabilnost (- = varijabilnost)	70
Slika 6.3.6.	Sklad (+ = krutost)	70
Slika 6.3.7.	Procesi spoznaje – 1. razina (6 taksona)	71
Slika 6.4.1.	Hijerarhija „spoznaja“ po općoj teoriji spoznaje	72
Slika 7.1.1.2.1.	1. Takson - negativna strana	82
Slika 7.1.1.2.2.	1. Takson - pozitivna strana	82
Slika 7.1.1.2.3.	2. Takson - negativna strana	82
Slika 7.1.1.2.4.	2. Takson - pozitivna strana	82
Slika 7.1.1.2.5.	3. Takson - negativna strana	82
Slika 7.1.1.2.6.	3. Takson - pozitivna strana	82
Slika 7.2.1.	Početni položaj ispitivane konstrukcije	84
Slika 7.2.2.	grafički prikaz projekcija progiba na faktore	85
Slika 7.2.3.	grafički prikaz projekcija progiba na glavni faktor	85
Slika 7.2.4.	Grafički prikaz projekcija progiba na taksone 2. razine	86
Slika 7.2.5.	Ekstremni objekti negativne strane 1. taksona	87
Slika 7.2.6.	Ekstremni objekti pozitivne strane 1. taksona	87
Slika 7.2.7.	Ekstremni objekti negativne strane 2. taksona	87
Slika 7.2.8.	Ekstremni objekti pozitivne strane 2. taksona	87
Slika 7.2.9.	Ekstremni objekti pozitivne strane glavnog taksona	87
Slika 7.2.10.	Ekstremni objekti negativne strane glavnog taksona	87
Slika 7.2.11.	Grafički prikaz projekcija varijabli na glavni takson	88
Slika 7.2.12.	1., 2. i 3. forma vibriranja	88
Slika 7.2.13.	Zadnja (13.) forma vibriranja	88

Slika 7.2.14.	Grafički prikaz projekcija varijabli na faktor OBQ1	93
Slika 7.2.15.	Grafički prikaz projekcija varijabli na faktor OBQ4	93
Slika 7.2.16.	Grafički prikaz projekcija varijabli na faktor OBQ5	93
Slika 7.2.17.	Grafički prikaz projekcija varijabli na faktor OBQ6	93
Slika 7.2.18.	Grafički prikaz projekcija varijabli na faktor OBQ3	93
Slika 7.2.19.	Grafički prikaz projekcija varijabli na faktor OBQ2	93
Slika 7.2.20.	Grafički prikaz projekcija varijabli - 2. razina, 2. faktor	94
Slika 7.2.21.	Grafički prikaz projekcija varijabli - 2. razina, 1. faktor	94
Slika 7.2.22.	Grafički prikaz projekcija varijabli - 2. razina, 3. faktor	94
Slika 7.2.23.	Grafički prikaz projekcija varijabli - 3. razina, 2. faktor	94
Slika 7.2.24.	Grafički prikaz projekcija varijabli - 3. razina, 1. faktor.	94
Slika 7.2.25.	Grafički prikaz projekcija varijabli - Glavni faktor	94

POPIS TABLICA

Oznaka	Naziv	Strana
Tablica 2.4.1.	Popis varijabli modela	4
Tablica 2.4.2.	Ostale varijable	5
Tablica 2.7.1.	Osnovni pojmovi	10
Tablica 5.1.5.1.	Projekcija varijabli na taksone 1. razine	57
Tablica 5.1.5.2.	Relacije svih varijabli i taksona	58
Tablica 6.2.1.1.	Taksoni 3. Razine – 2. Razina u općoj teoriji spoznaje (OTS)	63
Tablica 6.2.2.1.	Taksoni 2. Razine – 3. Razina u općoj teoriji spoznaje	65
Tablica 6.2.3.1.	Taksoni 1. Razine – 4. Razina u općoj teoriji spoznaje (OTS)	67
Tablica 7.1.1.1.1.	Orthoblique - Sklop	77
Tablica 7.1.1.1.2.	Korelacije orthoblique faktora	78
Tablica 7.1.1.2.1.	Tipovi (taksoni)	80
Tablica 7.1.1.3.1	Popis varijabli za opis p2 člana	83
Tablica 7.2.1.	Faktori, 1. razina	85
Tablica 7.2.2.	Faktori, 2. razina	85
Tablica 7.2.3.	Taksoni 1. razina	86
Tablica 7.2.4.	Glavni takson	88
Tablica 7.2.5.	η_{sp} formi vibriranja	90
Tablica 7.2.6.	Orthoblique faktori	92

1. UVOD

Jedno od najvažnijih svojstava po kojem se čovjek odvojio od svoje okoline je mogućnost obrade velike količine informacija. Taj trend je pogotovo razvidan u zadnje vrijeme za koje se može reći da predstavlja pravi informacijski „bum“, jer u današnje vrijeme lake dostupnosti gomile informacija putem medija, interneta, knjiga, količina informacija jest stvarno ogromna. No slični „bumovi“ zasigurno su postojali i u prošlosti. Otkriće govora, pisma ili tiskarskog stroja za ono vrijeme vrlo vjerojatno je predstavljao veći „šok“ od današnje „informatičke revolucije“.

No da se ne bi „ugušili“ u svim tim informacijama uvijek je postojao, pa tako i danas postoji suprotni trend kojim se nastoji informacije istog ili sličnog sadržaja podvesti pod isti zajednički nazivnik, te tako zadržati samo ono **bitno** od onih informacija koje su nam na raspolaganju. Ili u najmanju ruku nastojimo zadržati one informacije koje su nama kao pojedincima bitne. Ako se malo pogleda u povijest vjerojatno nema čovjeka, a pogotovo filozofa, koji nije pokušao proniknuti u *spiritus movens* svijeta, tj svega što nas okružuje. Objasniti informacije koje nas okružuju sa manjim brojem pravila kojima se pokoravaju, te proniknuti u suštinu neke pojave pravi je izazov. Zahvaljući ljudima koji su to u prošlosti radili danas imamo npr. Newtonov zakon ili npr. Fenomenologiju – znanost o bitnome.

Ali i oni koji nisu krenuli „filozofskim putem“ i ako su bili uspješni u svojim područjima, prije ili poslije pokušavali su svoje spoznaje proširiti i na ostala „nematična“ područja. Tako se primjerice došlo na određenoj razini spoznaje do maksimalne transparentije ili bolje rečeno do identičnosti nekih mehaničkih i električnih zakona, ili do sličnosti mikro i makro svijeta. Ili, slično tome, odavno je poznata činjenica da se proporcionalno, integracijsko i derivacijsko djelovanje lako mogu preslikati u ponašanje čovjeka [1], dakako ne nekoj razini promišljanja. No, čini se da su ovakve spoznaje nekako ostavljene po strani i to po načelu: „znamo mi da je matematički opis RLC električnog kruga i MDS mehaničkog „kruga“ matematički identičan, ali hajd'mo mi po starome“ !

Ako uvažimo ovu činjenicu nameće se zaključak: **identičnost matematičkog modela povlači za sobom i neko općenitije razmišljanje** koje sve to zajedno opisuje. Postoji „neka logika“ koja mora objasniti zašto je to isto – pa dakle, to je neki zakon koji kaže da su takva ponašanja pravilo. I točka ! Zašto, kako, ... e to je već drugo pitanje, ali činjenica da postoji zajedničko pravilo jest utvrđena.

Ovaj rad predstavlja prijedlog takvih **sveopćih pravila**. Dakle **ona koja važe uvijek i svugdje. Koja su važila i koja će trajno važiti**. Uostalom, već se ustanovilo da svi „filozofiramo“ i da svi radimo generalizacije. Pa kad ih već radimo, napravimo maksimalnu moguću !

2. METODOLOGIJA

2. 1. Pristup istraživanju

Kako bi mogli pronaći pravila koja važe svugde i uvijek potrebno je proučavati **sve**, odnosno sve što je postojalo i sve što će postojati !

No, iako se ovo čini apsolutno nemoguće, objasnimo na jednom primjeru kako je to ipak moguće. Prisjetimo se npr. III Newtonovog zakona, zakona akcije i reakcije koji glasi: „*Svakom djelovanju (akciji) suprotstavlja se po intenzitetu jednako i suprotno usmjereno djelovanje (reakcija). Djelovanje dva tijela jednog na drugo jednako je i suprotno usmjereno.*“ ($\vec{F}_1 = -\vec{F}_2$)“

Ovo pravilo se toliko često koristi prilikom rješavanja brojnih zadataka i problema u strojarstvu da ga se gotovo više i „ne primjećuje“. Drugim riječima pravilo je postao dio uobičajenog načina razmišljanja svakog strojara. Je li ovo pravilo vrijedilo prije nego ga je Newton uočio ? Očigledno jest. A hoće li postojati u budućnosti ? Pa zasigurno hoće ! Ono može biti poopćeno, može postati dio nekog drugog, općenitijeg pravila ali ono kao **temelj koji opisuje temeljnu interakciju dva fizička tijela bilo je i ostati će svevremensko i sveprisutno** !

Kao što je rečeno, ovo pravilo može biti integrirano, poopćeno u neko „bolje“, općenitije pravilo, ali za predhodno navedenu **razinu razmišljanja ono je apsolutno**. Čak što više, već sada se to pravilo može jednostavno poopćiti i na jedno totalno drugačije područje npr. Na odnose između ljudi. Ako npr. nekoga verbalno napadnemo vrlo vjerojatno možemo očekivati reakciju. Ovo *vrlo vjerojatno* ne znači relativizaciju pravila, već samo znači da reakcija ne mora biti istog *tipa* kao i akcija. Možda će taj netko vidjeti da smo veći, jači, opasniji, ili možda „nižih spoznaja“, pa „neće reagirati“ već „zanemariti“, odmaknuti se ili slično. A možda će nam uzvratiti i fizičkim napadom. No u svakom slučaju reakcija će postojati, bila ona latentna ili stvarna ! Ovo je u psihologiji poznato kao reakcija napada ili reakcija obrane, ovisno o aktivnosti napadnutog.

Ako se samo malo bolje razmisli očigledno je da se ovakvo pravilo može protegnuti na bilo što – dakle važi općenito. I danas i sutra i u mehanici i kod ljudi i Samo ga treba znati pravilno primjeniti, tj. prepoznati ga u konkretnom slučaju !

Izvedimo iz ovoga prvu bitnu premisu ovog rada: **svi dosadašnji zakoni moraju se moći objasniti u novopostavljenoj općoj teoriji spoznaje**. Ovo nadalje znači da će se u radu krenuti od postulata da su pravila koja nas okružuju primjenjiva svugde, kao npr. opisano proporcionalno, regulacijsko i derivacijsko pravilo ili malo prije spomenuti Newton-ov zakon. Jer inače nisu pravila !

Može se doduše i postaviti hipoteza da ne postoji opće pravilo. To bi značilo da skup pravila koja vrijede u strojarstvu jednostavno ne važe u elektrotehnici ili kod ljudi, planeta, itd. Drugim riječima to bi značilo da ne postoje opća pravila. No „problem“ ove tvrdnje jest to da su i strojevi i električni uređaji i ljudi i planete sastavljeni iz **istog** skupa „građevnog materijala“, samo su manje ili više složeni. Nadalje, to znači da oni složeniji „samo“ mogu imati više načina ponašanja, tj. mogu iskazivati više varijacija od onih manje složenih. U sve njih ugrađeni su isti zakoni, samo su sve složeniji prirodni zakoni prepoznatljivi kod složenijih oblika.

Iz ovoga slijedi druga bitna premisa ovog rada, a glasi da za **sve moguće objekte postoje univerzalna pravila**. No, ako postoje univerzalna pravila za sve objekte, nameće se logičan zaključak da onda i metode proučavanja objekata imaju nekakav zajednički dio. Pa dakle i metode upravljanja, regulacije i vođenja imaju dodirne točke sa svim ostalim područjima.

Sukladno svemu rečenome **u središte proučavanje stavlja se sve što postoji** ! Pod sve se podrazumjeva sve, bez ostatka, dakle bilo što postoji.

Kako je ovo realno tehnički nemoguće obuhvatiti, uzeti će se iz toga svega **slučajan reprezentativan uzorak**, te temeljem njega objektivno proučavati sve. Ovo znači da se ne smije krenuti iz nekog konkretnog područja npr. automatske regulacije, jer će se tako imati efekt neželjene selekcije tj. aspekt užeg područja promatranja. Ovakav pristup bi automatski značio gubitak reprezentativnosti proučavanih objekata i ulazak u, za ovaj rad, neželjeno konkretno područje, barem dok se ne pokažu opća pravila. Poslije mogu i konkretni primjeri.

Kako odabrati uzorak tj. kako objektivno odabrati entitete (objekte) ? Kako izbjeći zamku makar i nehotičnog odabira područja kojeg osobno najbolje poznajemo ? A u isto vrijeme da dobijemo konzistentan prostor proučavanja.

Čini se da je tada kao prostor proučavanja najbolje odabrati **maksimalno apstraktno područje**. To je vjerojatno maksimalno poopćenje koje je za ovakav pristup moguće. Tada je i transparentija na sva ostala poznata ali i „poznata“ područja maksimalna. Osim problema objektivnog odabira objekata u ovako apstraktno postavljenom problemu nameće se i zadaća izbjegavanja proizvoljnog ili špekulativnog tumačenja dobivenih rezultata.

2. 2. Prostor istraživanja

Osim navedenih problema, treba uzeti u obzir i druga realna ograničenja (vremenska, tehnička, ...). Stoga su za prostor istraživanja odabrani objekti koje je moguće smjestiti u raster 9 x 9.

No, osim crteža za opis objekata potrebno je mnogo više. Potrebno je odrediti **prostor egzistencije objekta**. Pod ovime se podrazumjeva da pomoću n varijabli (ili parametara) možemo opisati, u idelnom slučaju 100 % varijacija objekata u tako definiranom prostoru.

2.3. Model

Pod fenomenološkim modelom, a u svrhu spoznavanja bitnih odrednica takvog prostora, u skladu s ciljevima očekuje se utvrđivanje konstantnih zakonitosti koje vladaju unutar njega, i opisuju se skupom parametara (varijabli) koji razapinju multidimenzionalno područje spoznaje.

Dakle, unutar bilo kako određenog n -dimenzionalnog prostora, egzistira skup konstantnih k -dimenzionalnih zakonitosti.

Kriteriji za definiciju prostora u ovom radu jesu :

- pretpostavka o univerzalnosti zakonitosti,
- dovoljna razlučivost metodologije za otkrivanje svih zakonitosti, bez obzira na dimenzionalnost i longitudinalnost prostora,
- jednostavnost tehničkog provođenja istraživanja.

2.4. Uzorak varijabli

Kako bi se područje spoznaje moglo i opisati, pa i razapeti, potrebno je odrediti skup u tom području manifestnih i ne međusobno kolinearnih varijabli. Dakako, budući je skup manifestnih varijabli teorijski beskonačan, treba odabrati one koje će biti reprezentanti traženih zakonitosti analiziranog prostora, tj. bira se uzorak varijabli iz populacije varijabli uz uvjet reprezentativnosti. Za potrebe ovog rada konstruirano je ukupno 66 varijabli, u prvom koraku je zadržano njih 48 dok je za konačnu aplikaciju zadržano njih 18, u skladu s njihovim metrijskim karakteristikama (dobijenim na temelju informacija o maksimalnoj pripadnosti istraživanom području spoznaje, ali i na temelju informacija o njihovoj faktorskoj valjanosti). Varijable su prikazane *tablicom 2.4.1. i 2.4.2.*

Primjenjene varijable :

Napomena: varijable označene sa zvjezdicom (*) nisu linearno nezavisne, te se zato ne apliciraju skupno.

mogući tipovi varijabli: 1 - izmjerena varijabla; 2 - procjenjena varijabla.

š.varij.	opis varijable	mjerno područje	tip	nap.
BRPR	broj točaka za prijem informacija	cjelobrojno kontin.	1	
XXXX	broj zarobljenih pozicija ukupno	cjelobrojno kontin.	1	
BRSK	broj direktnih relacija skeleta	cjelobrojno kontin.	1	
BRTO	broj točaka	cjelobrojno kontin.	1	
JEDS	jednostavnost strukture	1,2,3,4,5	2	
REPR	reproducibilnost	1,2,3,4,5	2	
NSET	najudaljenija slobodna eksterna točka	cjelobrojno kontin.	1	
NSTO	najudaljenija slobodna točka općenito	cjelobrojno kontin.	1	
PRAV	pravilnost	1,2,3,4,5	2	
SIME	simetričnost	1,2,3,4,5	2	
IMNV	minimalni broj koraka potrebnih za prijenos informacije u najnepovoljnijem slučaju	cjelobrojno kontin.	1	
IMXV	maksimalni broj koraka potrebnih za prijenos informacije u najnepovoljnijem slučaju	cjelobrojno kontin.	1	
BREM	broj točaka za emisiju informacija	cjelobrojno kontin.	1	
BRSP	broj spojnica	cjelobrojno kontin.	1	
BRLU	ukupni broj linija (=brli+brzi)	cjelobrojno kontin.	1	*
BRVR	broj zarobljenih točaka (u vreći)	cjelobrojno kontin.	1	
BREL	broj ukupnih direktnih relacija	cjelobrojno kontin.	1	
ZAPO	broj praznih zarobljenih pozicija	cjelobrojno kontin.	1	

Tablica 2.4.1 – popis varijabli modela

š.varij.	opis varijable	mjerno područje	tip	nap.
BRCV	broj čvorova	cjelobrojno kontin.	1	
BRLI	broj ravnih linija	cjelobrojno kontin.	1	
BRPI	broj slobodnih završetaka (pipaka)	cjelobrojno kontin.	1	
BRSE	broj segmenata	cjelobrojno kontin.	1	
BRZI	broj zakrivljenih linija	cjelobrojno kontin.	1	
BSSS	broj segmenata slobodnog prostora	cjelobrojno kontin.	1	
CJEL	cjelovitost	1,2,3,4,5	2	
DIJU	dijagonalna usmjerenost	1,2,3,4,5	2	
DINA	dinamičnost	1,2,3,4,5	2	
HORU	horizontalna usmjerenost	1,2,3,4,5	2	
IZVO	izvornost	1,2,3,4,5	2	
KUTI	kut zakreta osi inercije	realno kontinuiran	1	*
LIPO	estetski dojam	1,2,3,4,5	2	
MIPO	polarni moment inercije	realno kontinuiran	1	*
MIXX	moment inercije po x os-i	realno kontinuiran	1	*
MIXY	centrifugalni moment inercije	realno kontinuiran	1	*
MIYY	moment inercije po y os-i	realno kontinuiran	1	*
MOPO	polarni moment otpora	realno kontinuiran	1	*
MOTX	moment otpora po x os-i	realno kontinuiran	1	*
MOTY	moment otpora po y os-i	realno kontinuiran	1	*
OMJR	omjer visina / širina	realno kontinuiran	1	
ORIP	prepoznatljivost ovisno o orijentaciji	1,2,3,4,5	2	
PINX	polumjer inercije po x os-i	realno kontinuiran	1	*
PINY	polumjer inercije po y os-i	realno kontinuiran	1	*
SICC	kapacitet za vodu (sić)	cjelobrojno kontin.	1	
SMNV	najpovoljniji broj „smočenih“ točaka	cjelobrojno kontin.	1	
SMXV	najnepovoljniji broj „smočenih“ točaka	cjelobrojno kontin.	1	
TEZC	udaljenost težišta od centra objekta	realno kontinuiran	1	
UOCL	uočljivost	1,2,3,4,5	2	
VERU	vertikalna usmjerenost	1,2,3,4,5	2	

Tablica 2.4.2. – ostale varijable

2. 5. Uzorak entiteta

U definiranom dvo-dimenzionalnom prostoru moguća je egzistencija konačnog, ali iznimno velikog broja entiteta. Iz tog razloga, a i u skladu s teorijom vjerojatnosti i zakonom velikih brojeva, očigledno je kako je neophodno odrediti dovoljno veliki uzorak entiteta, kako bi se eliminirale stohastičke varijacije projektiranja uzorka i sistematske greške, koje bi mogle kontaminirati rezultate i deformirati sliku o općim zakonitostima.

Stoga je definiran broj entiteta koji po tim kriterijima zadovoljava sve uvjete korektnog provođenja istraživanja, a taj broj je 700. Od posebnih uvjeta koje entiteti moraju zadovoljiti još je samo dodan takav po kojemu ne smije biti takvih dva ili više istih entiteta.

S obzirom na relativno veliku količinu informacija i relativno mali raster u kojem su entiteti prikazani, osim prikaza svih entiteta u rasteru (*slike 2.5.3 i 2.5.4.*), oni su prikazani i u vektorskom formatu (*slike 2.5.1 i 2.5.2.*). Ovo će biti od velike pomoći prilikom identifikacije. Napomenimo još da svjetlije točkice predstavljaju „točkice u vreći“; one nisu dio konstrukcije ali ipak pomažu bržem prijenosu informacija te sudjeluju u ukupnom broju točkica.

2. 6. Metode obrade podataka

Za obradu podataka, osim preliminarnih procedura, sukladno ciljevima, mogućnostima provjere hipoteza i modelu, odabran je multivarijantni pristup, i to Taksonomska analiza pod modelom polarnih taksona (E. Zakrajšek, 1974) također prikazana u [26]. Ova procedura osigurava prepoznavanje tipova entiteta po dominantnim karakteristikama na način da maksimizira položaj dijametralno suprotnih entiteta u okviru jedne karakteristike (taksona). Dakako da su dopuštene neortogonalne relacije između taksona. Procedura također daje informacije o opisu taksona varijablama, a dopušta da jedan entitet bude projiciran na jedan ili više taksona, čime se osigurava izuzetno precizna identifikacija tipova, pa dakle i mehanizama koji entitete strukturiraju, što znači da je osiguran opis očekivanih zakonitosti u kojemu sudjeluju sve informacije.

Osim ove procedure korištena je modificirana *Indifg* procedura prikazana također u [26]. Ova procedura se koristi za otkrivanje spoznajnih procesa entiteta.

1. E001	7. E007	13 E013	19 E019	25 E025	31 E031	37 E037	43 E043	49 E049	55 E055	61 E061	67 E067	73 E073	79 E079	85 E085	91 E091	97 E097	103 E103	109 E109	115 E115
-2.12	-0.35	-0.90	-0.82	0.72	-0.56	-0.54	0.02	-0.63	0.92	-0.67	-1.09	-0.64	-0.70	-0.30	-0.49	-1.28	0.33	-0.13	0.05
2. E002	8. E008	14 E014	20 E020	26 E026	32 E032	38 E038	44 E044	50 E050	56 E056	62 E062	68 E068	74 E074	80 E080	86 E086	92 E092	98 E098	104 E104	110 E110	116 E116
-3.34	-0.89	-0.72	-1.43	-1.44	-0.64	0.23	-0.59	-1.25	0.43	-0.48	-0.67	-0.19	-0.76	-0.45	-2.02	-0.92	0.34	-1.23	-0.93
3. E003	9. E009	15 E015	21 E021	27 E027	33 E033	39 E039	45 E045	51 E051	57 E057	63 E063	69 E069	75 E075	81 E081	87 E087	93 E093	99 E099	105 E105	111 E111	117 E117
-0.89	-1.18	0.05	-0.95	-0.27	-1.74	-0.52	-1.16	-1.32	-0.36	-0.31	-1.26	-0.46	-1.60	-0.34	-0.60	-0.10	-0.34	-2.36	0.20
4. E004	10 E010	16 E016	22 E022	28 E028	34 E034	40 E040	46 E046	52 E052	58 E058	64 E064	70 E070	76 E076	82 E082	88 E088	94 E094	100 E100	106 E106	112 E112	118 E118
-0.38	-3.02	-0.96	-0.31	0.26	-1.75	-0.77	0.37	-0.57	-1.69	-0.29	-1.34	-1.78	-0.23	0.00	-0.73	-0.01	0.35	0.86	0.21
5. E005	11 E011	17 E017	23 E023	29 E029	35 E035	41 E041	47 E047	53 E053	59 E059	65 E065	71 E071	77 E077	83 E083	89 E089	95 E095	101 E101	107 E107	113 E113	119 E119
-0.19	-1.95	-0.96	-0.47	-0.09	-1.34	-1.58	0.07	-1.28	-0.33	-0.85	-0.62	-0.27	-0.43	-1.04	-1.15	-0.07	-0.53	0.36	-1.79
6. E006	12 E012	18 E018	24 E024	30 E030	36 E036	42 E042	48 E048	54 E054	60 E060	66 E066	72 E072	78 E078	84 E084	90 E090	96 E096	102 E102	108 E108	114 E114	120 E120
-0.60	-1.18	-0.82	-0.85	-1.48	-0.54	-1.75	-4.59	-2.62	-0.94	-1.07	-0.14	-0.72	-0.37	-0.68	-0.58	-0.33	-0.59	-0.33	-0.33
12 E121	12 E127	13 E133	13 E139	14 E145	15 E151	15 E157	16 E163	16 E169	17 E175	18 E181	18 E187	19 E193	19 E199	20 E205	21 E211	21 E217	22 E223	22 E229	23 E235
0.39	-0.70	0.61	0.61	-0.38	-0.03	0.82	0.37	-0.31	0.00	0.52	0.52	-2.39	0.16	-0.30	-0.30	-0.43	0.36	0.29	0.02
12 E122	12 E128	13 E134	14 E140	14 E146	15 E152	15 E158	16 E164	17 E170	17 E176	18 E182	18 E188	19 E194	20 E200	20 E206	21 E212	21 E218	22 E224	23 E230	23 E236
-0.48	0.47	0.53	0.04	-0.47	0.27	0.14	0.10	0.40	0.24	-2.54	0.45	-0.04	0.08	-0.24	-1.57	0.89	0.43	1.30	1.26
12 E123	12 E129	13 E135	14 E141	14 E147	15 E153	15 E159	16 E165	17 E171	17 E177	18 E183	18 E189	19 E195	20 E201	20 E207	21 E213	21 E219	22 E225	23 E231	23 E237
0.13	-0.56	-1.51	0.61	-1.36	0.58	-0.36	-1.54	-0.02	-0.02	-2.28	0.37	-0.43	-0.02	-1.24	-2.43	0.01	0.50	-1.63	0.67
12 E124	13 E130	13 E136	14 E142	14 E148	15 E154	16 E160	16 E166	17 E172	17 E178	18 E184	19 E190	19 E196	20 E202	20 E208	21 E214	22 E220	23 E226	23 E232	23 E238
0.19	0.49	-0.61	-1.12	-0.04	0.37	-0.07	0.06	-0.11	-0.67	-0.68	0.02	-0.42	-0.24	0.68	-0.39	1.07	-0.89	2.84	2.84
12 E125	13 E131	13 E137	14 E143	14 E149	15 E155	16 E161	16 E167	17 E173	17 E179	18 E185	19 E191	19 E197	20 E203	20 E209	21 E215	22 E221	23 E227	23 E233	23 E239
-0.21	0.57	-1.93	-1.09	-0.24	-0.67	0.32	-1.57	-1.16	0.38	-0.58	-0.29	0.94	-0.46	-0.82	-1.03	-0.70	-0.10	-0.77	2.05
12 E126	13 E132	13 E138	14 E144	15 E150	15 E156	16 E162	16 E168	17 E174	18 E180	18 E186	19 E192	19 E198	20 E204	21 E210	21 E216	22 E222	23 E228	23 E234	24 E240
-0.52	0.54	0.21	-0.18	-0.14	-0.29	-0.26	-0.23	0.16	0.42	-0.72	0.15	-0.01	-2.90	-0.28	-1.22	-0.29	1.36	0.99	0.76
24 E241	24 E247	25 E253	25 E259	26 E265	27 E271	27 E277	28 E283	28 E289	29 E295	30 E301	30 E307	31 E313	31 E319	32 E325	33 E331	33 E337	34 E343	34 E349	35 E355
1.37	0.74	0.98	1.92	0.28	0.28	0.10	0.46	0.37	-3.08	-1.76	1.05	-0.06	0.54	-0.29	-0.50	-0.73	-0.55	-0.80	0.23
24 E242	24 E248	25 E254	26 E260	26 E266	27 E272	27 E278	28 E284	29 E290	29 E296	30 E302	30 E308	31 E314	32 E320	32 E326	33 E332	33 E338	34 E344	35 E350	35 E356
-1.60	0.97	0.55	-0.19	1.42	0.21	0.91	0.69	-1.65	-2.55	0.43	0.83	0.16	0.55	-0.09	-0.08	-0.30	-0.54	0.08	-0.73
24 E243	24 E249	25 E255	26 E261	26 E267	27 E273	27 E279	28 E285	29 E291	29 E297	30 E303	30 E309	31 E315	32 E321	32 E327	33 E333	33 E339	34 E345	35 E351	35 E357
2.07	-0.28	0.99	0.40	0.25	1.14	-1.48	0.72	0.41	2.73	2.35	0.02	0.27	0.92	-0.46	1.17	-0.58	-0.66	1.16	-0.34
24 E244	25 E250	25 E256	26 E262	26 E268	27 E274	28 E280	28 E286	29 E292	29 E298	30 E304	31 E310	31 E316	32 E322	32 E328	33 E334	34 E340	34 E346	35 E352	35 E358
0.06	1.48	1.19	0.54	-0.41	-1.24	-0.03	0.03	2.33	2.33	0.67	1.55	0.10	0.18	-0.40	0.06	-0.38	0.07	-0.32	-0.34
24 E245	25 E251	25 E257	26 E263	27 E269	27 E275	28 E281	28 E287	29 E293	29 E299	30 E305	31 E311	31 E317	32 E323	32 E329	33 E335	34 E341	34 E347	35 E353	35 E359
0.55	1.35	0.74	0.54	1.12	1.20	0.03	0.23	0.02	-2.96	0.15	1.90	-0.18	0.26	0.09	-0.44	-0.62	2.10	0.37	-1.35
24 E246	25 E252	25 E258	26 E264	27 E270	27 E276	28 E282	28 E288	29 E294	30 E300	30 E306	31 E312	31 E318	32 E324	33 E330	33 E336	34 E342	34 E348	35 E354	36 E360
0.76	1.32	-1.29	-6.14	-0.90	-1.54	1.17	-1.90	-0.75	-1.46	1.29	0.64	1.31	2.00	-0.40	0.15	-0.38	-0.27	0.43	-0.19
36 E361	36 E367	37 E373	37 E379	38 E385	39 E391	39 E397	40 E403	40 E409	41 E415	42 E421	42 E427	43 E433	43 E439	44 E445	45 E451	45 E457	46 E463	46 E469	47 E475
0.01	-0.91	0.76	0.70	1.01	-0.11	0.86	1.44	1.38	1.87	-1.24	-1.55	0.21	1.47	1.34	1.04	0.16	0.02	-0.07	-0.07
36 E362	36 E368	37 E374	38 E380	38 E386	39 E392	39 E398	40 E404	41 E410	41 E416	42 E422	42 E428	43 E434	44 E440	44 E446	45 E452	45 E458	46 E464	47 E470	47 E476
-1.56	-0.54	0.55	0.43	0.21	-0.98	0.11	-0.13	-0.26	-0.61	-0.60	1.12	0.43	1.48	1.71	1.93	0.36	-0.18	-0.10	-0.10
36 E363	36 E369	37 E375	38 E381	38 E387	39 E393	39 E399	40 E405	41 E411	41 E417	42 E423	42 E429	43 E435	44 E441	44 E447	45 E453	45 E459	46 E465	47 E471	47 E477
-1.20	-0.17	1.32	0.59	-0.46	-0.26	0.63	0.34	1.11	-0.06	0.44	0.93	0.80	0.65	1.24	1.38	0.36	0.29	-0.03	-0.21
36 E364	37 E370	37 E376	38 E382	38 E388	39 E394	40 E400	40 E406	41 E412	41 E418	42 E424	43 E430	43 E436	44 E442	44 E448	45 E454	46 E460	46 E466	47 E472	47 E478
-0.35	-0.27	0.56	1.10	0.54	0.84	1.54	0.85	0.51	0.27	-0.10	1.38	0.87	1.21	0.57	1.59	-0.52	0.28	-0.02	0.16
36 E365	37 E371	37 E377	38 E383	38 E389	39 E395	40 E401	40 E407	41 E413	41 E419	42 E425	43 E431	43 E437	44 E443	44 E449	45 E455	46 E461	46 E467	47 E473	47 E479
-0.87	1.35	0.93	1.69	-0.45	0.39	-0.14	-0.24	0.78	-1.13	-1.05	0.55	1.48	1.47	1.07	1.33	-2.27	0.20	-0.35	0.19
36 E366	37 E372	37 E378	38 E384	39 E390	39 E396	40 E402	40 E408	41 E414	42 E420	42 E426	43 E432	43 E438	44 E444	45 E450	45 E456	46 E462	46 E468	47 E474	48 E480
0.40	1.82	1.47	-0.61	-1.04	-0.09	0.32	0.73	1.29	-0.37	-1.44	0.60	1.40	1.12	1.20	0.80	-0.11	0.47	-0.62	0.97

Slika 2.5.1. Entiteti od E001 do E480 – vektorski format

48E481 -1.18	48E487 -0.41	49E493 0.05	49E499 0.03	50E505 0.27	51E511 -0.63	51E517 0.01	52E523 -1.18	52E529 0.37	53E535 1.20	54E541 0.66	54E547 -0.28	55E553 0.78	55E559 -0.83	56E565 0.32	57E571 -1.65	57E577 1.01	58E583 0.64	58E589 -0.06	59E595 -1.17										
48E482 1.01	48E488 -1.53	49E494 -0.14	50E500 -0.12	50E506 -0.19	51E512 -0.91	51E518 0.29	52E524 0.17	53E530 0.77	53E536 0.77	54E542 0.11	54E548 0.45	55E554 0.77	56E560 0.57	56E566 0.82	57E572 -1.24	57E578 2.82	58E584 -0.62	59E590 1.86	59E596 0.54										
48E483 0.38	48E489 -1.87	49E495 -0.08	50E501 -0.12	50E507 -0.96	51E513 -0.03	51E519 0.02	52E525 -0.32	53E531 -1.25	53E537 -0.23	54E543 0.04	54E549 0.25	55E555 -1.02	56E561 -0.94	56E567 1.11	57E573 0.88	57E579 1.52	58E585 1.18	59E591 0.25	59E597 0.61										
48E484 0.41	49E490 0.04	49E496 -0.25	50E502 0.30	50E508 -0.08	51E514 -0.37	52E520 0.07	52E526 0.07	53E532 -1.53	53E538 0.38	54E544 -0.22	55E550 1.02	55E556 0.41	56E562 -0.04	56E568 0.51	57E574 1.68	58E580 0.35	58E586 0.95	59E592 0.90	59E598 0.36										
48E485 -0.34	49E491 -0.57	49E497 -0.14	50E503 0.53	50E509 -0.01	51E515 0.15	52E521 -0.39	52E527 0.01	53E533 1.65	53E539 0.49	54E545 0.41	55E551 -0.62	55E557 0.53	56E563 0.22	56E569 0.49	57E575 1.36	58E581 -0.15	58E587 0.78	59E593 0.83	59E599 0.05										
48E486 -0.19	49E492 -0.36	49E498 -0.23	50E504 -1.39	51E510 0.24	51E516 -0.37	52E522 -0.40	52E528 -0.32	53E534 -0.39	54E540 0.00	54E546 -0.10	55E552 1.41	55E558 0.79	56E564 0.38	57E570 1.01	57E576 1.51	58E582 0.35	58E588 2.63	59E594 -0.73	60E600 0.07										
60E601 -1.43	60E607 1.08	61E613 0.65	61E619 -0.53	62E625 -0.11	63E631 0.50	63E637 -0.19	64E643 -1.56	64E649 -0.27	65E655 0.38	66E661 1.25	67E671 1.89	67E677 0.31	68E683 -0.02	68E689 0.93	69E695 1.61	66E666 0.76	67E672 0.75	67E678 1.14	68E684 -0.59	69E696 1.24									
60E602 0.17	60E608 0.76	61E614 0.12	62E620 -0.16	62E626 0.06	63E632 -0.46	63E638 -1.47	64E644 -0.18	65E650 0.11	65E656 0.73	66E662 1.00	66E668 0.84	67E674 -1.32	68E680 0.66	68E686 0.04	69E692 -0.94	66E667 0.06	67E673 0.52	67E679 0.27	68E685 0.64	69E691 0.67	69E697 -0.05								
60E603 2.39	60E609 1.44	61E615 1.61	62E621 0.38	62E627 0.45	63E633 -0.68	63E639 1.71	64E645 1.07	65E651 -0.66	65E657 1.01	66E663 0.87	66E669 0.44	67E675 0.66	68E681 -0.50	68E687 1.13	69E693 0.59	66E664 1.34	66E670 0.06	67E676 0.32	68E682 -0.51	68E688 2.18	69E694 0.70	70E700 -0.48	70E706 0.90						
60E604 -0.60	61E610 -0.00	61E616 1.15	62E622 0.36	62E628 0.23	63E634 -1.36	64E640 0.55	64E646 0.60	65E652 0.37	65E658 1.41	66E664 0.87	66E670 0.44	67E676 0.66	68E682 -0.50	68E688 1.13	69E694 0.59	66E665 0.76	67E671 1.89	67E677 0.31	68E683 -0.02	68E689 0.93	69E695 1.61	66E662 1.00	66E668 0.84	67E674 -1.32	68E680 0.66	68E686 0.04	69E692 -0.94	69E698 0.03	
60E605 -0.31	61E611 -0.17	61E617 1.47	62E623 -0.31	62E629 -0.11	63E635 0.01	64E641 0.40	64E647 -1.02	65E653 -0.19	65E659 1.41	66E663 0.87	66E669 0.44	67E675 0.66	68E681 -0.50	68E687 1.13	69E693 0.59	66E664 1.34	66E670 0.06	67E676 0.32	68E682 -0.51	68E688 2.18	69E694 0.70	70E700 -0.48	70E706 0.90	66E665 0.76	67E671 1.89	67E677 0.31	68E683 -0.02	68E689 0.93	69E695 1.61
60E606 1.00	61E612 1.51	61E618 0.14	62E624 -0.10	63E630 0.26	63E636 -0.55	64E642 -0.04	64E648 0.43	65E654 0.29	65E660 0.46	66E666 0.76	67E672 0.75	67E678 1.14	68E684 -0.59	69E696 1.24	66E667 0.06	67E673 0.52	67E679 0.27	68E685 0.64	69E691 0.67	69E697 -0.05	66E662 1.00	66E668 0.84	67E674 -1.32	68E680 0.66	68E686 0.04	69E692 -0.94	69E698 0.03		

Slika 2.5.2. Entiteti od E481 do E700 – vektorski format

E001, pr	E008, pr	E015, pr	E022, pr	E029, pr	E036, pr	E043, pr	E050, pr	E057, pr	E064, pr	E071, pr	E078, pr	E085, pr	E092, pr	E099, pr	E106, pr	E113, pr	E120, pr	E127, pr	E134, pr
1.	8.	15.	22.	29.	36.	43.	50.	57.	64.	71.	78.	85.	92.	99.	106.	113.	120.	127.	134.
E002, pr	E009, pr	E016, pr	E023, pr	E030, pr	E037, pr	E044, pr	E051, pr	E058, pr	E065, pr	E072, pr	E079, pr	E086, pr	E093, pr	E100, pr	E107, pr	E114, pr	E121, pr	E128, pr	E135, pr
2.	9.	16.	23.	30.	37.	44.	51.	58.	65.	72.	79.	86.	93.	100.	107.	114.	121.	128.	135.
E003, pr	E010, pr	E017, pr	E024, pr	E031, pr	E038, pr	E045, pr	E052, pr	E059, pr	E066, pr	E073, pr	E080, pr	E087, pr	E094, pr	E101, pr	E108, pr	E115, pr	E122, pr	E129, pr	E136, pr
3.	10.	17.	24.	31.	38.	45.	52.	59.	66.	73.	80.	87.	94.	101.	108.	115.	122.	129.	136.
E004, pr	E011, pr	E018, pr	E025, pr	E032, pr	E039, pr	E046, pr	E053, pr	E060, pr	E067, pr	E074, pr	E081, pr	E088, pr	E095, pr	E102, pr	E109, pr	E116, pr	E123, pr	E130, pr	E137, pr
4.	11.	18.	25.	32.	39.	46.	53.	60.	67.	74.	81.	88.	95.	102.	109.	116.	123.	130.	137.
E005, pr	E012, pr	E019, pr	E026, pr	E033, pr	E040, pr	E047, pr	E054, pr	E061, pr	E068, pr	E075, pr	E082, pr	E089, pr	E096, pr	E103, pr	E110, pr	E117, pr	E124, pr	E131, pr	E138, pr
5.	12.	19.	26.	33.	40.	47.	54.	61.	68.	75.	82.	89.	96.	103.	110.	117.	124.	131.	138.
E006, pr	E013, pr	E020, pr	E027, pr	E034, pr	E041, pr	E048, pr	E055, pr	E062, pr	E069, pr	E076, pr	E083, pr	E090, pr	E097, pr	E104, pr	E111, pr	E118, pr	E125, pr	E132, pr	E139, pr
6.	13.	20.	27.	34.	41.	48.	55.	62.	69.	76.	83.	90.	97.	104.	111.	118.	125.	132.	139.
E007, pr	E014, pr	E021, pr	E028, pr	E035, pr	E042, pr	E049, pr	E056, pr	E063, pr	E070, pr	E077, pr	E084, pr	E091, pr	E098, pr	E105, pr	E112, pr	E119, pr	E126, pr	E133, pr	E140, pr
7.	14.	21.	28.	35.	42.	49.	56.	63.	70.	77.	84.	91.	98.	105.	112.	119.	126.	133.	140.

Slika 2.5.3. Entiteti od E001 do E140 – rasterski format



Slika 2.5.4. Entiteti od E141 do E700 – rasterski format

2.7. Temeljni pojmovi

Kako bi se olakšalo praćenje rada i izbjegle moguće nejasnoće u ovom dijelu su zadani neki pojmovi za koje se smatra da su izuzetno važni u radu. Ovo je napravljeno iz razloga da se naglasi važnost ali isto tako da bi se izbjegao mogući nesporazum.

Istina	Nepobitna činjenica.
Sve	Cijeli svijet bez ikakvog ostatka u bilo kakvom pogledu, i bez ma kakvih ograničenja u bilo kojem smislu.
Prostor	Jasno određeni dio neke cjeline koji se od svega ostalog razlikuje po svojim jasno definiranim specifičnim granicama.
Sustav	Dio prostora koji ima makar intuitivne granice prema okruženju i koji ima interakcije s tom vanjskom sredinom u nekom definiranom prostoru.
Entitet / Objekt	Bilo kakva registrabilna pojava imanentna nekom prostoru
Zakovitost	Trajno i nepromjenjivo pravilo koje egzistira u bilo kako zadanom prostoru i kojemu se sve u tom prostoru bezuvjetno podvrgava.
Mehanizam	Izolirano pojedinačno pravilo od čije funkcije zavise bilo kako definirane manifestacije.
Hijerarhija	Uređenost zakonitosti u jasno strukturirane mehanizme različitih redova od nižih prema višima ili obrnuto.
Razina	Dosegnuti stupanj razvoja u ovladanosti (spoznatosti) zakonitostima.
Spoznaja	Skup zakonitosti kojima neki entitet vlada (koje je entitet spoznao) na nekoj razini.
Teorija	Skup komplementarnih spoznaja koje uključuju spoznaje različitih razina.

Tablica 2.7.1. – Osnovni pojmovi

Temeljne informacije i logičke premise

U ovom dijelu su navedene spoznaje i činjenice koje se neće posebno dokazivati. Pri tome je moguće utvrditi slijedeće logičke premise na koje se ovaj rad oslanja :

1. “Elementarno što je potpuno sigurno jest da svi, ma kakvi, entiteti postoje, jer ako ne postoje nema daljnje rasprave !”

Ako entiteti uopće ne postoje, ne postoji ni materijalni svijet.

2. Ako entiteti nisu različiti onda je samo jedan.

Ako postoji samo jedan jedini entitet tada nema apsolutno nikakve razlike u bilo kojem pogledu. Ako nema razlike, nema ni procesa jer je razlika preduvjet odvijanja bilo kakvog procesa. Ako nema procesa ništa se ne dešava. U ovom slučaju sve je stalno i nepromjenjivo te je daljnja rasprava nepotrebna.

3. Ako ima više entiteta i oni su različiti, onda su u njih očito ugrađene različite spoznaje.

Entiteti imaju različite spoznaje. Kako bi bila održiva, ova tvrdnja mora evidentno zadovoljiti uvjet prema kojemu je bitno spoznavati, dakle sve više i više.

Uvjet je zadovoljen ako se spoznaje sve više i više iz nekog dovoljno jasnog razloga, a taj razlog je : *spoznati SVE !* To znači, naravno, da će se spoznavati dok se ne dosegne SVE, tj. *cijeli svijet bez ikakvog ostatka u bilo kakvom pogledu, i bez ma kakvih ograničenja u bilo kojem smislu.* A zašto je bitno spoznati SVE ? Zato jer tek kad je spoznato SVE postignuti su u cijelosti i bez ostatka svi mogući ciljevi i dosegnuta je kompletna znanstvena (i svaka druga) *Istina.*

4. Razlike su uvjetovane sposobnostima entiteta

Ako među entitetima postoje razlike definirane stupnjem razvoja, to znači da su te razlike ustvari rezultat mogućnosti ma kako definiranih entiteta da se maksimalno realiziraju u zadanim uvjetima, u smislu spoznaje prostora ili razine u kojoj se nalaze.

5. Entiteti egzistiraju u nekom prostoru !

Dakako da određeni uvjeti ne moraju podjednako odgovarati svim entitetima za njihovu spoznajnu realizaciju, zbog čega i jesu prisutne razlike između entiteta. Budući entiteti egzistiraju u nekim uvjetima, područje monotonih promjena uvjeta ili stabilno područje bez ikakvih promjena uvjeta u kojemu neki entitet egzistira i realizira se zove se Prostor!

Prostor egzistencije

Uzmimo uzorak od m reprezentativnih entiteta iz nekog prostora proučavanja. Uzmimo također i n reprezentativnih varijabli kojima možemo opisati u idealnom slučaju sve varijacije uzetih entiteta. U ovom slučaju kažemo da smo razapeli n – dimenzionalni **prostor egzistencije** entiteta.

Ovaj prostor se može konkretizirati sa n – dimenzionalnim vektorskim prostorom što je u ovom radu i učinjeno. No, to nije isključivi uvjet. Može se odabrati i nekakav drugi način (prostori neeuclidiske metrike, ...); to je načeno „nevažno“, sa pozicije ovog rada radi se „samo“ o alatu koji nam pomaže da otkrijemo što to ustvari proučavamo. Riječ „nevažno“ nije slučajno u navodnicima – u uvodu je rečeno da nam i matematički alat daje mnogo informacija. Ili ako parafraziramo d'Alambert – ovo zapažanje o algebr: „*Algebra je darežljiva, često daje više nego što se od nje traži.*“ možemo kazati: „*Matematika je darežljiva, često daje više nego što se od nje traži.*“ uz dodatak „*ali to nije uvijek vidljivo*“.

Primjer 1: Neka je zadatak proučavanje grede nekih određenih svojstava (dužina, ...) učvršćene na dva kraja. Neka u okolini pronađemo m reprezentativnih greda od svih mogućih greda (zadanih svojstava) koje uopće postoje. Neka su one opisane sa n progiba na n različitim mjestima. U ovom slučaju gredu smatramo entitetom, a progib varijablom. Tada za svaku pojedinu gredu kažemo da egzistira u n – dimenzionalnom prostoru, tj. svaka greda se može opisati sa n – varijabli.

Primjer 2: Uzmimo jednu gredu istih svojstava kao i u predhodnom primjeru te promatrajmo njeno dinamičko ponašanje na način da u reprezentativnom broju vremenskih trenutaka opišemo trenutne vrijednosti sa istih n – varijabli iz predhodnog primjera. Može se ustvrditi da dinamička reprezentacija grede egzistira u n – dimenzionalnom prostoru ili što je isto, prostor egzistencije greda promatran dinamički jest n – dimenzionalan.

Tvrđnja 1: Prostori egzistencije u prvom i drugom primjeru su identični.

Tvrđnja 2: Predhodna tvrdnja vrijedi općenito; za bilo koje objekte/entitete.

Obrazloženje *Tvrđnje 1:* neka je u prvom slučaju zadan skup A kao skup svih mogućih položaja grede. No tada se u skupu A nalaze i svi dinamički položaji iz *Primjera 2*. I to iz jednostavnog razloga što su u skupu A svi mogući slučajevi, dakle u 2. slučaju ne može nastupiti slučaj koji nije u A . A kako je i u 1. i u 2. slučaju uzet reprezentativan skup nije bitno jesu li ta dva skupa identična, čak štoviše mogu biti i potpuno različiti; to nije ni bitno za istraživanje. Bitan je prostor egzistencije. Time je dokazana *Tvrđnja 1*.

No, ovo razmišljanje se može poopćiti na način da nije bitno koji su konkretni entiteti/objekti. Time je dokazana i *Tvrđnja 2*.

Predhodno razmišljanje nam dopušta „brisanje“ granice između dinamičkog i statičkog proučavanja entiteta/objekata. Jedino je bitno da dobro odredimo prostor egzistencije.

3. CILJEVI I HIPOTEZE

Ako egzistira ma kakav nadređeni mehanizam koji "upravlja" ponašanjem neke velike skupine entiteta u nekom ma kako određenom prostoru tada je prikladnim istraživačkim modelom moguće utvrditi pravila "ponašanja" unutar te skupine, i otkriti o kakvom se mehanizmu radi i kojim se parametrima može opisati. Ovo sve, naravno, uz poznatu pogrešku zaključivanja. Nadalje, ukoliko se odabirom različitih entiteta i parametara dobivaju takvi mehanizmi koji pokazuju perzistenciju i prepoznatljivost, tada je jasno da ustvari predstavljaju svojstva ili karakteristike tih uzoraka. I konačno, ako su egzistentni u različitim uvjetima ili ih je moguće objasniti dinamički, tada je jasno da se ne radi samo o svojstvima već o zakonitostima. Zatim treba dosta rigorozno provjeriti postoji li konzistentan, a uz to konačan i relativno mali broj takvih zakonitosti, tj. stalnih i prepoznatljivih relacija objekata ili utvrđenih zakonitosti.

U ovako zahtjevnom slučaju, tj. postavljanju temelja Opće teorije spoznaje, ostaje još samo provjera invarijantnosti takvih zakonitosti, i to kako u vremenskoj i prostornoj dimenziji, tako i u prostoru svih multidisciplinarnih područja. Ovdje se očividno radi o transparentnosti postavljenih temelja na sve druge moguće, bilo kako postavljene, uvjete, ograničenja ili primjene općenito. U skladu s navednim u prethodnim poglavljima, razvidno je kako se traži i očekuje cjelovitost referentnih kategorija koje opisuju model spoznajnog procesa, ali zbog evidentne univerzalnosti svih pojava i pretpostavki, također i cjelovitost rezultata, interpretacije, pa i eventualne primjene tako dobivenih spoznaja.

Prvi cilj rada jest: Pod fenomenološkim modelom, a na temelju odabranog uzorka entiteta, uzorka varijabli i postupaka transformacije podataka – utvrđivanje koherentnog prostora u kojemu leže sve bitne karakteristike neke pojave, procesa ili skupa objekata, tj. ona svojstva koja smatramo zakonitostima. Ovo možemo, uz samo malo mašte nazvati razapinjanje konzistentnog prostora u kojemu egzistiraju temeljni spoznajni mehanizmi.

Nulta hipoteza bi glasila da je nemoguće razapeti takav multidimenzionalni prostor u kojemu egzistiraju sve zakonitosti spoznajnih procesa. tj. da takvih jasnih konzistentnih pravila tj. zakonitosti nema, pa ih dakle ni istraživanjem nije moguće izolirati. To je dakle utvrđivanje konačnog, stabilnog i malog broja konzistentnih pravila "ponašanja" ma kako definiranog uzorka entiteta iz neke populacije entiteta, opisane ma kako definiranim uzorkom varijabli iz neke populacije varijabli.

Drugi cilj rada, a direktno povezan s prvim jest: Ako je prethodna hipoteza odbačena tada stupanj objašnjenosti svih varijacija (koje mogu egzistirati čak i pod stohastičkim pretpostavkama) takvog prostora mora biti poznat, i maksimalan.

Nulta hipoteza bi glasila da neće biti poznat stupanj objašnjenosti varijacija promatranih parametara u prostoru u kojemu egzistiraju odabrani entiteti, tj. kvantificirana pogreška modela neće biti poznata.

Treći cilj, a direktno u svezi s drugim jest: Ako je prethodna hipoteza odbačena, tada stupanj objašnjenosti svih varijacija pretpostavljenog multidimenzionalnog prostora nužno mora biti jako visok, i to toliko da dopušta generalizaciju i transparentiju dobivenih rezultata.

Nulta hipoteza bi glasila da je stupanj objašnjenja svih varijacija definirano prostora i entiteta opisanih parametrima premali te da ne dopušta generalizirano zaključivanje, što zasigurno niti ne dopušta generalizaciju u pravcu Opće teorije spoznaje.

Četvrti cilj rada jest: ako je prethodna hipoteza odbačena, utvrditi relacije između dobivenog skupa reprezentativnih odnosno latentnih mehanizama, tj. svojstava razapetog prostora.

Nulta hipoteza bi glasila da izolirani mehanizmi koji karakteriziraju razapeti prostor stoje u nultim relacijama, tj. da su ortogonalni.

Peti cilj rada jest: Ako je prethodna hipoteza odbačena, utvrditi egzistenciju nadređenih, i eventualno generalnog mehanizma, od kojih ovise sve varijacije rezultata u utvrđenom prostoru. Ovo bi značilo da se očekuje egzistencija mehanizama višeg reda, povrh kojih u svakom slučaju stoji generalni spoznajni mehanizam.

Nulta hipoteza bi glasila da ne postoji globalni mehanizam najvišeg reda od kojega ovisi funkcija njemu podređenih mehanizama.

Šesti cilj rada jest: Ako su utvrđeni bilo kakvi mehanizmi višeg reda, tada je potrebno ustanoviti o kakvim se mehanizmima radi, a što se postiže opisom tih mehanizama uz pomoć varijabli koje ga najbolje opisuju.

Nulta hipoteza bi glasila da nije moguće skupom odabranih varijabli opisati mehanizam višeg reda od kojeg ovisi "ponašanje" mehanizama nižeg reda.

Sedmi cilj rada jest: Ako su utvrđeni bilo kakvi mehanizmi višeg reda, tada je potrebno ustanoviti njihov tipološki karakter, tj. koji entiteti i s kakvim karakteristikama ponajbolje opisuju te mehanizme.

Nulta hipoteza bi glasila da nije moguće skupom odabranih entiteta opisati mehanizam višeg reda od kojeg ovisi "ponašanje" mehanizama nižeg reda.

Osmi cilj rada jest: Pod pretpostavkom da su za sve prethodne ciljeve prihvaćene alternativne hipoteze, očito je da je postavljen skup pravila u kojima se točno znade na koji način će se doći do ključnih i globalnih spoznaja za neki zadani problem. Međutim, ako je održiva i pretpostavka o univerzalnosti prostora egzistencije, tj. ako je irelevantno kakav je prostor koji se proučava (a dakako i kakvi su odabrani entiteti i parametri za procjenu) tada je jasno da će ta pravila tj. zakonitosti biti invarijantni na logičke premise određenja prostora. A tada će i transparentnost spoznaja iz prethodnih hipoteza biti maksimalna, i protezat će se preko svih mogućih logičkih konstrukata.

Nulta hipoteza bi glasila: Spoznaje dobijene ovim istraživanjem primjenjive su na SVE spoznaje, kako u prošlosti utvrđene, jednako tako i danas spoznate, a i one koje se tek očekuju. Isto tako i na parcijalna znanja uskog opsega, ali i na globalna. I jednako na sve vrste i tipove entiteta, npr. "živo" i "neživo", itd., itd. Budući je dokazivanje ove hipoteze izuzetno složeno (ali ne i nemoguće), tj. skopčano s velikim tehničkim poteškoćama, u ovom radu za dokazivanje ove hipoteze izvršit će se komparacija s reprezentativnim modelima u raznim područjima i disciplinama. Stupanj kongruentnosti spoznaja iz tih područja i disciplina sa zakonitostima dobijenim u ovom istraživanju bit će provjera vjerodostojnosti i zakonitosti same hipoteze. Svim zainteresiranim istraživačima ostaje zadaća konkretna provjera, ali i primjena rezultata ovog istraživanja za rješavanje konkretnih problema u pojedinim područjima i segmentima fundamentalnog ili aplikativnog djelovanja.

4. REFERENCE

4. 1. Automatska regulacija u širem smislu

U [1] navodi se kako se još od početka civilizacije pojavljuju strojevi koji zamjenjuju čovjekov fizički rad. Masovnija primjena strojeva bitna je za ljudsku povijest te ona obilježava eru mehanizacije – prvu industrijsku revoluciju. Tada su strojevi mogli izvršavati samo rutinski slijed operacija. Kasnije, u 19. stoljeću, strojevi se primjenjuju i za složenije operacije međutim za izvršavanje takvih operacija nužan je nadzor stroja, dakle upravljanje je u početku obavljao čovjek, a tek kasnije mehanički regulator. Ovo se može smatrati početkom koncepcije po kojoj se pod cjelinom smatra **objekt regulacije + regulator**. Ovakav pristup je prisutan i danas u modernoj teoriji automatske regulacije, npr. [2, 3]. Ova općepoznata definicija je navedena iz razloga što će se kasnije u radu predložiti drugačiji pristup.

U [2] se naglašava važnost poznavanja varijabli stanja sustava, ne samo izlaza, bez kojih nema učinkovitog upravljanja, regulacije ili vođenja procesa. Sa pozicije ovog rada to znači da se поближе (teorijski apsolutno točno) opisuje objekt kako bi znali koji je njegov prostor egzistencije. Iako su metode opisa problema različite u suštini se radi isto: opisuje se objekt (reprezentativnim) varijablama. U [2] se također ukazuje na mogućnost redukcije reda sustava naravno po kriteriju da se promatraju dominantne svojstvene vrijednosti. Sličan pristup je korišten i u ovom radu.

U [3] se navodi „*Sve izraženiji razvoj tehničkih sistema implicira kontinuirano povećanje stupnja njihove automatizacije.*“ Ako predhodnu tvrdnju promatramo na način da isključimo onoga koji je projektirao i izradio tehničke sustave (čovjek) i promatramo isključivo tehnički sustav, može se zaključiti da je on kao objekt spoznajno napredovao. Jer gledajući samo rezultate koje nam tehnički sustav daje, neminovno se dolazi do zaključka da je on sve kvatitetniji te se nužno zaključuje da je spoznajno napredovao !

Nadalje se navodi „*Takav trend vodi konceptu totalne automatizacije, gdje se sve funkcije tehničkog sistema odvijaju automatski, uz neprekidno adaptiranje u odnosu prema promjenama u sistemu i/ili okolini (okruženju) promatranog sistema.*“ Ova tvrdnja znači da koncept totalne automatizacije nastoji eliminirati neželjena djelovanja **bez ulaženja u razloge njihovog nastanka**, dakle zadatak automatizacije je očuvanje **postojećeg (funkcionalnog) stanja**. Ovo predstavlja tipični kibernetički pristup.

Sa druge strane u ovom radu **slučajne smetnje ne postoje** (proučava se *sve*) – smetnje se definiraju kao drugi trenutno nepoznati objekti koji također egzistiraju u prostoru proučavanja. Napomenimo da ti objekti mogu biti smatrani nevažnima ali to se ne može tvrditi dok ih se ne identificira, utvrdi način njihovog utjecaja, te objektivno utvrdi greška zbog takvog zanemarivanja.

Nadalje u [3] u dijelu „*Ekspertni sistemi i umjetna inteligencija*“, razmatraju se složeni sustavi te ukazuje na sve veću brzinu elektroničkih uređaja (procesora) koji zbog svoje „lake“ dostupnosti i izuzetne računске snage obrade, predstavljaju budućnost u automatskoj regulaciji. Razmišljajući na ovaj način još više se povećava jaz između objekta vođenja i regulatora koji je na ovaj način u većini slučajeva bitno brži od objekta regulacije. No, ta brzina neće rasti u nedogled, a i paralelno procesiranje će imati svoja ograničenja.

Koristeći prednosti ovog pristupa „lako“ se u takav regulator mogu smjestiti i složeni algoritmi upravljanja. Prednosti su jednostavna i više ili manje univerzalna primjena ovakvih regulatora, no, suština odnosa koji su doveli do poremećaja, što oni znače, zašto su nastali itd., ostaje nepoznato. Problem jest riješen, sustav se uglavnom ponaša očekivano ali zašto je problem nastao, hoće li nastati ponovno, kako će sve to zajedno dugoročno utjecati na objekt regulacije, ostaje nepoznato.

Sličan problem se javlja i kod neuronskih mreža. Naime kao što je poznato neuronske mreže se sastoje od ulaznog, skrivenog i izlaznog sloja. Logika koju mreža treba naučiti pohranjena je u srednjem sloju [4]. Predmet istraživanja neuronskih mreža usmjeren je isključivo prema rezultatu, ne razmatra se zašto je mreža baš takva kakva je, može li biti drugačija, koja je logika strukture mreže ili drugim riječima ne ulazi se u suštinu same mreže a time onda ni problema koji se proučava / rješava. Ovaj pristup nam nudi rješenja koja su kvalitetna, ali logika samog regulatora konceptu nije interesantna a samim time je i nepoznata.

Ovo logički podsjeća na princip eksterne linearizacije [3] (str. 287), gdje se nelinearnosti objekta upravljanja kompeziraju istim takvim ali „inverznim“ nelinearnostima unutar regulatora koje se onda međusobno poništavaju, te se izvana gledano ponovno ima linearan sustav koji se onda „lako“ regulira. No i ovdje ostaje problem da nam nije poznato „što se krije ispod površine“ tj. **nepoznata nam je suština**.

Ovakav pristup je ekstremiziran u radovima [5 ,6]. Tako je u radu [5] gdje se pomoću adaptivne neizrazite logike regulira sustav sa jednim ulazom i jednim izlazom, ali objekt regulacije je nelinearan i potpuno nepoznat. Slično u radu [6] se također razmatra adaptivni regulator sa neuronskom mrežom koji također ne zahtijeva poznavanje objekta regulacije ali uz neka ograničenja.

Primjena ovakvih ili još univerzalnijih regulatora zasigurno donosi brzi rezultat ali s obzirom da nam je suština nepoznata zasigurno u mnogim područjima brzo donosi i probleme. To možda nije toliko očito u tehničkim sustavima, ali ako pogledamo upravljanje većim socijalnim skupinama prečesto se teži konkretnom rezultatu dok se problemi koji se pri tome javljaju ostavljaju neriješenima ili pak samo djelomično riješenima. Ovakvo ponašanje kasnije donosi brojne probleme poput danas gotovo uobičajenog nasilja, ozonskih rupa, teških ekoloških poremećaja i sl.

Slične primjedbe važe i za fuzzy logiku gdje još, osim spomenutog, ostaje i problem sustava sa većim brojem ulaza / izlaza. U tom smislu npr. u radu [7] predložen je postupak poboljšanja ovog pristupa. Također je pokazano na primjeru da ovakav pristup daje bolje rezultate od klasičnog pristupa osobito kod slijedne regulacije.

Sasvim suprotan pristup je prikazan npr. u [8] gdje se vrši poopćenje dinamičkih sustava. To je učinjeno na način da se rješavaju problemi pristupa preko općih dinamičkih veličina. Tako su definirane: pohranjena veličina, tok i napor, zatim koeficijent kapaciteta, koeficijent otpora i koeficijent inercije. Pronađeni su odgovarajući ekvivalenti u mehaničkim procesima, električnim procesima, kemijskim procesima, toplinskim procesima te procesima pohrane (tekućine, plinovi) i za toplinske procese. Ovakav način proučavanja nužno dovodi do poopćenja, a vjerojatno osigurava i daljnje analogije te dublji uvid u prirodne procese i pojave.

Problem ovakvog pristupa je složenost pa se u zadnje vrijeme težište istraživanja prebacilo na neuronske mreže, neizrazitu logiku i njihovu kombinaciju. Ovo se naročito odnosi na probleme sa izrazito velikim brojem osnovnih parametara npr. pri prepoznavanju oblika u okolini ili prikom potrebe za upravljanjem hoda robota u realnim 3D uvjetima.

Ovo je vidljivo npr. u radu [9] gdje se razmatra planiranje kretanja dvonožnih hodajućih robota. Ovdje se osim klasičnog inženjerskog pojednostavljenja planiranje staze dijeli na dva dijela 2D i 3D. U složenijem 3D dijelu reducira se broj mogućih puteva na konačan broj predefiniраниh kojima se bitno dobija na pojednostavljenju. Predefiniрани putovi su birani na način da se omoguće gotovo sva praktično potrebna kretanja.

Ovaj problem postaje još složeniji kada se mijenjaju i značajke robota poput težine, te se u radu [10] vršila usporedba klasičnog puta pomoću Lagrangeovih dinamičkih jednadžbi sa metodama adaptivnog neizrazitog modela i metoda zasnovana na kliznim režimima s primjenom neuronskih mreža. Klasični pristup nije dao dobre rezultate dok su obje alternativne metode (meko računarstvo) dale odlične rezultate.

U radu [11] je prikazan pregled cijele klase radova koji se bave problemom složenih sustava koji su sigurnosno jako zahtjevni (npr. zrakoplovi, nuklearna elektrana). Pokazalo se da klasičan pristup u kojem se kruto ne toleriraju odstupanja pojedinih regulacijskih krugova mogu dovesti do neželjenih posljedica ili čak do nestabilnosti ukoliko dođe do kvara pojedinih djelova unutar nekog regulacijskog kruga. Ovdje se predlaže rješenje preko sustava koji toleriraju grešku („fault-tolerant control systems“) jer se ustanovilo da se tako dobiju bolji rezultati. Ovo je „lako“ objasniti jer ovdje objekt regulacije predstavlja čvrstu cjelinu pa su regulacijske staze jako međuovisne.

U [12] se razmatraju širi aspekti neizrazite logike te se navodi da postoji više mogućih gledišta: logički (uski), relacijski, teorijski (teorija neizrazitih skupova) te spoznajni. Pod pojmom spoznajni podrazumjeva se upotreba u bazama znanja te u prepoznavanju jezika.

Problem učenja kretanja robota po neravnom terenu u [13] promatra se u svijetlu činjenice da mladunci životinja brzo prohodaju. Iz toga se izvlači zaključak da životinje hodanje ne uče od početka, već da je sigurno dio tih znanja dobijen nasljeđem. U tom smislu predložen je model po kojem bi i robot nasljeđivao neke osobine od predhodne generacije. Prikazano je da se na ovaj način dobiju bolji rezultati. Nasljeđivanje od predhodne generacije iste vrste u jednom drugom smislu razmatrane su i u ovom radu.

4. 2. Filozofsko logičke postavke

Kako ovaj rad ima intenciju postaviti *Opću teoriju spoznaje* nužno je osvrnuti se na širi filozofski kontekst te „zaviriti“ i u druga područja koja se bave pitanjem spoznaje.

U tom smislu od izuzetnog interesa je upravo spoznajna teorija (gnoseologija). Prema [14] spoznajna teorija se definira kao znanost o spoznavanju koja pokušava urediti pravila, tj. utvrditi istinitost spoznaje, granice i objektivnu vrijednost.

Često se javlja i pojam epistemologija koji se prema [15] koristi u dva različita ali srodna načina:

1. Epistemologija se identificira sa spoznajnom teorijom koja se bavi pitanjima koja se odnose na *čovjekovu spoznaju uopće*,
2. Pod pojmom epistemologije se podrazumjeva znanstveno tumačenje svijeta.

U ovom radu se ne smatra da ne mogu postojati različita tumačenja svijeta (npr. opće i znanstveno tumačenje) pa će se točnim pristupom smatrati ono sveobuhvatnije, što u konkretnom slučaju znači čovjekova spoznaja uopće, koja uključuje i znanstvenu.

No, kako je rečeno u poglavlju 2.7. *Temeljni pojmovi*, pojam spoznaja ovdje se proširuje na entitet, koji kako je također rečeno u istom poglavlju, predstavlja bilo koju registrabilnu pojavu, pa dakle i na npr. strojeve i regulatore ! Jer kako inače objasniti da neki stroj nešto radi – on očigledno ima neka *znanja* tj. ima neka pravila ponašanja; ponašanja stroja nisu slučajna ! S obzirom da pojam znanje ima uže značenje, ovdje je korišten termin *spoznaja* koja i inače ima šire značenje. Jedina razlika u odnosu na klasičan pristup je u tome što je čovjeku oduzet privilegij da samo on ima spoznaju. Ona je pridružena i životinjama i stvarima i atomima ... tj. entitetu.

Pogled na živo kao jedinstvenu cjelinu nije nov [14]; u *indijskoj filozofiji* se utemeljuje tvrdnja da su svi biološki sustavi samo specifični izraz jedinstvenog života. Također *konceptualizam* definira logiku o univerzalnosti spoznaje nakon poimanja konkretnih stvari, a povezanost svih pojava u Univerzumu (svemu) možda najbolje ilustrira Lao-Tse svojom izrekom „*Kad leptir zamahne krilima zatrese se čitav svemir.*“

Na koji način je definirana epistemologija vidljivo je i u [16] gdje se navodi: *Središnja pitanja na koja epistemolozi nastoje pružiti odgovore uključuju: „Koja su vjerovanja opravdana, a koja nisu ? Što, ako išta možemo znati ?, Koja je razlika između znati i imati istinito vjerovanje ? Koja je ralacija između vidjeti i znati ?“*

Važan pojam kojim se filozofi bave jest i pojam *istine*. Tako se u [17] razmatra pitanje *istine*. No, čini se da se ovom pojmu pristupa dominantno iz kuta skepticizma, odnosno želi se doći do novih spoznaja isključivo putem užeg dijela filozofijske misli. Čini se da se zaboravljaju filozofske odrednice poput fenomenologije. Npr. na 26. strani se zaključuje da je moguće postojanje dvaju potpuno istih entiteta. Ovo je dakako nemoguće, jer iz fizike znamo da na jednom mjestu u isto vrijeme može biti samo jedan entitet/objekt, pa će se ti entiteti razlikovati barem po jednom paramertu – mjestu na kojem se nalaze. Nadalje, kada se razmatra definicija nekog entiteta kaže se da nikad taj entitet nije moguće u potpunosti opisati. Ovo drugim riječima znači da se uvijek mogu pronaći neke nove varijable za opis entiteta/objekta te tako nikada nećemo moći obuhvatiti sve moguće varijable. Iz ovoga slijedi da se ništa ne može definirati.

No, ako se „pozove u pomoć“ druga filozofska disciplina – fenomenologija tada nije sve tako „beznadno“. Stoga je fenomenologija metodološki okvir ovog rada.

Osim toga čini se da je u [16 i 17] nastupila glavna orijentacija prema ljudima općenito ili još gore na samog jednog jedinog čovjeka, što nikako ne bi trebao biti slučaj u filozofiji koja je po svojoj orijentaciji proučavanja najšira moguća. Spomenimo još samo konstataciju iz uvoda [17] koji praktično čini jedan od temelja knjige: „... *Ovo je gledište koje ću zastupati: da je istina događaj, tj. ona ne postoji dok se ne dogodi i održava se na životu samo toliko dugo koliko su prisutni uvjeti potrebni za njeno događanje.*“ Ako se prisjetimo definicije pozitivizma koji odriče svaku vrijednost samostalnoj apstraktnoj misaonoj djelatnosti, tada je jasno da se ovdje radi o čistom pozitivizmu. Dakle ovdje se potpuno odriče bilo koja vrijednost apstrakciji, što zasigurno neće biti slučaj u ovom radu. Ali u ovom radu se neće odricati vrijednost ni pozitivizmu, baš suprotno – bitna premisa ovoga rada jest da realno egzistiraju samo entiteti (pozitivizam). Sa druge strane razmatranjem viših, **latentnih** mehanizama doći će se do globalnih zakonitosti (apstrakcija).

Spoznajna teorija je dosta široko područje te će se ovdje dati jedna moguća podjela. Dakle, spoznajna teorija se može podijeliti na dva pravca:

1. Pravac koji se bavi izvorima spoznaje:
 - a. *empirizam* – utemeljitelj John Locke – sva ljudska spoznaja dolazi iz iskustva
 - b. *senzualizam (radikalni empirizam)* – sva ljudska spoznaja dolazi iz osjetilnih iskustva
 - c. *racionalizam* – utemeljitelj Descartes – čovjeka do spoznaje vodi razum (*ratio*) u 17 stoljeću na krilima razvoja matematike, mehanike, optike
 - d. *iracionalizam* – do spoznaje se dolazi iracionalno, ima više pravaca:
 - i. *histicizam* – stanje ekstaze, duša se spaja s izvorom
 - ii. *voluntarizam* – volja je nadređena razumu, koji jest instrument spoznaje, ali ne djeluje ako ga volja ne pokrene
 - e. *kriticizam* – naglašava važnost preispitivanja izvora i granica spoznaje, i suprotstavlja se dogmatskom pristupu. Immanuel Kant
 - f. *intuicionizam* – posebna spoznajna moć intuicija – neposredan uvid u bit stvari bez uporabe osjetila i racionalne analize
2. Pravci s obzirom na doseg i izvjesnost spoznaje
 - a. *dogmatizam* – pretpostavlja nekritičko mišljenje i oslanja se na nepromjenjive tvrdnje.
 - b. *skepticizam* – objektivna spoznaja nije moguća. Za svaku tvrdnju ima *pros* and *cons* koji su u ravnoteži, pa se treba suzdržati od donošenja suda
 - c. *agnosticizam* – bit stvari ne možemo spoznati, nespoznatljiva je. Radikalizacija skepticizma, ono što tvrdimo su naša uvjerenja i stavovi, a ne čisto znanje

Različiti se pristupi mogu pronaći u literaturi. U [18] se postavlja pitanje koji su ljudski potencijali, za što smo predodređeni? Kritički se odnosi prema, moglo bi se reći maskimalnoj površnosti današnjeg svijeta te ukazuje na potrebu da ljudski razvoj treba uskladiti u svakom smislu pogotovo po kriterijima morala. Ukazuje nam da moramo naći unutarnju snagu za odupiranje „porocima“ suvremenog društva (čak i znanosti!) te nam sugerira da postanemo više subjekti negoli objekti. Ovo se u mnogome slaže sa ovim radom – uostalom ovdje se čak i strojevi promatraju kao subjekti!

Zanimljiv je i članak [19] gdje se razlikuje poznavanje (understanding) i razumjevanje (comprehension). Ipak se (skeptično) zaključuje da je univerz (sve) neshvatljiv. Razlika između poznavanja i razumjevanja vjerojatno pripada u neku od kategorija pamćenja prikazanih u [20]. Tamo se definiraju 4 razine pamćenja : razina traga, razina prepoznavanja, razina reprodukcije i razina automatizacije. Osim toga definirana su i 3 načina pohranjivanja: senzorno, kratkotrajno (električne promjene) te dugotrajno (kemijske promjene). U ovom radu pod spoznajom bi se podrazumjevale sve razine, dakle bez difencijacije ili određivanja gdje bi se konkretne informacije spremale. Ovo bi zasigurno bio mogući put daljnjeg istraživanja.

Zajednički presjek tehničkih znanosti sa ostalim djelatnostima ljudi sve je veći, što je lako uočljivo u svakodnevnom životu. Također postoji i sve veći interes za proučavanjem tehničkog područja iz drugih područja. Primjer za ovo je vidljiv u [21] gdje se iz područja psihologije proučava računalo. U članku se tvrdi da računalo nikada neće moći razumjeti program koji izvršava. Ali sa pozicije ovog rada postavljaju se 3 zanimljive hipoteze: 1) za spoznajom nije potrebno razumjevanje, 2) netko može imati sve informacije o nečemu (X) ali to ne znači da taj netko razumije X i 3) razumjevanje načelno vodi reduciranju vremena potrebnog za nalaženje informacija. Očigledno se i ovdje znanje može razmatrati u okviru [20] ili neke druge podjele, ali što je naročito bitno u ovom članku: ovdje se podrazumjeva da stroj (računalo) ima spoznajom iako program koji izvodi zasigurno ne razumije, te se može reći nema razumjevanje (znanje).

Područja razumjevanja i spoznaje od važnog su interesa za edukaciju i shvaćanje čovjeka uopće. I ovo je zanimljivo područje, a uostalom područje automatske regulacije vezano uz neuronske mreže nastalo je baš po uzoru na ljudski mozak.

U tom smislu može se primjetiti razvoj novih ideja za rješavanje složenih problema razumjevanja sadržaja neke rečenice ili teksta. U [23] se predstavlja program koji ima mogućnosti automatiziranog postavljanja pitanja sa ciljem provjere usvojenih znanja.

U članku [24] se uočava da ljudi ne raspolazu sa toliko velikom količinom informacija, a da ipak posjeduju kvalitetna znanja. Ovo se pripisuje latentnoj semantičkoj analizi te je predstavljena nova općenita teorija koja je zasnovana na latentnoj semantičkoj analizi.

Očigledno problemu znanja se pristupa sa raznih pozicija. Zadatak prepoznavanje semantike ali i razumjevanja pročitnog teksta zasigurno nije jednostavan te se možda u nekim od ovih područja kriju neke nove ideje.

Na kraju će se spomenuti još dvije jako važne reference [25, 26] koje su praktično prethodile ovom radu.

5. REZULTATI

5. 1. IDENTIFIKACIJA TAKSONA

U ovom dijelu rada su predstavljeni dobiveni rezultati. Od početnih 18 varijabli u prvom koraku dobijeno je 6 interpretabilnih taksona. Ovim postupkom dolazi do odmicanja od konkretnog entiteta, njegova konkretna izvedba nije toliko zanimljiva, ali sa druge strane dobilo se poopćenje modela. U slijedećem koraku dobijena su tri taksona, zatim dva da bi se na kraju dobio jedan, generalni takson koji najbolje opisuje sve tipove objekata koje egzistiraju u početnom 18 – dimenzionalnom prostoru.

Na slikama 5.1.5.1. – 5.1.5.48. prikazani su konkretni entiteti/objekti koji imaju ekstremne vrijednosti na taksonima. Za svaki takson i svaki pol pojedinog taksona prikazana su po 24 najtipičnija predstavnika. Uz svaki entitet je i njegova jedinstvena oznaka te veličina projekcije na konkretni takson. Npr. na slici 5.1.5.1. vidimo da je na negativnoj strani 1. taksona najtipičniji predstavnik E031 čiji je iznos projekcije na takson jednak $pr = -2.9$. Projekcije predstavljaju z – vrijednosti pojedinih entiteta na taksonu. Zbog lakše identifikacije isti takson je prikazan i u vektorskom formatu (npr. slika 5.1.5.1. i 5.1.5.3.).

Osim grafičkog prikaza, u tablici 5.1.5.1. i tablici 5.1.5.2. prikazan je i opis taksona varijablama. Na ovaj način moguće je na kvalitetan način izvršiti identifikaciju dobivenih taksona (tipova) proučavanih entiteta.

5. 1. 1. TAKSONI 1. RAZINE

Kao što je već rečeno na prvoj razini je dobiveno šest taksona. Oni su prikazani slikama 5.1.5.1. – 5.1.5.24. Projekcije varijabli za ovu razinu prikazane su u tablici 5.1.5.1..

5. 1. 1. 1. Takson br. 1. – Organiziranost (Jednostavnost – Složenost)

Pogledom na slike 5.1.5.1. – 5.1.5.4. gotovo već na prvi pogled može se ustanoviti da polovi ovog taksona predstavljaju sa jedne strane izrazito **jednostavne**, dok se sa druge strane mogu vidjeti izrazito **složeni** entiteti/objekti. Složenost se naročito uočava na slici 5.1.5.4., gdje je vidljiv veliki broj relacija subsegmenata unutar samog objekta.

Potvrda ovom razmišljanju vidljiva je u tablici 5.1.5.1. Iz tablice se vidi da je varijabla sa najvećom apsolutnom projekcijom upravo jednostavnost (JEDS = -0.93), zatim reproducibilnost (REPR = -0.89) i broj relacija skeleta (BRSK = 0.72). Ovo je u skladu sa rečenim, jer negativna strana upravo predstavlja jednostavnost, lako je reproducibilna a ima i mali broj relacija skeleta. Od ostalih varijabli koje opisuju ovaj takson ističu se još NSET = -0.57 , NSTO = -0.60 , BRTO i XXXX.

Ako su polarne strane taksona *Jednostavnost* i *Složenost* tada cijeli takson opisuje **supanj organiziranosti objekta**, ili kraće *Organiziranost*. Zanimljivo je za primjetiti da čak osam varijabli ima dominantnu projekciju na ovaj takson, dakle daleko najviše u odnosu na sve ostale taksone ove razine. Uostalom, u zadnjem retku tablice 5.1.5.1. je vidljivo da ovaj takson opisuje gotovo trećinu ukupnog varijabiliteta. Iako svi taksoni ove razine hijerarhijski svi stoje na istoj razini ipak nije za zanemariti važnost ovog taksona.

No, ako su ovo opća pravila, tada to znači da je „prva“ karakteristika bilo kojeg objekta upravo stupanj organizacije.

Da vidimo kako po ovom pitanju „stoji“ automatska regulacija ? Ako se pod nekim novim objektom podrazumijeva objekt regulacije zajedno sa regulacijskim sustavom, kakvoj tada organizaciji težimo mi u automatskoj regulaciji ? Što je regulacijski sustav jednostavniji, lakše je izvediv, manje je mogućih kvarova, manji je red sustava, sustavom je lakše upravljati, ... – drugim riječima mi u automatskoj regulaciji težimo ekstremnoj strani taksona koja je obilježena negativnim projekcijama varijabli. Iako se naslučuje, što zaista ova spoznaja znači u *teoriji spoznaje* prerano je za raspravu – ovo će biti razvidno tek na slijedećim razinama.

5. 1. 1. 2. Takson br. 2 – Stabilnost (Varijabilnost – Postojanost)

Objekti, reprezentanti ovog taksona mogu se vidjeti na slikama 5.1.5.5. – 5.1.5.8. Opis ovog taksona varijablama vidljiv je u *tablici 5.1.5.1.*

Ako se pogledaju reprezentativni objekti ovog taksona vidljivo je da su na negativnoj strani uglavnom objekti za „zakrivljenim linijama“, koji su „nestalni“ ili najbolje rečeno **varijabilni**. Na suprotnom polu vidljivi su entiteti koji su „masivni“, „teško podložni promjenama“, i za razliku od negativne strane, kad bi i izgubili dio konstrukcije ne bi se ništa bitno desilo, objekt bi ostao cjelovit i jasan. Na negativnoj strani ovo nije slučaj, nedostatak i najmanjeg dijela konstrukcije vrlo vjerojatno bi uzrokovao prekid entiteta tj. najvjerojatnije bi došlo do dijeljenja entiteta na više djelova. Zato bi entitete na negativnoj strani bilo „lako deformirati“, što sa objektima na pozitivnoj strani nikako nije slučaj. Može se reći da su objekti na pozitivnoj strani na neki način stalni ili bolje rečeno postojani. Stoga je odabran naziv **postojanost**.

Ako se još jednom pogledaju objekti, te ako se uzmu u obzir nazivi suprotnih polova može se zaključiti da cijeli takson opisuje pouzdanost objekta u smislu sigurnosti (da će ostati isti), stoga je cijeli takson nazvan **stabilnost**. U ovo se moguće dodatno uvjeriti pregledom tipičnih predstavnika na slikama 5.1.5.7. i 5.1.5.8.

Zanimljivo je da najveće projekcije na ovaj takson imaju varijable *pravilnost* (PRAV = 0.83) i *simetričnost* (SIME = 0.89), za koje bi se reklo da nemaju nikakve veze sa stabilnošću. No, veza je očigledno posredna jer kada (ponovno) pogledamo slike 5.1.5.5. – 5.1.5.8. vidimo da su polovi taksona stvarno bitno određeni spomenutim varijablama. Očigledno, objekt u zadanom rasteru ne može se biti nesimetričan i nepravilan ako ujedno ne odaje dojam, tj. ima karakteristiku postojanosti (Ako se malo promisli ovakvo razmišljanje neće vrijediti samo za raster.). Suprotno od toga očigledno jest moguće. Od ostalih varijabli može se još spomenuti *ukupni broj linija* (BRLU), *broj spojnica* (BRSP) te *makimalan broj koraka potrebnih za prijenos informacije u najnepovoljnijem slučaju* (IMXV) koji su potpuno nevažani za opis ovog taksona – ovaj podatak nam govori da nije bitna kompleksnost konstrukcija kao što se to iz slika entiteta možda čini. Spomenimo još varijable *najudaljenija slobodna eksterna točka* (NSET = -0.56) te *najudaljenija slobodna točka općenito* (NSTO = -0.52) koje imaju jako malu vrijednost na pozitivnoj strani te govori o kompaktnosti objekta.

Kako bi opisali područje automatske regulacije ovim taksonom ? Jasno i nedvosmisleno pozitivnom stranom taksona, dakle postojanost. Uostalom stabilnost je „*condicio sine qua non*“ u automatici !

5. 1. 1. 3. Takson br 3. – Cjelovitost (Kompaktnost – Raspršenost)

Ovaj takson prikazan je slikama 5.1.5.9. – 5.1.5.12. te tablicom 5.1.5.1..

Uvidom u projekcije varijabli ovog taksona može se vidjeti dominacija triju varijabli: *maksimalni broj koraka potrebnih za prijenos informacije u najnepovoljnijem slučaju* (IMXV = 0.84), *minimalni broj koraka potrebnih za prijenos informacije u najnepovoljnijem slučaju* (IMNV = 0.71), te *broj točaka za emisiju informacija* (BREM = 0.68). Kada se ovim varijablama još pridruži i *broj prijema* (BRPR = 0.44) vidljivo je da ovaj takson ima informacijsko usmjerenje. Nebitnost konstrukcije (i njenog oblika) potvrđuju slijedeće varijable: BRTO, JEDS, PRAV, BRLU, BRVR koje su sve odreda nevažne za definiciju ovog taksona.

No da bi informacije mogle kvalitetno putovati objektom potrebno je da je on izgleda kao objekti negativnog pola taksona, tj da objekt „izmrežan“ i „cjelovit“ dakle **kompaktan**. Identifikaciju suprotnog pola nije teško odrediti ako se pogledaju reprezentativni entiteti pozitivnog pola taksona. Entitet je razasut tj. **raspršen** po cijelom prostoru (rasteru).

Iz ukupne slike cijelog taksona vidljivo je da cijeli takson opisuje homogenost tj. **cjelovitost** entiteta.

Kakvi su objekti u automatskoj regulaciji ? Kompaktni ili raspršeni ? Ovdje se vrlo vjerojatno može reći da su klasični regulacijski sustavi kompaktni, dok bi se za npr. fleksibilne proizvodne sustave moglo reći da imaju i tendenciju prema raspršenosti. No, ipak bi glavna tendencija bila prema kompaktnosti jer npr. u većim sustavima regulacije poput npr. vođenja procesa u nuklearnoj elektrani ili slično raspršenosti zasigurno nema, naravno iz razloga sigurnosti.

Iako se čini da je ova karakteristika uvijek poželjna kao kompaktna to ne mora biti uvijek tako. Za primjer se mogu uzeti „moderna“ sociološko-demografska (politička) stremljenja gdje je u zadnje vrijeme vidljiva težnja regionalizaciji, dake stanovitoj raspršenosti države kao entiteta.

5. 1. 1. 4. Takson br. 4 – Sklad (Fleksibilnost – Krutost)

Ovaj takson je prikazan slikama 5.1.5.13. – 5.1.5.16. te tablicom 5.1.5.1..

Dominantnu projekciju na ovaj takson imaju varijable *broj linija ukupno* (BRLU = 0.77) te *broj spojnice* (BRSP = 0.75). Kada se uzme u obzir da je *broj zarobljenih (dakle „neaktivnih“ u smislu konstrukcije) točaka* (BRVR = -0.40) onda se (ponovno) dobije asocijacija na konstrukciju. No, varijable *broj ukupnih direktnih relacija* (BREL) i *broj direktnih relacija skeleta* (BRSK) ne da ne prate predhodno spomenute varijable, već naprotiv imaju lagano suprotno usmjerenje (= -0.15). Ovo upućuje na razmišljanje da se ne radi o čistom opisu konstrukcije u smislu čvrstoće ili općenito neke otpornosti na promjenu već da je u pitanju oblik konstrukcije, odnosno oblik njenih subsegmenta. Pod tim oblikom se ne podrazumjevaju ekstremi objekta (NSET i NSTO) ili jednostavnost konstrukcije (JEDS i REPR) koji su svi odreda nevažni za opis ovog taksona.

Potvrdu ovakvog razmišljanja dobije se pogledom na slike tipičnih entiteta koji predstavljaju polove ovog taksona. Vidljivo je da su na pozitivnoj strani ovog taksona sukladno nekom pravilu „ustrojeni“ entiteti. Očigledan je obrazac „ponašanja“ (npr. E297, E243, E298, ...). Mogli bi reći da se radi o, u prenesenom značenju „uniformiranoj“ organizaciji objekata. Ovdje se očigledno radi o jasnom obrascu strukture od kojeg „nema odstupanja“, dakle ovaj takson se može opisati kao pravilna ustrojenost, **krutost**. Na suprotnom polu vidljivo je baš dijametralno suprotna logika: varijacije konstrukcije, koje više ne prate isključivo oblik rastera i ne ponavljaju se sistematski kao na suprotnoj strani. Baš naprotiv vidljivi su oblici nekarakteristični za prostor (raster) u kojem egzistiraju, vidljivi su zaključivljeni oblici a što je glavna karakteristika ovog pola taksona. Može se reći da su ovi objekti na neki način „gumasti“, drugim riječima ovi objekti su **fleksibilni**.

Ovaj takson „govori“ o tome na koji način su subsegmenti objekta posloženi unutar zajedničke cijeline, „govori“ o njihovoj međusobnoj usklađenosti, pa je ovaj takson po tome i nazvan – **sklad**.

Ako je automatska regulacija po ijednom dosad opisanom taksonu mijenjala svoju poziciju onda jest sigurno po ovom. Početni regulacijski sustavi su bili zasigurno kruti i neadaptibilni, sve je moralo biti „pod konac“ („po špagu“). Danas to zasigurno nije slučaj, regulacijski sustavi pa tako i cjelina – objekt regulacije sa regulatorom sve su fleksibilniji i sve pristupačniji. Dakle, može se zaključiti da „automatska regulacija“ krenula (odlučno) naprijed – prema negativnoj strani ovog taksona ! No, kako je već rečeno, što to znači u stvarnosti vidjeti će se na slijedećim razinama.

5. 1. 1. 5. Takson br. 5 – Ekspanzija (Prostorna – Materijalna)

Pogledom na slike 5.1.5.17. – 5.1.5.20. lako se može zaključiti da se radi o načinu „osvajanja“ prostora u kojem entiteti egzistiraju. Vidljivo je da su i na pozitivnoj i na negativnoj strani entiteti došli do granica prostora, samo je to svatko učinio na svoj način. Oni na negativnoj strani to su učinili zaposjedanjem praznog prostora (ZAPO = -0.80), dok su entiteti na pozitivnoj strani to učinili sa „točkicama u vreći“ (BRVR = 0.74). Ove točke u vreći mogu se shvatiti kao „građevni materijal“ za strukturu objekta. Dakle one predstavljaju „materijal“ ali koji nije dio konstrukcije. Osim toga BREL = 0.55 jer i točkice u vreći sudjeluju u relacijama.

Ovdje se očigledno radi sa jedne strane o „šupljoj“ tj. **prostornoj**, te sa druge strane o punoj, tj. **materijalnoj ekspanziji**. Zanimljivo je i za primjetiti da je objektima na negativnoj strani dovoljno odstraniti jedan jedini strukturni element pa da im unutrašnjost bude izložena što zasigurno nije slučaj na suprotnoj strani.

Analogija ovim pojmovima u običnom životu ima na pretek, a najlakše se može opisati kao površnost i sustavnost. U današnje vrijeme najlakše bi bilo naći primjer u društvenim odnosima (misli se općenito i u svijetu). Radi o uspinjanju društvenom ljestvicom sa i bez adekvatnog znanja i sposobnosti. Čovjek koji se na društvenoj ljestvici nalazi visoko i ima dovoljnja znanja i sposobnosti, ima široki prostor djelovanja u „ovladani“ društveni prostor, ali i dovoljno znanja i sposobnosti da „pokrije“ taj „ovladani“ prostor. Dakle u smislu ovog taksona on je tada izvršio materijalnu ekspanziju u socijalnoj okolini. Kako bi izgledala negativna strana ovog taksona, također u socijalnom polju ? Zamišljanje ovakvog djelovanja nije nezamislivo, nažalost baš suprotno, konkretni primjeri se lako pronalaze.

No, kako ovdje prolazi automatska regulacija? Strogo strukovno gledano radi se isključivo o materijalnoj ekspanziji tj. kontrolira se samo ono čije je ponašanje strogo poznato, tj. u fazi projektiranja su poznati svi bitni parametri. U ovom smislu, po autorovom mišljenju, povećanje npr. brzine modernih vlakova do krajnjih granica znači ulazak u rizično područje, dakle prostornu ili površnu ekspanziju prevoznih sredstava u prostor brzine.

5. 1. 1. 6. Takson br. 6 – Komunikativnost (Aktivnost – Pasivnost)

Reprezentativni objekti zadnjeg taksona ove razine prikazani su na slikama 5.1.5.21. – 5.1.5.24., te u tablici 5.1.5.1.

Na ovom taksonu nema izrazito dominantnih varijabli, no za opis ovog taksona mogu poslužiti slijedeće varijable: *minimalni broj koraka porebnih za prijenos informacije u najnepovoljnijem slučaju* (IMNV = 0.48) *broj točaka za emisiju informacija* (BREM = -0.44), *maksimalni broj koraka porebnih za prijenos informacije u najnepovoljnijem slučaju* (IMXV = 0.39), *broj točaka za prijem informacija* (BRPR = -0.38), te *najudaljenija slobodna točka općenito* (NSTO = 0.38) i *najudaljenija slobodna eksterna točka* (NSET = 0.30).

Ovdje se radi o „mješavini“ „informativskih“ (IMNV, IMXV), „senzornih“ (BREM, BRPR) kao i varijabli koje opisuju ekstreman domet objekta (NSET, NSTO). Očigledno se radi o taksonu koji opisuje mogućnosti prijema i emitiranja informacija iz/u svoju okolinu. Ovaj takson opisuje interakciju objekta sa okolinom, tj. opisuje bitne djelove za komunikaciju objekta sa okolinom – stoga je ovaj takson i nazvan **komunikativnost**.

Način komunikacije lako se može uočiti iz slika tipičnih predstavnika ovog taksona. Objekti na negativnoj strani praktično su cijeli „senzori“ (BREM, BRPR) dok je na suprotnom polu prijem zapriječen drugim razlozima (oblik, zauzet cijeli prostor, ...). Također je vidljivo da su objekti na negativnoj strani praktično „urezani“ u svaki dio prostora tj. prema samom rasteru su izrazito agresivno postavljeni, dok se na suprotnoj strani uočava suprotno „ponašanje“. Stoga je za naziv negativne strane odabran naziv **aktivnost**, dok se je pozitivna strana nazvana **pasivnost**.

Ako ovo prenesemo među ljude, negativna strana predstavljala bi „razigranost“, dakle djecu, dok bi suprotna strana predstavljala odrasle, u smislu istraživanja okoline, ipak pasivne objekte.

Ovdje bi se automatska regulacija kao disciplina mogla predstaviti kao izrazito aktivna, jer je njen razvoj izrazit, stalno se pronalaze nova područja primjene. Ovo logički sa pozicije automatske regulacije kao objekta predstavlja izrazito agresivno dakle aktivno ponašanje prema okolini. S druge strane, za već gotove regulacijske sustave može se reći da su ipak još uvijek izrazito pasivni tj. da pripadaju pozitivnoj strani ovog taksona. Gotovi regulacijski uređaj uzima samo već poznate ulaze i načelno nema govora da bi aktivno „malo istraživao“ prostor u kojem vrši regulaciju.

Sa ovim taksonom opisani su svi taksoni 1. razine. Kao što je rečeno, svi opisani taksoni nalaze se na istoj hijerarhijskoj razini, nisu jedan drugome nadređeni tj. ravnopravni su. Ova ravnopravnost je ponešto narušena količinom varijabiliteta koja nije jednaka za svaki takson (*tablica 5.1.5.1.*). U tom smislu bitno odskače prvi takson, dok ostali taksoni padaju prema sve nižim vrijednostima što je i bilo za očekivati.

Ovo se naizgled može možda pripisati odabiru varijabli, ali to se ovdje neće smatrati bitnim jer su ostale varijable ali i konkretan prikaz ostalih objekata na polarnim stranama taksona dostatni za kvalitetnu identifikaciju taksona 1. razine. Uostalom, ukupan objašnjeni varijabilitet je 85 %, što je za ovako složeni projekt predstavlja izvrsnu i visoku vrijednost.

5. 1. 2. TAKSONI 2. RAZINE

Taksoni prve razine nisu međusobno neovisni, što nam omogućava ekstrahiranje slijedeće razine. Sada se postupa na način da se objekte opisuje u šesterodimenzionalnom prostoru (taksoni prve razine) te vrši nova taksonomizacija.

Na ovoj razini dobivena su tri taksona. Opis ovih taksona varijablama, ali i taksonima 1. razine nalazi se u *tablici 5.1.5.2*. Taksoni druge razine prikazani su *slikama 5.1.5.25. – 5.1.5.1.36*. U ovom slučaju zadatak je prepoznati latentne mehanizme druge razine što znači da će iz osnovnih varijabli ali i slika entiteta biti znatno teže prepoznati o kojem svojstvu se radi. Ovo je bilo i za očekivati jer se ekstrakcijom viših mehanizama sve više udaljavamo od konkretnog entiteta i direktno izmjerenih varijabli.

5. 1. 2. 1. Takson br. 1 – Perzistencija (Osjetljivost – Robusnost)

Reprezentanti ovog taksona prikazani su *slikama 5.1.5.25. – 5.1.5.28.* a opis varijablama i taksonima predhodne razine *tablicom 5.1.5.2.*

Neka polazište za opis ovog taksona budu osnovne varijable. Takson jest dominantno opisan slijedećim varijablama: *broj zarobljenih pozicija ukupno* (XXXX = 0.78), *broj točaka za emisiju informacija* (BREM = -0.77), *broj direktnih relacija skeleta* (BRSK = 0.69), *broj točaka* (BRTO = 0.67), *broj ukupnih direktnih relacija* (BREL = 0.59), *broj spojnica* (BRSP = 0.58), *ukupni broj linija* (BRLU = 0.56), *broj praznih zarobljenih pozicija* (ZAPO = 0.51), *najudaljenija slobodna eksterna točka* (NSET = -0.51), *najudaljenija slobodna točka općenito* (NSTO = -0.43). Pažljivijim promatranjem nabrojanih varijabli može se zaključiti da je svim ovim varijablama (osim BREM) zajedničko – opis konstrukcije ! No, ako ovo predstavlja opis konstrukcije, pogledajmo kakva konstrukcija može biti (pogledajmo i slike):

a) Pozitivna strana

- a. Jako puno zarobljenih pozicija – konstrukcija je „velika“,
- b. BREM mali – nema previše komunikacije sa okolinom
- c. BRSK veliki – veliki skelet izmrežan spojnicama
- d. BRTO veliki – masivna konstrukcija
- e. BREL veliki – veliki broj relacija općenito tj. interakcija općenito
- f. BRSP veliki – veliki broj spojnica – kompleksnost, ukrućenost
- g. BRLU veliki – veliki broj elemenata konstrukcije
- h. ZAPO veliki – zauzima se i prazni prostor
- i. NSET, NSTO mali – ne smije imati „pipke“

Ako se uzmu u obzir predhodne varijable te pogleda *slika 5.1.5.28.* vidi se da je ovime opisana čvrsta, teško promjenjiva „konstrukcija“, pa se može zaključiti da je riječ o **robustnosti**, te je pozitivna strana ovog taksona tako i nazvana.

Suprotno tome sva predhodna razmišljanja su „ista“, samo usmjerena u suprotnom smjeru – a kako to izgleda može se vidjeti na slici 5.1.5.27. Očigledno je riječ o laganoj, „prenosivoj“ i komunikativnoj konstrukciji koja čitav svoj „izgled“ zasniva na odašiljanju u okolinu, „odaje sebe drugima“ (BREM veliki, a broj prijema BRPR = 0 !) dosta toga se temelji na okolini, dakle **osjetljiva** je prema njoj. Može se reći da „odaje sebe u okolinu“.

No, samo stalan, „jak“, **perzistentan** objekt može sebe odavati u okolinu. Druga, polarna strana jest robusnost, koja „ne mari baš previše za okolinu“, već se čini da je tu okolinu integrirao u sebe.

U tablici 5.1.5.2. se može vidjeti da je robusnost definirana kao *stabilnost* (0.78), pol *postojanost*, *komunikativnost* (0.53), pol *pasivnost*, te *cjelovitost* (–0.50), pol *kompaktnost*. Osim toga „nije na odmet“ ni malo *organiziranosti* (0.47), tj. pola *složenosti*, a ni malo „uniformiranog“ *sklada* (0.26), dakle pola *krutosti*. Iako malo (–0.12), izgleda da je potrebno i malo *prostorne ekspanzije*. Dakle prerezistencija neke konstrukcije mogla bi se predstaviti kao postojana, cjelovita i kompaktna. Ona kao takva nužno će biti i složena te kruta.

Suprotno tome osjetljivi objekt bio bi (po pitanju *stabilnosti*) *varijabilan*, po pitanju *komunikativnosti* *aktivan* te po pitanju *cjelovitosti* *raspršen*. Osim toga po pitanju *organiziranosti* bio bi *jednostavan*, te po pitanju *sklada* *fleksibilan*.

U teoriji automatske regulacije proučavaju se identični pojmovi, dakle robusnost i osjetljivost, koji su također definirani kao suprotni. Osim toga, kako je poznato kod jednovarijabilnih sustava robusnost se definira preko amplitudne i fazne rezerve, dakle preko stabilnosti ! No i u ovom radu se dobilo da je za robusnost najvažnija stabilnost (0.78), ali se ovdje do tog zaključka došlo na **totalno drugačiji način** koji je „potpuno neovisan“ od onog u automatskoj regulaciji !

Ovo nas uvjerava u postavci da su **pravila opća**, samo se u **različitim područjima** „različito“ manifestiraju !

5. 1. 2. 2. Takson br. 2 – Upravljivost (Elementarnost – Sustavnost)

Podsjetimo se da je entitet u ovom istraživanju predstavljen kao apsolutno samostalan, a varijable sa kojima je opisan usmjerene su, odnosno orjentirane **isključivo prema njemu samom** (Zato se i ne koristi naziv objekt jer bi pravilan naziv bio subjekt. Kako subjekt nije uobičajen naziv, odabran je naziv entitet). Čak i varijable poput BRPR koje opisuju moguću komunikaciju sa drugim entitetima, tu komunikaciju mjere **isključivo sa pozicije promatranog objekta/entiteta**, dakle ne sa pozicije nekog potencijalnog entiteta sa kojim bi mogao doći u doticaj. Ovo je u skladu sa postavljenim ciljem: proučavanje univerzalnih entiteta unutar univerzuma (svega). Dakle, onda kada proučavamo entitet tj. kada se vrši mjerenje neke varijable **okolina entiteta ne postoji** ili realnije rečeno apsolutno je irelevantna za mjernu vrijednost neke varijable.

Ovaj takson opisan je *slikama* 5.1.5.29. – 5.1.5.32. te *tablicom* 5.1.5.2.

Za opis ovog taksona može se promotriti njegov opis taksonima prethodne razine:

Svojtvo	projekcija	– strana	+ strana
Organiziranost	0.58	jednostavnost	<u>složenost</u>
Ekspanzija	0.54	prostorna	<u>materijalna</u>
Cjelovitost	-0.47	<u>kompaktnost</u>	raspršenost
Komunikativan	-0.44	<u>aktivnost</u>	pasivnost
Sklad	-0.35	<u>fleksibilnost</u>	krutost
Stabilan	0.26	varijabilnost	<u>postojanost</u>

Podcrtan je opis pozitivne strane taksona.

Podimo od negativne strane ovog taksona; kakav je to objekt koji je jednostavan, ima prostorno širenje, raspršen, pasivan, malo krut te pomalo varijabilan ?

Postavimo i drugo pitanje: Kako izgledaju elementarni načini regulacije, npr. sa PID regulatorom ?

Njegova prva karakteristika je zasigurno *jednostavnost*, tj. prilikom projektiranja regulacijskih sustava teži se što manjem redu sustava, dakle jednostavnosti. Zasigurno ovi regulatori su *kruti*, tj. transfer istog regulatora na druge objekte regulacije je minimalan, bolje rečeno nemoguć. Dakle kakva je *ekspanzija* ovih objekata ali sa pozicije **objekta** ? Pa, naravno površna, tj. *prostorna* i to iz jednostavnog razloga jer je znanje regulatora uneseno izvana, tj. od projektanta. Nadalje, ovakav pristup forsira *raspršenost* – svaki sustav ima svoj PID regulator – nema integracije sa drugim PID regulatorima jer inače nije jednostavan. No tada je i sa pozicije objekta (regulatora) on *pasivan* (mi ga namještamo !), a uz to sigurno i varijabilan – jer sa pozicije PID regulatora sigurno nije moguće odgonetnuti zašto je jedan „ovakav“ a drugi „onakav“.

Kako bi ovo izgledalo u prostoru ljudi ? Uzmimo za primjer ponašanje nekog djeteta od 5 godina. Obrasci ponašanja moraju biti *jednostavni* (zato jer je dijete), ono kao dijete ima (sa njegove pozicije) veliki djelokrug kontakata (vršnjaci, roditelji, rodbina, susjedi, vrtić,) te ono iako egzistira u takvoj okolini, nema neophodne obrasce ponašanja (zato i jest pod nadzorom odraslih). No to znači da je njegova ekspanzija u socijalnu okolinu „šuplja“, „prazna“ ili kako je takson nazvan *prostorna*. Isto tako njegovo ponašanje nije *cjelovito*, nema dovoljno „jak“ obrazac ponašanja u svim ovim prilikama, pa je u smislu ponašanja *raspršen*, negdje se zna ponašati relativno dobro, da bi se drugom prilikom ponašao totalno neprimjereno. Također u smislu ponašanja jest *pasivan* jer praktično radi kako mu netko kaže – dakle nalazi se u pasivnoj poziciji. Dakako da je i pomalo *krut* jer teško prepoznaje nove socijalne situacije te obično pokuša zadržati poznatu socijalnu okolinu (npr. ne želi se odvajati od roditelja). Kako ne zna točno procjeniti situaciju, njegovo ponašanje je i *varijabilno*.

Nasuprot tome pozitivna strana ovog taksona opisuje objekte, npr. ljude koji su *složeni* (nije tek tako moguće utjecati na njegovo ponašanje), zatim imaju *materijalnu ekspanziju*, dakle imaju na raspolaganju složene obrasce ponašanja te ih primjenjuju na cijeli prostor socijalnog djelovanja. Što se tiče *cjelovitosti* – *kompaktni* su, može se reći i prepoznatljivi bilo da se nalaze na ulici ili u kući. Osim toga za kvalitetno ustrojavanje načina vlastitog ponašanja potrebna je *aktivna komunikacija*, ali i *fleksibilnost* da bi mogli usvojiti tuđe stavove i savjete, dakako sukladno svojim spoznajama.

Sve opisano odnosi se na manifestacije tj. na manifestni prostor objekta, odnosno na onaj dio koji mi kao promatrači možemo vidjeti. No, kako je već rečeno ovdje se proučavaju objekti sami, okolina nije bitna, te stoga sva ova razmišljanja treba „okrenuti“ prema objektu/entitetu proučavanja. Što je potrebno da bi mogli uočiti sve opisano, da entitet počme mijenjati svoje ponašanje, svoje navike, svoju „vanjsku“ pojavu ?

Za ovako nešto neophodna je **strukturna promjena objekta**, jer obrazac ponašanja direktno ovisi o objektu i kao takvoga ga nije moguće „odglumiti“ ili to barem nije moguće na dulje vrijeme. Dakle slika (dakako stvarna, a ona jest stvarna jer su varijable objektivne !) koju mi kao promatrači vidimo jest posljedica **interne strukture** koja se na **negativnoj strani taksona mijenja izvana**, a na **pozitivnoj strani taksona iznutra (!)**. Očigledno u oba slučaja riječ je o **internoj reorganizaciji objekta samog**.

Kako je cijeli takson nazvan upravljivost, to znači da se pod upravljivosti ovdje podrazumjeva **spособnost promjene interne strukture objekta** i to u skladu sa novim spoznajama !

Kao što je već rečeno, ona može biti inicirana izvana (negativan pol) ili iznutra (pozitivan pol).

Iako se čini da pozitivna strana taksona (promjena iznutra) nije moguća u tehničkim sustavima, to nije točno. Zamislimo, recimo razvoj računarnog programa (npr. Matlab) čija je svrha rješavanje problema automatske regulacije (u širem smislu). U samom početku bili bi to relativno nezavisni programi namjenjeni rješavanju diferencijalnih jednadžbi napisanih u Fortranu. No prije ili poslije „netko se sjetio“ i te je programe spojio u neku kompaktniju cjelinu sa ciljem olakšane manipulacije podacima i rezultatima. Može se reći da je oformljena „nova varijanta“ Matlab-a. Nakon toga su i nadalje dodavane nove rutine, nakon nekog vremena pojavili su se i toolbox – ovi. No, u jednom trenutku sve zajedno je krenulo u jednom smjeru koji se na početku nije mogao predvidjeti. Fortran je postao prošlost, vrijeme je C jezika, grafičkog sučelja, pojavili su se drugi operativni sustavi, nova računala, broj dodatnih rutina je enormno narastao (možemo kazati da je Matlab *materijalno ekspandirao*), ... Drugim riječima u jednom trenutku sve se toliko usložnilo, da samo dodavanje novih funkcionalnosti nije teklo bez problema te je trebalo izvršiti temeljnu reorganizaciju samog programa. Upravo ova reorganizacija je **inicirana potrebama samog Matlab-a kao entiteta** koji više nije mogao odoljevati novim zahtjevima, metodama rješavanja i sl., a da se sam ne reorganizira. **Dakle sa pozicije Matlab-a, on kao samostalni entitet je izvršio internu reorganizaciju !** Dakako da je sa pozicije Matlab-a **totalno nevažno što su to konkretno učinili „neki ljudi“**, jer **stoji neosporna činjenica da je Matlab kao samostalan entitet napredovao !** (Matlab jest samostalan jer egzistira i bez svojih tvoraca !)

Drugim riječima sa pozicije teorije spoznaje Matlab ima dovoljne spoznaje da ga se može identificirati kao zasebnu cjelinu tj. entitet. Primjedbe tipa da on bez računala ne egzistira nije argument jer se isto tako može reći ni da ljudi bez planete Zemlje ne postoje, pa dakle ljudima oduzimamo samosvojsnost i dajemo je Zemlji (računalu).

Je li moglo biti drugačije ? Može se kazati da ljudi nisu morali razvijati Matlab. No, to bi značilo da problemi automatske regulacije u tom dijelu nisu riješeni. Pa bi se ponovno pojavila potreba za rješavanjem tog problema koji bi u međuvremenu samo – narastao ! Dakle razvoj Matlab-a ili nekog Matlab-a je neminovnost. Može se zaključiti da u spoznajnom smislu, tj. **sa pozicije teorije spoznaje entitet Matlab jest potreban te je zbog toga i nastao!**

Ako se ovakvo razmišljanje generalizira, može se zaključiti da **novi entiteti općenito** (po teoriji spoznaje) **nastaju kao posljedica potrebe za pohranom novih spoznaja !!** Dakle sa pozicije teorije spoznaje, konkretni entitet je „nevažan“ – važna je samo njegova spoznaja !! Ovo se može i iskazati na način da je konkretan entitet nastao isključivo iz razloga „smještaja“ spoznaja, jer prisjetimo se – realno postoje samo entiteti/objekti ! No važi i obrnuto : **ne može postojati entitet bez spoznaje** (mora ima barem elementarnu spoznaju, a ta je da se razlikuje od okoline) – ova dva pojma neraskidivo su povezana.

Zaključimo: Matlab kao alat za rješavanje problema automatske regulacije u početku je napredovao dominantno intervencijama sa strane, da bi na nekoj točki razvoja napredovanje bilo inicirano dominantno iz Matlab-a samog !

Analogno razmišljanje se može primjeniti na i PID regulator koji je, ako promatramo prostor regulatora napredovao do složenih algoritama vođenja procesa. Ako razapnemo prostor egzistencije regulatora i izmjerimo sve relevantne parametre sigurno ćemo dobiti razlike između njih. Razlike su uzrokovane njihovom složenošću, ugrađenom znanju ili općenitije rečeno spoznajama.

Sada je jasniji i naziv polova ovog taksona – intervencije sa strane jesu temeljna, **elementarna upravljivost**, dok je ona unutarnja složena, **sustavna upravljivost**.

5. 1. 2. 3. Takson br. 3 – Edukatibilnost (Površnost – Sistematičnost)

Ovaj takson je prikazan *slikama 5.1.5.33. – 5.1.5.36.*, a opis varijablama je vidljiv u *tablici 5.1.5.2.*

Za opis ovog taksona daleko najvažniji su *sklad* (0.78) te *ekspanzija* (0.65). Uostalom ako želimo ekspanzirati u bilo koji prostor moramo u tom smislu biti „usklađeni sa samim sobom“ u vezi načina na koji želimo proširiti u okolni prostor. Ovdje se očito radi o mogućnosti napredovanja, dakle ovaj takson predstavlja **edukatibilnost** entiteta.

Pozitivan pol taksona definiran je dominantno *krutim skladom* te *materijalnom ekspanzijom*. Osim navedenih taksona, na razini osnovnih varijabli još je vidljiva i važnost *velikog broja spojnica* (BRSP), *velikog ukupnog broja linija* (BRLU), *malog zaposjednutog prostora* (ZAPO) te *malo vrijeme prijenosa informacija* (IMNV, IMXV). Tipični predstavnici vidljivi su na slikama.

Može se zaključiti da pozitivni pol ovog taksona predstavlja *skladnu materijalnu ekspanziju* entiteta u okolni prostor te su ovi tipovi entiteta prostor „osvajali“ u skladu sa svojim spoznajama, „korak po korak“, dakle **sistematično**.

Negativna strana može biti opisana kao *skladna fleksibilna prostorna ekspanzija*. Čini se da je ovdje riječ o tome da se prostor „osvoji dinamički“ tj. da se svojom *fleksibilnošću* i „malom složenošću konstrukcije“ bude u svakom dijelu prostora. „Mala složenost konstrukcije“ može se opisati sa gotovo *nevažnim brojem točkica* (BRTO), *malim brojem spojnica* (BRSP), *linija ukupno* (BRLU), te *velikim vremenom prijenosa informacija* (IMNV, IMXV). Očigledno su entiteti ovakvog tipa prividno, **površno** osvojili prostor.

5. 1. 3. TAKSONI 3. RAZINE

Nakon taksonomizacije predhodne razine dobivena su dva taksona. Opis ovih taksona svim predhodnim razinama uključujući i početnu sa varijablama dan je u *tablici 5.1.5.2.* Na slikama *5.1.5.37. – 5.1.5.44.* prikazani su tipični reprezentanti dobijenih taksona.

5. 1. 3. 1. Takson br. 1 – Determinizam (Dezintegracija (neodređenost) – Integracija (određenost))

Ovaj takson je vidljiv na *slikama 5.1.5.37. – 5.1.5.40.* i u *tablici 5.1.5.2.*

Negativna strana ovog taksona može se sa taksonima predhodne razine opisati kao: *perzistentan – osjetljiv i upravljiv – elementaran* te malo *edukabilan – površan*. Ako se uz to pogleda slika tipičnih predstavnika ovog tipa entiteta dobije se jasna slika o raspadnutim, **dezintegriranim** entitetima. Praktično nije moguće odrediti, zamisliti što konkretan entitet predstavlja.

Ovdje se može zaključiti da je zasigurno ova karakteristika nepoželjna, jer vodi raspadu entiteta.

Pozitivna strana je opisana kao *perzistentna – robusnost i upravljivost – sustavnost* te malo *edukabilnost – sistematičnost*. Ako se pogleda *slika 5.1.5.40.* vidljivo je da je riječ o solidnim, jasno **određenim** i lako prepoznatljivim entitetima koje nije moguće zamijeniti jednog za drugog, te oni kao takvi su **integritani** u jednu cjelinu.

Ovo je sigurno poželjno svojstvo entiteta: treba biti robustan (da može odoljeti neželjenim utjecajima iz okoline), sustavan (da može izvršiti internu reorganizaciju kada je to potrebno) te malo sistematično edukabilan (previše *edukabilnosti* može uzrokovati napredak koji *perzistencija* ne može pratiti tj. previše *edukabilnosti* može narušiti „njegovo ja“).

Cijeli takson nam praktično „govori“ o tome „ima li uopće što“ u prostoru koji promatramo, dakle predstavlja određenost, **determinizam**. Očigledno je da po negativnoj strani taksona malo što određeno, i suprotno tome da je na pozitivnoj strani malo što neodređeno.

5. 1. 3. 2. Takson br. 2 – Razvoj (Zasićen – Svestran)

Tipični predstavnici ovog taksona prikazani su slikama *5.1.5.41. – 5.1.5.44.*, a opis taksona varijablama nalazi se u *tablici 5.1.5.2.*

Pozitivna strana ovog taskona može se taksonima predhodne razine opisati kao dominantno *edukabilnost – sistematičnost* (0.86) nešto manje i kao *perzistencija – osjetljivost* (–0.51). Potrebno je i malo *upravljivosti – sustavnosti* (0.12). Ovdje odmah „upada u oči“ podatak da su *edukabilnost i perzistencija* suprotnih predznaka, dakle uz *edukabilnost* ne ide *perzistencija – robusnost*, već upravo suprotno *osjetljivost*. Ako se malo razmisli, nije moguća *edukabilnost* uz *robusnost* iz jednostavnog razloga što je glavno svojstvo *robusnosti* da ne dopusti (nepoželjne ali isto tako i „poželjne“) promjene !

Pregledom tipičnih predstavnika ovog taksona (*slika 5.1.5.42.*) vidljivo je da se radi o razvoju i to na sve moguće strane rastera, dakle ova strana predstavlja **svestrani razvoj**.

Suprotna strana predstavljena je *površnom edukatibilnošću* i *robustnom perzistencijom*. Dakle ako imamo robustan entitet moguća je samo površna a ne i stvarna edukatibilnost !

Ovo je vidljivo i na *slici 5.1.5.41.* gdje se može vidjeti da je razvoj u okolni prostor blokiran te je u razvojnom smislu limitiran, **zasićen**.

5. 1. 4. RAZINA 4. – GLAVNI TAKSON – Spoznaja (Parcijalna – Globalna)

Na zadnjoj razini dobijen je jedan jedini opis prostora proučavanja. Ovaj, zadnji takson je najbolji jednodimenzionalni (bipolarni) opis svih tipova koji egzistiraju u proučavanom prostoru. On također predstavlja najsazetiji mogući opis prostora egzistencije entiteta.

U *tablici 5.1.5.2.* vidljivo je da je ovaj takson na pozitivnoj strani jednako definiran *determinizmom – integracija* kao i *svestranim razvojem* (0.71). Na slikama *5.1.5.45. – 5.1.5.48.* jasno je vidljivo kako se prostor može osvojiti (spoznati) stvarno, sadržajno tj. **globalno** ali isto tako i samo po pojedinim segmentima, djelomično, **parcijalno**.

No, ako je najtipičniji predstavnik cijelog prostora upravo entitet E238, to znači da je upravo on najbolji u tom prostoru. To isto tako znači i da je on najbolje (idealno) „shvatio“ što je najvažnije u prostoru, dakle „shvatio“ je pravila prostora. Nije bitno ima li on mozak ili možda najnoviji procesor, on sve o prostoru u kojem jest ima u sebi, nevažno je kako je, i u kojem dijelu entiteta sve to skupa pohranjeno. Sve te elementarne informacije kao i one složenije koje E238 ima zovu se skupnim imenom spoznaja. No i svi ostali entiteti imaju barem neke spoznaje pa čak i onaj zadnji entitet (E264). Stoga je cijeli glavni takson predstavljen maksimalno općenito, onime što se obuhvaća sve – dakle glavni takson je **spoznaja**.

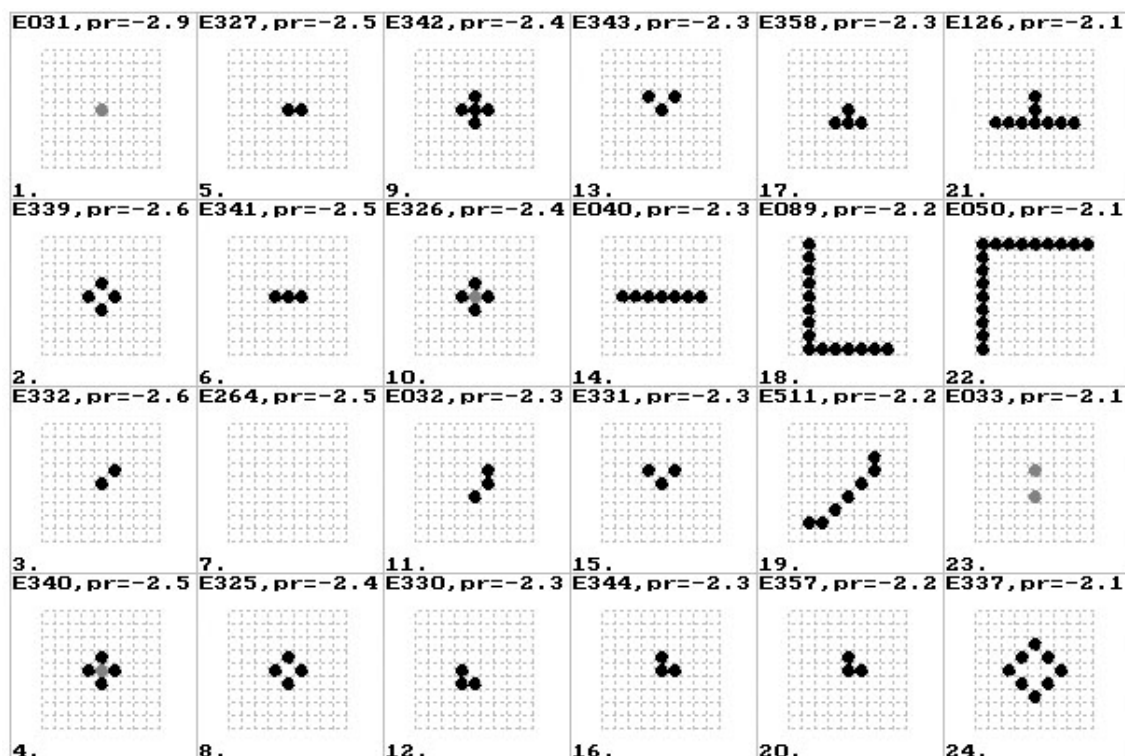
Na početku istraživanja postavili smo uvjet da proučavamo sve bez ostatka. Sa generalnim taksonom došli smo do kraja. Drugim riječima entitet E238 ima u sebi svo znanje, tj. kompletnu spoznaju svega !

Je li ovo onda predstavlja kraj u općem smislu ? Naravno ne. Uostalom ovdje se proučavalo 4 razine, s time da nije niti ispitano koliko ih uopće ima.


No, ipak ovaj rad ima intenciju ponuditi pronađene razine i sva pronađena pravila kao npr. pravila 2. razine (perzistencija, upravljivost i razvoj) kao sjevremenske i nepromjenjive ! Uostalom krajnja gornja pravila su najlakše uočljiva te ih je logično i najlakše identificirati i opisati.

Tako se pozitivna strana prvog taksona u znanosti ne zove globalna spoznaja nego znanstvena istina. A kakva maksimalna spoznaja određenog prostora može biti nego istinita, jer ako je lažna ili dijelom lažna, tada možemo reći da je i dijelom istinita, a dijelom nije tj. možemo reći da je *parcijalna* (negativna strana glavnog taksona).

5. 1. 5. SLIKE TAKSONA I TABLICE SA PROJEKCIJAMA



Slika 5.1.5.1. Organiziranost (1. razina, 1. takson); negativna strana: Jednostavnost



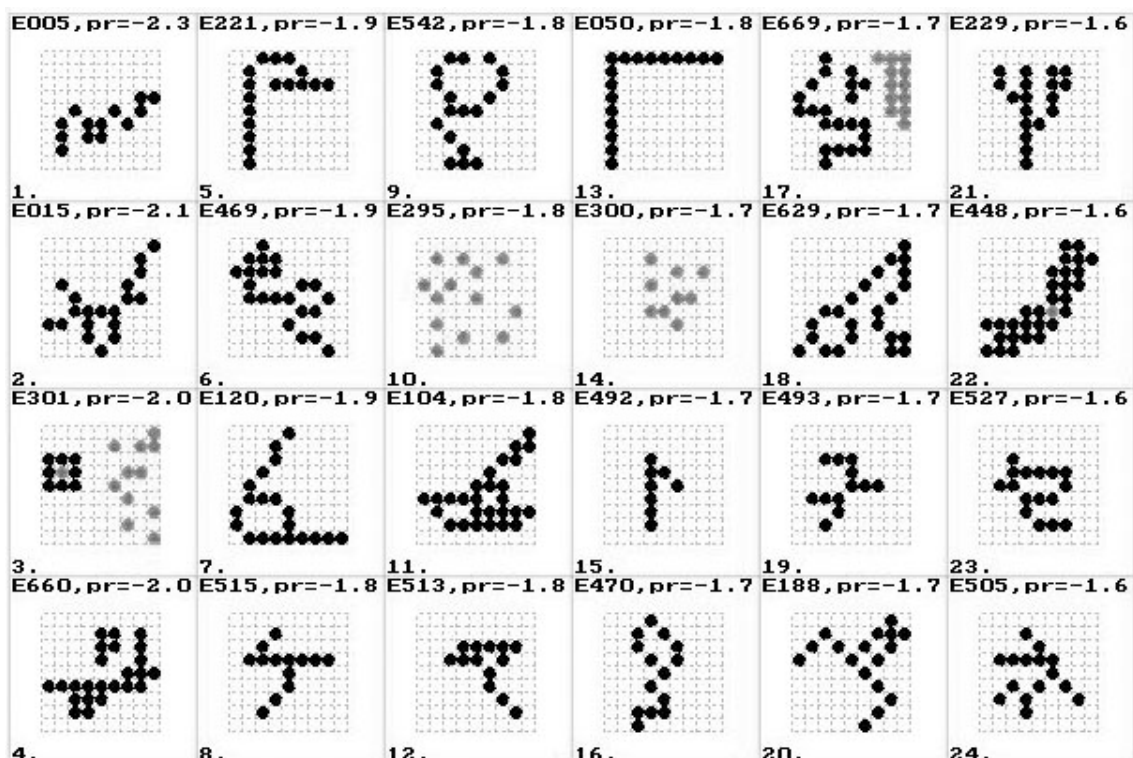
Slika 5.1.5.2. Organiziranost (1. razina, 1. takson); pozitivna strana - Složenost

1. E031 -2.9392	5. E327 -2.5744	9. E342 -2.4082	13. E343 -2.3603	17. E358 -2.3046	21. E126 -2.1826
2. E339 -2.6662	6. E341 -2.5467	10. E326 -2.4041	14. E040 -2.3553	18. E089 -2.2801	22. E050 -2.1725
3. E332 -2.6586	7. E264 -2.5228	11. E032 -2.3725	15. E331 -2.3380	19. E511 -2.2520	23. E033 -2.1248
4. E340 -2.5902	8. E325 -2.4801	12. E330 -2.3653	16. E344 -2.3324	20. E357 -2.2008	24. E337 -2.1132


Slika 5.1.5.3. Organiziranost (1. razina, 1. tax.); negativna strana: **Jednostavnost**

1. E567 2.2122	5. E403 2.0622	9. E269 1.9694	13. E412 1.8629	17. E409 1.7989	21. E399 1.7442
2. E372 2.2018	6. E411 2.0504	10. E695 1.9213	14. E373 1.8532	18. E371 1.7816	22. E297 1.7238
3. E700 2.2003	7. E576 1.9891	11. E400 1.9056	15. E311 1.8296	19. E415 1.7632	23. E414 1.6988
4. E609 2.0723	8. E383 1.9763	12. E402 1.8639	16. E381 1.7991	20. E578 1.7595	24. E406 1.6884

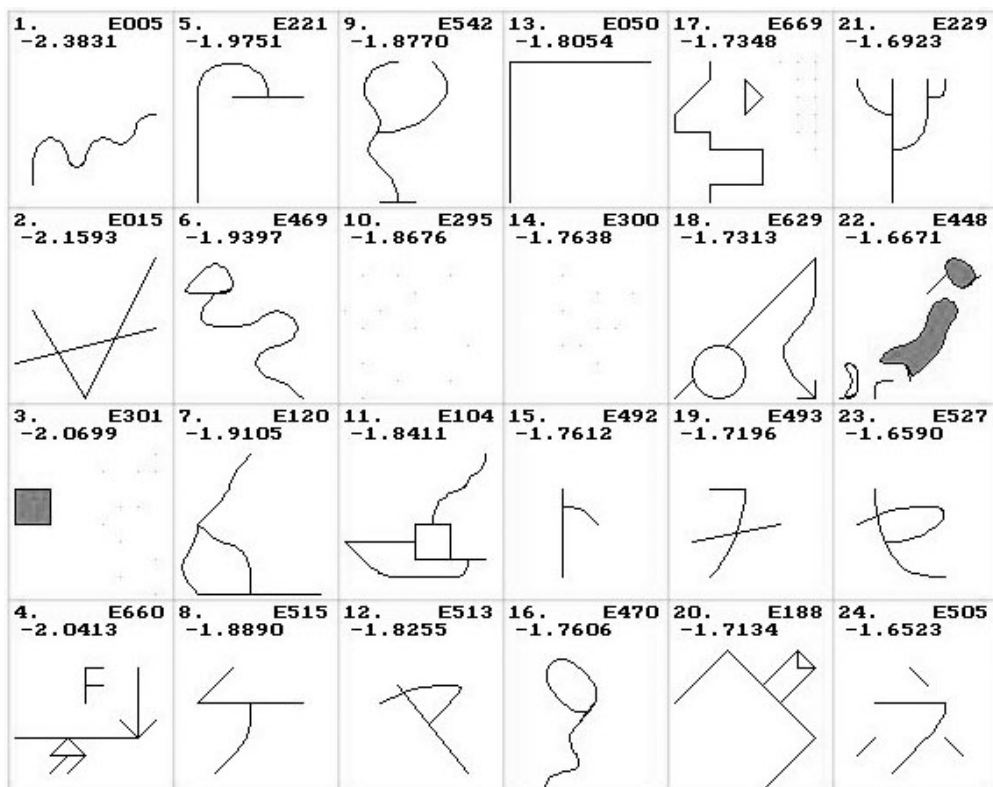
Slika 5.1.5.4. Organiziranost (1. razina, 1. takson); pozitivna strana - **Složenost**




Slika 5.1.5.5. Stabilnost (1. razina, 2. takson); negativna strana - Varijabilnost



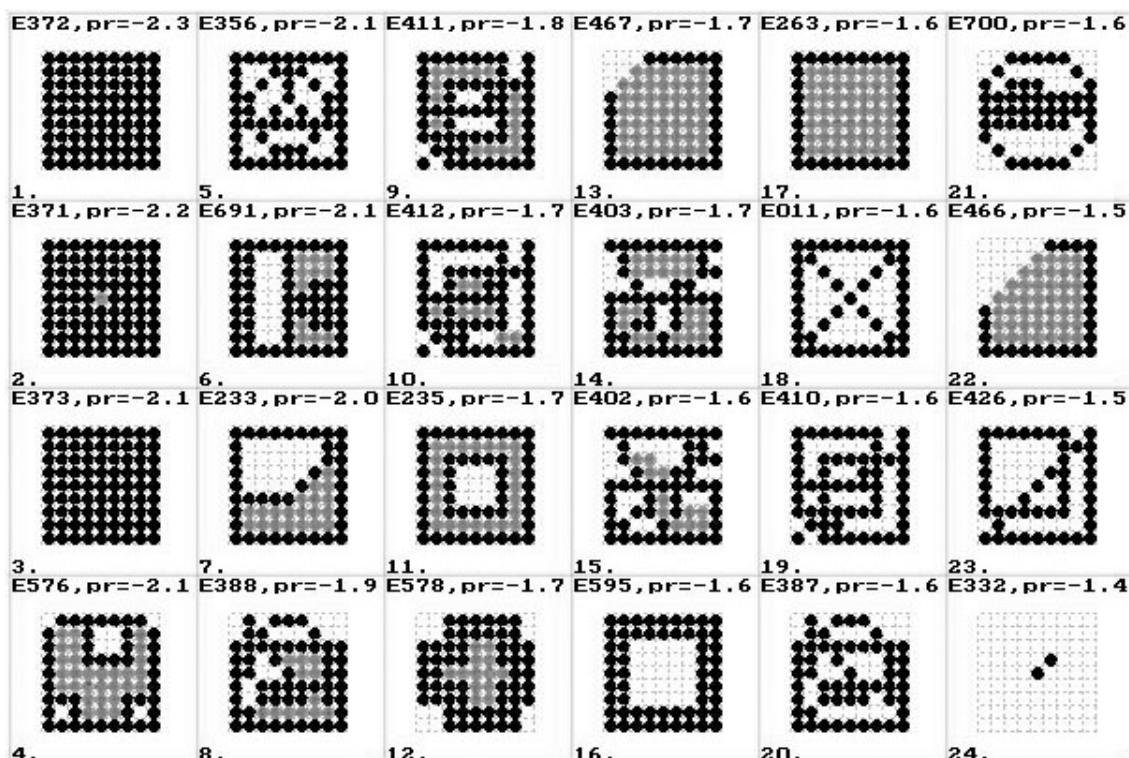
Slika 5.1.5.6. Stabilnost (1. razina, 2. takson); pozitivna strana - Postojanost




Slika 5.1.5.7. *Stabilnost* (1. razina, 2. takson); negativna strana - *Varijabilnost*



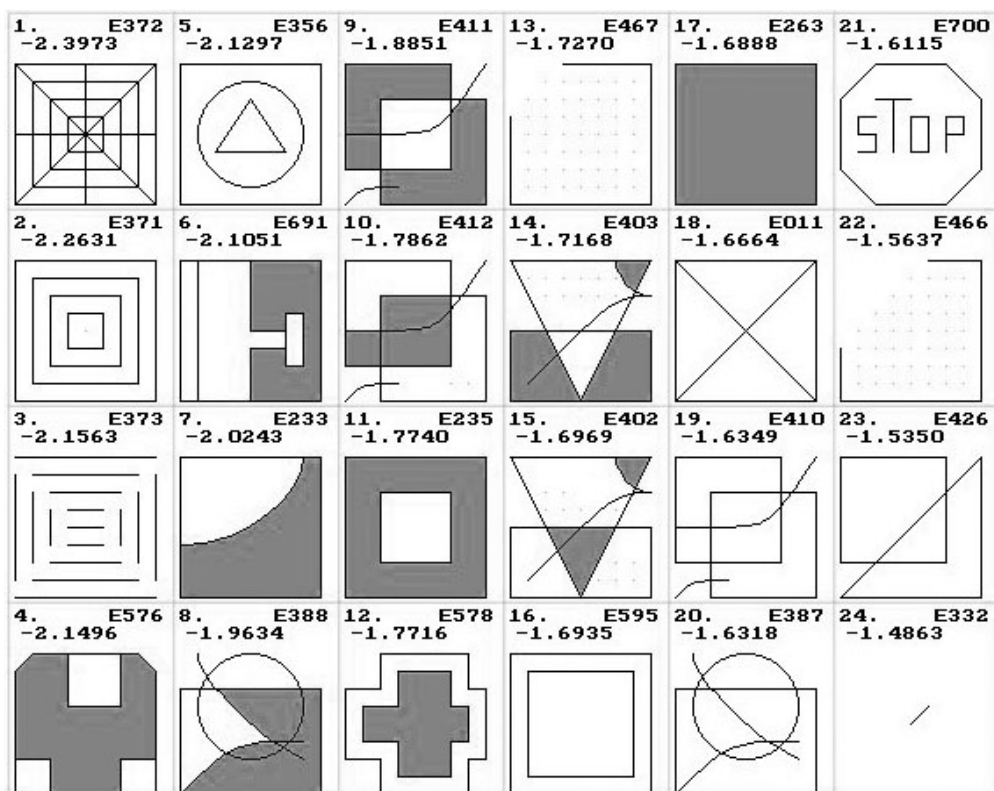
Slika 5.1.5.8. *Stabilnost* (1. razina, 2. takson); pozitivna strana - *Postojanost*



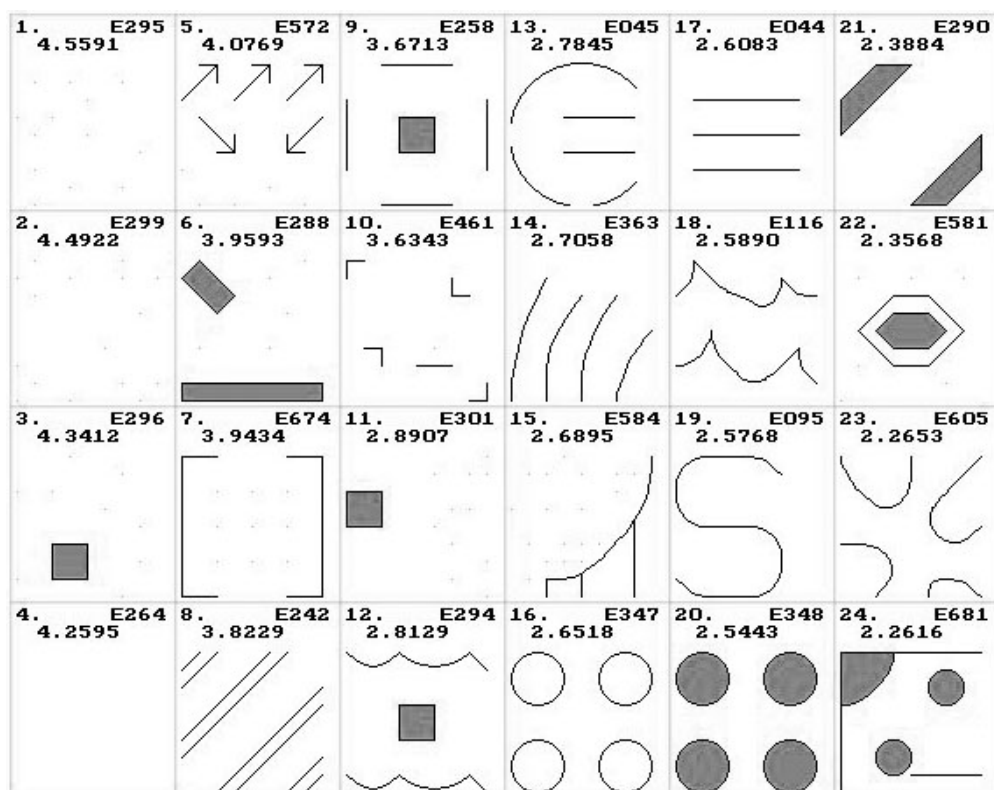
Slika 5.1.5.9. Cjelovitost (1. razina, 3. takson); negativna strana - Kompaktnost




Slika 5.1.5.10. Cjelovitost (1. razina, 3. takson); pozitivna strana - Raspršenost




Slika 5.1.5.11. *Cjelovitost (1. razina, 3. takson); negativna strana - Kompaktnost*




Slika 5.1.5.12. *Cjelovitost (1. razina, 3. takson); pozitivna strana - Raspršenost*



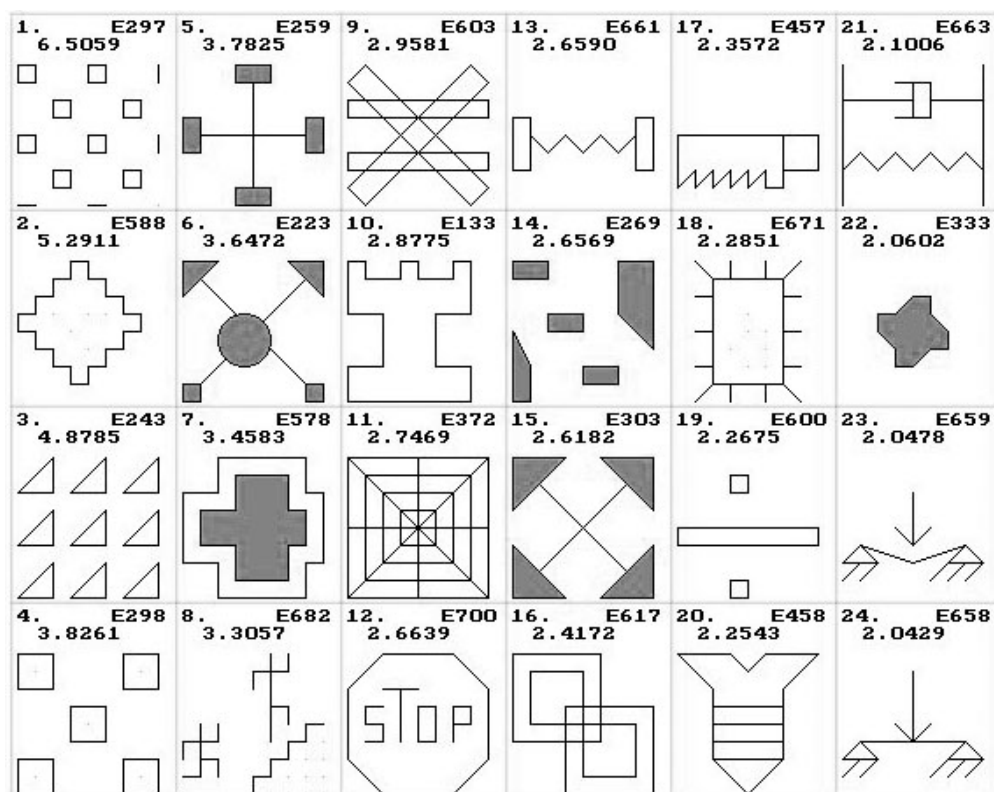
Slika 5.1.5.13. Sklad (1. razina, 4. takson); negativna strana - *Fleksibilnost*




Slika 5.1.5.14. Sklad (1. razina, 4. takson); pozitivna strana - *Krutost*




Slika 5.1.5.15. *Sklad* (1. razina, 4. takson); negativna strana - *Fleksibilnost*




Slika 5.1.5.16. *Sklad* (1. razina, 4. takson); pozitivna strana - *Krutost*



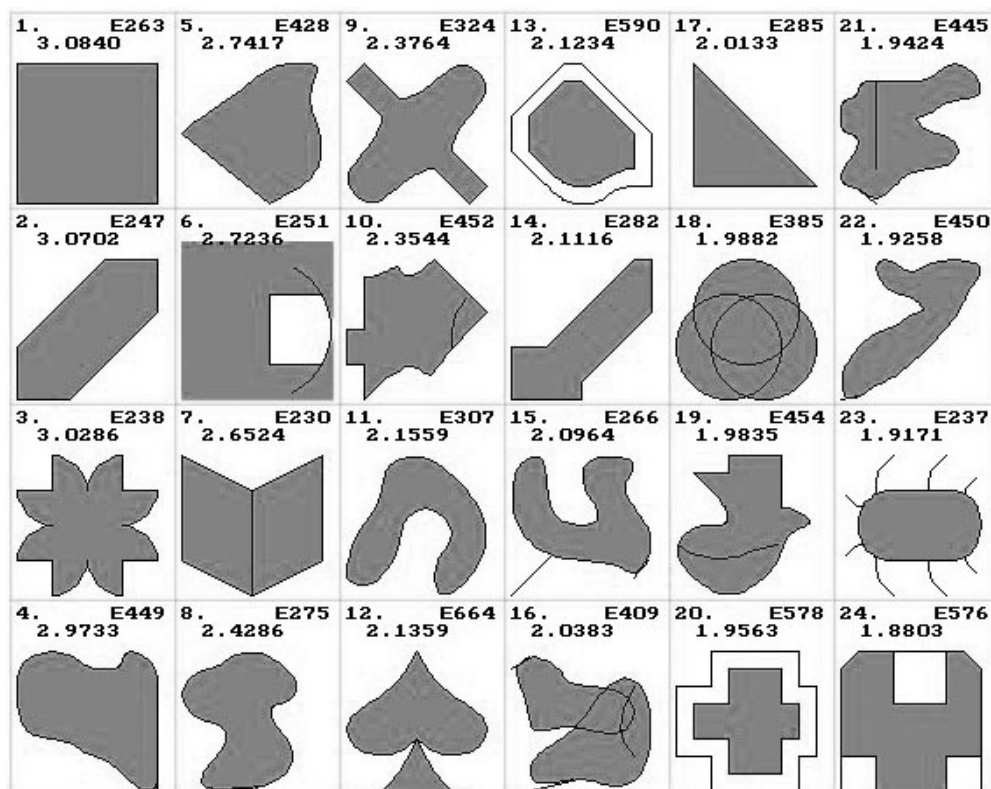
Slika 5.1.5.17. Ekspanzija (1. Razina, 5. Takson); negativna strana - Prostorna




Slika 5.1.5.18. Ekspanzija (1. Razina, 5. Takson); pozitivna strana - Materijalna




Slika 5.1.5.19. Ekspanzija (1. Razina, 5. Takson); negativna strana - Prostorna



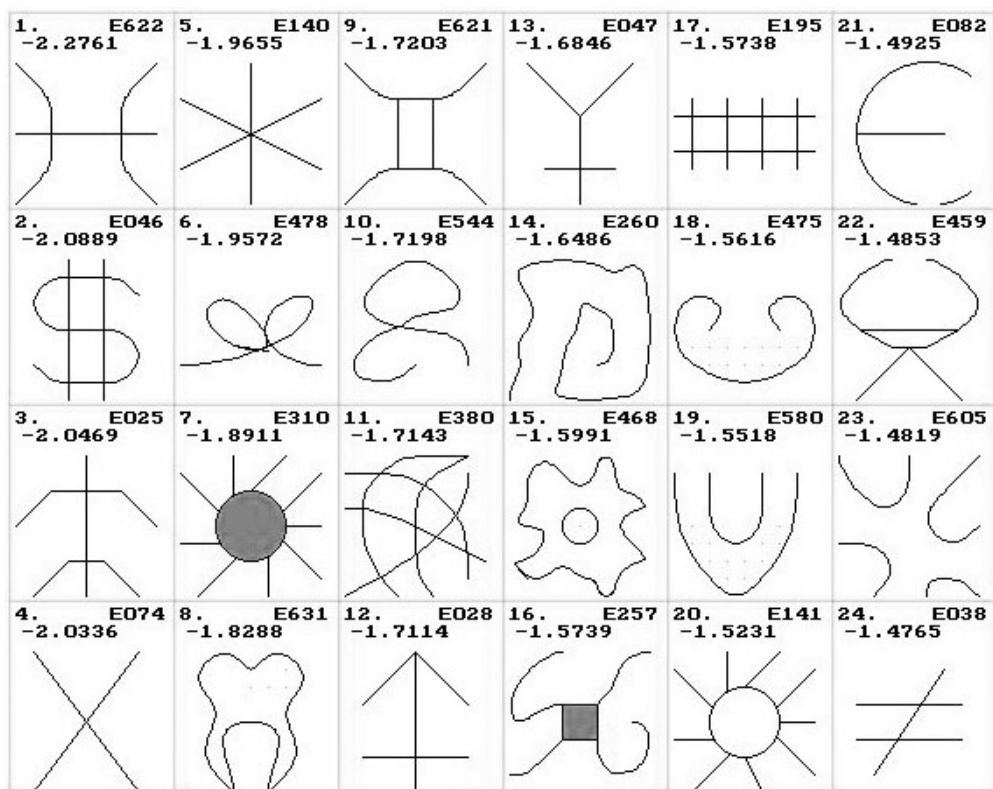
Slika 5.1.5.20. Ekspanzija (1. Razina, 5. Takson); pozitivna strana - Materijalna



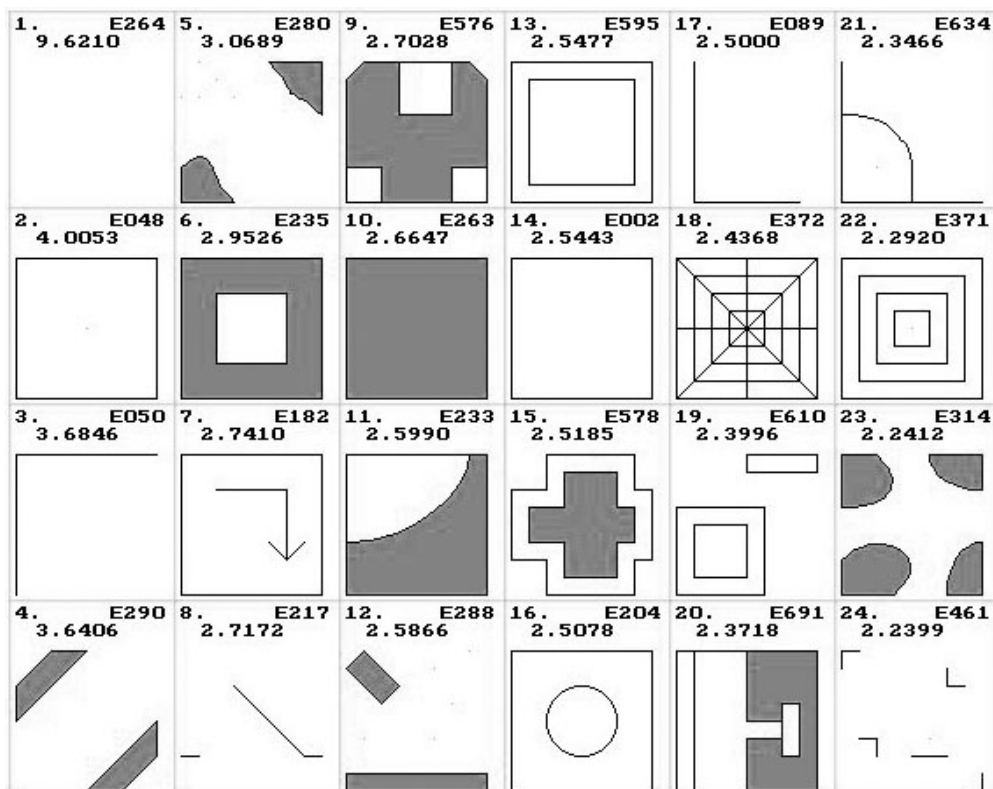
Slika 5.1.5.21. Komunikativnost (1. razina, 6. takson); negativna strana - Aktivnost



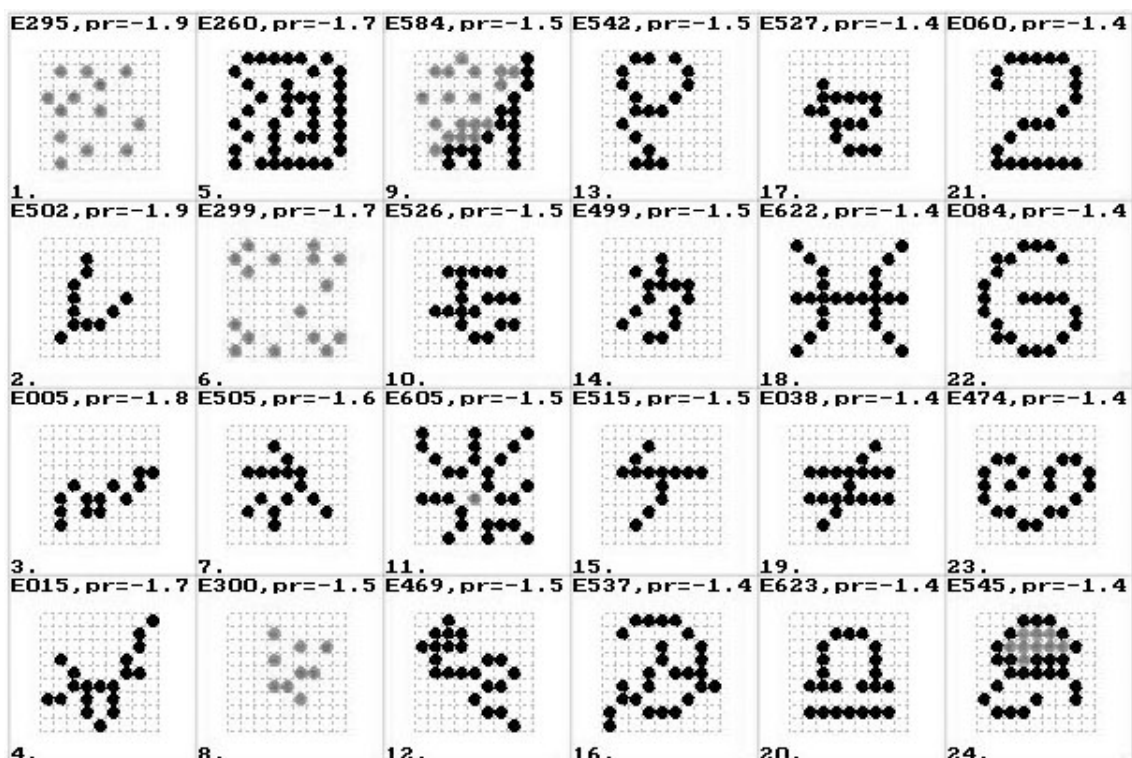
Slika 5.1.5.22. Komunikativnost (1. razina, 6. takson); pozitivna strana - Pasivnost




Slika 5.1.5.23. *Komunikativnost* (1. razina, 6. takson); negativna strana - *Aktivnost*



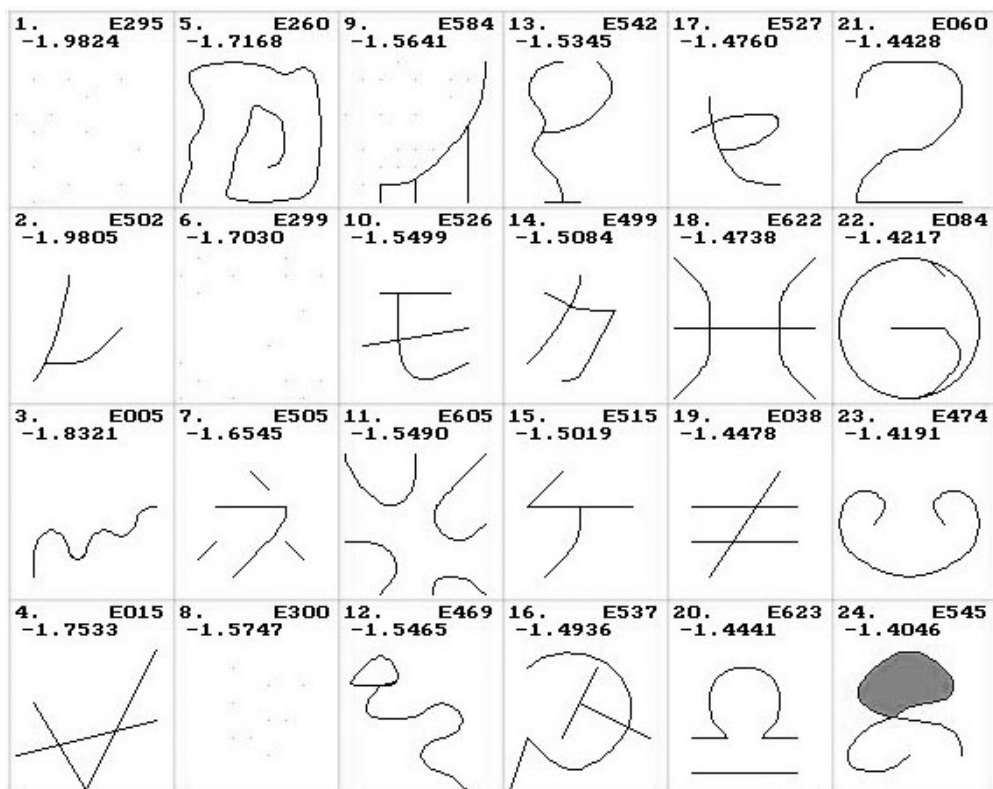
Slika 5.1.5.24. *Komunikativnost* (1. razina, 6. takson); pozitivna strana - *Pasivnost*



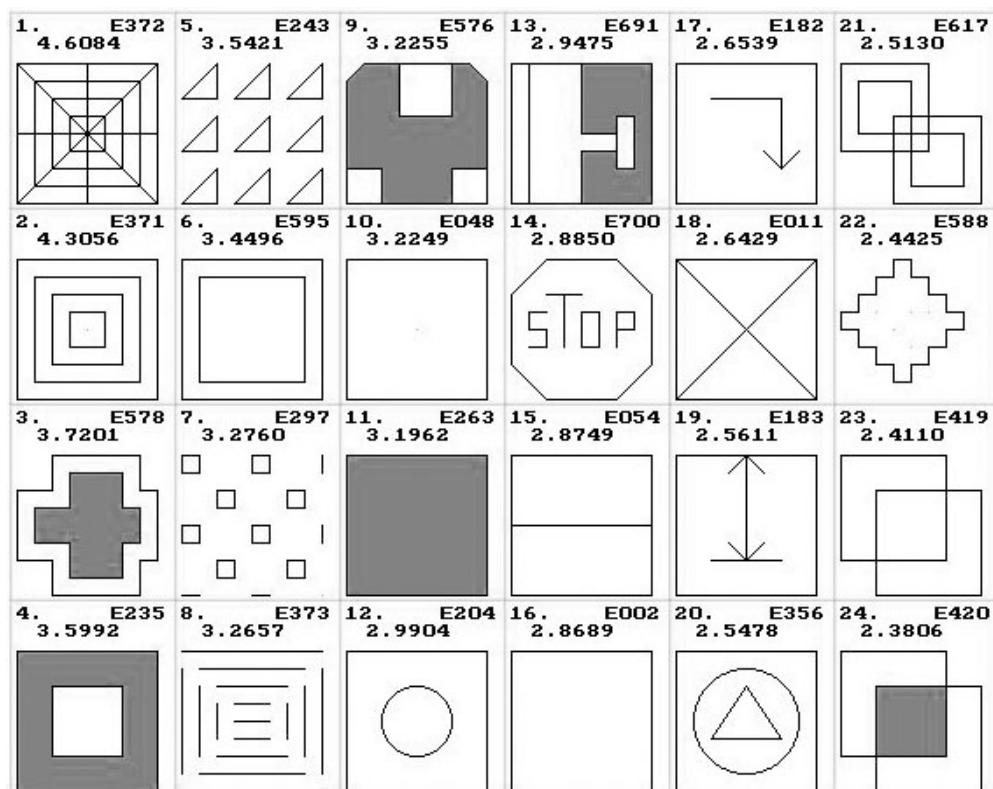
Slika 5.1.5.25. Perzistencija (2. razina, 1. takson); negativna strana - Osjetljivost



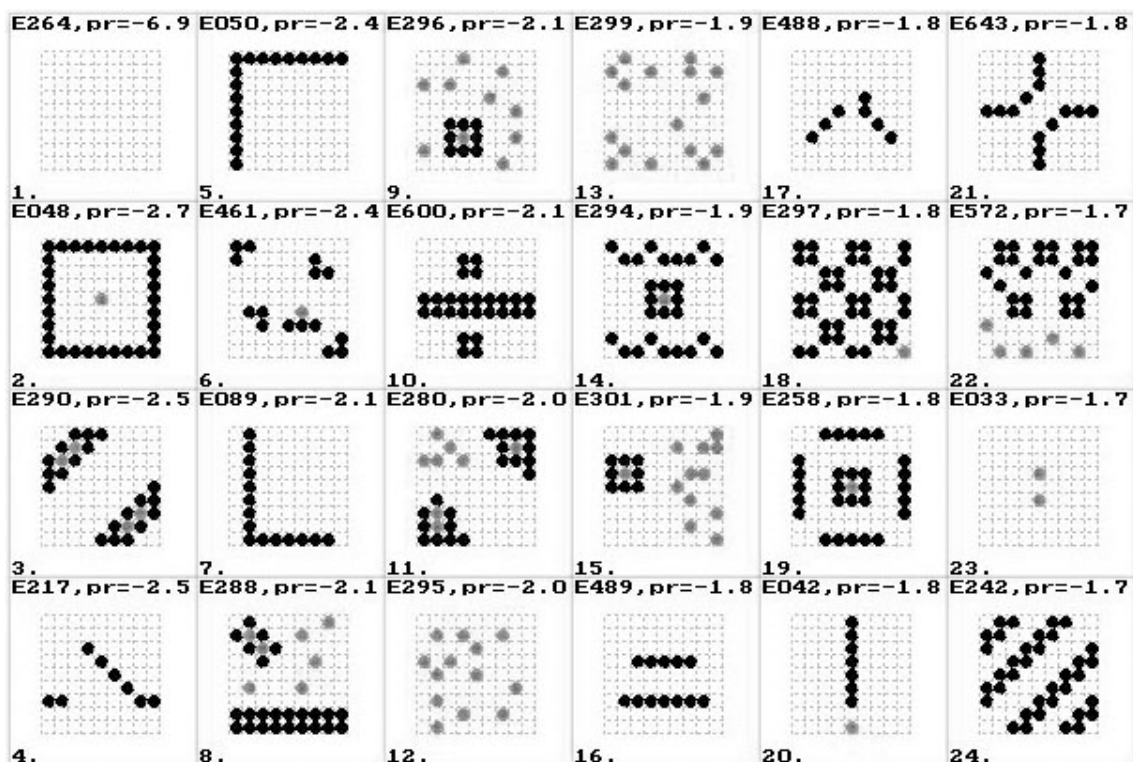
Slika 5.1.5.26. Perzistencija (2. razina, 1. takson); pozitivna strana - Robusnost




Slika 5.1.5.27. *Perzistencija* (2. razina, 1. takson); negativna strana - *Osjetljivost*



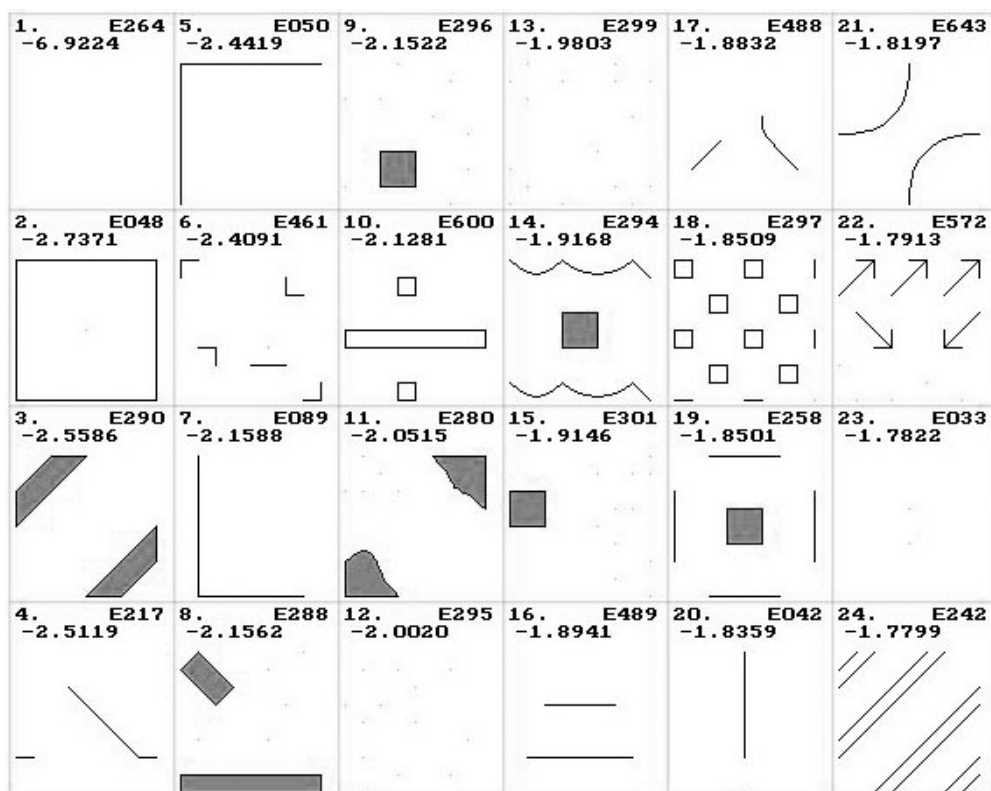
Slika 5.1.5.28. *Perzistencija* (2. razina, 1. takson); pozitivna strana - *Robusnost*



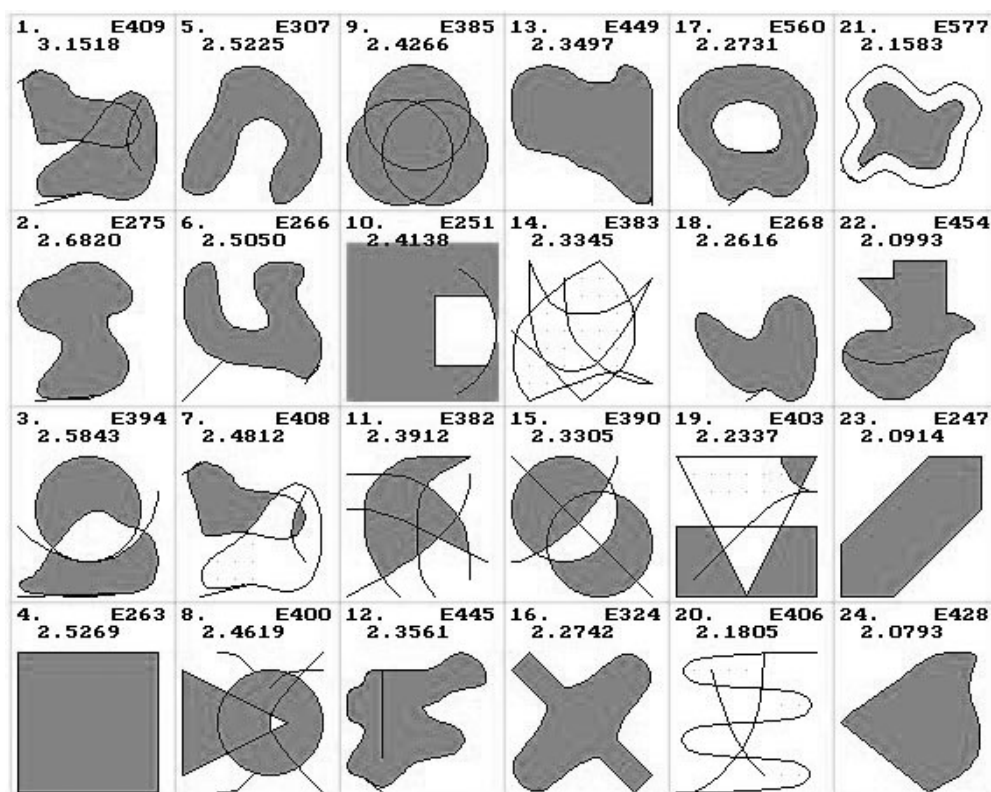
Slika 5.1.5.29. Upravlјivost (2. razina, 2. takson); negativna strana - Elementarnost




Slika 5.1.5.30. Upravlјivost (2. razina, 2. takson); pozitivna strana - Sustavnost




Slika 5.1.5.31. *Upravlјivost* (2. razina, 2. takson); negativna strana - *Elementarnost*



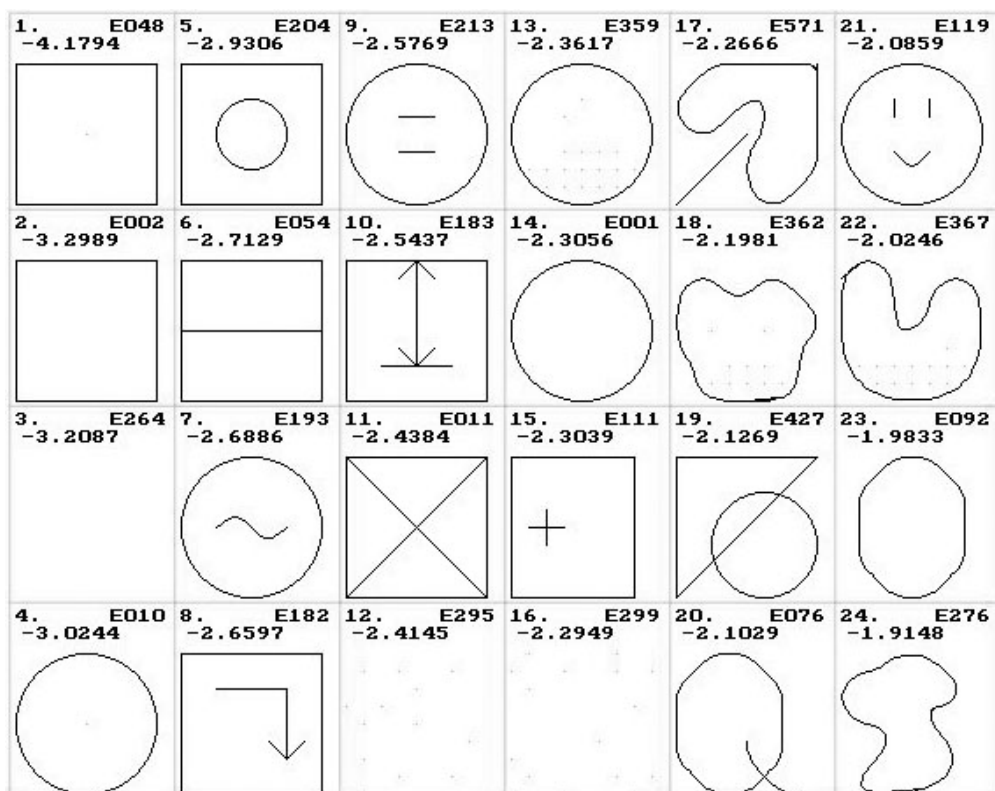
Slika 5.1.5.32. *Upravlјivost* (2. razina, 2. takson); pozitivna strana - *Sustavnost*



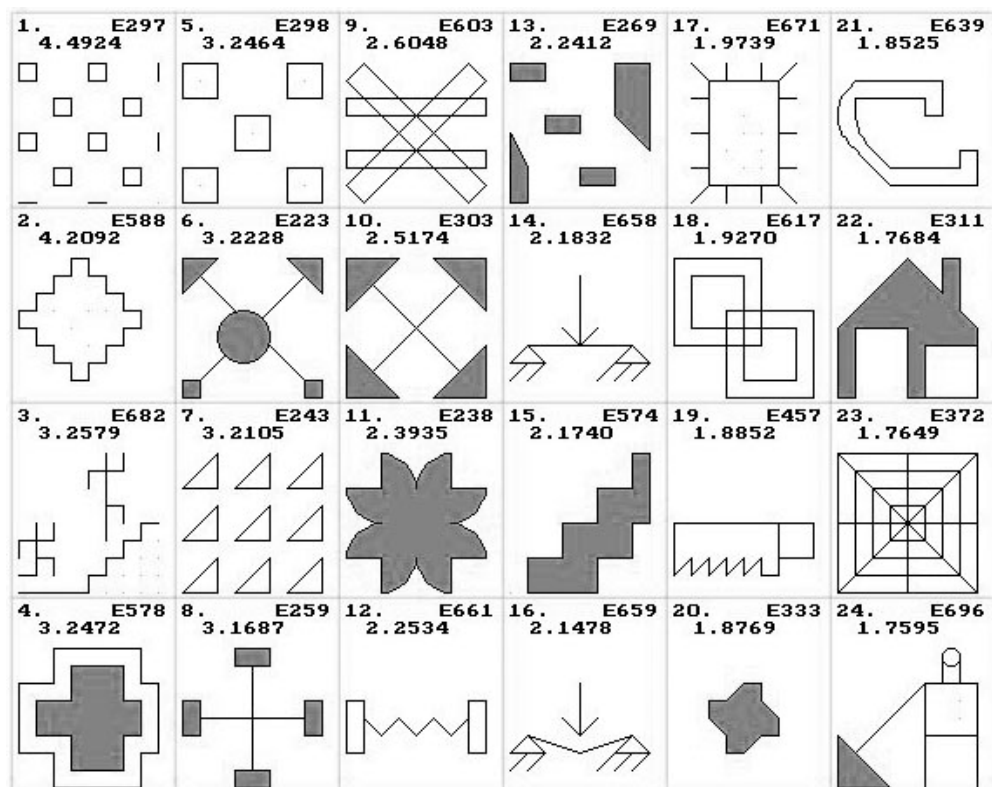
Slika 5.1.5.33. Edukatibilnost (2. razina, 3. takson); negativna strana - Površnost



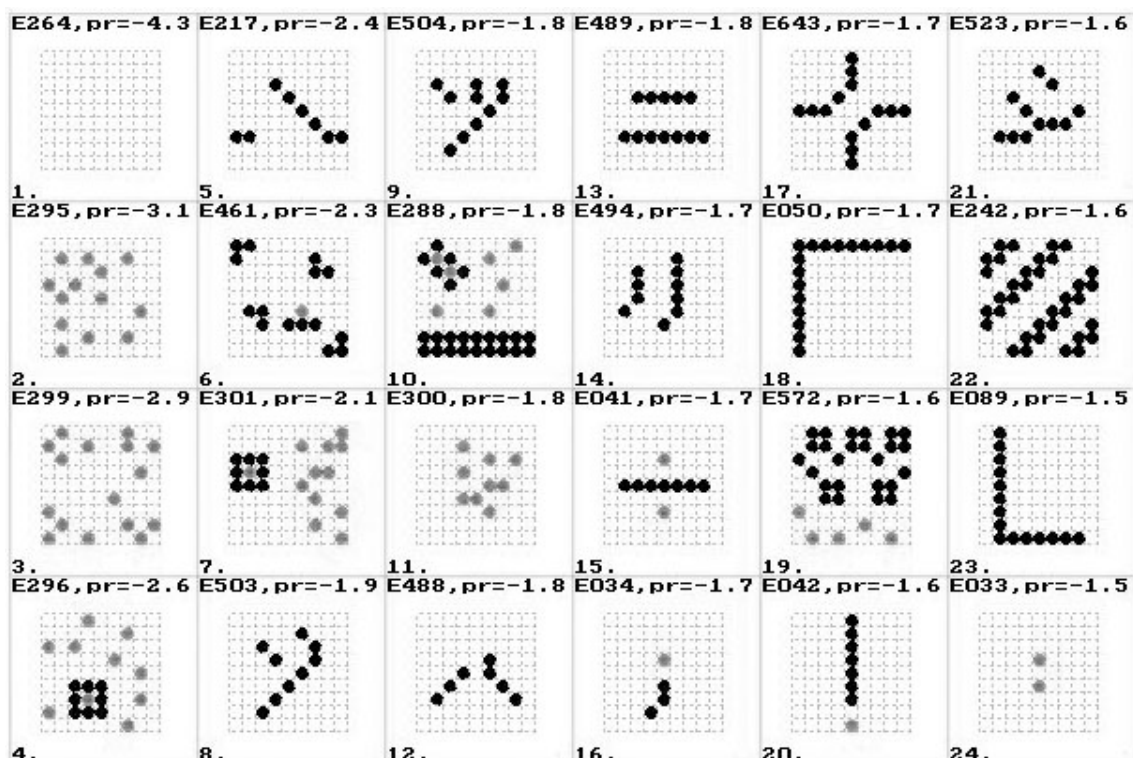
Slika 5.1.5.34. Edukatibilnost (2. razina, 3. takson); pozitivna strana - Sistematičnost



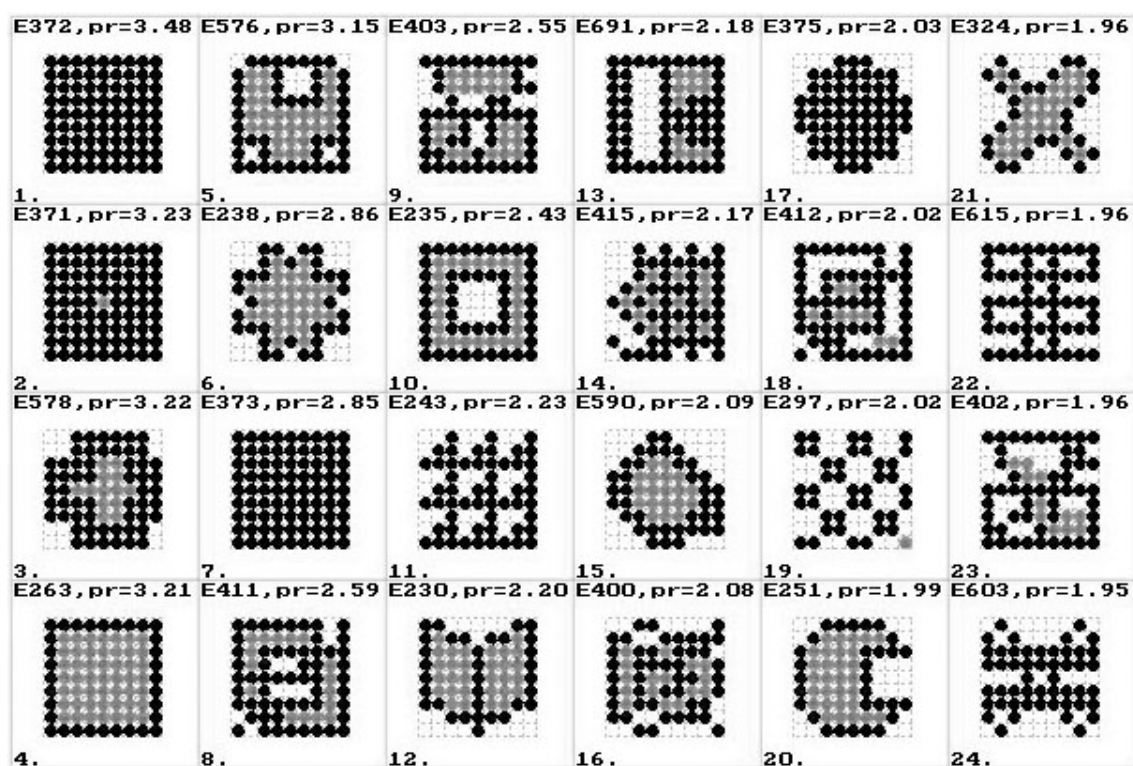
Slika 5.1.5.35. Edukatibilnost (2. razina, 3. takson); negativna strana - Površnost



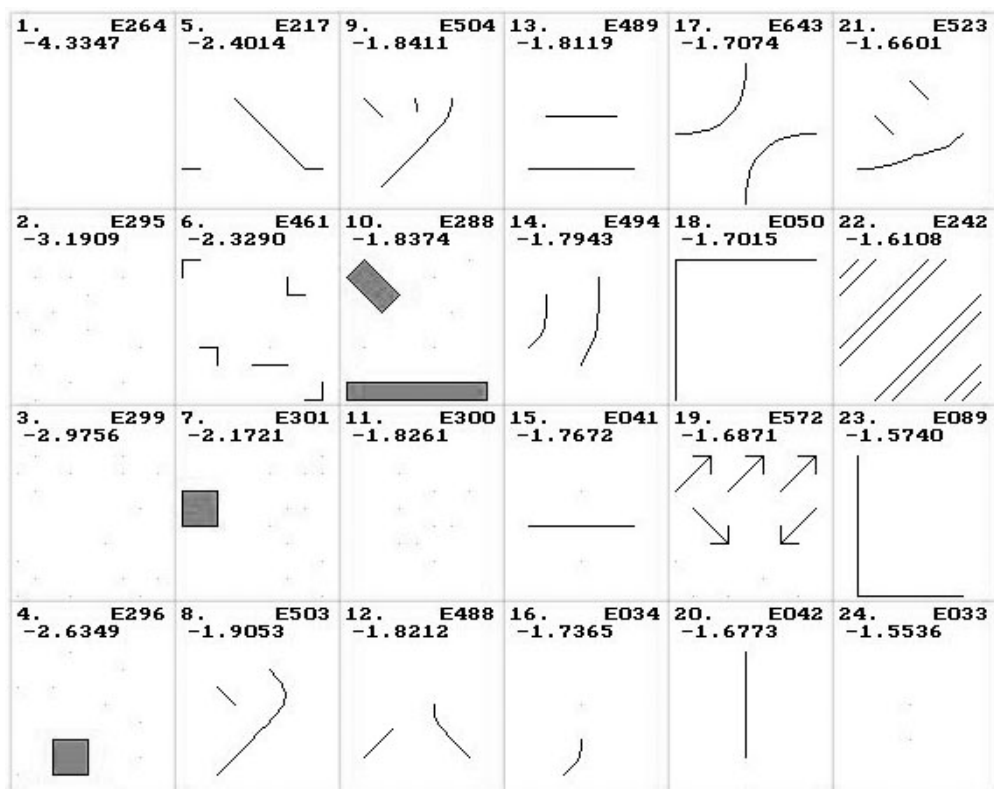
Slika 5.1.5.36. Edukatibilnost (2. razina, 3. takson); pozitivna strana - Sistematičnost




Slika 5.1.5.37. *Determinizam (3. raz., 1. tax.); neg. str. – Dezintegracija (neodredenost)*




Slika 5.1.5.38. *Determinizam (3. razina, 1. tax.); poz. strana – Integracija (odredenost)*




Slika 5.1.5.39. **Determinizam** (3. raz., 1. tax.); neg. str. – **Dezintegracija** (neodredenost)



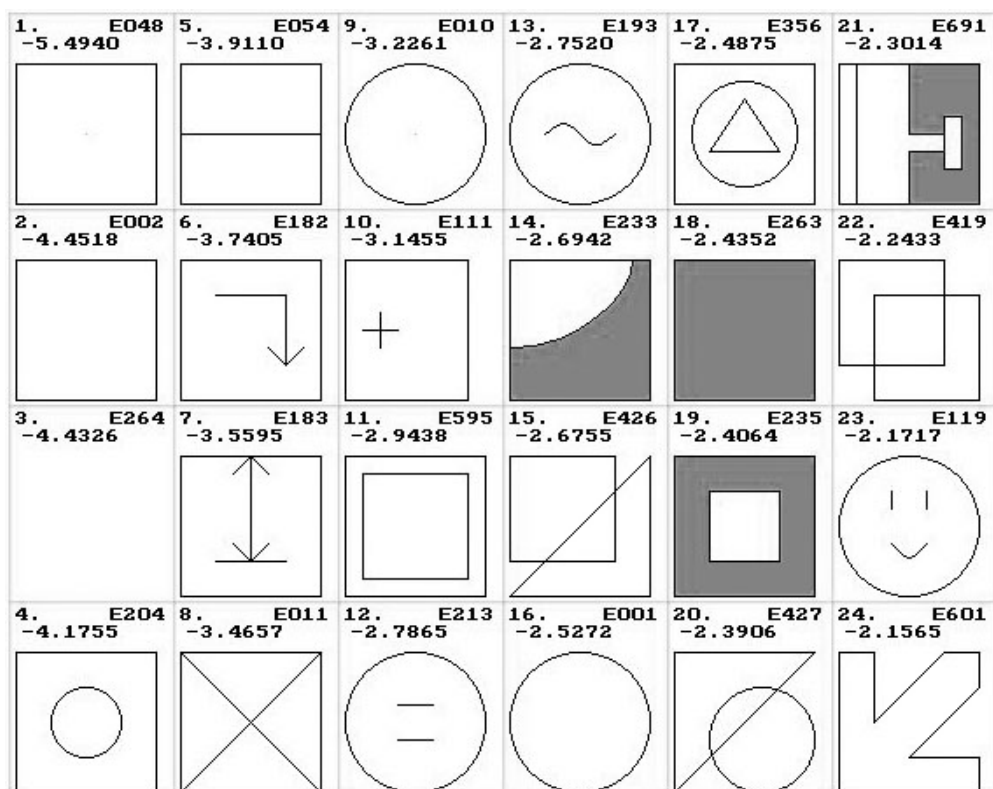
Slika 5.1.5.40. **Determinizam** (3. razina, 1. tax.); poz. strana – **Integracija** (odredenost)



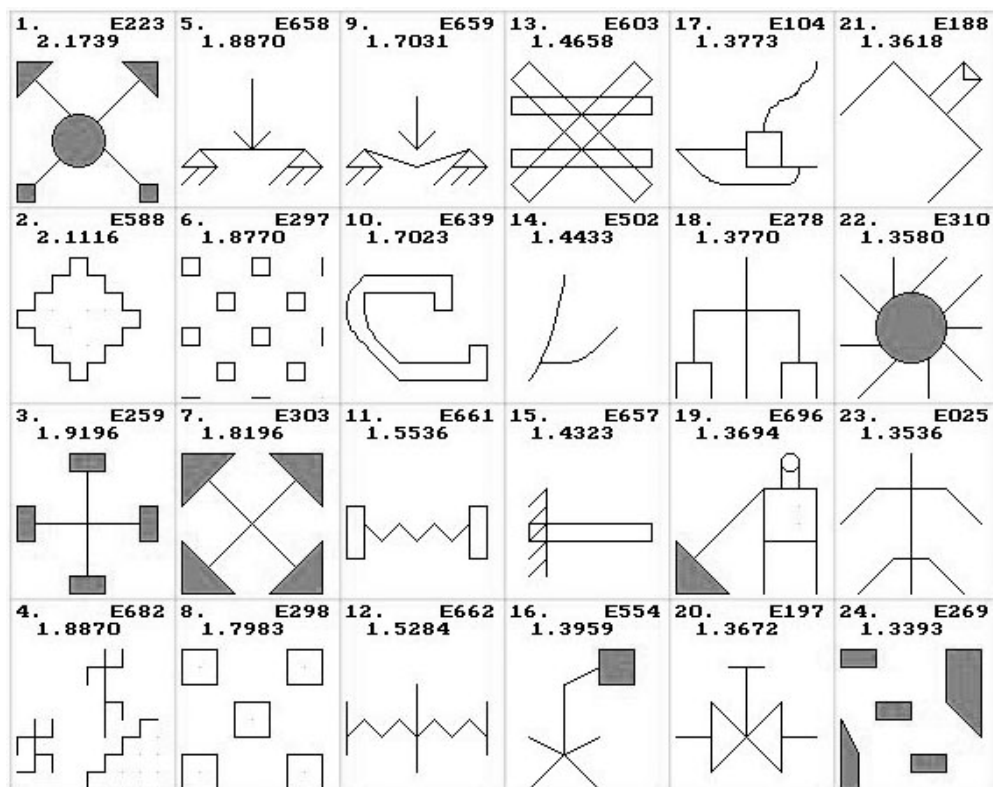
Slika 5.1.5.41. Razvoj (3. razina, 2. takson); negativna strana – Zasićen



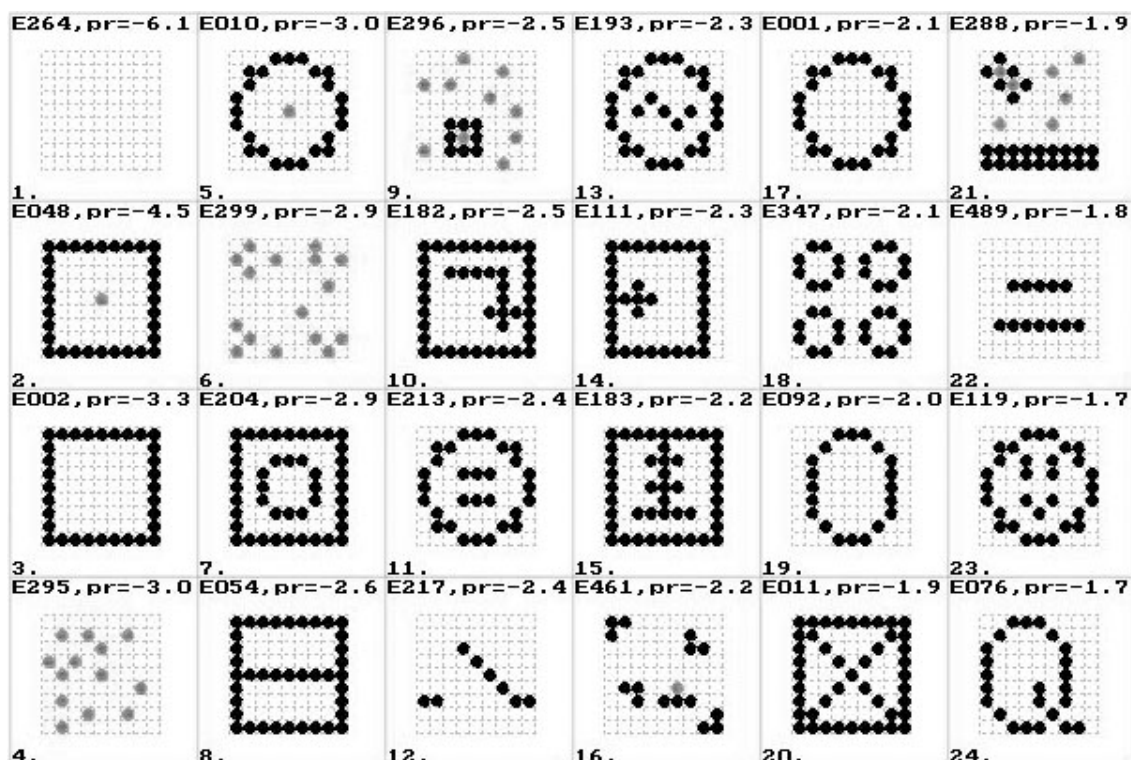
Slika 5.1.5.42. Razvoj (3. razina, 2. takson); pozitivna strana - Svestran




Slika 5.1.5.43. Razvoj (3. razina, 2. takson); negativna strana – Zasićen



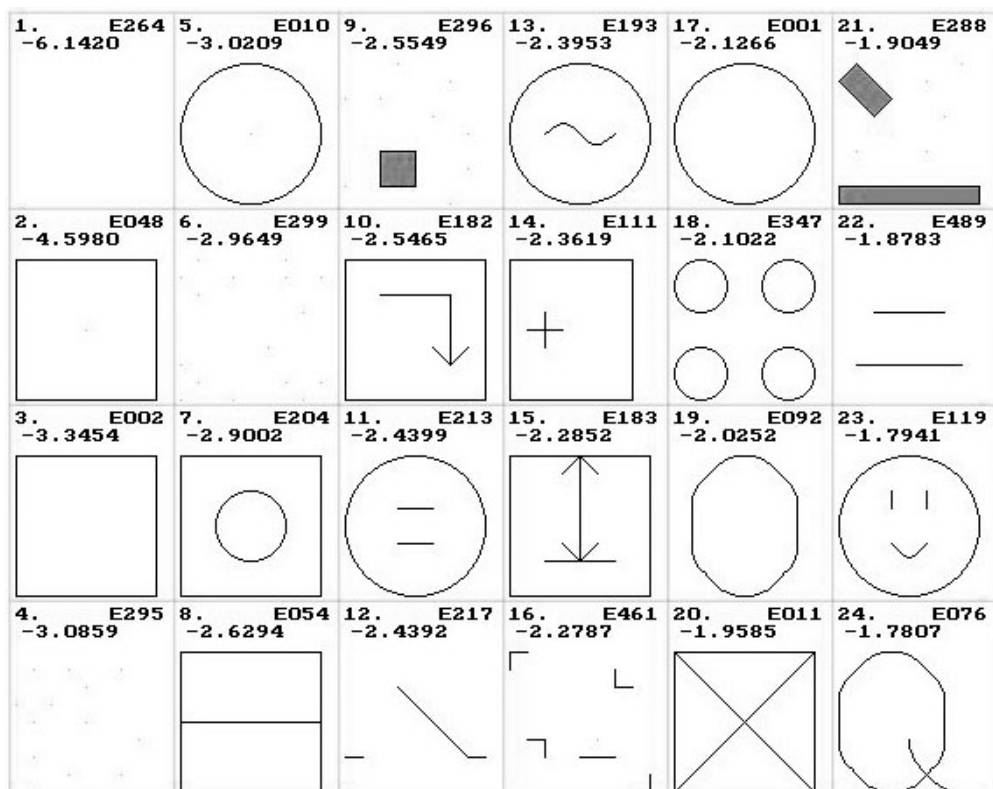
Slika 5.1.5.44. Razvoj (3. razina, 2. takson); pozitivna strana - Svestran



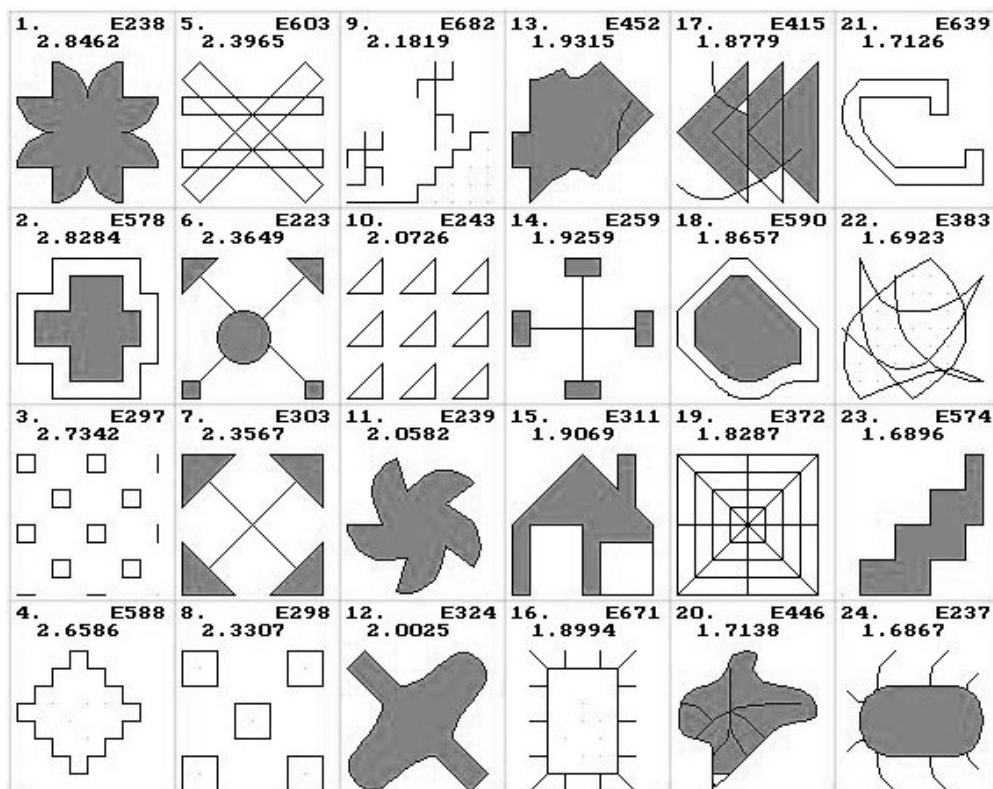
Slika 5.1.5.45. Spoznaja (4. razina, glavni takson); negativna strana - Parcijalna



Slika 5.1.5.46. Spoznaja (4. razina, glavni takson); pozitivna strana - Globalna



Slika 5.1.5.47. *Spoznaja* (4. razina, glavni takson); negativna strana - *Parcijalna*



Slika 5.1.5.48. *Spoznaja* (4. razina, glavni takson); pozitivna strana - *Globalna*

	Organiziranost	Stabilnost	Cjelovitost	Sklad	Ekspanzija	Komunikativnost
- pol	Jednostavnost	Varijabilnost	Kompaktnost	Fleksibilnost	Prostorna	Aktivnost
+ pol	Složenost	Postojanost	Raspršenost	Krutost	Materijalna	Pasivnost
BRPR	0.53	0.12	0.44	0.09	0.33	-0.38
XXXX	0.49	0.40	-0.42	-0.26	-0.22	0.12
BRSK	0.72	0.30	-0.15	0.13	-0.05	0.01
BRTO	0.66	0.41	-0.08	-0.10	0.30	0.11
JEDS	-0.93	0.35	0.05	0.06	0.04	0.15
REPR	-0.89	0.48	0.10	0.04	-0.04	0.11
NSET	-0.57	-0.56	-0.09	0.08	0.27	0.30
NSTO	-0.60	-0.52	-0.13	0.06	0.19	0.38
PRAV	-0.68	0.83	0.09	0.21	-0.07	-0.04
SIME	-0.47	0.89	0.12	0.28	0.00	-0.10
IMXV	0.36	0.04	0.84	-0.11	-0.19	0.39
IMNV	0.35	0.16	0.71	-0.16	-0.30	0.48
BREM	-0.03	-0.26	0.68	0.12	0.12	-0.44
BRSP	0.46	-0.01	-0.13	0.75	0.09	0.23
BRLU	0.51	0.00	-0.06	0.77	0.05	0.18
BRVR	0.12	0.38	-0.03	-0.40	0.74	0.15
BREL	0.46	0.39	-0.16	-0.13	0.55	0.17
ZAPO	0.30	0.19	-0.31	-0.14	-0.80	0.01
%VAR	30.8 %	18.2 %	12.6 %	9.1 %	11.1 %	6.4 %

Tablica 5.1.5.1. – Projekcija varijabli na taksone 1. razine

	Perzistencija	Upravljivost	Edukatibilnost	Determinizam	Razvoj	Spoznaja
BRPR	-0,09	0,44	0,32	0,33	0,37	0,49
XXXX	0,78	0,51	-0,34	0,70	-0,64	0,04
BRSK	0,69	0,49	0,10	0,77	-0,22	0,38
BRTO	0,67	0,68	0,10	0,87	-0,20	0,47
JEDS	-0,10	-0,54	-0,13	-0,45	-0,12	-0,40
REPR	-0,03	-0,53	-0,21	-0,42	-0,22	-0,45
NSET	-0,51	-0,45	0,25	-0,53	0,43	-0,07
NSTO	-0,43	-0,50	0,17	-0,54	0,32	-0,16
PRAV	0,33	-0,32	-0,13	-0,05	-0,31	-0,26
SIME	0,43	-0,16	-0,02	0,15	-0,26	-0,08
IMXV	-0,02	-0,41	-0,34	-0,38	-0,32	-0,49
IMNV	0,17	-0,41	-0,48	-0,30	-0,53	-0,59
BREM	-0,77	-0,19	0,20	-0,53	0,55	0,02
BRSP	0,58	0,01	0,67	0,54	0,27	0,57
BRLU	0,56	0,00	0,66	0,53	0,27	0,55
BRVR	0,25	0,65	0,08	0,60	0,01	0,43
BREL	0,59	0,72	0,22	0,89	-0,05	0,59
ZAPO	0,51	-0,02	-0,60	0,12	-0,77	-0,46
Organiziranost	0,47	0,58	0,11	0,69	-0,09	0,42
Stabilnost	0,78	0,26	-0,21	0,57	-0,55	0,02
Cjelovitost	-0,50	-0,47	-0,13	-0,65	0,10	-0,38
Sklad	0,26	-0,35	0,78	0,15	0,48	0,44
Ekspanzija	-0,12	0,54	0,65	0,47	0,66	0,80
Komunikativnost	0,53	-0,44	-0,15	-0,02	-0,45	-0,33
Perzistencija	1,00	0,12	-0,01	0,68	-0,51	0,12
Upravljivost	0,12	1,00	0,09	0,76	0,12	0,62
Edukatibilnost	-0,01	0,09	1,00	0,35	0,86	0,84
Determinizam	0,68	0,76	0,35	1,00	0,02	0,71
Razvoj	-0,51	0,12	0,86	0,02	1,00	0,71
Spoznaja	0,12	0,62	0,64	0,71	0,71	1,00

Tablica 5.1.5.2. – Relacije svih varijabli i taksona

5. 2. PROCESI SPOZNAJE

U uvodnom dijelu rada poglavlje 2.7. *Temeljni pojmovi* naglašeno je da je prostor egzistencije reprezentativnog broja entiteta identičan prostoru egzistencije dinamičkog ponašanja jednog entiteta. Ako ovu spoznaju preslikamo na ovaj primjer to znači da se proučavane entitete može shvatiti kao **700 različitih entiteta**, ali i kao **jedan jedini entitet** koji **globalno** gledano **napreduje od minimalne** (totalno parcijalne) **do maksimalne** (totalno globalne) **spoznaje**.

Dakle ako su sa 700 entiteta predstavljene **sve bitne** varijacije entiteta tada bilo koji entitet koji „uđe“ u ovako definiran prostor ne može doći u neko „novo“ već neopisano stanje. Ova spoznaja je izuzetno važna jer nam omogućava „zanemarivanje“ vremena kao bitne varijable te uvođenje zadnjeg taksona *spoznajne* kao glavnog mjerila.

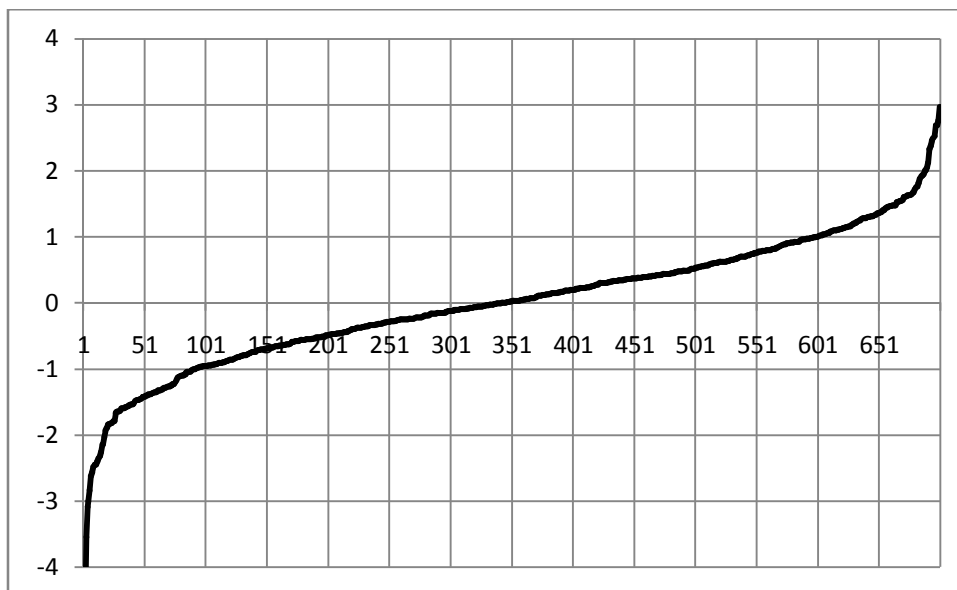
Primjer spoznajnog mjerila (skale) imamo npr. u školi. Nije relevantno (iako nije nevažno, baš naprotiv !) vrijeme provedeno u školi ili za knjigom već znanje iz konkretnog predmeta. Tamo se prati napredovanje učenika, pomaže mu se u učenju i to na kraju predstavlja ocjenu iz konkretnog predmeta. Dakle, u školi se mjeri znanje tj. spoznaja te se sa pozicije ovog rada koristi spoznajna mjera.

U predhodnom poglavlju uzeto je 700 različitih entiteta te su promatrani u stacionarnom stanju. Na početnoj razini njihove varijacije su objašnjene sa početnim skupom od 18 varijabli, na slijedećoj razini su opisani sa 6, nakon toga sa 3 zatim sa 2 da bi ih na kraju opisali sa samo jednom karakteristikom (*spoznajom*).

No, može se postaviti i drugačiji zadatak: promatrati kako se jedan jedini entitet mijenja ako „putuje“ npr. po glavnom taksonu, dakle po *spoznaji*. On će pri tome proći sve razvojne faze od *parcijalne* do *globalne spoznaje*. Ovo znači da se na ovaj način ustvari prati **proces** promjene spoznaje entiteta. No ako se mijenja spoznaja entiteta tada se nužno mijenja i entitet sam, što znači da se ovim postupkom promatra i **proces** mijenjanja entiteta. Može se zaključiti da su entitet sam i njegova spoznaja usko vezani, moglo bi se reći da su gotovo istoznačnice, samo iskazane drugačijom mjerom.

Kako će se dobiti sve razvojne faze entiteta ? Pa jednostavno na način da ih poredamo sukladno stupnju spoznaje, dakle po projekcijama na zadnji *spoznajni* takson. No, ovo je već jednim dijelom urađeno kada se vršila identifikacija glavnog taksona (*slike 5.1.5.45. - 5.1.5.48.*). Kako se vidi na razini crteža nije baš očito kako je entitet prešao iz jednog u drugo stanje, ali jest sigurno da se je promijenio, te kada bi se pogledali sve slike sortiranih entiteta napredak bi zasigurno bio očit ! Uočimo još da sada imamo model (taksone i njihove relacije) te lako možemo reproducirati bilo koji entitet na željenim razinama.

Na *slici 5.2.1.* prikazane su sortirane Z – vrijednosti taksona spoznaje, dakle prikazana je mjera spoznaje svih proučavanih entiteta. S obzirom da će se proučavati jedan entitet, na osi apcisa prikazana su (reprezentativna) stanja u kojima će se entitet nalaziti, dok je na osi ordinata prikazana njegova *spoznaja* u svakom pojedinom stanju. Može se reći da je *spoznaja* funkcija stanja entiteta. No iz slike je vidljivo da vrijedi i obrnuto, pa je tako iz poznate spoznaje moguće odrediti stanje entiteta.



Slika 5.2.1. – Sortirani glavni takson

Putujući taksonom spoznaje postavlja se pitanje kako se mijenjaju ostali opisi entiteta. Npr. jako interesantno pitanje je kolika je perzistencija entiteta na početku u sredini te na kraju taksona spoznaje. Dakle interesantno pitanje je kako se mijenja npr. *perzistencija* entiteta duž *spoznaje* tj. zanima nas $perzistencija = f(spoznaje)$. Na 2. razini definirani su i *upravljivost*, te *edukabilnost*. Korisno bi bilo znati i ove ovisnosti, je li kontinuirano rastu, padaju, koji su međusobni odnosi i sl. Već od prije (*tablica 5.1.5.2.*) je poznato da taksoni nisu neovisni te će ove povezanosti zasigurno biti multivarijabilne.

Napomenimo još da se entitet ne mora kretati isključivo u pozitivnom smjeru *spoznaje*, već se može kretati i u negativnom smjeru. Pod negativnim smjerom podrazumjeva se kretanje entiteta od *globalne* prema *parcijalnoj spoznaji*. U ovom slučaju entitet ima sve manje spoznaje, pa se logično zaključuje da je riječ o **destruktivnom procesu**. Suprotno od toga kada entitet napreduje po spoznaji govorimo o **konstruktivnom procesu**.

Entitet može biti podvrgnut konstruktivnom procesu na način da sa nekim drugim entitetom teži uspostavljanju neke nove zajedničke funkcije. U tom slučaju entitet napreduje po spoznajnoj skali te se u krajnjem slučaju formira nadentitet (*slika 5.2.2.*).

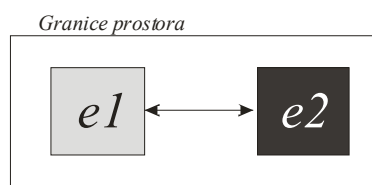
U suprotnom slučaju, prilikom destruktivnih procesa entitet je podvrgnut djelovanjima drugih entiteta iz okruženja sa kojima ne može uspostaviti relacije. Ako su ta djelovanja toliko snažna da se entitet njima ne može oduprijeti dolazi do destrukcije entiteta te njegovog pretvaranja u „građevni materijal“ za druge entitete. (*slika 5.2.3.*)

Konstruktivni i destruktivni procesi u području kineziologije prikazan je u [37], dok je model u općenitom obliku predstavljen u [28].

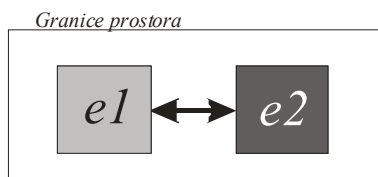
a) Dva entiteta u trenutku geneze



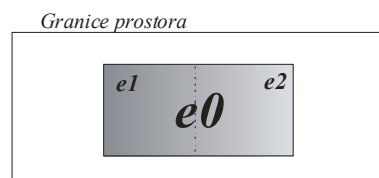
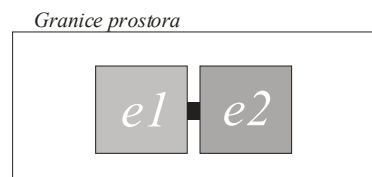
b) Dva entiteta u početnoj relaciji



c) Početak uzajamnog djelovanja i smanjenje razlike



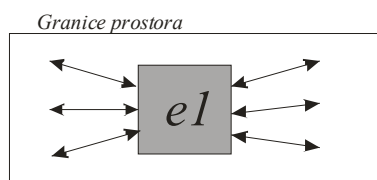
d) Maksimizacija uzajamnog djelovanja s još uvijek dva entiteta



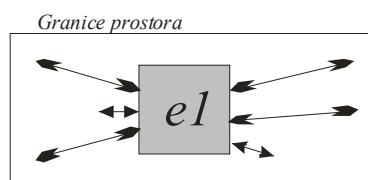
e) Novi entitet s fiktivnim elementima

Slika 5.2.2. – Konstruktivni procesi

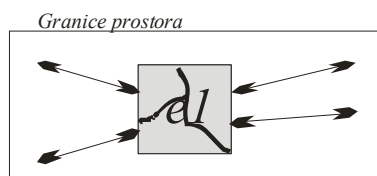
a) Entitet i djelovanja iz okruženja



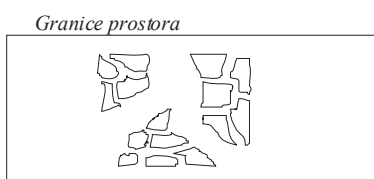
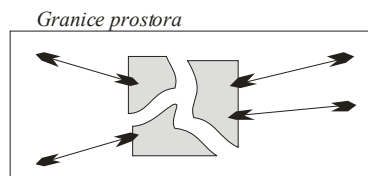
b) Entitet i neka iznimno snažna djelovanja iz okoline



c) Djelovanja koja uvjetuju popuštanje interne konzistencije entiteta



d) Raspad entiteta na dijelove



e) Nestanak entiteta u materijal za druge entitete

Slika 5.2.3. – Destruktivni procesi

6. OPĆA TEORIJA SPOZNAJE

6. 1. Temelji Opće teorije spoznaje – definicija

Krećući od osnovnih postavki rada (*poglavlje 2.*) odredio se prostor istraživanja te skup entiteta i varijabli. U *poglavlju 3.* temeljem provjerene metodologije izolirani su tipovi entiteta koji egzistiraju u proučavanom prostoru.

No, proučavani prostor je **Sve**, a ako se uzmu u obzir pretpostavke s kojima se započelo istraživanje, nameće se zaključak da su dobiveni **tipovi egzistentnih entiteta opći**, te stoga predstavljaju **zakovitosti**. Nadalje, ako su dobivene zakonitosti koje vrijede u **svemu**, tada to znači da će vrijediti i u prostorima koji proučavaju manje od svega – dakle svim ostalim prostorima. Pod uvjetom da su zakonitosti pravilno prepoznate one **vrijede uvijek – u svim vremenima i svim prostorima** ! To znači da su vrijedila i juče (samo ih „nismo znali napisati“), vrijede danas ali će vrijediti i u budućnosti. Ako se podsjetimo da je entitet definiran kao bilo koja registrabilna pojava tada se zaključuje da Opća teorija spoznaje vrijedi za **bilo koji entitet, dakako u svim vremenima i u svim prostorima.**

Ona naravno, mogu biti nadopunjena novima, npr. ako se krene od većeg broja početnih varijabli, ali **ovdje dobivena pravila ponovno će se reproducirati kada se dođe do razina koje je proučavao ovaj rad.** Slično, ako početni prostor reduciramo npr. na peterodimenzionalan tada se zasigurno neće dobiti 1 razina ovog rada gdje je dobiveno 6 zakonitosti, ali ako se krene od znatno većeg broja parametara među njima će biti i ona dobivena u ovom radu.

Kako je generalno, glavno pravilo upravo spoznaja to je cijela teorija nazvana *Opća teorija spoznaje*.

No, kako glasi, tj **kako se Opća teorija spoznaje definira** ?

1. **Postoje opće zakonitosti koje važe uvijek i svugdje,**
2. **Generalna zakonitost jest spoznaja,**
3. **Postoje hijerarhijski niže rangirane, međuovisne spoznaje.**

Iako izgleda kao aksiomatski sustav, on to nipošto nije, što je vidljivo iz dosadašnjeg izlaganja. Uostalom osma hipoteza rada ostavlja maksimalnu slobodu za provjeru valjanosti Opće teorije spoznaje.

Ako **Opću spoznajnu teoriju definiramo sa pozicije entiteta** može se izreći slijedeća definicija (koja je analogna predhodnoj):

1. **Postoje entiteti koji su kreirani po općim zakonitostima,**
2. **Cilj svakog entiteta jest maksimalna spoznaja,**
3. **Entitet je strukturiran međuovisnim hijerarhijskim razinama.**

Također, ako gledamo sa pozicije entiteta tada je njegov **cilj spoznati sve**. Gledano sa pozicije spoznaje entiteti nastaju isključivo iz razloga da bi se spoznaja „imala gdje smjestiti“ (*poglavlje 5.1.2.2*).

6. 2. Ostale prepoznate razine opće teorije spoznaje

U ovom radu su osim generalne razine pronađene i definirane još 3 hijerarhijski niže rangirane razine (tablice: 6.2.1.1., 6.2.2.1. i 6.2.3.1.). Brojevi u tablici predstavljaju korelacije.

6. 2. 1. Druga razina opće teorije spoznaje

Prva slijedeća 2. razina po općoj teoriji spoznaje (3. razina u radu) definirane su dvije zakonitosti (tablica 6.2.1.1.): *Determinizam* (– *dezintegracija*, + *integracija*) te *Razvoj* (– *zasićen*, + *svestran*). *Determinizam* nam govori nalazi li se entitet uopće u prostoru proučavanja tj. može li se s pozicije prostora proučavanja uopće prepoznati.

Ovo je elementarna informacija te nam govori o tome ima li naš proizvod (npr. regulator) uopće ikakvu prepoznatljivu funkciju (tj. ispunjava li ikako svrhu postojanja), te ako ima, pokazuje li opću kvalitetu funkcioniranja. Druga zakonitost nam govori o tome ima li entitet budućnost u promatranom prostoru, tj. ima li prilike za nadogradnju i usavršavanje unutar promatranog prostora te time mogućnosti unapređivanja kvalitete izvršenja onoga zbog čega je i proizveden.

Ove dvije karakteristike su gotovo neovisne, što se može objasniti na primjeru nekog prototipa koji jedva da može ispuniti ono što se od njega očekuje, ali samo iz te informacije teško možemo zaključiti o njegovom ukupnom potencijalu. Uzmimo još za primjer PID regulator ali proučavan u prostoru svih danas poznatih regulatora. On bi vjerojatno bio jako determiniran jer svoju funkciju obavlja kvalitetno ali bi isto tako bio razvojno zasićen iz jednostavnog razloga što je on svoj maksimum već dosegao te on sam za sebe nema daljnje mogućnosti razvoja.

– pol	Dezintegracija (neodređenost)	Zasićen
Takson	Determinizam	Razvoj
+ pol	Integracija (određenost)	Svestran
Determinizam	1.00	0.02
Razvoj	0.02	1.00

Tablica 6.2.1.1. – Taksoni 3. razine – 2. razina u općoj teoriji spoznaje (OTS)

Iz tablice 5.1.5.2. vidi se da je *Determinizam* nastao dominantno pod utjecajem *Perzistencije* i *Upravljivosti* sa predhodne razine. Ovo se poklapa sa predhodnom tvrdnjom da se *sustavnošću* vrši interna reorganizacija koja na slijedećoj razini zajedno sa perzistencijom definira koliko smo uopće uspjeli *determinirati* proizvod za funkciju kojoj je namijenjen. Ako je reorganizacija vršena sustavno biti će i veća determiniranost, dakle i proizvod će kvalitetnije obavljati željenu funkciju.

Iz iste tablice je vidljivo da je poželjna manja perzistencija za svestraniji razvoj, ovo vrlo vjerojatno iz razloga što ako imamo neki proizvod koji je *perzistentan* – *robustan* tada će ga u budućnosti teže moći promjeniti bez većih zahvata, što automatski znači da je vjerojatnije da će ostati kakav jest, dakle njegov razvoj će biti blokiran – *zasićen*.

U općem smislu ovdje se može prepoznati i **Teorija kaosa** koja je ovdje opisana kao negativna strana *determinizma – dezintegracija (neodređenost)*. Naime ukratko u Teoriji kaosa se kaže da nije moguće predvidjeti u kakvom će stanju biti neki sustav tj. sustav se ponaša nepredvidljivo, kaotično. Ovo se može opisati i na način da će sustav na dva ista ulaza dati različite izlaze. Dakako da je ova zadnja tvrdnja nemoguća, jer negira temeljnu logičku premisu da svaka posljedica ima nekakav uzrok. Očito se radi o tome da nam eksperiment jednostavno nije pod kontrolom.

U [38] se navodi primjer: "*Ako leptir zamahne krilima u Pekingu, on može uzrokovati uragan na Floridi. To ne znači da vjetar koji nastaje mahanjem leptirovih krila uzrokuje uragan, već da i mahanje leptirovih krila može promijeniti slijed događaja koji bi se zbilo da leptir nije mahao krilima (svi smo bitni). Također bi se moglo reći i kako će zamah leptirovih krila spriječiti pojavu uragana na Floridi. Kada bi uspjeli uvrstiti sve moguće utjecaje na početne uvjete, pokazalo bi se da i dalje ne bi mogli u potpunosti predvidjeti buduća zbivanja.*"

Ova tvrdnja je ekvivalentna tvrdnji „*Neka se na mostu čija je nosivost 1000 kN nalazi 10 kamiona svaki težine točno 100 kN, dakle most je operećen do točno krajnje granice. Ako na most sleti leptir, most će se srušiti.*“ I sada se iz ovoga izvlači zaključak da smo svi bitni dakle i leptir, jer točno, ako leptir ne sleti na most most se neće srušiti. No ovdje se postavlja pitanje: **tko to na mostu na kojem je 10 kamiona, svaki težine 100 kN (!) može uočiti leptira ???!** Očito samo neki biolog i to specijalist za leptire !

Kojeg uz to ni najmanje ne zanimaju ni kamioni ni njihova ogromna težina, a ponajmanje kako su tamo dospjeli !! Ovdje se dakle, iz uskog prostora „biologije“ pokušava objasniti sasvim drugo područje, te kada se u tome ne uspjeva, tada se zaključuje kako ponašanje sustava uopće nije predvidljivo !!!!!!!

Osim toga nadalje se tvrdi da „*Kada bi uspjeli uvrstiti sve moguće utjecaje na početne uvjete, pokazalo bi se da i dalje ne bi mogli u potpunosti predvidjeti buduća zbivanja*“. Ova tvrdnja ne dokazuje ništa drugo nego da nam eksperiment nije pod kontrolom, jer za iste početne uvjete, tada imamo različito ponašanje. To se u kibernetici (i automatici) zovu šumovi, koji očigledno mogu biti fatalni po konstrukciju, pa dakle ponovimo: **eksperiment nije pod kontrolom.**

Ovdje se ipak vrlo vjerojatno radi o tome da neki istraživač „biolog“ u stvarnosti proučava područje o kojem praktično ništa ne zna, dakle naišao je na neki novi problem kojeg ne zna objasniti. I tada umjesto da pokuša problemu prići „sa neke druge strane“, sa neke druge razine on problem praktično priglašava nerješivim. To ne znači da se ovdje tvrdi da je problem trivijalan, baš suprotno problem je istraživaču baš izuzetno složen jer o njemu očito vrlo malo (ništa) zna.

Sa pozicije teorije spoznaje to znači da niti otprilike nismo „pogodili“ prostor egzistencije problema kojeg proučavamo, te smo stoga debelo na negativnoj strani *Determinizma*. Također po spoznajnoj teoriji ovo znači da treba proglasiti da smo naišli na nešto nepoznato, te pokušati drugim pristupima odredi parametre (varijable) sa kojima se može opisati proučavani problem.

Jedan širi pristup Determinizmu i kaosu dan je u [34].

Naravno nikako ne treba isključiti mogućnost da je upravo teorija kaosa dobar put u istraživanjima novih, praktično potpuno nepoznatih područja, ali stoji neosporna činjenica da se o proučavanom problemu gotovo ništa ne zna, te stoga tvrdnja da se sustav ponaša kaotično ne predstavlja ništa drugo nego **potvrdu o nepoznavanju proučavanog problema**. Samo to i ništa drugo !

6. 2. 2. Treća razina opće teorije spoznaje (2. razina u radu)

Ako smo predhodnu razinu uspješno savladali tj. ako nam je proizvod *determiniran* (ispunjava svoju osnovnu funkciju) dakle ne ponaša se kaotično, može se pristupiti slijedećoj razini koja je prikazana *tablicom 6.2.2.1.*

– pol	Osjetljivost	Elementarnost	Površnost
Takson	Perzistencija	Upravlјivost	Edukatibilnost
+ pol	Robusnost	Sustavnost	Sistematičnost
Perzistencija	1.00	0.12	-0.01
Upravlјivost	0.12	1.00	0.09
Edukatibilnost	-0.01	0.09	1.00

Tablica 6.2.2.1. – Taksoni 2. razine – 3. razina u općoj teoriji spoznaje

Može se primjetiti da je moguće da nam proizvod na predhodnoj razini ima i limitirani razvoj, svejedno to nije eliminacijski faktor. Iako ćemo vrlo vjerojatno debelo promisliti hoćemo li proizvoditi proizvod koji kasnije neće moći imati nove varijante, dakle poželjno je da naš proizvod ima mogućnosti *svestranog razvoja*.

Prvo pravilo, *perzistencija* sa svojim polovima *robustnost* i *osjetljivost* može se gotovo u potpunosti poistovjetiti sa pojmovima *robustnost* i *osjetljivost* koji se koriste u klasičnoj automatici. Razlika je u tome što se ovdje kod osjetljivosti daje više naglasak na osjetljivost za druge etitete u okolini a ne kao utjecaj nepozantih utjecaja na objekt (npr. starenje).

Slijedeći pojam *upravlјivost* već je komentiran u *poglavljju 5.1.2.2. (Upravlјivost)*. Zamislimo ovdje primjer kuće koju je potrebno grijati. Najelementarniji pristup jest uključeno grijanje bez povratne veze – upravljanje. Složeniji slučaj je regulacija, dakle uvodi se povratna veza. Sa pozicije kibernetike imamo sustav u okolini koji je izložen smetnjama te smo uveli povratnu vezu da te smetnje eliminiramo. Primjer smetnje je npr. promjena vanjske temperature ili slučaj kada je netko ostavio otvoren prozor.

Podsjetimo se, u *poglavljju 5.2. (Procesi spoznaje)* objekt napreduje od *parcijalne* do *globalne spoznaje*, dakle razvija se. Također (*poglavljju 5.1.2.2. Upravlјivost*) u teoriji spoznaje središte proučavanja je fokusirano na objekt. Ovo u navedenom primjeru znači da će grijanje zgrade napredovati strukturno.

Lako možemo zamisliti slijedeći scenarij: Najprije će se spoznati da je nepredviđeno paljenje peći uzokovano otvaranjem prozora, a otvaranje prozora npr. ponešto punačijim čovjekom kome je prevruće. Slijedeći korak će biti ugradnja promjenjivog termostata. No nakon nekog vremena problem prozora će se ponovno javiti zbog presuhog zraka. A zatim i problem hlađenja.

No, tada se neće npr. posebno ugrađivati ovlaživač zraka, a posebno klima za svaku prostoriju, već će se prozori jednostavno eliminirati i ugraditi kompletno postrojenje za kondicioniranje zraka.

Sa pozicije *opće teorije spoznaje* rekli bi : **zgrada je spoznajno napredovala !**

Isto tako zadnje spomenute promjene učinjene su zbog zgrade same, jer postojeći način nije bio isplativ tj. postao je prekompliciran, te je zbog sposobnosti *sustavne upravljivosti* zgrade, zgradna sustavno i promjenjena.

Ponovimo, sa pozicije *opće teorije spoznaje* nevažno je tko je taj napredak omogućio; neosporno su u zgradu ugrađena nova znanja tj. spoznaje. Kako su spoznaje ugrađene u zgradu, samo se logično zaključuje – zgrada je *spoznajno* napredovala.

Još jedan argument: može se primjetiti da smo mi ljudi, kao entiteti ustvari integrirani tj. na određen način podređeni interesima entiteta moderne zgrade. Ako dvojite u rečeno otidite u jednu od njih i – probajte otvoriti prozor !

U kibernetici / automatskoj regulaciji jedno od temeljnih polazišta jest adaptacija na promjene u okolini i/ili sustavu **što uopće nije registritabilno na spoznaji** i to iz jednostavnog razloga jer se opisano djelovanje svodi na održavanje postojećeg stanja. No, ako se održava postojeće stanje to znači da cijela (klasična) automatska regulacija ali i **kibernetika** pripada pod takson **perzistencija**. Isto tako ako se održava postojeće stanje to tada znači da entitet spoznajno ne napreduje te ostaje na istoj točki na spoznajnom taksonu. Naravno, u slučaju da ne postoji automatska regulacija tada ne bi bila održana perzistencija entiteta što bi u konačnici dovelo do promjene položaja entiteta na *spoznaji* (dakako u negativnom smjeru).

Kod živih organizama postoji spoznajno napredovanje / nazadovanje jedinke ali i u okviru vrste. Kod tehničkih sustava dominantno je napredovanje „unutar vrste“, što ne znači da će to tako ostati jer već danas moderni sustavi vođenja imaju, doduše ograničene mogućnosti učenja.

Konstatirajmo da se u kibernetici inzistira na adaptaciji u okolinu, dok se u Općoj teoriji spoznaje u fokus stavlja promjena spoznaje entiteta.

No, ako se prati napredovanje više entiteta (u ovom radu to se neće raditi), tada je naglasak na oba entiteta ali i na interakciju tih dvaju (ili više) entiteta.

U prethodnom primjeru to bi značilo da neće jedino polazište biti samo potreba zgrade kao entiteta već da će se (ponovno) uzeti u obzir i čovjek. Drugim riječima autor živi u nadi da će biti moguće ponovno otvoriti prozor !

Na ovoj razini ostao je još takson *Edukatibilnost* sa negativnom stranom *površnost* i pozitivnom *sistematičnost*. Ovdje se radi o mogućnostima razvoja entiteta. Ovo bi značilo da bi prilikom projektiranja entiteta trebali ostaviti mogućnosti nadogradnje entiteta nakon što bude završen na proizvodnoj liniji. Ovo se često postiže mogućnostima modularne gradnje. *Edukatibilnost* je najočitija kod računala čija je edukatibilnost u odnosu na ostale tehničke uređaje vjerojatno daleko najveća. Jednostavnom ugradnjom dodatnih djelova računalo se može unaprijediti u željenom smjeru. Sa pozicije teorije spoznaje – računalo je spoznajno napredovalo !

6. 2. 3. Četvrta razina opće teorije spoznaje (1. razina u radu)

Iako su svi taksoni pravilno prepoznati, na ovoj razini nije se nedvosmisleno mogla pronaći veza pravila i primjera koji bi ih se do kraja opisalo. Umjesto toga biti će predložen najbolji pronađeni model. O ovome se raspravlja i u [27, 28].

U tablici 6.2.3.1. prikazana je šesta razina pravila.

- pol	Jednostavnost	Varijabilnost	Kompaktnost	Fleksibilnost	Prostorna	Aktivnost
Takson	Organiziranost	Stabilnost	Cjelovitost	Sklad	Ekspanzija	Komunikativ
+ pol	Složenost	Postojanost	Raspršenost	Krutost	Materijalna	Pasivnost
Organizir.	1.00	0.29	-0.13	0.02	0.15	0.00
Stabilnost	0.29	1.00	-0.26	0.03	-0.10	0.14
Cjelovitost	-0.13	-0.26	1.00	-0.01	-0.14	-0.04
Sklad	0.02	0.03	-0.01	1.00	0.07	0.03
Ekspanzija	0.15	-0.10	-0.14	0.07	1.00	-0.11
Komunika.	0.00	0.14	-0.04	-0.03	-0.11	1.00

Tablica 6.2.3.1. – Taksoni 1. razine – 4. razina u općoj teoriji spoznaje (OTS)

Na ovoj razini potrebno je još dublje proniknuti u pravila strukturiranja entiteta. Predlaže se sljedeće:

1. Senzor
2. Relacija
3. Model
4. Zakonitost
5. Ekspanzija (identificirani takson)
6. Sklad (identificirani takson)

Logično je za pretpostaviti da svaki entitet ima **senzore** (1). No senzorske informacije nisu nezavisne. Npr. neka neki robot ima mogućnost prihvata nekog predmeta. Tada može imati dvije senzorske informacije – veličinu predmeta (otvorenost prihvatnice robota) ali i silu potrebnu za držanje predmeta.

Kada robot bude analizirao ove podatke vjerojatno će uspostaviti pozitivnu vezu između otvorenosti prihvatnice i potrebne sile. Drugim riječima uspostavio je **relacije** (2) senzornih informacija.

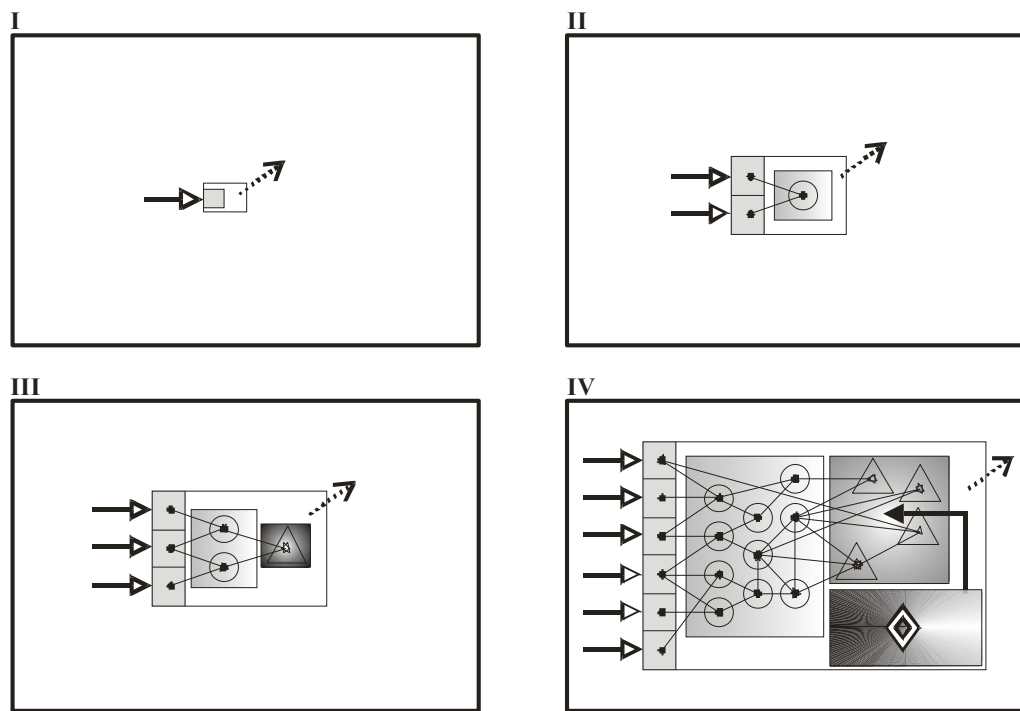
Ali kada npr. uhvati čovjeka, prethodno uspostavljena relacija ostati će očuvana, no vjerojatno će ustanoviti i da je potrebna dodatna kompenzacija silama za održavanje stabilnog položaja. Ovo iz jednostavnog razloga jer se čovjek može pomicati ruku, nogu, ... te time i mijenjati zajedničko težište.

Slijedeća razina bi bila uspostavljanje **modela** (3) fiksnih i pomičućih objekata.

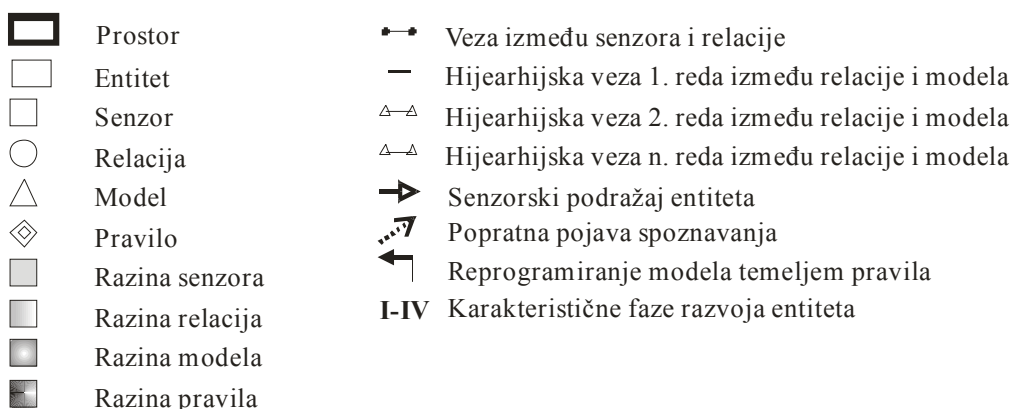
No isto tako, robot bi ujedno ustanovio da ljudi često ne dopuštaju da ih se diže i nosi naokolo. Istovremeno bi otkrio da tako nešto ne važi za predmete.

Time bi vjerojatno zaključio da načelno stvari treba prenesti a ljude načelno ne. Takav zaključak bi tada predstavljao **zakonitost** (4): ljudi ne dopuštaju da ih se bez razloga nosi, dok takav zaključak za stvari nije točan.

Iz svih dosadašnjih zaključaka mogao bi izvršiti **ekspanziju** (5) u prostor ljudi, tj. moglo bi ga se pustiti da slobodno bude u istom prostoru sa ljudima. Tada bi **skladno** (6) sa ljudima mogao raditi na nekim poslovima gdje je potreban prijenos stvari.



Legenda:



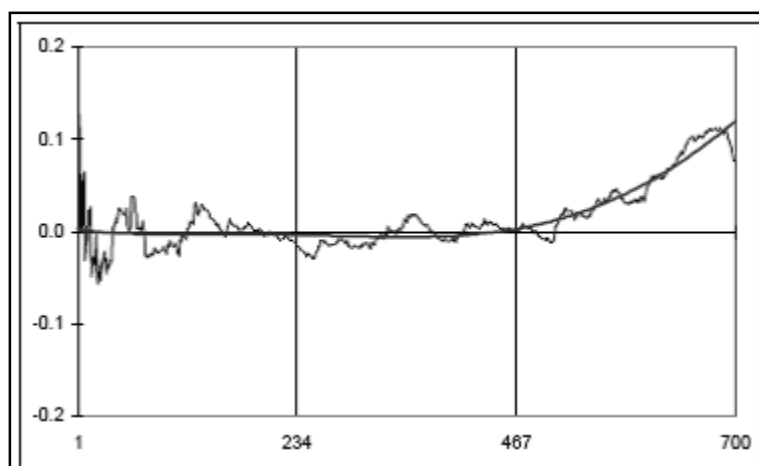
Slika 6.2.3.1. – Shema spoznavanja entiteta u prostoru njegove egzistencije

Hipotetski entitet i način njegovog spoznavanja predstavljen je slikom 6.2.3.1. U svim fazama razvoja (I - IV) je vidljivo da je širenje entiteta posljedica spoznavanja („popratna pojava spoznavanja“). Entitet se fizički širi u okolni prostor zahvaljujući nagomilanim spoznajama, dakle fizičko širenje je posljedica sve veće spoznaje entiteta. Također je vidljivo da su za uspostavu relacije potrebna barem dva senzora, za uspostavu modela barem dvije relacije a za uspostavu pravila barem dva modela. U IV fazi spoznavanja je prikazano i „reprogramiranje modela temeljem pravila“. Ovo predstavlja reorganizaciju vlastitih spoznaja u skladu s vlastitim potrebama. Reorganizacija se dešava na prikazanoj 4. razini, ali za nju je prvenstveno odgovoran mehanizam više razine koji je nazvan *sustavna upravljivost* (poglavlje 5.1.2.2.). Ovo znači da, gledajući sa ove 4. Razine, nisu potpuno jasni razlozi promjene. Za odgovor je potrebno proučiti odgovorni nadređeni mehanizam (*upravljivost*) koji se nalazi na višoj 3. razini.

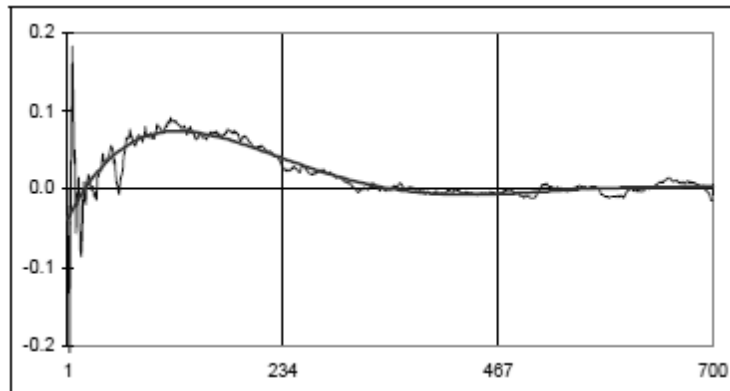
6. 3. Procesi na 4. razini opće teorije spoznaje

U poglavlju 5.2. (*Procesi spoznaje*) pokazano je da je moguće promatrati promjenu spoznaje jednog entiteta. Nažalost, nakon jednostavnog sortiranja podaci kojima je „putujući“ entitet opisan nisu baš sasvim jasni. Da bi bilo vidljivo što točno podaci predstavljaju primjenjen je modificirani *Indifg* algoritam [26]. Ovdje će ukratko biti opisani dobijeni podaci.

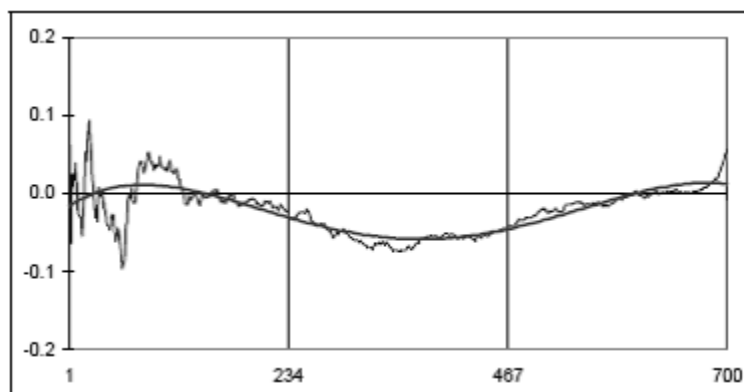
Nakon obrade podataka dobiveni su slijedeći rezultati: slike 6.3.1. – 6.3.7. Zbog lakše identifikacije podaci su dodatno aproksimirani polinomom 5. stupnja.



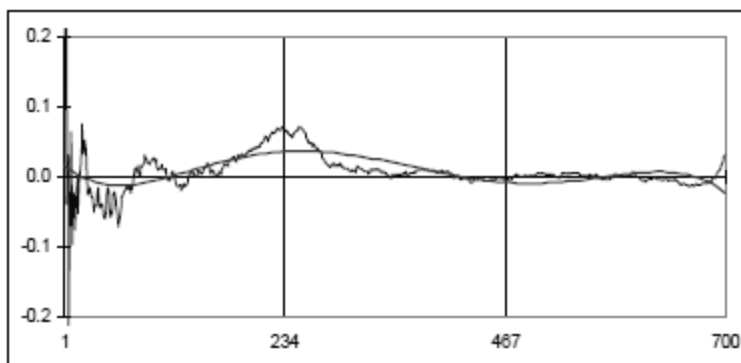
Slika 6.3.1. Komunikativnost (+ = pasivnost)



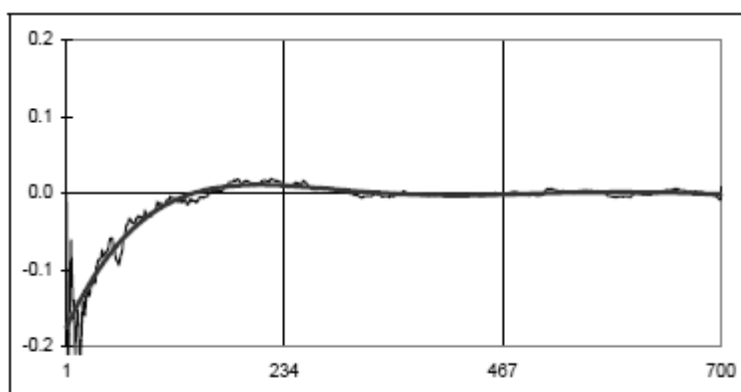
Slika 6.3.2. Ekspanzija (+ = materijalna)



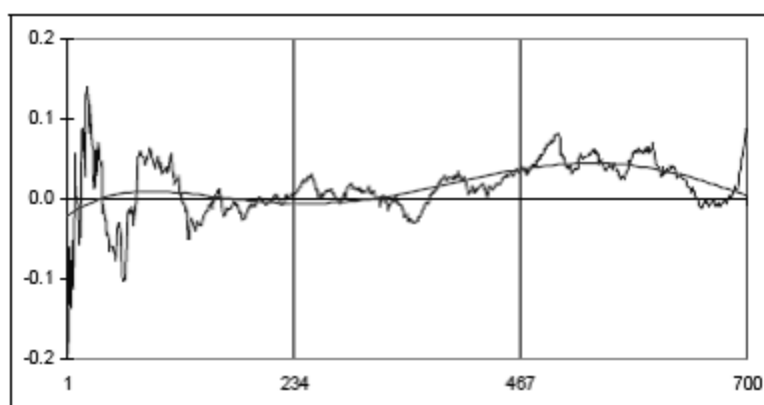
Slika 6.3.3. Organiziranost (- = jednostavnost)



Slika 6.3.4. Cjelovitost (+ = raspršenost)

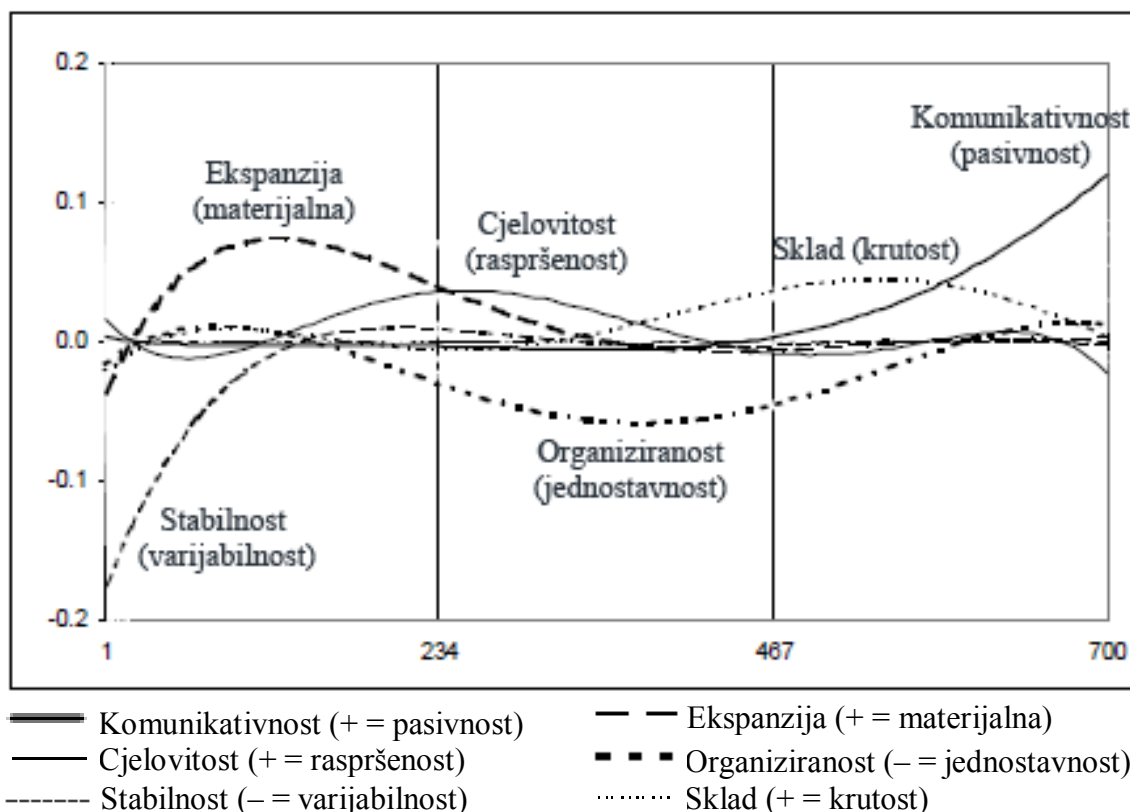


Slika 6.3.5. Stabilnost (- = varijabilnost)



Slika 6.3.6. Sklad (+ = krutost)

Na slici 6.3.7. prikazani su svi procesi zajedno. Vidljivo je da nema originalnih podataka (zbog lakše razumljivosti slike) već su samo predstavljene aproksimacije.



Slika 6.3.7. Procasi spoznaje – 1. razina (6 taksona)

Svaka krivulja predstavlja jedan takson. Na osi apcisa nalazi se svih 700 stanja entiteta dok je na osi ordinata intezitet procesa tj. intezitet svake pojedine karakteristike (taksona) u pojedinom stanju. Vidljivo je da svaki takson ima neko dominantno područje djelovanja. Ako se promotri slika može se identificirati što se sa entitetom događa:

Na samom početku procesa vidljiva jer izrazita *varijabilnost* entiteta što je vrlo vjerojatno uzrokovano „nesnalženjem“ entiteta u novom prostoru, spoznaja je minimalna pa entitet „luta“ po prostoru. Nakon nekog vremena *varijabilnost* kao dominantna karakteristika nestaje, a pojavljuje se *materijalna ekspanzija*. Može se reći da je entitet započeo sa „prikupljanjem“ spoznajnog „materijala“ te se širi u prostor. Vidljivo je i da je trajanje ova dva procesa oko 1/3 ukupnog procesa. Još prije 1/3 ukupnog procesa vidljivo je i simultano djelovanje *raspršenosti* što je vjerojatno uzrokovano naglim prikupljanjem znanja (poznato je da se u početku najbrže uči). Nakon ove faze, negdje oko 1/2 ukupnog procesa svoj maksimum postiže *organiziranost* i to *jednostavnost* koja vjerojatno govori o tome da se učenje velikim dijelom provodi usvajanjem jednostavnih znanja, koja se kasnije *skladno* i to *kruto* strukturiraju u entitet. Ovo bi značilo da se jednostavna znanja skladno i nedvosmisleno (kruto) usvajaju te kasnije predstavljaju kvalitetnu „bazu znanja“ entiteta. Na kraju dominira *pasivnost* u smislu komunikacije jer kako proces teče kraju sve manja i manja količina znanja „pristiže“ u entitet.

Ova i ostale razine spoznajnih procesa razine u prostoru ljudi, konkretno područje kineziologije prikazano je u [30, 32, 33, 35, 36, 37].

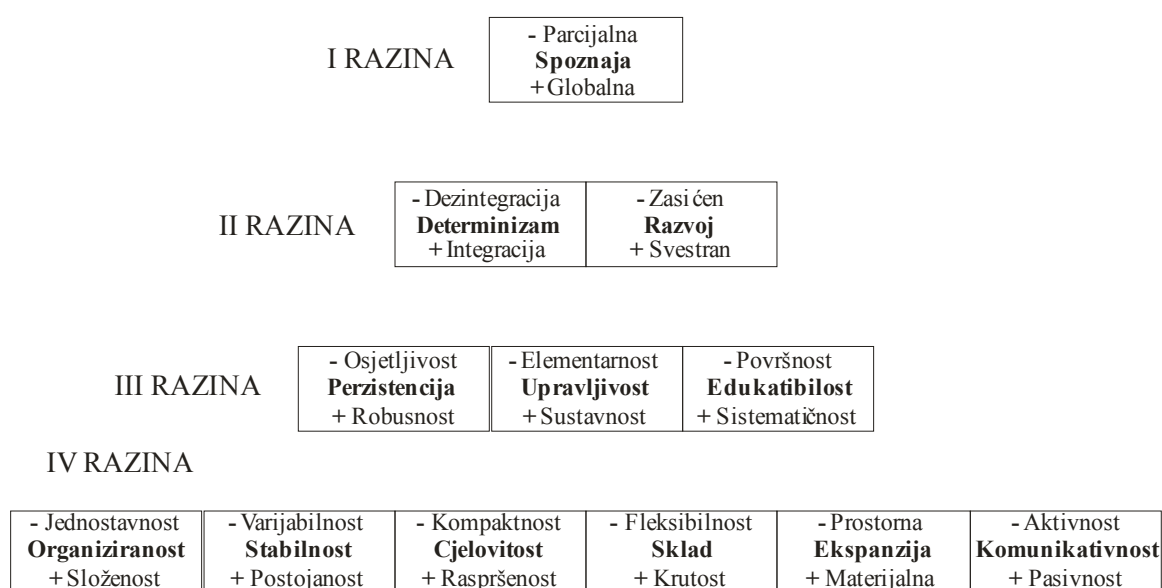
6. 4. Hijerarhija prepoznatih razina opće teorije spoznaje

Na slici 6.4.1. prikazani su svi dobijeni taksoni tj. njihova hijerarhija.

Može se primjetiti da se u prvom dijelu rada (*poglavlje 5.1.*) koristio pristup „bottom – up“, dok se je u *poglavlju 6.2.* koristio pristup „upside – down“.

U prvom dijelu vršena je identifikacija taksona tj. analizirali su se rezultati. Može se primjetiti da drugačiji pristup nije bio ni moguć; sa nižim razinama opisivane su više razine. No, ako se provede bilo koje istraživanje nužno je krenuti od dna iz jednostavnog razloga jer nisu poznate pojave i pravila – uostalom zato je i pokrenuto istraživanje.

Važi općenito: **kod istraživanja pristup je odozdo prema gore, od manifestnog prema latentnome.**



Slika 6.4.1. – Hijerarhija „spoznaja“ po općoj teoriji spoznaje

U drugom dijelu rada napravljen je obrnut pristup.

1. I razina. Što se želi ? Npr. želi se riješiti neki problem / projektirati neki proizvod.
 - a. Najprije smo ga u glavi „skicirali“, dobili nekakvu početnu ideju kako problem riješiti. Riješili smo možda neki glavni problem npr. princip funkcioniranja, ali su se s konkretnim rješenjem pojavili još i neki drugi problemi koje nismo odmah uočili. Drugim riječima imamo *parcijalnu spoznaju* rješenja problema
 - b. Nakon nekog vremena ideja se „izbistrila“, „usputne“ probleme smo rješavali te smo na kraju konačno upotpunili spoznaju kako riješiti problem. Imamo *globalnu spoznaju* kako riješiti problem
2. II Razina. Nakon toga smo odlučili kreirati (projektirati) entitet. Drugim riječima odlučili smo mu „udahnuti mu život“ tj. **prenijeti mu svoje spoznaje.**
 - a. Kakav on mora biti ? Osnovna karakteristika jest da **ispuni funkciju** koju smo mu namijenili dakle mora biti prepoznatljiv, *determiniran* u prostoru u kojem će egzistirati. No nemojmo se prevariti, ovo nije ujedno i njegov teleološki cilj. Njegov **teleološki cilj će uvijek biti spoznaja !** Mi mu „samo“ dajemo početni impuls !

- b. Druga karakteristika ove razine govori o potrebi ostavljanja mogućnosti *svestranog razvoja*. Ako to nije moguće sa konkretnim entitetom, onda ga treba projektirati na način da se ostavi mogućnost „lakog“ preprojektiranja za nove funkcionalnosti ili poboljšanja koje će uslijediti u novim varijantama.
3. III Razina. Sada treba naći načina da entitet:
 - a. Bude *perzistentan*, tj. da može stupiti u realan svijet a da ima sačuvano svoje ja, dakle da obavlja svoju funkciju bez obzira na upade iz okoline. U ovaj dio spada i **automatska regulacija (kibernetika)** tj. očuvanje funkcije bez obzira na okolne utjecaje.
 - b. Bude upravljiv tj. da na neki način smislimo način da se kasnije može kvalitetno reorganizirati. S obzirom da je po *općoj teoriji spoznaje* reorganizacija neminovna, treba ostaviti odmah u početku prostora za tako nešto.
 - c. Bude edukatibilan. Treba ostaviti mogućnost nadogradnje, npr modularni pristup, primjer: računalo.
 4. Konkretna izvedba entiteta; prijedlog: senzor, relacija, model, zakonitost, ekspanzija, sklad prikazana je u poglavlju 5.2. *Procesi spoznaje*.

Ovo međutim, predstavlja postupak projektiranja. Dakle važi općenito: **kod projektiranja koristi se pristup odozgo prema dolje, tj od ideje do proizvoda.**

6. 5. Potvrda hipoteze

Što se do sada dobilo ?

1. U uvodnim djelovima objašnjene su premise rada (*poglavlje 2.1. Pristup istraživanju i 2.7. Temeljni pojmovi*):
 - a. univerzalnost prostora egzistencije,
 - b. univerzalnost disciplina,
 - c. uvjeti istovjetnosti dinamičkog i statičkog proučavanja entiteta
2. Razapet je prostor proučavanja kao sve bez ostatka
3. Unutar svega odabran je reprezentativan broj entiteta. Entiteti su birani na način da se maksimalno minimizira utjecaj istraživača (*slike 2.5.1. – 2.5.4.*)
4. Odabrane su potencijalne varijable za opis varijacija odabranih entiteta (*tablice 2.4.1. i 2.4.2.*)
5. Odabrana je odgovarajuća metodologija obrade podataka (*poglavlje 2.6.*)
6. Odabran je konzistentan skup varijabli koje opisuju odabrane entitete sa poznatom zadovoljavajućom greškom opisa (*tablica 2.4.1.*)
7. Iz početnog skupa entiteta pronađeno je 6 bipolarnih tipova – 1. razina koji stoje u nenultim relacijama (*tablica 5.1.5.1., slike 5.1.5.1. – 5.1.5.24.*)
8. Iz tipova prve razine daljnjom kontrakcijom prostora pronađena su 3 tipa slijedeće 2. razine (*tablica 5.1.5.2., slike 5.1.5.25. – 5.1.5.1.36.*)
9. Iz tipova 2. razine pronađena su 2 nadređena tipa 3. razine (*tablica 5.1.5.2., slike 5.1.5.37. – 5.1.5.44.*)
10. Iz predhodne razine jest pronađen glavni, vrhovni tip proučavanog prostora (*tablica 5.1.5.2., slike 5.1.5.45. – 5.1.5.48.*)
11. Zaključilo se da su to pravila strukturiranja entiteta u prostoru sve (*5.1. Identifikacija taksona*)
12. Temeljem ranije ustanovljene transparentije zaključeno je da su to opća pravila strukturiranja entiteta bilo kojeg prostora (*6.1. Temelji Opće teorije spoznaje*)
13. Proučavan je proces nastanka (spoznavanja) entiteta (na 4. razini) – *6.3. Procesi na 4. razini opće teorije spoznaje.*

No, sa predhodnim:

1. odbačena je nulta hipoteza tj. pronađen multidimenzionalni prostor u kojem leže sve bitne karakteristike zakonitosti spoznajnih procesa (točke 1 – 12)
2. odbačena je druga hipoteza, tj. pronađen stupanj varijacija promatranih parametara (točka 6)
3. odbačena je treća hipoteza tj. izmjerena greška modela je prihvatljivo mala (točka 6)
4. odbačena je četvrta hipoteza tj. izolirani mehanizmi nisu ortogonalni (točka 7)
5. odbačena je peta hipoteza tj. pronađene su 4 nadređene razine te je na krajnjoj 4. razini izoliran takson *spoznaja* (točke 8, 9 i 10)
6. odbačena je šesta hipoteza tj. pronađeni mehanizmi su opisani i prepoznati (točke 7, 8, 9 i 10)
7. odbačena je sedma hipoteza tj. pronađeni su reprezentativni entiteti koji opisuju taksone svih razina (točke 7, 8, 9 i 10)
8. prihvaćena je hipoteza da je spoznaje dobivene ovim istraživanjem moguće primjeniti na sve ostale entitete, neovisno o području ili vremenu nastanka. Primjeri transparentije su navođeni kroz cijeli rad, a u slijedeća dva poglavlja biti će prikazana još dva konkretna primjera

**OVIME SE SMATRA DA JE ZA ZADANU RAZINU DOKAZANA I UTEMELJENA
OPĆA TEORIJA SPOZNAJE.**

7. PRIMJERI

U ovom dijelu rada će se prikazati primjeri koji su od direktnog interesa za automatsku regulaciju ali i dinamičke sustave općenito.

U prvom primjeru težište je na dokazivanju *opće teorije spoznaje* u klasičnom masa – prigušenje – opruga sustavu. Osim toga biti će prikazan jedan drugačiji pristup proučavanju tehničkih sustava. S obzirom da će rezultati biti očekivani, moći će se izvući i zaključak o univerzalnosti konkretnih metoda istraživanja.

U drugom primjeru će se doći do nekih novih zaključaka te jednog drugačijeg poimanja dinamičkih procesa. Također će biti predložen jedan potpuno novi način vrednovanja kvalitete dinamičkog sustava, te sukladno tome predložiti nove dodatne kriterije za projektiranje dinamičkih sustava općenito.

U oba primjera koristiti će se slijedeći **koraci proučavanja**:

- 1) Razapinjanje prostora egzistencije (ono što nas zanima). U razapetom prostoru postoje objekti (vrši se odabir objekata te varijabli kojima opisujemo objekte). Objektivnost: mogu se dodavati i objekti i varijable po želji – model ostaje konzistentan.
- 2) Mjera stupnja objašnjenja varijacija (teorijska „pouzdanost“ modela) u tako definiranom prostoru egzistencije (spoznaje) – **koliko model uopće opisuje varijacija** (Entiteti unose varijacije, varijable informacije.).
- 3) Utvrditi latentne mehanizme na način da se utvrdi što se mjerilo, te da se otkriju tipovi objekata koji postoje u tako definiranom prostoru.
- 4) Utvrditi hijerarhiju tako dobivenih latentnih dimenzija (mjera i objekata)
- 5) Na svakoj razini postoje objekti različitog stupnja spoznaje. Zadnji (na vrhu pozicioniran) izolirani mehanizam predstavlja opću spoznaju prostora.

7. 1. Primjer br. 1

Koraci:

1) Ideja

Što : Želimo proučavati p2 članove.

Zašto : Želimo pronaći zakonitosti formiranja objekata koji se mogu opisati pravilom „p2“

Kako : Korištenjem metodologije koja nam omogućava „Korake proučavanja“.

2) Realizacija

Razapinjanje prostora egzistencije:

Odabire se prostor egzistencije „svih“ prigušenih oscilacijskih p2 članova.

Odabire se konačan broj objekata proučavanja – 710.

Da bi se moglo proučavati objekte oni će se opisati varijablama.

Napomena: Odabir prigušenih oscilacijskih p2 članova sa nenultim rezonantnim izdizanjem (stupanj prigušenja < 0.707) nije slučajno odabran. Naime kada bi odabrali i p2 članove sa nadkritičnim prigušenjem tada npr. varijabla rezonantno izdizanje nema smisla iz jednostavnog razloga jer kod nadkritičnog prigušenja rezonantno izdizanje nije definirano ! Ili u „najgorem slučaju“ rezonantno izdizanje je uvijek $= 0$, što znači da rezonantno izdizanje za p2 članove sa nadkritičnim prigušenjem nije varijabla već konstanta ($=0$) ! Uzet je oscilacijski slučaj jer on ima najveći broj varijacija, dakle i varijabli.

Varijable

Inicijalno je odabran skup od 54 varijable (poglavlje 7.1.1.3). Sve varijable su imale vrlo visoke udjele objašnjenosti (uglavnom preko 95 %) što znači da sve odabrane varijable pripadaju prostoru proučavanja.

Iterativnim postupkom analize modela utvrđeno je da je skup varijabli nerealno velik; neke varijable su gotovo kolinearne ili praktično opisuju istu pojavu, te je taj skup u konačnici smanjen na 11 varijabli sa kojima je postavljen model. S obzirom da sve varijable pripadaju modelu, za odabir varijabli korištena su dva kriterija:

a) korelacija varijabli ne smije biti veća od 0.9 (apsolutno)

b) ne smije postojati „velika“ disproporcija pojedinih varijabli po faktorima / taksonima.

Kriterij pod b) se odnosi na mogućnost dobivanja nerealnih rezultata forsiranjem samo varijabli određenog tipa.

Objekti i način provođenja eksperimenta

S obzirom da nije bilo mogućnosti proučavanja stvarnih objekata, korišten je pristup simuliranja objekata prema, u praksi provjerenom matematičkom modelu p2 člana.

Kao alat za analizu korišten je *Matlab*. Tako je definiran p2 član koji se ispitivao jediničnim step ulazom.

Napravljen je program (u *MatLab-u*) koji kvazislučajno bira vrijednosti mase, prigušenja i krutosti opruge. Nakon odabira vrši se simulacija konkretnog p2 člana. Za vrijeme simulacije kao i na kraju vrše se mjerenja svih navedenih varijabli. Za lakši pristup pojedinim vrijednostima modela dodatno je napravljen i simulink model iz kojeg se onda jednostavno mogu izmjeriti željene vrijednosti.

Kao što je već rečeno za vrijednosti mase, prigušenja i krutosti opruge korišteni su kvazislučajni brojevi koji su birani iz skupa realnih brojeva od 0 do 1000. Eliminacija objekata koji ne pripadaju proučavanom prostoru vršena je na način da su eliminirani svi oni objekti koji su izvan +/- 3.5 standardne devijacije na bilo kojoj proučavanoj varijabli. Za ovaj konkretan primjer proučavano je 710 objekata.

7. 1. 1. Rezultati

7. 1. 1. 1. Orthoblique faktori

U *Tablici 7.1.1.1.1.* vidljiv je odabir varijabli modela (stupac „Var“), njihove maksimalne i minimalne vrijednosti (stupac „min“ i „max“), kao i komunaliteti (stupac h2). Kao što se vidi broj varijabli modela je „pao“ na samo 11, ali je također vidljivo da je taj odabir realan jer svaka od varijabli ima visoke komunalitete što u konačnici rezultira izvrsnom ukupnom vjerodostojnosti modela od 96 % !

Na slijedećoj razini vidljivo je što je to ustvari mjereno:

Prvi faktor je opisan dominantno brzim prigušenjem oscilacija ($t_{msi} = -0.92$), velikim stupnjem prigušenja (0.9), velikim faktorom prigušenja (0.87), te malom rezonantnom amplitudom (-0.8). Također je vidljivo da su za opis ovog faktora nevažni vrijeme porasta i prigušena vlastita frekvencija, a od malog značaja su i masa, krutost opruge i trajno regulacijsko odstupanje. Ovaj faktor ustvari predstavlja mjeru stupnja prigušenja oscilacija oko ravnotežnog položaja, te je zbog praktičnih razloga skraćeno nazvan **Prigušenje**.

Ovaj faktor je vrlo vjerojatno identičan stupnju prigušenja. Zanimljivo je napomenuti da se u više desetaka ponavljanja simulacija gotovo u pravilu dobivala jako velika projekcija stupnja prigušenja na faktor *Prigušenje*. Ona je u pravilu uvijek bila veća od projekcije varijable faktora prigušenja, što onda sugerira moguću pogrešku u nazivu ovih mjernih karakteristika, dakle sukladno dobivenim rezultatima nazivi bi trebali obrnuti !

Var	Prigušenje	Brzina	Amplituda		h2	min	max
mmm	-0.145	-0.833	-0.071		0.9534	39.089	999.803
ddd	0.746	-0.535	-0.415		0.9759	14.952	995.988
sss	0.200	0.373	-0.942		0.8829	123.874	997.830
omp	0.076	0.946	-0.392		0.9831	0.325	3.294
amr	-0.821	0.158	0.600		0.9694	0.001	0.026
stp	0.903	-0.432	-0.037		0.9872	0.022	0.600
fpr	0.866	0.220	-0.307		0.9702	0.042	1.460
tra	0.023	-0.867	0.618		0.9675	0.516	5.750
tsmi	-0.924	0.069	0.286		0.9622	2.359	92.358
e0	0.192	0.361	-0.957		0.9456	0.992	0.999
minf	-0.450	0.854	-0.188		0.9641	0.100	2.248
				Total	96 %		

Tablica 7.1.1.1.1. – Orthoblique - Sklop

Na drugom faktoru dominiraju prigušena vlastita frekvencija (0.95), malo vrijeme porasta ($\text{tra} = -0.87$) te velika frekvencija na kojoj započinje rezonantno izdizanje (10% od maksimalnog). Vidljivo je i da je vrijeme smirivanja nevažno ($\text{tsmi} = 0.07$), a od manjeg značaja su i rezonantna amplituda ($\text{amr} = 0.16$) i faktor prigušenja ($\text{fpr} = 0.22$). Zanimljivo je i primijetiti da je vrijeme porasta nebitno na prvom a jako važno na drugom faktoru, dok kod mjere vremena smirivanja vrijedi obrnuto: na prvom je najznačajniji, dok je na drugom nevažan.

Temeljem ovih informacija može se zaključiti da ovaj faktor mjeri brzinu p2 objekta te je zbog toga i nazvan **Brzina**.

Treći faktor jest definiran prvenstveno malom krutošću opruge (-0.94) i jako malim regulacijskim odstupanjem (-0.96). Očigledno je da ovim faktorom mjerimo stacionarno stanje. Zanimljivo je za primijetiti da ovakvu mjeru definira, tj. da se je može relativno dobro procijeniti i pomoću vremena porasta (0.62) i rezonantne amplitude (0.6). S time je povezano i malo prigušenje ($\text{ddd} = -0.42$), kao i mala prigušena vlastita frekvencija (-0.39). Ovaj faktor je nazvan **Amplituda** jer očigledno mjeri amplitudu u stacionarnom stanju (suprotna metrijska orijentacija od e0).

Iz tablice 7.1.1.1.2. je vidljivo da su **Brzina** i **Prigušenje** lagano negativno korelirani (-0.14), što vrlo vjerojatno odgovara realnosti. No ova veza nije jako negativna kao što bi možda bilo za očekivati jer nam se nekako intuitivno čini da je brzina u suprotnosti sa prigušenjem. Iz tablice 7.1.1.1.2. je vidljivo i da je **Amplituda** negativno korelirana sa **Prigušenjem** i **Brzinom** i to gotovo u istom iznosu.

	Prigušenje	Brzina	Amplituda
Prigušenje	1.000	-0.143	-0.288
Brzina	-0.143	1.000	-0.253
Amplituda	-0.288	-0.253	1.000

Tablica 7.1.1.1.2. – Korelacije orthoblique faktora

Može se zaključiti da se sa sve 54 odabrane varijable ustvari mjere 3 latentne dimenzije i to : **Prigušenje** (oscilacija), **Brzina** i **Amplituda** p2 člana. Također se može zaključiti da ove mjere **nisu neovisne** već ovise jedna o drugoj, kako je prethodno opisano.

7. 1. 1. 2. Polarni taksoni

Kako je već prije rečeno, u prirodi egzistiraju samo realni objekti dok su varijable „samo“ misaoni konstrukti i u materijalnom (realnom) svijetu ne postoje. Ovdje se smatra da izmjerene varijable predstavljaju našu predodžbu proučavanih entiteta što ne mora (i obično nije) identično sa onim što stvarno egzistira. Također, u prethodnim poglavljima je rečeno da postoje samo objekti te da oni imaju svoj stupanj spoznaje. Definirana je također i spoznajna skala, kao mjera spoznaje svakog pojedinog entiteta.

U tom smislu odrediti će se tipovi p2 objekata. Ovdje je za te potrebe korištena metoda polarnih taksona koja osim što daje tipove, također daje i poziciju svakog pojedinog objekta na definiranom tipu.

Rezultati polarne taksonomske analize prikazane su u *tablici 7.1.1.2.1*. Osim varijabli modela u tablici su prikazane i projekcije prethodno dobivenih faktora na taksone, ali su dodane i neke nove varijable zbog lakše identifikacije taksona. Ove varijable su smještene u dijelu tablice *Ostale varijable* i **nisu** korištene za dobivanje modela.

Identifikacija taksona je nešto teža i nije tako očigledna kao otrhoblique faktori. Pošto se radi o konkretnim objektima bilo bi idealno imati slike objekata, no to ovdje nije slučaj. No, sa druge strane to što nemamo konkretne objekte već teorijski model daje nam mogućnost maksimalne transparentije. Ovdje „klasičan“ pristup taksonomiziranja samo preko mase i ostalih „opipljivih“ parametara nije jedini bitan jer se radi o dinamičkim sustavima. U tom smislu uzeto je u obzir da gibajući entitet nema samo masu u klasičnom smislu već on titrajući zauzima i neki prostor koji na određeni način „čuva“ tj. u određenim vremenskim odsječcima nalazi se u svakoj točki prostora kojim se giba. Osim toga on sa uzbudnom silom čini cjelinu i iako uzbudna sila nije dio modela, model je napravljen upravo na temeljima djelovanja uzbudne sile na objekte.

Za podršku ovakvom pristupu kao logično rješenje se nameće korištenje *Bode*-ovih dijagrama. To je i učinjeno te su na *slikama 7.1.1.2.1. – 7.1.1.2.6*. prikazani po dva karakteristična objekta za svaku stranu svakog pojedinog taksona. Na svakom dijagramu su nacrtani svi objekti korišteni u istraživanju, a podebljanom crnom crtom prikazana su prva dva karakteristična objekta za konkretnu stranu konkretnog taksona.

Prisjetimo se još da je u elektrotehnici $I = U / Z$ (I – struja, U napon, Z impedancija), za što je u mehaničkom području ekvivalent $v = F / Z$, odnosno $a * \omega = F / Z$, odakle slijedi:

$$a = (F/\omega) / Z$$

gdje je a – amplituda, F sila (jedinični step), ω – frekvencija dok Z predstavlja ekvivalent električne impedancije, dakle Z je mehanička impedancija. Može se pokazati da je :

$$Z^2 = ddd^2 + (\omega * mmm - sss/\omega)^2 \quad (1).$$

Sada se *Bode*-ov dijagram može podijeliti na tri dijela:

- 1) Područje malih frekvencija gdje je $\omega \ll$, pa iz (1) slijedi da je sss / ω dominantan te u ovom području dominantnu ulogu na ponašanje sustava ima opruga – **opružna kontrola**.
- 2) Rezonantno područje gdje amplituda dominantno ovisi o prigušenju (ddd) – **frikcijska kontrola**
- 3) Područje visokih frekvencija gdje dominira član $\omega * mmm$, te amplituda dominantno ovisi o masi te ovo područje možemo nazvati područje **masene kontrole**.

U *Tablici 7.1.1.2.1.* prikazane su projekcije varijabli i faktora na pojedine taksone. Također su dodane još neke varijable u dijelu *Ostale varijable* radi lakše identifikacije taksona.

Prvi takson na pozitivnoj strani je definiran kao jako spori (-0.85) i prigušeni (0.61) objekti čija amplituda (-0.01) nije bitna. Suprotno tome, negativna strana je definirana kao jako brzi (0.85) i neprigušeni (-0.61) objekti čija je amplituda također nevažna (0.01).

Pozitivnu i negativnu stranu definira više varijabli koje se mogu opisati kroz već definirane faktore, ali posebno se ističe varijabla minf (-0.88) koja označava frekvenciju na kojoj je započelo rezonantno izdizanje računajući prema rastućim frekvencijama. Ovu varijablu prati i omr (-0.78), a kada se pogledaju *Bodeovi* dijagrami na *slikama 7.1.1.2.1.* i *7.1.1.2.2* vidi se da je područje masene nasuprot opružne kontrole dominantna karakteristika ovog taksona. Stoga negativna i pozitivna strana ovog taksona predstavljaju tipove p2 objekata koji su dominantno opružno, odnosno maseno kontrolirani. Također je poznato da opruga reagira na nižim frekvencijama – dakle proporcionalno. Suprotno (polarno) tome je visoka frekvencija na koju reagira masa. Masa dakle u ovom slučaju kontrolira čitav objekt pri velikim frekvencijama, dakle reagira na naglu promjenu – derivaciju. Zbog rečenog takson se može opisati kao proporcionalno – derivacijski kontroliran. No, i u jednom i u drugom slučaju radi se o načinu apsorpcije energije iz okoline, pa se ovaj takson može nazvati „Energija unutar objekta“. Ovome u prilog ide i činjenica da je ukupan rad sile prigušenja za ovaj takson nevažan (WFpuk = 0.06). Dakle, objekt reagira na podražaj proporcionalno, odnosno derivacijski te ima određeni stupanj akumulacije energije pobude.

OTS	Perzistencija	Upravlјivost	Edukatibi- lnost
- Strana (pol)	Opružna kontrola (Proporci.)	Tvrđi prijelaz	Velika energija sustava
+ Strana (pol)	Masena kontrola (Derivac.)	Meki prijelaz	Mala energija sustava
Naziv	Energija unutar objekta	Tranzicija	Akumulirana energija
mmm	0.640	0.498	0.160
ddd	0.848	-0.427	0.009
sss	-0.065	-0.611	0.837
omp	-0.688	-0.637	0.345
amr	-0.599	0.723	-0.150
stp	0.770	-0.485	-0.462
fpr	0.255	-0.856	-0.173
tra	0.629	0.590	-0.629
tsmi	-0.518	0.753	0.225
e0	-0.056	-0.605	0.856
minf	-0.881	-0.133	0.433
Korelacije taksona			
Energ.	1.000	0.073	-0.249
Tranz.	0.073	1.000	0.208
Energ.	-0.249	0.208	1.000
Korelacije obq. faktora sa taksonima			
Priguš.	0.614	-0.775	-0.264
Brzina	-0.854	-0.456	0.326
Amplit.	-0.084	0.637	-0.847
Ostale varijable			
omn	-0.603	-0.716	0.297
omr	-0.776	-0.517	0.395
mpp	-0.789	0.493	0.479
mpa	-0.117	0.713	-0.739
mpt	0.539	0.704	-0.583
omb	-0.712	-0.612	0.365
maxf	-0.721	-0.584	0.372
m-mf	-0.457	-0.756	0.251
smx	-0.117	0.713	-0.739
vmx	-0.696	0.129	-0.397
amx	-0.579	-0.433	-0.142
Ep	0.053	0.606	-0.855
WFouk	-0.645	-0.691	-0.041
WFpuk	0.057	-0.604	-0.856
WFiuk	-0.620	-0.713	-0.106
WFFuk	-0.606	-0.720	-0.135
Wukup	-0.608	-0.721	-0.132

Tablica 7.1.1.2.1. – Tipovi (taksoni)

Pozitivna strana drugog taksona opisana je kao slabo prigušen (0.78) i spor (-0.46) objekt velike amplitude (0.64). Od varijabli koje nisu već korištene prilikom opisa faktora ističe se m-mf (-0.76) koja opisuje širinu područja rezonantnog izdizanja. Tu svakako treba uočiti i širinu pojasa ($\text{omb} = -0.61$). Ako se uzmu u obzir i Bodeovi dijagrami 2. taksona (*slike 7.1.1.2.3. i 7.1.1.2.4.*) vidljivo je da se radi o načinu prijelaza preko rezonantne frekvencije; postoje tipovi objekata čiji je taj prijelaz „buran“ – tvrdi prijelaz, te suprotno tome – meki prijelaz. Takson ukupno opisuje tranziciju kroz kritično područje, te je tako i nazvan – Tranzicija.

Pozitivna strana trećeg taksona je opisana kao jako mala amplituda (-0.85), brzina je nešto veća (0.33) a slično je i prigušenje koje je suprotnog smjera (-0.26), dakle lagano je neprigušen. Od varijabli koje nisu razmatrane u faktorskom dijelu posebno se ističu jako mala potencijalna energija ($E_p = -0.85$), jako mali ukupan rad sile prigušenja ($WF_{puk} = -0.86$) kao i mala maksimalna sila u opruzi. Čini se da cijeli takson opisuje tipove u ovisnosti o količini apsorbirane energije. Pozitivna strana su tipovi sa malo, a negativna strana sa puno akumulirane energije. Stoga je takson i nazvan Akumulirana energija.

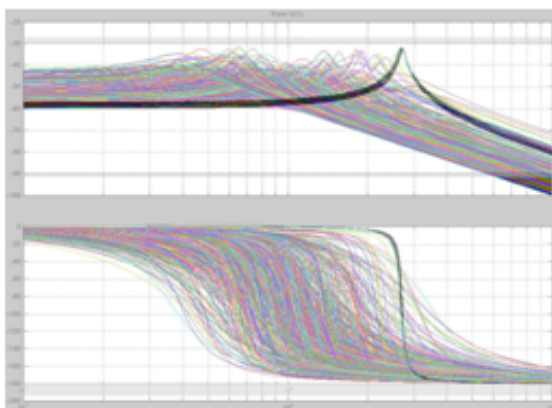
U općoj teoriji spoznaje na 3. razini prepoznata su 3 tipa objekata: Perzistencija, Upravlјivost i Edukatibilnost. Ako se taj model preslika na p2 član, logičan izbor bi bio onaj naznačen u 1. retku tablice 7.1.1.2.1. Ako se uzme u obzir opće fizikalno značenje energije, očigledno je da **akumulirana energija** predstavlja **otpornost na okolne utjecaje, bazu za „napredovanje“ – perzistencija**.

A što predstavlja upravlјivost ? Kakvi tipovi p2 članova s obzirom na upravlјivost u dinamičkom smislu postoje ? Postoje tipovi objekata koji meko ili tvrdo prijeđu preko rezonantne frekvencije, to za p2 članove predstavlja upravlјivost; kako prijeći iz jednog svog stanja (opruzna kontrola) u drugo (masena kontrola) ! Ako se opisu p2 člana pristupi na ovaj način, to tada znači da je „regulator“ ustvari sastavni dio p2 člana, a bez da je eksplicite ugrađen. Uostalom kada se ugradi PID regulator u neki objekt, u jednostavnijim slučajevima promatra se kao slabo prigušeni p2 član. To znači da će se (vrlo vjerojatno) i tamo nalaziti isti tipovi samo će biti opisani drugim fizičkim dijelovima, no logika će ostati ista ! To ustvari i tvrdi ovaj rad – **svi objekti imaju perzistenciju, upravlјivost i edukatibilnost**, naravno na nekoj razini – ovdje konkretno na razini 2.

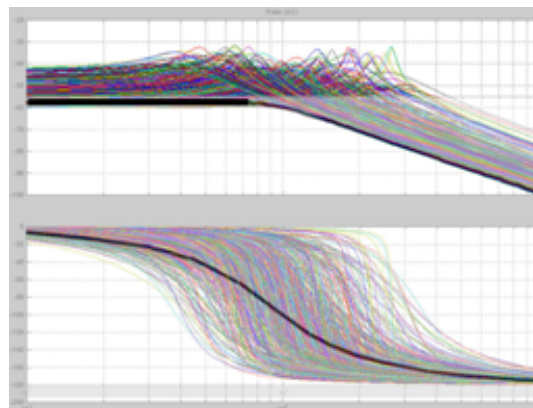
Za identifikaciju Edukatibilnosti preostala je još jedna mogućnost – Akumulirana energija. (Ovo naravno pod pretpostavkom da je transparentija moguća.) No, što predstavlja energija općenito u fizici ? Ona je sinonim mase, pa se dakle može kazati da kada se akumulira dovoljno energije „povećat će se red sustava“ !

Neka nas ne smeta maksimalna analogija – samo se koristi pozitivna strana prije spomenutog da su objekti teorijski. S obzirom da je model p2 člana opći, dopušteno nam je tražiti analogije i u područjima koja nisu „matična“.


Bodeovi dijagrami objekata koji su tipični predstavnici taksona



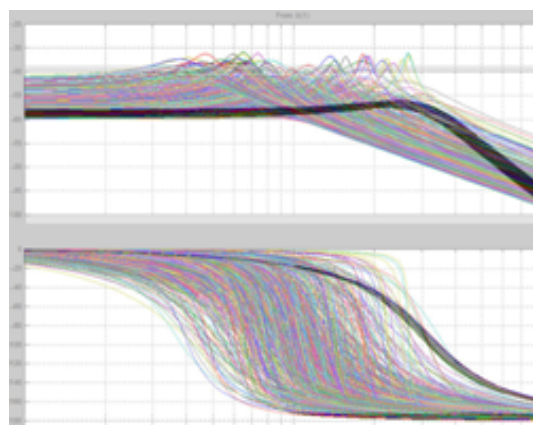
Slika 7.1.1.2.1. – 1. Takson - neg. strana




Slika 7.1.1.2.2. – 1. Takson - poz. strana




Slika 7.1.1.2.3. – 2. Takson - neg. strana



Slika 7.1.1.2.4. – 2. Takson - poz. strana



Slika 7.1.1.2.5. – 3. Takson - neg. strana



Slika 7.1.1.2.6. – 3. Takson - poz. strana

7. 1. 1. 3. Popis svih varijabli

šif. var.	Opis varijable	šif. var.	Opis varijable
mmm	masa	fp	maksimalna sila u prigušivaču
ddd	prigušenje	fi	maksimalna sila inercije
sss	krutost opruge	sm	= s/m
omn	neprigušena vlastita frekvencija	dm	= d/m
omp	prigušena vlastita frekvencija	m1	= 1/m
omr	rezonantna frekvencija	ds	= d/s
amr	amplituda na rezonantnoj frekvenciji	WFom	maksimalni rad sile opruge
stp	stupanj prigušenja	WFomt	vrijeme maksimalnog rada sile opruge
fpr	faktor prigušenja	WFim	maksimalni rad sile inercije
tra	vrijeme porasta odziva sa 10% na 90%	WFimt	vrijeme maksimalnog rada
tsm	vrijeme smirivanja (odstupanje +/- 10%)	WFFm	maksimalni rad ulazne sile
e0	trajno regulacijsko odstupanje	WFFmt	vrijeme maksimalnog rada ulazne sile
mpp	postotni prebačaj (t – područje)	Ep	potencijalna energija na kraju
mpa	apsolutna maksimalna amplituda (t – područje)	WFouk	ukupan apsolutan rad sile opruge
mpt	vrijeme maksimalne amplitude (t – područje)	WFpuk	ukupan apsolutan rad sile prigušenja
omb	širina pojasa	WFiuk	ukupan apsolutan rad sile inercije
minf	frekvencija na kojoj je rezonantno izdizanje 10 % maksimalnog izdizanja (niža frekvencija)	WFFuk	ukupan apsolutan rad ulazne sile
maxf	frekvencija na kojoj je rezonantno izdizanje 10 % maksimalnog izdizanja (viša frekvencija)	Wukup	ukupna energija
m-mf	= maxf – minf	PFom	maksimalna snaga opruge
mr	rezonantno izdizanje	PFomt	vrijeme maksimalne snage opruge
fr10	frekvencija kod koje je fazni pomak = – 10 st.	PFpm	maksimalna snaga prigušivača
fr90	frekvencija kod koje je fazni pomak = – 90 st	PFpmt	vrijeme maksimalne snage prigušivača
fr170	frekvencija kod koje je fazni pomak = – 170 st.	PFim	maksimalna snaga sile inercije
fr1-7	= fr170 – fr10	PFimt	vrijeme maksimalne snage sile inercije
vmx	maksimalna brzina	PFFm	maksimalna snaga ulazne sile
amx	maksimalno ubrzanje	PFFmt	vrijeme maksimalne snage ulazne sile
fo	maksimalna sila u opruzi	Pmxuk	suma maksimalnih snaga

Tablica 7.1.1.3.1. – Popis varijabli za opis p2 člana

7. 2. PRIMJER br. 2.

Koji je način da nešto saznamo o nekom objektu ?

Načelno postoje dva načina:

Prvi (I) uključuje promatranje objekta kroz neki vremenski period te uočavanje pravila njegovog ponašanja. Što je period proučavanja dulji, a broj parametara koje pratimo veći – veća je i vjerojatnost pravilnog zaključivanja.

Drugi (II), agresivniji pristup, podrazumijeva da mi kao istraživači aktivno i sa određenim ciljem provociramo objekt koji želimo ispitati. Ovdje također važi pravilo: što više parametara u što dužem vremenskom periodu = točnija procjena objekta.

Na koji se način objekt može ispitati ? U tehničkom području objekti se obično ispituju **nezavisnim** uzбудama po pojedinim parametrima koje smatramo bitnima, te tako upravo zahvaljujući **nezavisnosti** ulaza na „jednostavan“ način možemo doći do informacija o nepoznatom objektu. Neka se ovaj način ispitivanja označi sa **(IIA)** (klasična automatika).

Koji bi način ispitivanja objekata bio dijametralno suprotan gore spomenutom ?

Pa, dijametralno suprotan način ispitivanja objekta bio bi proizvesti **nezavisne** reakcije objekta. Dakle, na objekt treba djelovati na takav (vjerojatno **neslučajan** !) način tako da reakcije objekta budu jedna u odnosu na drugu **nezavisne**. Neka se ovaj način ispitivanja označi sa **(IIB)**.

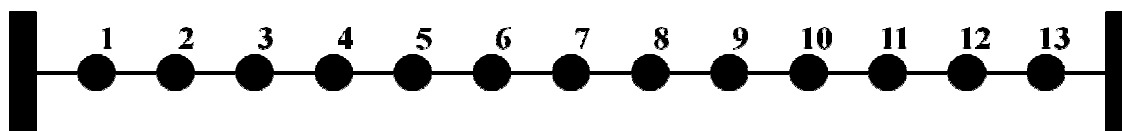
Napravimo jedan (jednostavan) primjer za zadnja dva načina ispitivanja sustava !

Primjer:

Neka je zadano 13 serijski spojenih masa spojenih oprugama i prigušivačima. Neka su prva i zadnja masa također oprugom i prigušivačem pričvršćene za zid. Neka su ulazi predstavljeni silama na svakoj od masa (*Slika 7.2.1*, mase 1 – 13), a neka su izlazi pomaci pojedinih masa svakog pojedinog objekta.

7. 2. 1. Slučaj br 1. – nezavisne uzbude

Na konstrukciju ćemo primijeniti dovoljan broj parova uzbuda – sila, te ćemo promatrati progib svake pojedine mase u stacionarnom stanju (*slika 7.2.1*). U ovom slučaju objekt nam predstavlja konačno stanje konstrukcije, a varijable kojima mjerimo objekt su pomaci svake od masa.



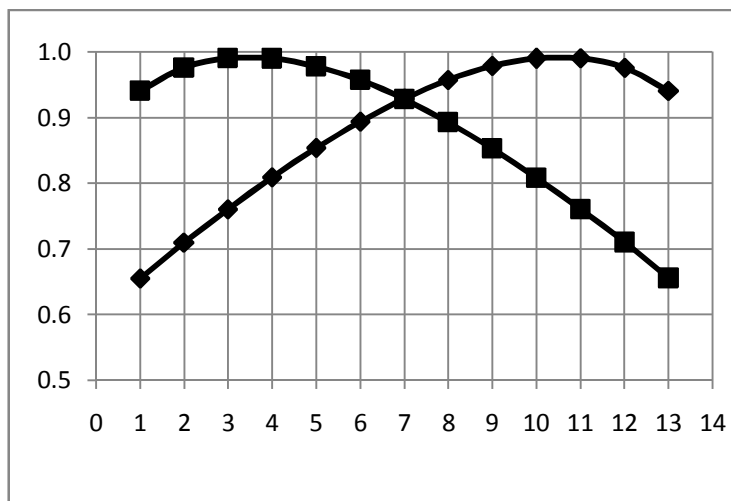
Slika 7.2.1.

Početni položaj ispitivane konstrukcije

7. 2. 1. 1. Rezultati:

7. 2. 1. 1. 1. Orthoblique faktori

Kao što je vidljivo iz *tablice 7.2.1.* na 1. razini dobivena su dva visoko korelirana orthoblique faktora (0.8). Očigledno je dobivena dobro poznata situacija po kojoj se mjerenje progiba može aproksimirati dvama progibima na dva kraja, negdje oko 4. i 10. mase (*Slika 7.2.2.*).

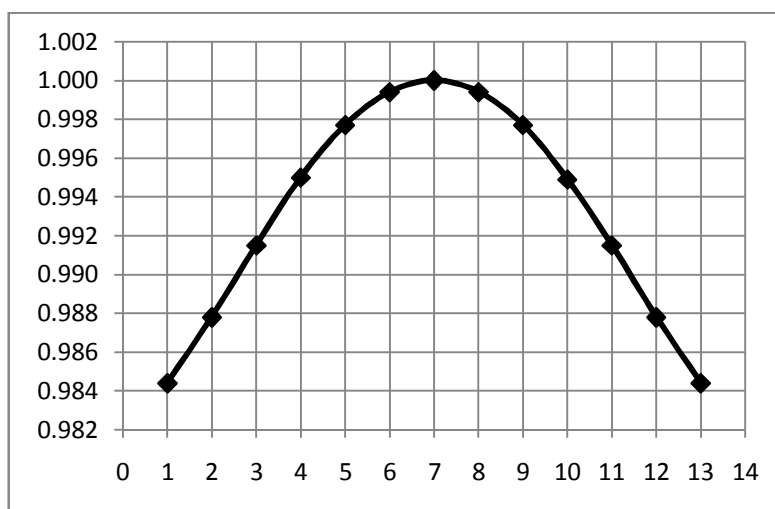


Slika 7.2.2. – Grafički prikaz projekcija progiba na faktore

	OBQ1	OBQ2
PR01	0.655	0.941
PR02	0.710	0.976
PR03	0.761	0.990
PR04	0.809	0.990
PR05	0.854	0.978
PR06	0.894	0.957
PR07	0.929	0.928
PR08	0.958	0.893
PR09	0.979	0.853
PR10	0.990	0.808
PR11	0.990	0.761
PR12	0.976	0.710
PR13	0.941	0.656
OBQ1	1.000	0.797
OBQ2	0.797	1.000

Tablica 7.2.1. – Faktori, 1. razina

Na slijedećoj 2. (generalnoj) razini dobiven je orthoblique faktor najvišeg reda (*Slika 7.2.3. i Tablica 7.2.2.*). Vidljivo je da su sve projekcije osnovne razine gotovo maksimalne, te je dovoljno mjeriti samo jednog od njih, najbolje onog točno u sredini (PR07 = 1) koji je praktično sam faktor. Ovi rezultati ne predstavljaju ništa neobično, osim (možda) same činjenice o visokoj koreliranosti faktora.



Slika 7.2.3. – Grafički prikaz proj. progiba na glavni faktor

	GM
PR01	0.984
PR02	0.988
PR03	0.992
PR04	0.995
PR05	0.998
PR06	0.999
PR07	1.000
PR08	0.999
PR09	0.998
PR10	0.995
PR11	0.992
PR12	0.988
PR13	0.984
OBQ1	0.948
OBQ2	0.948

Tablica 7.2.2. – Faktori, 2. razina

7. 2. 1. 1. 1. Polarni taksoni

Uobičajeno polarni taksoni daju tipove objekata. No, ovdje se proučava sustav koji ima izrazita dinamička obilježja, pa će se onda govoriti o tipovima ponašanja.

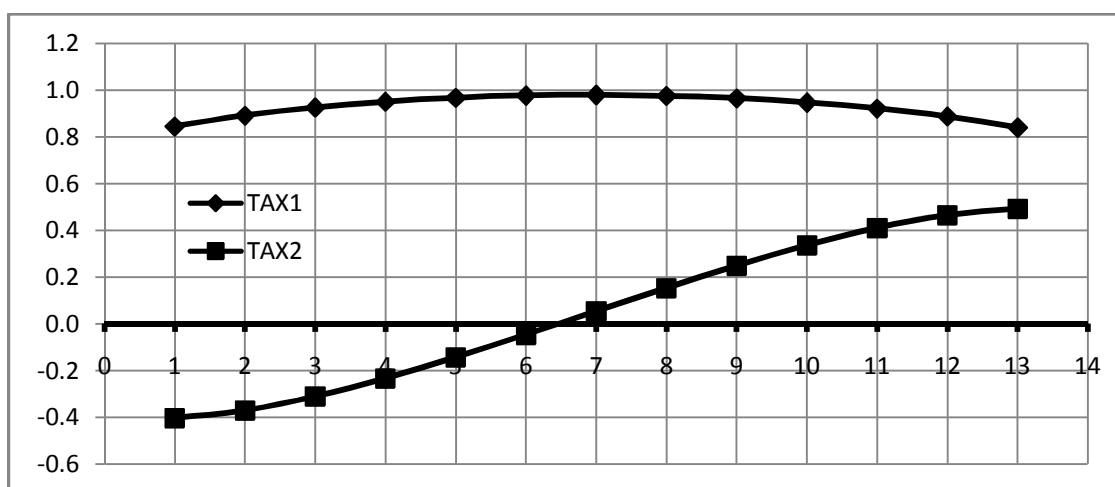
U tablici 7.2.3. prikazane su projekcije pojedinih varijabli (pomaka /progiba/ pojedinih masa). Zbog zornosti isti rezultati su prikazani i na slici 7.2.4. Treba imati na umu da pomaci nisu u smjeru osi y nego u smjeru osi x, iako je poznato da bi se jako slični ili isti rezultati dobili i da su se mjerili progibi ekvivalentne grede. Komunaliteti varijabli su svi odreda jako visoki, pa je tako i ukupna objašnjenoost modela čak 98.8 % ! Korelacije glavnih komponenata (nerotirani faktori) sa taksonima su jako velike te su oni praktično identični.

Na slikama 7.2.5 – 7.2.8 prikazano je po nekoliko tipičnih objekata za svaku stranu svakog pojedinog taksona. Vidljivo je da su tipični predstavnici pojedinih taksona praktično isti kao i projekcije varijabli na entitete (slika 7.2.4.), sa jedinom razlikom što na slici 7.2.4. nije nacrtana negativna strana taksona. Iz tablice 7.2.3. je vidljivo da su taksoni praktično ortogonalni (0.05). Iz tablice 7.2.3. se može izračunati i ukupna duljina taksona (ukupna projekcija varijabli) koja za 1. takson iznosi 3.35 dok duljina 2. taksona iznosi 1.14, što znači da drugi takson nosi u sebi gotovo 3 puta više informacija od prvog. Rađene su simulacije sa još većim brojem varijabli te je tada ta razlika još drastičnija, što upućuje na veliku važnost 1.taksona.

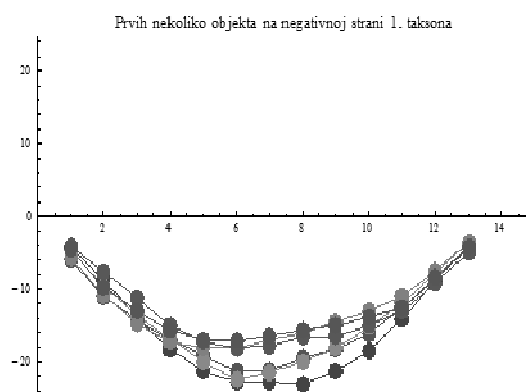
Konačno u tablici 7.2.4, te slikama 7.2.9, 7.2.10 i 7.2.11 prikazan je glavni takson. On je linearna kombinacija taksona prethodne razine što se najbolje vidi na slici 7.2.11. Vidljivo je da taksoni prethodne razine imaju jednaku projekciju na generalni (glavni) takson.

	TAX1	TAX2
PR01	0.844	-0.403
PR02	0.892	-0.370
PR03	0.926	-0.311
PR04	0.951	-0.233
PR05	0.967	-0.143
PR06	0.977	-0.046
PR07	0.980	0.054
PR08	0.976	0.153
PR09	0.965	0.248
PR10	0.947	0.335
PR11	0.922	0.409
PR12	0.887	0.464
PR13	0.840	0.492
TAX1	1.000	0.048
TAX2	0.048	1.000

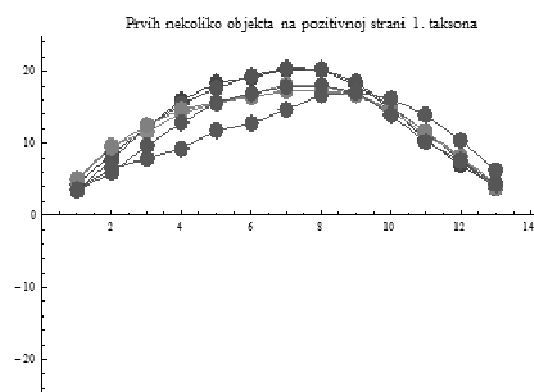
Tablica 7.2.3. – Taksoni 1. razina




Slika 7.2.4. – Grafički prikaz projekcija progiba na taksoni 2. razine



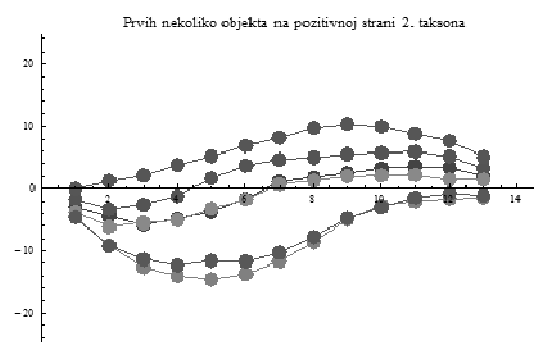
Slika 7.2.5. – Ekstremni objekti negativne strane 1. taksona



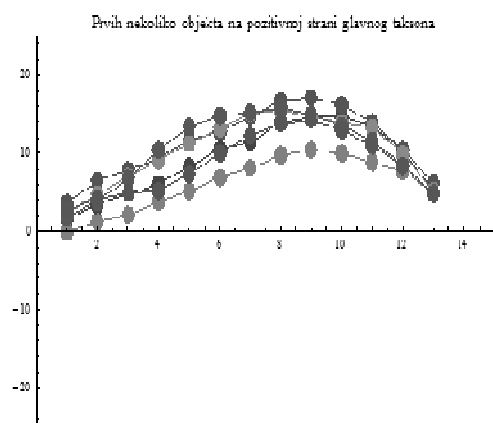
Slika 7.2.6. – Ekstremni objekti pozitivne strane 1. taksona



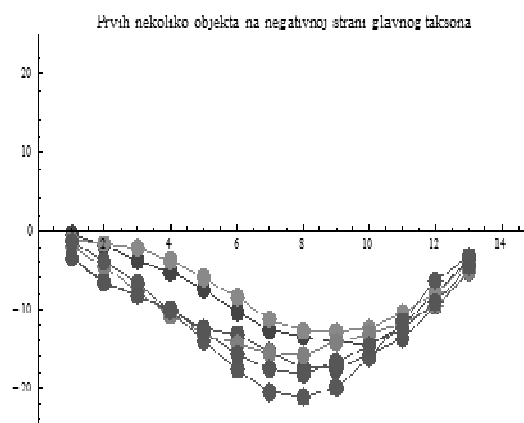
Slika 7.2.7. – Ekstremni objekti negativne strane 2. taksona



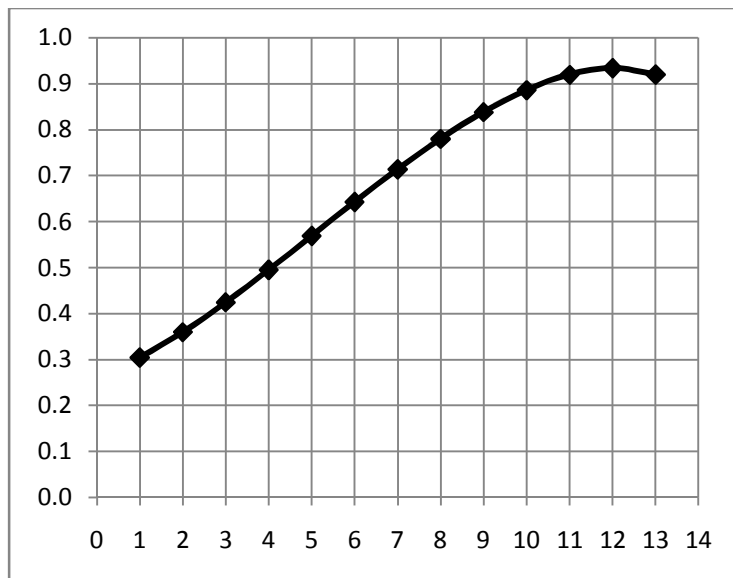
Slika 7.2.8. – Ekstremni objekti pozitivne strane 2. taksona



Slika 7.2.9. – Ekstremni objekti pozitivne strane glavnog taksona



Slika 7.2.10. – Ekstremni objekti negativne strane glavnog taksona



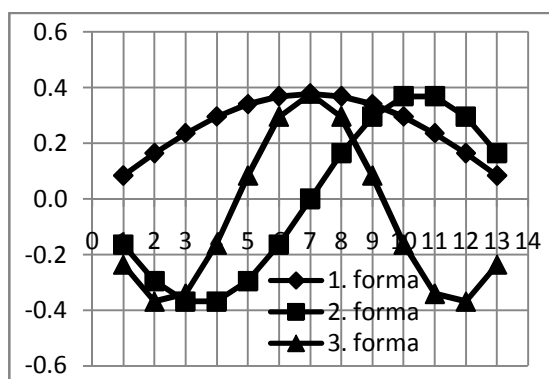
Slika 7.2.11. Grafički prikaz projekcija varijabli na glavni takson

	GTX
PR01	0.305
PR02	0.360
PR03	0.425
PR04	0.496
PR05	0.569
PR06	0.643
PR07	0.714
PR08	0.780
PR09	0.838
PR10	0.886
PR11	0.919
PR12	0.934
PR13	0.920
TAX1	0.724
TAX2	0.724

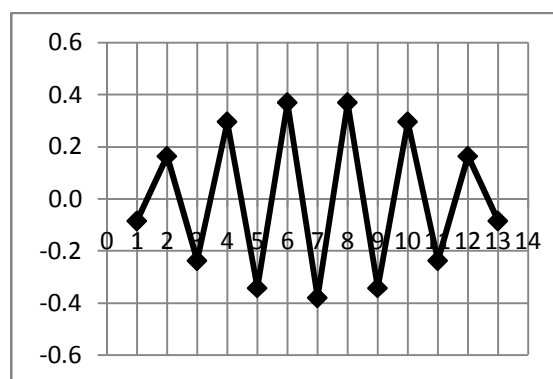
Tablica 7.2.4. –
Glavni takson

Dakle, orthoblique faktori nam „kažu“ da se mjerenje proučavanih objekata na višoj razini mogu aproksimirati dvama mjerenjima progiba dvaju masa blizu lijevog i desnog kraja, dok nam krajnja razina kaže da je dovoljno mjeriti progib u sredini.

Taksoni nas pak, podsjećaju na forme vibriranja. Uostalom, kako je već rečeno taksoni su praktično identični faktorima (ortogonalna solucija), a kako je poznato forme vibriranja za jedinične mase mogu se dobiti kao svojstveni vektori matrice krutosti. Može se pokazati da su na sličan način dobiveni i faktori. U tom bi slučaju lambde faktora bile proporcionalne vlastitim frekvencijama, jer nam i lambde i frekvencije govore o važnosti pojedinog **načina ponašanja konstrukcije**.



Slika 7.2.12. – 1., 2. i 3. forma vibriranja



Slika 7.2.13. – Zadnja (13.) forma vibriranja

Dakle ovdje se ne može govoriti o tipovima u klasičnom smislu (a što je vidljivo i sa dosad analiziranim rezultatima) već o **tipovima ponašanja**. Uostalom forme vibriranja predstavljaju karakteristične načine ponašanja neke dinamičke konstrukcije. Jedina primjedba koja bi se mogla uputiti na ovakvo razmišljanje jest činjenica da smo proučavali statička stanja konstrukcija. No taj argument ne stoji ako se uzme u obzir da je uzet reprezentativan broj položaja koja konstrukcija uopće može zauzeti, dakle tu su obuhvaćena i dinamička stanja !

Može se postaviti i pitanje koja je razlika između taksona i formi vibriranja. Odgovor na to pitanje autoru nije u potpunosti poznat, ali i forme vibriranja zasigurno predstavljaju tip ponašanja. Bitna razlika između formi vibriranja i taksona jest i u tome da su forme vibriranja ortogonalna solucija, dok to taksoni gotovo u pravilu nisu. Neortogonalnost taksona i općenito taksonomska analiza omogućava hijerarhiju, dok to kod formi vibriranja nije slučaj.

Sa strogo taksonomske točke gledišta početna pretpostavka jest da imamo beskonačno objekata pa dakle i beskonačno tipova, uz dakako apsolutnu preciznost tvrdnje. U slijedećem koraku smanjuje se broj tipova nekim objektivnim postupkom uz, dakako gubitak preciznosti.

Ako se ovdje primijeni analogija prethodnom razmišljanju, može se kazati da je početna pretpostavka da imamo ne beskonačno već točno 13 **tipova ponašanja**. Ova tvrdnja je apsolutna jer se svako stanje konstrukcije može predstaviti linearnom kombinacijom formi vibriranja. Slijedeća tvrdnja je da imamo samo 2 osnovna tipa ponašanja predstavljena taksonima prve razine. Ovdje je po nekom objektivnom kriteriju izvršena aproksimacija što je smanjilo preciznost tvrdnje ali istovremeno je povećana generalizacija. U slijedećem, zadnjem koraku generalizacija je maksimalna te je dobiven jedan jedini tipa ponašanja koji je predstavljen generalnim taksonom.

Uostalom isti način razmišljanja se koristi prilikom projektiranja nekog regulacijskog sustava – određivanjem bitnosti nekog pola prijenosne funkcije (koji je direktno vezan sa formom vibriranja), ustvari se određuje bitnost pojedinog tipa ponašanja promatrane konstrukcije – dakle **u suštini se vrši procjena glavnog načina ili tipa ponašanja objekta regulacije** ili prevedeno na jezik ovog rada **procjenjuje se generalni takson !!**

Dakle u početku se tvrdi da imamo 13 tipova ponašanja i apsolutnu točnost. Suprotno tome, na krajnjoj razini je postignuta maksimalna generalizacija ali i minimalna točnost. No **glavni takson je najbolja aproksimacija onoga što smo proučavali**, to je tip ponašanja koji je dobiven na temelju svih prethodnih i ustvari predstavlja ono što konstrukcija sama za sebe „najbolje zna“ ! To je **suštinski, generalni način ponašanja konstrukcije**. Ali osim toga, ako je to njeno glavno ponašanje, onda to ponašanje ujedno predstavlja i **(glavnu) svrhu konstrukcije**, dakako u dinamičkom smislu.

„Neka nas ne brine“ što konstrukciji „dajemo“ mogućnost „znanja“; zato se u ovom radu objektima i pridružuje pojam **spoznaja** koja je uzeta kao širi pojam. Ne može se poreći da konstrukcija ima neke spoznaje jer kada npr. stanete na nju, ona će vam na neki svoj način odgovoriti. Odgovor može biti jednostavna poput reakcija podloge, ali ako je konstrukcija složenija, reakcija može biti i mnogo složenija. Npr. poput nekog mehanizma ili u krajnjem slučaju poput reakcije suvremenih robota. Očigledno, složenija konstrukcija direktno je proporcionalna sa složenošću ponašanja – dakle **stupnju spoznaje konstrukcije**. Ili bilo kojeg drugog objekta.

Može se postaviti i obrnuto pitanje: kako temeljem nekog ulaza (stimulusa) prepoznati o kojoj se konstrukciji radi ? U konkretnom slučaju u odzivu konstrukcije bi trebalo **prepoznati** prva dva tipa ponašanja (taksona) ili glavni način ponašanja konstrukcije. Na isti način se postupa i u automatskoj regulaciji kada se npr. brzom Fourierovom transformacijom izlaznog signala pokušava odrediti dominantne utjecaje, tj. (glavne) najniže frekvencije vibriranja dijelova objekta.

Proučimo još jednu posljedicu dosadašnjih razmišljanja: ako zadnji takson predstavlja glavni tip ponašanja svih mogućih ponašanja objekta u tako definiranom problemu, te ako smo varijablama „dobro“ opisali problem koji nas zanima tada imamo apsolutnu mjeru kojom možemo klasificirati **sve** tipove ponašanja unutar definiranog problema. Primjetimo da je rangiranje „apsolutno“ objektivno, tj. **nema izvanjskog kriterija** (kojeg je zadao npr. projektant). Rangiranje ovisi samo o zadanim varijablama tj. o **topologiji proučavane konstrukcije** ili rečeno jezikom, u ovom radu definirane *teorije spoznaje: o prostoru egzistencije* objekata. No ovdje nailazimo na još jedan problem. Naime, u dosadašnjem dijelu rada to smo rangiranje vršili jednostavnim sortiranjem svih objekata po generalnom taksonu proučavanih objekata. To je bila apsolutna mjera spoznaje svakog objekta. Ovdje takav pristup nije moguć iz jednostavnog razloga što (iako je i dalje nedvojben pozitivan i negativan pol) je logički taj pristup nedopustiv jer se, kako se vidjelo iz rezultata radi o tipu ponašanja. U dinamičkom smislu možemo kazati da objekt titra između dva krajnja pola taksona te je u tom smislu pozitivna i negativna strana imaju sasvim drugo značenje – to su ekstremi kojima je definirano takvo ponašanje ! (Ovo podsjeća na općeniti pristup u fizici gdje „+“ i „-“ u pravilu predstavljaju suprotstavljene značajke ali istovremeno „+“ ne znači da je ta neka značajka poželjnija od one označene sa „-“.). No, generalni takson ili generalno ponašanje je i dalje generalno samo sada je potrebno pronaći neki drugi način usporedbe. Npr. treba odrediti koliko je titranje po 1. formi vibriranja (*slika 7.2.12.*) sukladno generalnom taksonu. Ili isto pitanje možemo postaviti za zadnju formu vibriranja (*Slika 7.2.13.*).

Kad postavimo ovo pitanje, mi se ustvari pitamo koliko je neko zadano ponašanje, titranje konstrukcije ustvari sukladno generalnom ponašanju tj. koliko je sukladno **svrsi konstrukcije!**

Kao mjera sukladnosti ponašanja predlaže se uvođenje **spoznajnog stupnja djelovanja (η_{sp})**, definiranog kao kvadrat projekcije ekstrema promatranog ponašanja na glavni tip ponašanja, oba svedena na vektor jedinične duljine. Time je definirano područje vrijednosti spoznajnog stupnja djelovanja od 0 (minimalno, nikakvo podudaranje) do 1 (maksimalno, 100 % podudaranje). Moguća je i slična definicija, koja uzima u obzir duljine vektora, tj. η_{sp} može se definirati kao omjer projekcije promatranog ponašanja na glavni takson i duljine glavnog taksona.

Izraženo matematički (prvi slučaj), za konkretni primjer slijedi:

Neka je \mathbf{X} vektor formi vibriranja (\mathbf{X} je ortonormiran) koji u svojim stupcima ima definirane forme vibriranja. \mathbf{GTX} je jednostupčana matrica glavnog taksona, predstavljena *tablicom 7.2.4.* (prvih 13 redaka) ali također normirana na jediničnu duljinu.

Tada je $\eta_{sp} = (\mathbf{GTX}^T * \mathbf{X})^2$, gdje \mathbf{T} označava transpon, operacija $*$ predstavlja matrično množenje, dok se operacija kvadriranja provodi za svaki element jednostupčane matrice posebno.

Sada je naravno, ispunjeno da je za sve forme zajedno (*Tablica 7.2.5.*) tj. $\sum_{i=1}^{13} \eta_{spi} = 1$, tj. sve forme vibriranja zajedno objašnjavaju 100 % glavnog taksona.

	η_{sp}	%
FORMA01	0.8166	81.66
FORMA02	0.0744	7.44
FORMA03	0.0627	6.27
FORMA04	0.0112	1.12
FORMA05	0.0186	1.86
FORMA06	0.0036	0.36
FORMA07	0.0072	0.72
FORMA08	0.0014	0.14
FORMA09	0.0028	0.28
FORMA10	0.0005	0.05
FORMA11	0.0009	0.09
FORMA12	0.0001	0.01
FORMA13	0.0001	0.01

Tablica 7.2.5. - η_{sp} formi vibriranja

U *tablici 7.2.5.* prikazani su spoznajni stupnjevi djelovanja formi vibriranja. Vidljivo je da prva forma ima daleko najveći η_{sp} , što je u skladu sa dosadašnjom raspravom. Iako 2 forma podsjeća na 2 takson ipak postoje razlike koje vjerojatno nadoknađuje 3. forma vibriranja. Ove tri forme vibriranja zajedno imaju $\eta_{sp} = 95.37\%$, dok se ostalih 10 formi vibriranja vrlo vjerojatno može zanemariti. Također se može primijetiti i da kasnije forme imaju sve manji i manji η_{sp} , što upućuje na njihovu sve manju važnost. Ovo je također u skladu sa dinamikom objekta, jer kasnijim formama pripadaju i znatno više frekvencije.

Napomena:

Kroz prethodna dva primjera vidljivo je da varijable sa kojima se entitete opisivalo nisu identične opisima stvarno egzistentnih entiteta (taksoni). Tako primjerice proučavajući varijable i njihove faktore nije bilo moguće proniknuti u „suštinu“ entiteta / objekta. Konkretno, suština entiteta u 2. primjeru su njegove forme vibriranja, a ne progibi pojedinih materijalnih točaka. Progibi materijalnih točaka su nama lako uočljivi što ne znači (a što se i u konkretnom primjeru i pokazalo) da je to i suština tj. svrha entiteta ! Kao što se pokazalo svrha entiteta tj. njegove spoznaje su forme vibriranja.

Dakle, može se zaključiti da je sa varijablama prikazan naš pogled na entitete koje se proučavalo ali da to sa pozicije entiteta nije realno ! Ako se ovakav pristup poopći dolazi se do jako važne spoznaje – entitete oko nas treba proučavati i iz kuta entiteta samih jer nam jedino tako može biti jasno njihovo ponašanje. Entiteti se ponašaju sukladno svojim spoznajama a ne temeljem onoga što mi mislimo, odnosno smatramo da bi za pojedini entitet bilo važno. Može se zaključiti da su varijable naš početni pogled na neke proučavane entitete.

Ovo je glavni razlog zbog kojeg se u ovom radu smatra da su varijable (i faktori) misaoni konstrukti koji realno ne postoje, a da realno postoje samo objekti / entiteti (u ovom radu konkretno opisani taksonima).

7. 2. 2. Slučaj br 2. – nezavisne reakcije objekta

U ovom slučaju potrebno je dobiti nezavisne reakcije objekata. To je napravljeno na način da je odabrano 697 slučajnih brojeva, te oni predstavljaju reakcije objekata. Da bi se dobile sve zacrtane pomake konstrukcije izračunate su potrebne sile za svaki objekt posebno.

Dakle, ovdje objekti neće biti konstrukcija već će se pod **objektom** podrazumijevati **skup od 13 sila** koji djeluju na iste one mase iz prethodnog primjera (konstrukcija). **Varijable** kojima su opisani objekti su **iznosi svake pojedine sile**. Može se reći da će se ovdje proučavati neki nepoznati objekti koji djeluju na konstrukciju.

7. 2. 2. 1. Rezultati: Orthoblique faktori

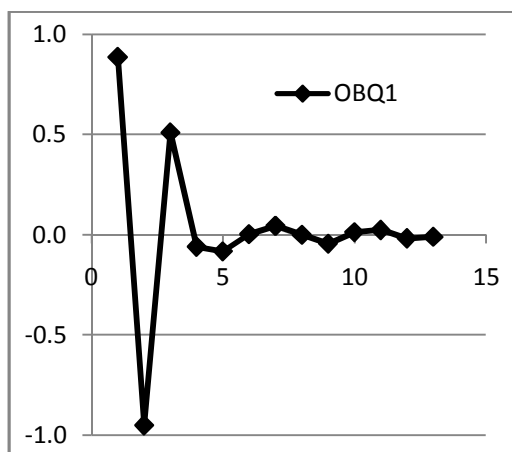
Kao i u prethodnom primjeru komunaliteti varijabli su redom jako visoki, pa je tako i ukupan komunalitet čak 98.8 % ! No, za razliku od prethodnog primjera ovdje je broj faktora iznenađujuće velik, a korelacije među njima jako male. Projekcije varijabli na svih 6 orthoblique faktora prikazane su u *tablici 7.2.6*. Zorniji prikaz je na *slikama 7.2.14 – 7.2.19* na kojima je vidljivo smično djelovanje sila na elemente konstrukcije. I ostali faktori su jako slični, samo sile djeluju na drugim dijelovima konstrukcije.

	OBQ1	OBQ2	OBQ3	OBQ4	OBQ5	OBQ6
F01	0.888	-0.027	-0.021	0.062	0.013	-0.009
F02	-0.949	0.000	-0.021	-0.399	0.046	-0.037
F03	0.512	0.025	0.047	0.839	-0.007	0.045
F04	-0.058	0.004	0.010	-0.940	-0.308	0.048
F05	-0.082	-0.037	-0.062	0.589	0.759	-0.079
F06	0.004	0.007	-0.010	-0.123	-0.955	-0.176
F07	0.046	0.041	0.096	-0.092	0.708	0.643
F08	0.001	-0.007	0.073	0.042	-0.247	-0.947
F09	-0.043	-0.073	-0.537	0.044	-0.046	0.806
F10	0.015	-0.036	0.926	-0.031	0.062	-0.366
F11	0.025	0.478	-0.867	-0.016	0.013	0.025
F12	-0.017	-0.942	0.429	0.008	-0.021	0.048
F13	-0.009	0.893	-0.069	0.021	-0.008	0.001
OBQ1	1.000	0.008	0.018	0.231	-0.038	0.022
OBQ2	0.008	1.000	-0.237	-0.008	0.013	-0.038
OBQ3	0.018	-0.237	1.000	-0.022	0.042	-0.206
OBQ4	0.231	-0.008	-0.022	1.000	0.199	-0.042
OBQ5	-0.038	0.013	0.042	0.199	1.000	0.190
OBQ6	0.022	-0.038	-0.206	-0.042	0.190	1.000

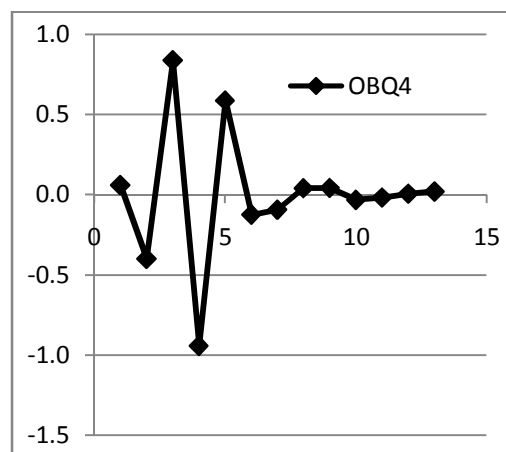
Tablica 7.2.6. – Orthoblique faktori

Proučavajući faktore nameće se zaključak da sa njima mjerimo **stupanj smičnog djelovanja** na konstrukciju. Tako se mogu opisati svi faktori svih razina (*slike 7.2.14. – 7.2.25.*), jedino što je različito jest mjesto na kojem sile djeluju, te širina konstrukcije koja je obuhvaćena djelovanjem sila.

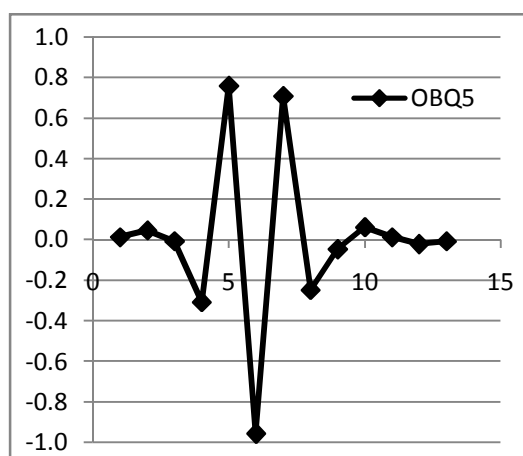
Orthoblique faktori – 1. razina



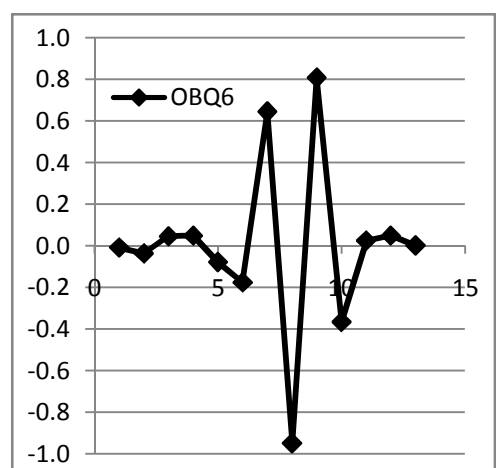
Slika 7.2.14. – Grafički prikaz projekcija varijabli na faktor OBQ1



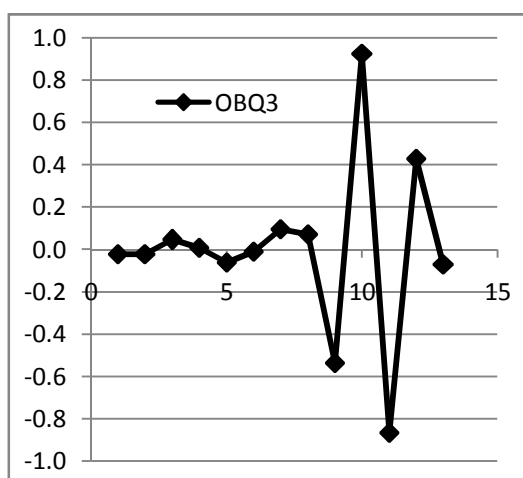
Slika 7.2.15. – Grafički prikaz projekcija varijabli na faktor OBQ4



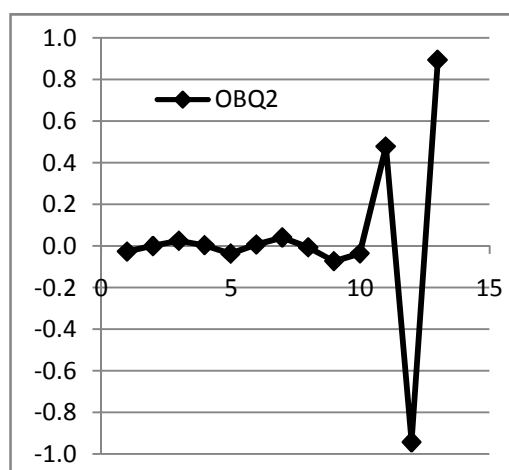
Slika 7.2.16. – Grafički prikaz projekcija varijabli na faktor OBQ5



Slika 7.2.17. – Grafički prikaz projekcija varijabli na faktor OBQ6

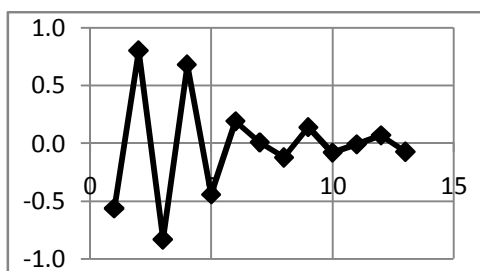


Slika 7.2.18. – Grafički prikaz projekcija varijabli na faktor OBQ3

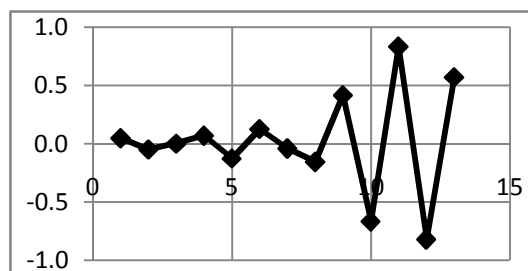


Slika 7.2.19. – Grafički prikaz projekcija varijabli na faktor OBQ2

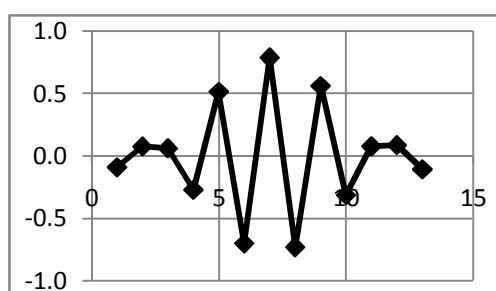
Orthoblique faktori - 2. razina



Slika 7.2.20. Grafički prikaz projekcija varijabli - 2. razina, 2. faktor

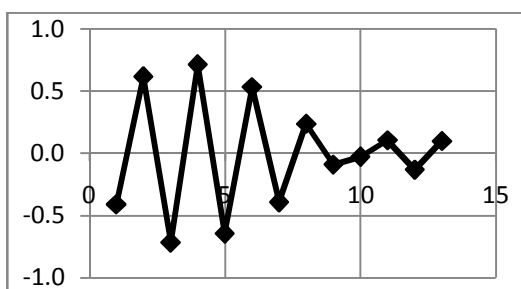


Slika 7.2.21 Grafički prikaz projekcija varijabli - 2. razina, 1. faktor

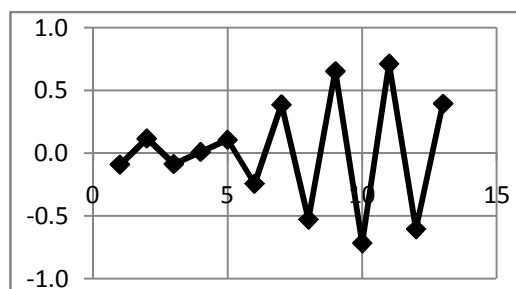


Slika 7.2.22 Grafički prikaz projekcija varijabli - 2. razina, 3. faktor

Orthoblique faktori - 3. razina

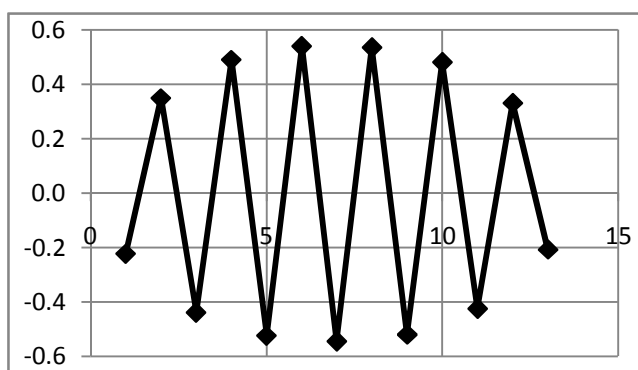


Slika 7.2.23 Grafički prikaz projekcija varijabli - 3. razina, 2. faktor



Slika 7.2.24 Grafički prikaz projekcija varijabli - 3. razina, 1. faktor

Glavni orthoblique faktor - 4. Razina



Slika 7.2.25 Grafički prikaz projekcija varijabli – Glavni faktor

Što predstavljaju ovi rezultati ? Očigledno destrukciju konstrukcije ! Na 1. razini ta destrukcija je lokalna i djeluje gotovo na parove masa (dakle najmanje što je uopće moguće). Na drugoj razini taj utjecaj se širi po prostornoj koordinati konstrukcije, da bi na konačnoj 4. razini taj utjecaj bio rasprostranjen preko cijele konstrukcije. Ovdje je riječ o silama, dakle ne pomacima konstrukcije. No, ako primjenimo silu opisanu glavnim orthoblique faktorom na konstrukciju dobije se potpuno isti oblik deformacije konstrukcije, naravno u nekom drugom mjerilu. Osim toga, navedeni generalni oblik identičan je zadnjoj formi vibriranja (*slika 7.2.13.*), što je zasigurno najmanje važna forma vibriranja. Uz to još, ova forma (pa dakle i glavni orthoblique faktor) ima i najmanji η_{sp} koji iznosi 0.01 % ! Ovo nas još više učvršćuje u spoznaji da je riječ o kranje **destruktivnom** djelovanju na konstrukciju. Uostalom to je bilo i za očekivati jer smo konstrukciju opterećivali silama koje proizvode nezavisne pomake konstrukcije. Drugim riječima **negirali smo konstrukciju !**

Zaključak

- a) Slučaj (I) istraživanja primijenjen je u 1. dijelu ovog magistarskog rada.
- b) Slučaj (IIA) je klasični kibernetički princip koji mi u automatici redovito koristimo. No, s pozicije *teorije spoznaje*, spoznajnom objektu (konstrukciji) mi ne unosimo nikakve nove informacije. Ili bolje rečeno ne unosimo nikakve spoznaje u interakciju sa promatranim objektom. Pošto su naši stimulusi (ulazi) nezavisni, jedine informacije koje možemo uočiti dolaze od same ispitivane konstrukcije, tj. svi pomaci ili bolje rečeno svi **tipovi ponašanja** dolaze od same konstrukcije. Ustvari „mi“, kao „provokatori“ „nismo materijalizirani“ u tom prostoru već smo svedeni samo na unos energije, ili dinamički gledano na pokrivanje energetskih gubitaka. Može se kazati da mi kao istraživači ustvari **ignoriramo objekt**, dok on (sa pozicije *teorije spoznaje*) titra na sve moguće načine na koje „zna“ tj. **pokušava uspostaviti komunikaciju sa otkrivenim objektom u okolini**.
- c) Ako se ovo generalizira, može se uzeti primjer odnosa učitelj – učenik ili profesor – student. Učitelj se ponaša neovisno o ponašanju učenika, ispituje njegovo znanje različitim pitanjima te temeljem odgovora zaključuje o njegovom znanju. Iako polazište nije *spoznajna teorija*, identifikacija nekih parametara objekta u radu [29] jesu upravo forme vibriranja – „vlastito ja objekta“.

Dakle, može se zaključiti da se nezavisnim uzbudama dobiva spoznaja entiteta kojeg ispitujemo.

- d) Slučaj (IIB). Kad bi u ovom slučaju postojao nezavisni promatrač on bi promatrajući odzive mogao samo zaključiti da konstrukcije nema i to iz jednostavnog razloga jer nema nikakve povezanosti između varijabli. Da bi se stvorio takav privid mi moramo djelovati neslučajno. Drugim riječima ovakvo ponašanje **negira objekt !** Osim toga vidjelo se da je η_{sp} gotovo jednak nuli što znači da nas objekt „uopće ne razumije“, te ovakvo djelovanje zasigurno **vodi raspadu objekta**. U ekstremnom slučaju primjer za ovo je idealan servo sustav ! Idealan servo sustav imao bi pomake totalno neovisne o konstrukciji i ovisio bi samo o npr. čovjeku koji njime upravlja. Ovo je lokalno točno, no ako proširimo prostor proučavanja, tada ovaj zaključak nije točan, jer ako se uzme cjelokupna konstrukcija vrlo vjerojatno mi ćemo prigušivati samo neko manje važno ponašanje cjelokupne konstrukcije.

Nameće se zaključak da je slučaj (IIB) dijametralno suprotan slučaju (IIA). Dakle u slučaju (IIB) sve spoznaje objekta se ignoriraju.

7. 3. Kako postupati po općoj teoriji spoznaje ?

Spoznajni pristup, za razliku od kibernetičkog u središte proučavanja stavlja objekt. Proučavaju se njegove spoznaje.

U okviru (II) može se reći da su ekstremi spoznajnog pristupa slučajevi (IIA) i (IIB) dok je „sredina“ ustvari „pravi“ spoznajni pristup. Konkretno, to znači da npr. iz konstrukcije izdvojimo recimo masu 2 i 3 te masu 4 i masu 5. Ova 4 elementa zajedno stvaraju nadentitet koji ima integrirane spoznaje svih početnih masa. Jedan bitni zadatak bio bi proučavanje kako se pojedini subsegment uklopio u novi objekt, koliki je npr. η_{sp} subsegmenta masa 2 i 3 u novoj konstrukciji. Ideal je naravno da je $\eta_{sp} = 1$!

Kao posljedica ovakvog pristupa javila bi se potreba da se regulator projektira sukladno spoznaji objekta dakle s ciljem da zadovolji glavni takson (!), a ne sukladno željama izvana ! Ovo je u potpunoj suprotnosti sa kibernetičkim pristupom !

To u konkretnom primjeru (ali i općenito) stavlja naglasak općenito na topologiju, te otkrivanje koji parovi objekata imaju željeno ponašanje – svrha stroja.

Ponašanje u skladu sa formama vibriranja ne treba nužno shvatiti negativno, uostalom 1. forma vibriranja ruke manipulatora je upravo pomak ruke, a to je ono što i želimo, to je ono što je svrha stroja. Tako se vjerojatno može reći da se u automatici i danas prigušuju ona, uglavnom minorna neželjena ponašanja.

No zar nije tako i u „običnom“ životu ? Neka za primjer posluži „projekt“ čovjek. Dok je dijete malo „ugrađuju“ mu se obrasci ponašanja, omogućuje mu se razvoj, ali isto tako koji put se poseže za „regulacijskim djelovanjem“ prema „objektu“ tj. djetetu kada npr. napravi kakvu nepodopštinu. Ali u suštini to ne smije biti pravilo ! Jer inače „objekt“ usvoji načine (tipove) ponašanja koje treba stalno ispravljati, što u ekstremnim primjerima vodi prema „policijskoj regulaciji“.

Ovakvim pristupom se „briše“ razlika između dinamike i statike; svi su objekti dinamički i kao takvi se i trebaju od početka projektirati. Dakako da ovakav zahtjev nije nimalo jednostavan i da će u konačnici uvijek postojati potreba za korekcijom, **samo ta korekcija treba biti u skladu sa spoznajom stroja, a spoznaja stroja mora bit u skladu sa željenom svrhom !**

U protivnom radimo ili destrukciju stroja ili pak destrukciju korisnika stroja – dakle samih sebe !

7. 4. Dodatni osvrt na neke tvrdnje

U poglavlju 2.7. *Temeljni pojmovi* definiran je prostor egzistencije. On je od izuzetnog značenja. U idealnom (100 % obješnjenoj varijaciji entiteta) slučaju definicijom prostora egzistencije sve je apsolutno determinirano: znamo odrediti u kojoj mjeri neki novi entitet pripada proučavanom prostoru, ali isto tako može se odrediti kako će izgledati neki novi entitet po pravilima proučavanog prostora.

Slično tome i u neidealnom slučaju (objašnjenoj <100%) greška proučavanja je poznata, što je izuzetno važno; ako želimo možemo daljnim istraživanjima tu grešku po želji smanjiti !

No, ako su pravila uvijek ista (kao što se u ovom radu tvrdi), **dovoljno je samo odrediti dimenziju prostora i sve bitno je poznato** !! Npr. ako se proučava 18 – dimenzionalni prostor tada se znaju pravila, „samo“ ih preba znati preslikati na željeni prostor proučavanja, kao npr u [8] gdje je izvršeno preslikavanje unutar određenih područja. Uz određene modifikacije (primjer 1) ovo odgovara 3. razini *opće teorije spoznaje*. Uz precizniji matematički aparat može se uspostaviti (jednoznačno) preslikavanje između 3. razine i konkretne razine nekog MDS objekta.

Ovo preslikavanje je već načinjeno u područje koje nema nikakve direktne veze sa tehničkim područjem općenito. To se može vidjeti u radovima [30, 31]. Osim toga u radovima [32, 33] dobijeni su i procesi ostalih razina, sve do zadnje globalne gdje je dobivena i krivulja platoa učenja. Isti rezultati se dobiju i sa entitetima iz ovog rada, ali zbog nekih manjih nedorečenosti ovdje nisu prikazani.

Primjetimo još da nakon što je određen prostor egzistencije entiteta – sve je određeno. **To što smo tražili više mehanizme urađeno je iz isključivog razloga jer nam nisu bile jasne promatrane varijacije. Dakle istina (spoznaja) tog prostora je postojala čim su postojali entiteti koji su taj prostor fizički „ispunili“, samo nama nije bila vidljiva !** Kako se proučavalo sve – **globalna spoznaja (istina) postoji stalno, samo je mi konkretno iz nekog razloga ne možemo vidjeti !!** Ovo je u potpunoj suprotnosti sa konstatacijom iz [17] da se istina ne može utvrditi i da postoji samo dok se dešava. Baš naprotiv, ona je stalno tu, sve se dešava u skladu sa njom, **a to što je mi ne možemo prepoznati, za postojanje same istine je potpuno nevažno.** Ovakvo razmišljanje podsjeća na teoriju determinističkog kaosa (*poglavlje 6.2.1. Druga razina opće spoznajne teorije*) gdje se praktično kad nešto konkretna osoba ne zna riješiti – proglašava nerješivim.

Ovo se može opisati još jednim primjerom. Postoji li katapult i danas ? U fizičkom obliku možda u nekom muzeju, ali načelno ne. Međutim u spoznajnom smislu postoji itekako ! Jer što katapult predstavlja ? On predstavlja spoznaju o naglom oslobađanju potencijalne energije te njenom pretvaranju u kinetičku energiju koju kasnije koristimo za destrukciju protivnika. Dakle, bez dijela destrukcije katapult postoji i danas u svakoj srednjoj školi u kojoj se uče osnove fizike – dakle istina katapult je prisutna bez obzira je su li učenici u konkretnoj školi napravili katapult ili ne !

Čini se da je ovime zaokružena cjelina ovog rada. U tom smislu budućnost ovog pristupa će se vjerojatno odvijati u tri pravca: dovršetak definicije procesa (1, 2 i 3 razina *opće teorije spoznaje*), provjera u drugim prostorima te po autoru možda najvažniji dio: pronalaženje **čvrstih matematičkih temelja teorije.**

8. ZAKLJUČAK

Zadatak ovog rada je bio „*Analiza modela upravljanja i regulacije u općoj teoriji spoznaje*“. Da bi se ovaj zadatak uspješno riješio bilo je potrebno naprije postaviti *Opću teoriju spoznaje*, te nakon toga predstaviti model upravljanja i regulacije pomoću postavljene teorije. Stoga se u prvom dijelu rada postavila teorija. U drugom dijelu su prepoznati djelovi postojećih pristupa u spoznajnoj teoriji. Na kraju, u trećem dijelu dana su dva konkretna primjera. U prvom primjeru je predstavljen opis p2 člana pomoću *opće teorije spoznaje*. U drugom primjeru su izvršene dopune *teorije* te je predložen *spoznajni* pristup proučavanju dinamičkih sustava koji se gotovo u pravilu susreću u tehničkim znanostima, a samim time i u automatskoj regulaciji. Predložen je novi opći i od projektanta nezavisni kriterij vrednovanja dinamičkih konstrukcije - η_{sp} .

Postavljanje teorije je krenulo od maksimalnog poopćenja. Postavljeni su osnovne premise, postavljen je model, odabran je skup varijabli za opis te su prikazani rezultati.

U poglavlju 6.1. **postavljena je Opća teorija spoznaje:**

1. **Postoje opće zakonitosti koje važe uvijek i svugdje**
2. **Generalna zakonitost jest spoznaja**
3. **Postoje hijerarhijski niže rangirane, međuovisne spoznaje**

Teorija je definirana i sa pozicije **entiteta**, a koja je, naravno analogna predhodnoj definiciji. Ona tada glasi:

1. **Postoje entiteti koji su kreirani po općim zakonitostima**
2. **Cilj svakog entiteta jest maksimalna spoznaja**
3. **Entitet je strukturiran međuovisnim hijerarhijskim razinama**

S obzirom da je glavno pravilo, vrhunac *globalna spoznaja*, glavni cilj svih entiteta je upravo maksimalna spoznaja, tj. **teleološki cilj svakog entiteta jest spoznati sve !** Gledano sa pozicije **spoznaje entiteti su mjesta operacionalizacije spoznaja.**

Smatra se da se **svi** pristupi mogu objasniti preko teorije. U poglavlju 6.2. prikazane su ostale prepoznate razine spoznajne teorije, a s obzirom da je intencija *teorije* da bude **opća** kroz primjere je prikazano koji se dijelovi već koriste, te predloženi neki novi pristupi.

U poglavlju 6.4., *slika 6.4.1.* prikazana je hijerarhija „*Spoznaja*“. Tamo je prikazano da se u **teoriji spoznaje znanstveni rad prepoznaje kao napredovanje od nižih razina prema višima.** Suprotno tome, **stručni rad se prepoznaje kao kretanje od opće spoznaje prema konkretnom entitetu/proizvodu u koji ugrađujemo svoje spoznaje (tehnologija).**

Kibernetika kao znanstvena disciplina prepoznata je na trećoj razini - pravilo *Perzistencija*. Drugim riječima temeljna funkcija kibernetike je održavanje **postojećeg stanja**, tj. funkcije objekta. **Sve što narušava postojeću funkciju objekta proglašava se nepoželjnim** te eliminira regulacijskim krugom.

S druge strane *opća teorija spoznaje* ne poznaje pojam okoline već se kao prostor proučavanja uzima **sve** pa dakle i okolinu. No tada više nema slučajnih poremećaja; to su sve drugi entiteti u okolini, samo ih treba prepoznati te tek onda odlučiti je li riječ o nepoželjnom djelovanju ili je pak u pitanju potencijalni „partner“ za neki novi zajednički entitet ili možda neka nova spoznaja. O ovome se brine dio koji je prepoznat kao edukatibilnost.

Jedna od najvećih razlika u odnosu na dosadašnje razmišljanje je pojam *upravljivosti* koji se poima na jedan potpuno drugačiji način – kroz internu reorganizaciju. No, i ovdje se na negativnoj strani *upravljivosti* definira *elementarnost* koja podrazumjeva da se pravila ponašanja unose izvana – isto kao kod kibernetike gdje se logika regulatora definira izvana. No, ekvivalent pozitivne strane upravljivosti nije pronađen – ono podrazumjeva **internu reorganizaciju entiteta u skladu sa novim spoznajama te općenito ponašanje entiteta u skladu sa svojim spoznajama**.

Ovo znači i da je na istom pravilu prepoznata automatska regulacija. Sukladno rezultatima *teorije u Primjeru 2* je predložen drugačiji pristup u automatskoj regulaciji, gdje je **predložen i objektivni kriterij kvalitete objekta u dinamičkom okruženju. Drugim riječima predlaže se napuštanje koncepta objekt regulacije + regulator te predlaže integralni pristup.**

Pokazana je i „neminovnost“ ovakvog pristupa npr. kroz primjer spoznajnog napredovanja zgrade. Ako pozovemo u pomoć ljude i njihovo odrastanje automatska regulacija će sve više proizvoditi objekte koji polako ali sigurno ulaze u „pubertet“ tj. **neminovno dolazi vrijeme kada će strojevi koje smo proizveli početi pokazivati nove, u vrijeme projektiranja nepoznate a možda i „nepoželjne“ načine ponašanja.** Ako je analogija sa ljudima potpuna a vrlo vjerojatno jest, onda je pred nama buran razvoj objekata ili bolje rečeno entiteta. No, ako je izrečeno točno, to znači da i samu **automatsku regulaciju čeka interna reorganizacija** (koja se i predlaže), naravno sa ciljem da bi mogla odoljeti novim izazovima.

Na drugoj razini je prepoznata Teorija kaosa kao negativan pol (*dezintegracija*) pravila nazvanog *determinizam*.

Na samom kraju je kao **VRHUNAC SVEGA** smještena **SPOZNAJA** dok je na njenom pozitivnom kraju **GLOBALNA SPOZNAJA** prepoznata **ZNANSTVENA ISTINA** ili kraće

ISTINA.

9. LITERATURA

- [1] Šurina T. Automatska regulacija. Školska knjiga. 1991. Zagreb.
- [2] Novaković B. Regulacijski sistemi. Fakultet strojarstva i brodogradnje. 1990.
- [3] Novaković B. Metode vođenja tehničkih sistema. Školska knjiga. 1990.
- [4] Novaković B. Majetić D. Široki M. Umjetne neuronske mreže. Fakultet strojarstva i brodogradnje. 1998.
- [5] Bing Chen, Xiaoping Liu, Kefu Liu, Chong Lin. Direct adaptive fuzzy control of nonlinear strict-feedback systems. *Automatica* 45 (2009) 1530_1535. http://flash.lakeheadu.ca/~kliu/automatica_2009_2.pdf
- [6] Hayakawa, T.; Haddad, W.M.; Hovakimyan, N.; Neural Network Adaptive Control for a Class of Nonlinear Uncertain Dynamical Systems With Asymptotic Stability Guarantees *Neural Networks, IEEE Transactions on*. Vol. 19 Issue:1. 2008.
- [7] Kirola M., Novaković B. Samoorganiziranje neizrazitog analitičkog regulatora pri vođenju mobilnog robota. *Strojarstvo* 51 (1) 49-62 (2009) http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=66522
- [8] Kecman V. Dinamika procesa
- [9] Robert Cupec, Günther Schmidt . Prikaz slobodnog prostora za dvonožne hodajuće robote. *Automatika*. Vol.50 No.1-2 Travanj 2009.
- [10] Rojko A., Šafarić R., Jezernik K. Primjena tehnika mekog računalstva za upravljanje gibanjem robota. *Automatika*. Vol.48 No.3-4 Studeni 2007
- [11] Youmin Zhang, Jin Jiang. Bibliographical review on reconfigurable fault-tolerant control systems. *Annual Reviews in Control* 32 (2008) 229–252. http://users.encs.concordia.ca/~ymzhang/publications/ARC32-2-98Zhang_pp.229-252.pdf
- [12] Lotfi A. Zadeh. Is there a need for fuzzy logic? *Information Sciences* 178 (2008) 2751–2779 <http://www.soshianest.com/Downloads/Fuzzy%20Logic.pdf>
- [13] Brooks, Rodney A. A Robot that Walks: Emergent Behaviors from a Carefully Evolved Network. <http://hdl.handle.net/1721.1/6500>
- [14] Grlić D. Filozofija. Panorama. 1965. Zagreb.
- [15] * * *. Wikipedija. <http://bs.wikipedia.org/wiki/Epistemologija>
- [16] Dancy J. Uvod u suvremenu epistemologiju. Sveučilište u Zagrebu Hrvatski studiji. 2001. Zagreb.
- [17] Pivčević E. Što je istina ?. Sveučilište u Zagrebu Hrvatski studiji. 2002. Zagreb.
- [18] Sullivan, Pat Madden. What is the human race meant to be? What is our potential?. *Proceedings (Academy of Religion & Psychical Research)*;2004, p159 <http://connection.ebscohost.com/c/articles/14584505/what-human-race-meant-be-what-our-potential>
- [19] Zeigler D. An Incomprehensible Universe. *Skeptic*;2011, Vol. 16 Issue 2, p31. 2011. <http://connection.ebscohost.com/c/articles/58478725/incomprehensible-universe>
- [20] Nazor M. Psihologija odgoja i obrazovanja. Fakultet prirodoslovno matematičkih znanosti i kineziologije sveučilišta u Splitu. 2007. Split.
- [21] Overskeid, Geir. Empirically understanding understanding can make problems go away: the case of the chinese room. *Psychological record*;fall2005, vol. 55 issue 4, p595. 2005. <http://connection.ebscohost.com/c/articles/18717103/empirically-understanding-understanding-can-make-problems-go-away-case-chinese-room> i <http://opensiuc.lib.siu.edu/cgi/viewcontent.cgi?article=1203&context=tpr>
- [22] * * *. http://en.wikipedia.org/wiki/Ultimate_fate_of_the_universe

- [23] Kintsch, Eileen. Comprehension Theory as a Guide for the Design of Thoughtful Questions. Lippincott Williams & Wilkins
http://www.eric.ed.gov/ERICWebPortal/search/detailmini.jsp?_nfpb=true&_ERICExtSearch_SearchValue_0=EJ712700&ERICExtSearch_SearchType_0=no&accno=EJ712700
- [24] By Landauer, Thomas K.; Dumais, Susan T. A solution to Plato's problem: The latent semantic analysis theory of acquisition, induction, and representation of knowledge. *Psychological Review*, Vol 104(2), Apr 1997, 211-240.
[10.1037/0033-295X.104.2.211](http://dx.doi.org/10.1037/0033-295X.104.2.211)
- [25] Carev Z. Bonacin D. Global Comprehensive Theory. *Journal of Theoretic*. Volume 6-4, Aug/Sept 2004.
<http://d1002391.mydomainwebhost.com/JOT/Links/Papers/Bonacin02.pdf>
- [26] Bonacin D. Carev Z. The Universal Methodology of Process Identification. *Journal of Theoretic*.
<http://d1002391.mydomainwebhost.com/JOT/Articles/6-4/carevjot-final.pdf>
- [27] Carev Z. Opća uloga i pozicija senzora u sustavima prepoznavanja, nadzora, regulacije i upravljanja. Seminarski rad. 2001.
- [28] Carev Z. Opće zakonitosti procesa kao pojma i zakonitosti dinamike. Seminarski rad. 2001.
- [29] Mišković N., Vukić Z., Barišić M. Identifikacija bespilotnih ronilica korištenjem postupka vlastitih oscilacija. *Automatika*. Vol.50 No.3-4 Prosinac 2009.
http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=73156
- [30] Bonacin D. Identifikacija restrukturiranja taxona biomotoričkih dimenzija djece uzrasta 7 godina pod utjecajem transformacijskih procesa. Doktorat. 2004.
<http://www.dbonacin.com/DOBROMIR/PDFS/Doktorat.pdf>
- [31] Bonacin D. Blažević S. Carev Z. Global Comprehensive Theory In Kinesiological Learning Methods. Daegu universiade conference. Korea. 2003.
<http://www.dbonacin.com/DOBROMIR/PDFS/Daegu2003-1.pdf>
- [32] Bonacin D. Univerzalna spoznajna načela egzistencije procesa. II International symposium of New Technologies in Sport Sarajevo. 2007.
<http://www.dbonacin.com/DOBROMIR/PDFS/NTS2007-1.pdf>
- [33] Bonacin D. Carev Z. Blažević S. Utvrđivanje apsolutnih procesa kao temelja svih vrednovanja u kineziologiji. 13. ljetna škola kineziologa Republike Hrvatske. Rovinj. 2004.
<http://www.dbonacin.com/DOBROMIR/PDFS/Rovinj2004-1.pdf>
- [34] Bonacin D. Determinizam i kaos. Simpozij „Čovjek i moderni svijet“. Sarajevo.
<http://www.dbonacin.com/DOBROMIR/PDFS/SaModerniSv-1.pdf>
- [35] Bonacin D. Carev Z. Process identification. *Kinesiology new perspectives*. 3. International Scientific Conference. Opatija, 2002.
<http://www.dbonacin.com/DOBROMIR/PDFS/Opatija2002-1.pdf>
- [36] Bonacin D. Univerzalnost procesa. *New Technologies in Sport – 3rd International Symposium*. 2009. <http://www.dbonacin.com/DOBROMIR/PDFS/NTS2009-1.pdf>
- [37] Carev Z., Bonacin D., Blažević S. Constructive and Destructive Kinesiological Processes. Daegu universiade conference. Korea. 2003.
<http://www.dbonacin.com/DOBROMIR/PDFS/Daegu2003-2.pdf>
- [38] * * * http://hr.wikipedia.org/wiki/Teorija_kaosa

KRATKI ŽIVOTOPIS

1. Formalna edukacija:

Rođen 14. veljače 1967. g. u Splitu. Srednju tehničku školu završio je u Splitu te 1985. godine i stekao zvanje „Elektromehaničar za dizala i transportere“. Na Fakultetu elektrotehnike strojarstva i brodogradnje u Splitu 1992. g. diplomirao na zadacima i problemima simulacije rada diesel motora, te stekao zvanje Diplomirani inženjer strojarstva. Položio tečaj za računalnog operatera sa upisom u radnu knjižicu 2003. godine. Na prirodoslovno matematičkom fakultetu u Splitu 2010. g. završio Dopunsko pedagoško – psihološko – didaktičko – metodičko obrazovanje po bolonjskom procesu te stekao 60 ETCS bodova. Upisuje edukacijski fakultet u Travniku smjer Matematika – Informatika te 2011.g. postaje apsolvent.

2. Radno iskustvo:

Radno iskustvo od cca 6 godina stekao je na slijedećim poslovima: Projektant u Monter Split, Informatičar i Rukovoditelj automatske obrade podataka u Jadrantrans Split d.d. Jednu školsku godinu obavljao posao profesora strojarske grupe predmeta u srednjoj strukovnoj školi „Blaž Jurjev Trogirani“ u Trogiru, pola školske godine poslove profesora matematike u srednjoj elektrotehničkoj školi u Splitu. Povremeno na više mjesta obavljao i poslove profesora matematike, fizike, informatike te tehničkog odgoja.

3. Ostalo:

Predavač u PC školi (Kaštela) s dozvolom nadležnog Ministarstva za upis u radnu knjižicu, neko vrijeme aktivan sportaš u košarci i nizu drugih aktivnosti. Neoženjen. Aktivno se služi engleskim jezikom.

4. Publikacije

Članci u časopisima:

- Carev, Z., & Bonacin D. (2004). Global Comprehensive Theory. *Journal of Theoretics*. 6(4), Aug/Sept 2004.
- Bonacin, D., & Carev, Z. The Universal Methodology of Process Identification. *Journal of Theoretics*.
- Bonacin, D., & Carev, Z. (2010). The universal methodology of process identification, *Sport Science*, 3(1), 58-64 (Reprint). /A1/

Priopćenja na skupovima:

- Bonacin, D., & Carev, Z. (2002). Process identification. *Kinesiology new perspectives*. 3. *International Scientific Conference*. Opatija, Proceedings: 632-635. /A1/
- Bonacin, D., Blažević, S., & Carev, Z. (2003). Global comprehensive theory in kinesiological learning methods. *Daegu Universiade conference, Korea*, Proceedings: 696-702.
- Carev, Z., Bonacin, D., & Blažević, S. (2003). Constructive and Destructive Kinesiological Processes. *Daegu Universiade conference, Korea*, Proceedings: 681-685.
- Bonacin, D., Carev, Z., Blažević, S., & Kovačević, K. (2003). Opća spoznajna teorija u definiciji metoda učenja u kineziologiji. *Metode rada u području edukacije, sporta i sportske rekreacije*. 12. ljetna škola kineziologa R. Hrvatske, Rovinj, Zbornik radova: 116-118.

Bonacin, D., Carev, Z., & Blažević, S. (2004). Utvrđivanje apsolutnih procesa kao temelja svih vrednovanja u kineziologiji. *13. ljetna škola kineziologa Republike Hrvatske. Rovinj*. Zbornik radova: 420-424.

Knjige:

Bonacin, D., & Carev, Z. (2001). *Mreža*. Kaštela: Vlastito izdanje.

Recenzije udžbenika:

Katić, R., & Bonacin, D. (2001). *Kineziologija za sva vremena*. Split: PMF.

Bonacin, D., Katić, R., & Zagorac, N. (2001). *Model kineziološke edukacije*. Split: PMF.

SHORT BIOGRAPHY

1. Formal education:

Born on February 14th 1967 in Split. Graduated from Secondary Technical School in Split in 1985 obtaining the degree of Electromechanical operator for elevators and transporters. At the University of Split, Faculty of Electrical Engineering, Mechanical Engineering and Naval Architecture, he graduated in 1992 on the tasks and problems in simulation of diesel engine, obtaining the degree of mechanical engineer. Finished the course for computer operator in 2003. On the Faculty of Mathematics in Split in 2010 finished additional pedagogical-didactic-methodical psychological education according to the standard Bologna Process acquiring 60 ECTS points. Enrols in the Faculty of Education in Travnik, Bosnia and Herzegovina, course Mathematics and Information Technology, and in 2011 becomes senior student qualified to sit for his degree exams.

4. Work experience:

Work experience of about six years he acquired working the following jobs: designer in Monter Split, informatician and head of automatic data processing in Jadrantrans Split d.d. For one school year worked as a teacher of mechanical group of subjects in the Secondary school for vocational training "Blaž Jurjev Trogiraniin" in Trogir. Half of school year worked as a teacher of mathematics in the Secondary electrotechnical school in Split. Occasionally worked in different schools as a teacher of mathematics, physics, informational technology, and design and technology.

5. Other:

Teacher in PC school (Kaštela) with the permit from the competent Ministry, for a while an active basketball player and many other activities. Single. Can actively use English language.

Publications:

Articles in magazines:

Carev, Z., & Bonacin D. (2004). Global Comprehensive Theory. *Journal of Theoretics*. 6(4), Aug/Sept 2004.

Bonacin, D., & Carev, Z. The Universal Methodology of Process Identification. *Journal of Theoretics*.

Bonacin, D., & Carev, Z. (2010). The universal methodology of process identification, *Sport Science*, 3(1), 58-64 (Reprint). /A1/

Announcements at conferences:

Bonacin, D., & Carev, Z. (2002). Process identification. *Kinesiology new perspectives*. 3Rd International Scientific Conference. Opatija, Proceedings: 632-635. /A1/

Bonacin, D., Blažević, S., & Carev, Z. (2003). Global comprehensive theory in kinesiological learning methods. Daegu *Universiade conference, Korea*, Proceedings: 696-702.

Carev, Z., Bonacin, D., & Blažević, S. (2003). Constructive and Destructive Kinesiological Processes. Daegu *Universiade conference, Korea*, Proceedings: 681-685.

- Bonacin, D., Carev, Z., Blažević, S., & Kovačević, K. (2003). Global Theory of Comprehension in the Definition of Learning Methods in Kinesiology. *Methods of work in the field of Education, Sports and Sport Recreation. 12th summer school of Kinesiology of the Republic of Croatia*. Rovinj, Collection of papers: 116-118.
- Bonacin, D., Carev, Z., & Blažević, S. (2004). Establishing the absolute processes as a foundation of all evaluations in Kinesiology. *13th summer school of Kinesiology of the Republic of Croatia*. Rovinj. Collection of Papers: 420-424.

Books:

Bonacin, D., & Carev, Z. (2001). *The Network*. Kaštela: Personal publication.

Course book reviews:

Katić, R., & Bonacin, D. (2001). *Kinesiology for all times*. Split: PMF

Bonacin, D., Katić, R., & Zagorac, N. (2001). *The Model of Kinesiologic Education*. Split: PMF.