

UNIVERZITET SINGIDUNUM
BEOGRAD
DEPARTMAN ZA POSLEDIPLOMSKE STUDIJE I
MEĐUNARODNU SARADNJU

- DOKTORSKA DISERTACIJA -

**NOVI MODEL ANALOGIJE
VEŠTAČKIH I BIOLOŠKIH KOGNITIVNIH STRUKTURA
BAZIRAN NA SVOJSTVIMA FRAKTALNE MODULARIZACIJE
CELULARNIH NEURALNIH MREŽA**

Mentor:
prof. dr Miroslav Lutovac

Kandidat:
mr ing. Pavle Kostić

Beograd, 2015. godina

Sadržaj

1	Uvodna razmatranja.....	1
1.1	Struktura disertacije	1
1.2	Aktuelnost teme	3
1.1	Značaj teme	5
1.3	Hipoteze, cilj i metode istraživanja.....	7
2	Fraktalna modularizacija u veštačkim Celularnim neuralnim mrežama (CNM)....	11
2.1	Ključni pojmovi i definicije	11
2.2	Celularne neuralne mreže (CNM).....	16
2.3	Fraktalna modularnost u veštačkim celularnim nerualnim mrežama	20
2.4	Klase fraktalno-modularnih CNM sa složenim bihevioralnim karakteristikama .	23
3	Pregled savremenih istraživanja iz oblasti neuronauka	33
3.1	Metodologija sistematskog pregleda i meta-analize	33
3.2	Modularnost i fraktalnost u neurokognitivnim strukturama	34
3.3	Prostorno-vremenska dinamika u neurokognitivnim sistemima.....	46
4	Identifikacija bitnih karakteristika sličnosti bioloških neurostrukura sa fraktalno-modularnim CNM.....	74
4.1	Klasifikacija bitnih karakteristika i svojstava neurostruktura	74
4.2	Strukturalne karakteristike i organizaciona svojstva (neuroanatomske osobine) .	76
4.3	Funkcionalne karakteristike i dinamička svojstva (nurofiziološke osobine)	84
4.4	Bihevioralne karakteristike (neuropsihološke osobine)	91
4.5	Rekapitulacija.....	96
5	Analogije na nižim nivoima kognitivnih procesa (sličnost funkcionalnih modela nekih klasa fraktalno-modularnih CNM sa identifikovanim biološkim strukturama)	97
5.1	Model funkcionalne analogije bioloških neurokognitivnih sistema i fraktalnom-modularnih CNM	97
5.2	Homogenizacija modela (informaciono enkodiranje).....	100
5.3	Linearizacija (aproksimacija u režimu malih signala)	103
5.4	Rekapitulacija.....	106

6	Analogije na višim nivoima kognitivnih procesa (bihevioralna sličnost višeslojnih frkatalno-modularnih CNM i hijerarhijeske anatomije viših kognitivnih nivoa mozga)	107
6.1	Model bihevioralne analogije bioloških i fraktalno-modularnih CNM na višim kognitivnim nivoima	108
6.2	Funkcionalna (komputaciona) neurodinamička energija	111
6.3	Neurooscilacije.....	113
6.4	Talasi.....	116
6.5	Rekapitulacija.....	118
7	Zaključak i završna razmatranja.....	120
7.1	Konceptualne postavke i izvorište teze.....	121
7.2	Rezultati i potvrda teze	125
7.3	Primenjivost rezultata	127
7.4	Nastavak razvoja modela i pravci daljih istraživanja.....	128
7.5	Zaključna diskusija	131
8	Literatura	134
9	Prilozi	151
9.1	Prilog 1: Celularne neuralne mreže – osnovni pojmovi i definicije	151
9.2	Prilog 2: Fraktalna modularizacija u CNM.....	157
9.3	Prilog 3: Firing-rate (FR) model neurona	167

1 Uvodna razmatranja

Predmet istraživanja ove disertacije je novi model analogije fraktalno-modularnih veštačkih celularnih nerualnih mreža - CNM (i srodnih informaciono-procesnih struktura uopšte) i bioloških neuralnih odnosno neurokognitivnih (moždanih) struktura.

Razvoj novih biomedickinskih tehnologija i značajan progres u oblasti neuronauka donosi nova saznanja o neuroanatomskim svojstvima i neurofiziološkim procesima u mozgu, ali sveobuhvatno sagledavanje načina funkcionisanja kognitivnih procesa i mozga uopšte je još uvek vrlo kompleksno pitanje. Čak i na najnižim nivoima neuralnih struktura, pojedinačnih neurona ili grupa, formalno matematičko modelovanje je vrlo složeno jer se *de facto* radi o problemu reverznog inženjeringu odnosno modelovanju „crne kutije“ (sistema koji se može meriti spolja ali nije poznata njegova potpuna unutrašnja struktura i/ili egzaktan matematički model). Sa druge strane, veštačke neuronske strukture poput fraktalno-modularne veštačke celularne neuralne mreže, imaju jasnu strukturu, opisuju se egzaktnim fizičko-matematičkim modelima, imaju razumljiva i predvidiva ponašanja.

Traženje sličnosti i analogija veštačkih i bioloških neurostruktura stoga može doprineti da se formiraju novi teorijski i eksperimentalni modeli koji mogu dati nove poglede ili objašnjenja za funkcionisanje neurokognitivnih struktura pa i samog mozga kao celine. U ovoj disertaciji se analiziraju domeni i kriterijumi tih sličnosti, formuliju analogije i pokazuju na primerima nekih klasa fraktalno-modularnih veštačkih celularnih neuralnih mreža i bioloških neurokognitivnih struktura.

1.1 Struktura disertacije

Disertacija je strukturirana kroz uvod, pet poglavlja i zaključak.

U uvodnom razmatranju ukratko je izložen problem koji će se razmatrati u ovoj disertaciji. Uvod sadrži opšte podatke o statusu ovog problema u svetu. Metodološki pristup, kao i struktura rada izneti su u uvodnom razmatranju.

U okviru prvog poglavlja dat je uvod u celularne neuralne mreže (*Cellular Neural Networks - CNM*), osnovne teorijske modele i svojstva koja ih karakterišu i čine specifičnim u odnosu na druge veštačke neuralne mreže i srodne strukture (celularne automate i sl.). Definisana je *fraktalna modularizacija* kao paradigma u celularnim neuralnim mrežama. Dat je pregled konkrentih klasa fraktalno-modularnih veštačkih celularnih nerualnih mreža koje će biti osnova za metodološko istraživanje analogije sa biološkim strukturama.

Drugo poglavlje sadrži pregled istraživanja iz oblasti neuronauka a koja su izvršena u poslednjih desetak-dvadeset godina, dakle u periodu nakon ranije navedenih rezultata u oblasti frakdale modularizacije u celularnim neuralnm mrežama. Akcenat je na praćenju progrsa u sagledavanju topoloških i funkcionalnih svojstava na različitim nivoima korteksa i neurofizioloških struktura, identifikaciji funkcionalnih i procesnih modela, kao i interpretaciji tih rezultata u smislu približavanja matematičkom modelovanju kao osnovi za egzaktno posmatranje i razumevanje bihevioralnih svojstava kognitivnih procesa.

Treće poglavlje je posvećeno identifikaciji bitnih topoloških, funkcionalnih, procesnih (bihevioralnih) i drugih karakteristika bioloških struktura različitih nivoa (od retine, preko primarnog vizuelnog korteksa pa do viših kognitivnih nivoa mozga) koji se uočavaju ili imaju sličnosti sa fraktalno-modualrnim strukturama veštačkih celularnih neuralnih mreža. Kroz analizu tih sličnosti, definišu se parametri i karakteristike koje služe kao kriterijumi analogije veštačkih i bioloških struktura i sistema.

Četvrto poglavlje izvodi analogije nekih klasa fraktalno-modularnih veštačkih celularnih nerulanih mreža sa biološkim strukturama (nižih i srednjeg nivoa) kod kojih postoje identifikovani kriterijumi sličnosti fizičkih (dinamičkih, prostorno-vremenskih) odnosno funkcionlanih i topoloških (neuroanatomskih) modela (koji se mogu matematički opisati).

Peto poglavlje se bavi analogijom na višim nivoima kognitivnih procesa, kod kojih se analogija ne može bazirati direktno na matematičkim modelima (specifično jer ne postoje sveobuhvatni matematički modeli neuropsiholoških procesa na višim nivoima bioloških kognitivnih struktura odnosno „svesti“). Pokazuje se bihevioralna sličnost višeslojnih fraktalno-modularnih veštačkih celularnih neuralnih mreža i hijerarhijeske modularne strukture viših kognitivnih nivoa mozga (cerebralnog korteksa i sl.).

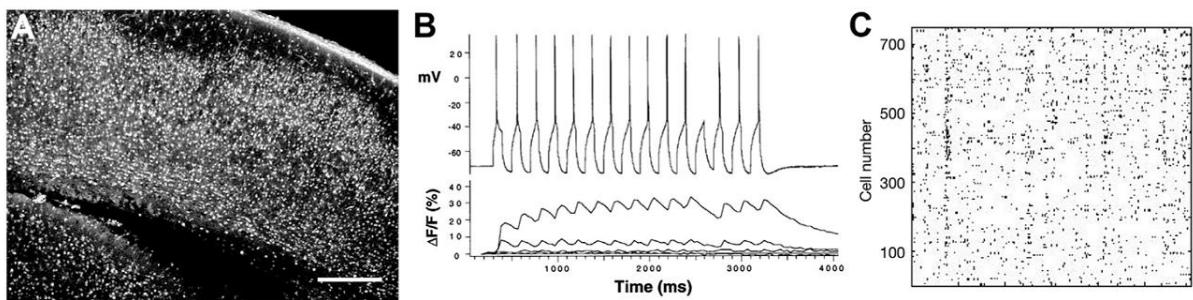
Na kraju disertacije iznet je zaključak sa mogućim pravcima daljih istraživanja u ovoj oblasti, kao i mogućnostima formiranja novih metodologija i eksperimentalnih modela neurofizioloških ili neuropsiholoških istraživanja baziranih na pokazanim analogijama sa veštačkim fraktalno-modularnim strukturama.

1.2 Aktuelnost teme

Razvoj novih biomedicinskih tehnologija u skorije vreme doprineo je naglog progresu u neuronaukama posebno u oblastima koje se bave fiziologijom i kognitivnim svojstvima neuralnih sistema (moždanih struktura poput vizuelnog i motornog korteksa i sl.). Kvantifikacija, merenje i napredno eksperimentalno sagledavanje biofizičkih procesa dovelo je do dubinskog razumevanja mnogih segmenata ovih fizioloških procesa (senzorskih stimulusa, prenosa tih stimulusa korz neuronske strukture, reakcije i ponašanja kako pojedinačnih tako i grupnih struktura i sl.) na raznim nivoima neurokognitivnih struktura ([1], [2]). Npr. iscrpno su istraženi procesi u retini oka ([3]), primarnom vizuelnom korteksu ([4]) itd. Sa druge strane, posmatranjem na višem nivou korteksa, proučavanje neuropsiholoških procesa i rekacija, učinjeni su značajni pomaci u razumevanju kognitivnih procesa - onoga što se često referiše i kao „svest“ [5]. I ovde su nove tehnologije doprinele da se mogu izvršiti egzaktna eksperimentalna testiranja i sagledavanja interoperabilnosti raznih nivoa i struktura neuroanatomije. Sve ovo je, važno je naglasiti, postalo moguće u zadnjih desetak godina, razvojem novih biomedicinskih tehnologija koje ranije nisu postojale uključujući i povećanje efikasnosti senzora, minijaturizacije, hibridne tehnologije, neuroprostetike i sl. koje omogućavaju interkonektivnost sa tkivom čak i na subcelularnom nivou, napredne obrade signala itd. ([6]).

Sistemski posmatrano, fiziološki procesi na nižim nivoima korteksa i kognitivni procesi na višim nivoima su međusobno povezani i uslovljeni ([7], [8]). To dovodi do problema u ne samo posmatranju i analizi već i u modelovanju tih procesa u terminima koji bi omogućili njihovu egzaktniju analizu i sintezu. Trenutno se veliki naporovi ulažu u matematičko odnosno „inženjersko“ modelovanje tih procesa na svim nivoima. Jedan od najvećih naučno-istraživačkih projekata u Evropskoj Uniji pod naslovom „Human Brain Project“ je upravo posvećen i ovoj temi ([9]). U okviru ovog projekta, posebna oblast se bavi upravo razvojem sveobuhvatne teorije funkcionalisanja mozga.

Ipak, iako su na rapsolaganju obilje novih podataka i mogućnosti za eksperimentalne analize, sistemsko modelovanje je vrlo složeno jer se radi o *de facto* reverznom inženjeringu ([10], [11], [12], [13]) - biološki sistemi se analiziraju „spolja“ (jer bi interferencija „unutar“ njih mogla dovesti do nepredvidivih poremećaja koji onda remete ili potpuno obespredmećuju eksperiment) odnosno inženjerski gledano predstavljaju „crne kutije“¹. Takve „komponente“ se sada zahvaljujući novim tehnologijama lakše identifikuju i mere se signali na njima (Slika 1), ali je njihova unutrašnja struktura i matematičko modelovanje još uvek veoma kompleksno ([14], [15], [16]). Dakle, savremena biomedicinska tehnologija je doprinela da se sada lakše uočava i identificuje topološka struktura (fizička povezanost) u neuroanatomskim sistemima, da se preciznije i pouzdanoji mere signali i posmatra vremensko-prostorna dinamika neurofizioloških signala, ali je i dalje vrlo aktuelno i otvoreno pitanje razumevanja unutrašnjih procesa, funkcionalnih i procesnih modela kako struktura na nižim nivoima (od pojedinačnih neuron, manjih grupa i struktura primarnih nivoa korteksa) tako i ukupnog funkcionalnog modela ka srednjim i višim strukturama gde se već govori o kognitivnim procesima odnosno svesnoj inteligenciji ([17]).



Slika 1: Nove neuroimaging tehnologije omogućavaju snimanje neuroaktivnosti pojedinačnih neurona u velikim strukturama in vivo i in vitro (preuzeto iz [16]). (A) Presek živog tkiva primarnog vizuelnog korteksa miša ekscitovanog indikatorom kalcijuma fura-2 AM. Više od hiljadu neurona su prepoznati i mogu biti snimljeni dvofotonskim mikroskopom (Yuste et al., 2011). (B) Koncentracija kalcijuma u somi neurona (donji grafik) verno prati povorku aktivacionih impulsa neurona (gornji grafik) (Smetters et al., 1999.). (C) Rekonstrukcija „rasterizacije“ spontane aktivnosti 754 neuronske celije iz sličnog eksperimenta (Cossart et al., 2003).

¹ „black box“ - sistem koji se može meriti spolja ali nije poznata njegova potpuna unutrašnja struktura i/ili egzaktan matematički model

Upravo zadnjih godina sve više dolazi do približavanja i čak spajanja trendova u proučavanju i analizi u neurofiziologiji i drugim neuronaukama sa procesima koji su decenijama postojali i razvijali se u oblastima nekih inženjerskih disciplina, posebno teoriji električnih kola, obrade signala, dinamičkim sistemima upravljanja i konačno u veštačkoj inteligenciji i posebno veštačkim neuralnim mrežama ([18]). Mnogi rezultati koju su u tim oblastima postignuti u naporima da se stvore veštački sistemi inteligentnog procesiranja signala i/ili informacija u opštem smislu, sada postaju aktuelni jer se može naći analogija sa biološkim strukturama i procesima koji se pojavljuju na horizontu istraživanja neuronauka.

1.1 Značaj teme

Celularne neuralne mreže (CNM, engl. *Cellular Neural Networks*) su posebna klasa veštačkih neuralnih mreža, najčešće posmatrano kao električna ili elektronska kola, koje se karakterišu svojstvom lokalne povezanosti procesorskih elemenata – „ćelija“ [19]. Osnovna ćelija („neuron“) CNM mreže je definisan kao jednostavna procesorska struktura, koja obrađuje analogne (kontinualne) ili diskretne signale (odnosno informacije u opštem smislu) [20]. Stabilnost i konvergentnost određenih klasa CNM je bazirana na striktno definisanim uslovima koje struktura CNM ćelije i njene povezanosti moraju ispunjavati i pod kojim uslovima važe matematički modeli koji garantuju kritična svojstva (konvergentnost i stabilnost izlaza odnosno rezultata procesiranja u konačnom vremenu) [21]. Ti matematički modeli, iako razvijeni za potrebe modelovanja električnih kola, imaju univerzalni karakter i mogu se implementirati i u drugim tehnologijama (npr. opto-elektronskim [22], kvantnim [23] i nano-tehnologijama [24], *soft-computing* sistemima [25] ili na drugi način koji se modeluje istim jednačinama stanja dinamičkog modela). Naravno, otvara se i pitanje mogućnosti sinteze odnosno formiranja takvih struktura i u biološkim sistemima ([26]) gde su prisutni slični ili analogni fizički procesi i interakcije.

Fraktalna modularizacija predstavlja generalizaciju osnovnog koncepta CNM u smislu da se umesto prostih „ćelija“ struktura mreže formira od manjih CNM modula (male CNM mreže) koji se povezuju na sličan način kao i ćelije CNM (lokalna povezanost u pravilnim i repetitivnim topološkim formama koje potsećaju na fraktalne strukture – otuda i naziv „fraktalna modularnost“ i „fraktalno-modularne strukture“) ([27], [28], [29]). Dakle, fraktalna modularnost je koncept koji omogućava formiranje složenijih neuro-procesnih struktura, koje

mogu ispoljavati daleko složenija svojstva u odnosu na „klasične“ CNM. Proces koji vodi do formiranja ovakve strukture, dekompozicijom složenog matematičkog modela koji opisuje ponašanje strukture odnosno u funkcionalnom smislu ima praktičnu primenu da vrši neku „inteligentnu“ obradu signala odnosno informacija, nazvan je *fraktalna modularizacija* i služi kao alat odnosno vodilja u inženjeringu fraktalno-modularnih struktura.

Gruba analogija je sa DNK lancima odnosno genomima, gde lokalno povezane repetitivne strukture ispoljavaju poznata i priznata memorijska svojstva u biološkim sistemima ([30]). Dok su ova memorijska svojstva statična, odnosno memorijski zapisi imaju invarijantan karakter (ne menjaju svoju informatičku sadržinu tokom vremena, što im je i funkcionalni zadatak odnosno ponašanje), fraktalno-modularni sistemi prvenstveno se karakterišu dinamičkim osobinama koje u funkcionalnom smislu imaju „inteligentna“ svojstva koja se manifestuju kroz ponašanja koja odgovaraju kognitivnim procesima (npr. vizija, orijentacija, optimalni izbor, ekstrapolacija i sl.).

Nova istraživanja upućuju da postoji značajna korelacija između genetskih (genomske) matrica koje definišu strukturalne i funkcionalne osobine ćelijskih - neuronskih struktura, i kognitivnih procesa koji se inherentno javljaju u mozgu. Posebno je značajno što se sve više javljaju termini poput „modula“ ili „modularnosti“ bioloških neuralnih i moždanih anatomske (neuroanatomske) struktura ([31], [32], [33], [34], [35]) i oni se povezuju sa funkcionalnim svojstvima odnosno kognitivnim i bihevioralnim funkcijama ([36], [37], [38]). Iako je modularna struktura vrlo aktuelna u rezultatima i istraživanjima mnogih autora u skorijem periodu, tek relativno nedavno su se pojavila i zapažanja koja povezuju modularnost sa fraktalnim strukturama ([39], [40]). Konačno, pojavila su se i nova istraživanja koja su povezala modularnost i dinamička svojstva modela neurofizioloških i kognitivnih struktura mozga ([41], [42], [43]).

Fraktalno-modularne CNM, koje su podloga ovog istraživanja, upravo pružaju egzaktna modelovanja dinamički procesa koja očigledno gađaju aktulne fokuse pažnje neuronauka u različitim segmentima. To nije slučajno, jer upravo fraktalno-modularni koncepti CNM omogućava da se kroz egzaktni matematički model interpretaju ova tri važna svojstva koja su prepoznata kao fundament kognitivnih procesa - modularnost, prostorno-vremenska dinamika i bihevioralna funkcionalnost - i to na različitim kognitivnim nivoima.

1.3 Hipoteze, cilj i metode istraživanja

1.3.1 Hipoteze

Opšta hipoteza je da postoji analogija između veštačkih fraktalno-modularnih struktura i prirodnih (bioloških) neuralnih sistema odnosno kognitivnih struktura u opštem smislu.

Formalno modelovanje bioloških struktura je veoma složeno ([44], [45], [46], [47], [48]), jer nauronauke još uvek nisu u mogućnosti da sagledaju sve aspekte složenih bioloških sistema a samim tim ni da definišu precizne i pouzdane matematičke modele (obziro da se radi o reveznom inženjeringu odnosno posmatranju i modelovanju “*black box*” sistema). Nasuprot tome, veštačke fraktalno-modularne strukture imaju striktno definisane matematičke modele i njihovo ponašanje je predvidivo. Poređenje i analogija bioloških i veštačkih struktura se stoga ne može vršiti samo na nivou egzaktnih matematičkih modela već se domen analogije proširuje i na sličnosti topologije, informaciono-procesnog ponašanja i sl. ([49])

Posebna hipoteza koja proizilali iz opšte je da analogija može biti pokazana i na bazi sličnosti fizičkih (matematičkih) modela (gde su oni identifikovani, na nižim i srednjim nivoima neurostruktura) ali i na funkcionalnim odnosno bihevioralnim sličnostima (na višim neuroanatomskim i kognitivnim nivoima, tamo gde matematički modeli nisu potpuni).

Pojedinačne hipoteze koje su primenjene obuhvataju:

- Sličnost fraktalno-modularne topologije i neuroanatomskih struktura,
- Sličnost matematičkih (funkcionalnih i procesnih) modela koji opisuju veštačke i biološke strukture,
- Sličnost bihevioralnog odziva odnosno ponašanja veštačkih i bioloških struktura,

1.3.2 Cilj istraživanja

Cilj ovog istraživanja je da se identifikuju i utvrde domeni sličnosti u strukturalnim, funkcionalno-dinamičkim i bihevioralnim karakteristikama i pokažu analogije nekih klasa

fraktalno-modularnih celularnih neuralnih mreža i bioloških neurokognitivnih struktura. Dalje, analizom utvrđenih sličnosti se formiraju analogije kako u matematičkim modelima tako i u ponašanjima, sa ciljem da se utvrde ključne karakteristike sličnosti između ovih struktura kao i da se identifikuju ključni parametri koji mogu biti potsticajni za modelovanje ili pak ograničenja u primenama utvrđenih analogija.

1.3.3 Metodologija

U toku naučnog i istraživačkog rada upotrebljene su različite metode kako bi bili zadovoljeni osnovni metodološki zahtevi – objektivnost, pouzdanost, opštost i sistematičnost.

U skladu sa izabranom problematikom, definisanim ciljevima istraživanja i postavljenim naučnim hipotezama radi definisanja naučnih i stručnih zaključaka i iznalaženja mogućih rešenja upotrebljena je teorijska analiza uz korišćenje rezultata istraživanja iz međunarodne naučne literature, odnosno saznanja naučnika i drugih autora koji su istraživali problematiku kojom se bavi i ovaj rad. Obzirom na multidisciplinarnost i kompleksnost oblasti istraživanja, posebna pažnja je posvećena istraživanju naučno-teorijskih saznanja, relevantne literature i savremene prakse korišćenjem većeg broja metoda, i to: istorijske metode, deskriptivne, induktivne i deduktivne metode, metode analize i sinteze, metode generalizacije i specijalizacije, metode dokazivanja i opovrgavanja, kao i metode kompleksnog posmatranja i analize sadržaja.

Primenom istorijskog metoda pribavljeni su i sistematizovani rezultati istraživanja samog autora disertacije, kao i drugih autora koji su se bavili problematikom veštačkih celularnih nerualnih mreža, posebno fraktalno-modularnim strukturama, kao i rezultata iz oblasti neuronauka (neruofiziologije, neruoanatomije i neuropsihologije) koje se bave proučavanjem i modelovanjem fizioloških i kognitivnih procesa u biološkim sistemima i strukturama. Pribavljeni podaci potiču uglavnom iz otvorene naučne literature objavljene u domaćim i međunarodnim izvorima.

Metoda kompleksnog posmatranja i meta-analiza sadržaja primenjena je prilikom obrade rezultata preuzetih iz istraživanja. Prepoznaju se i klasifikuju se biološke strukture koje imaju sličnosti ili pokazuju svojstva koja su bliska fraktalno-modularnim sistemima veštačkih nerulanih mreža. Zatim se identifikuju naučni rezultati koji su primenjivi na

modelovanje tih bioloških kognitivnih struktura a koji koreliraju sa matematičkim i bihevioralnim modelima fraktalno-modularnih veštačkih celularnih nerualnih mreža.

Primenom metode analize i sinteze se vrši identifikacija konkretnih domena sličnosti, kriterijuma i parametara za svaki domen.

Metoda generalizacije i specijalizacije se primenjuje u interpretaciji kriterijuma i parametara sličnosti, i definisanju analogija na opštim i partikularnim slučajevima.

Metoda dokazivanja i opovrgavanja se zatim primenjuje na sagledavanju niza primera gde se uspostavljeni kriterijumi i domeni analogije stavljuju u kontekst konkretnih slučajeva i gde se traže granice i ograničenja validnosti tih analogija i kriterijuma sličnosti.

1.3.4 Očekivani naučni doprinos

Nova istraživanja u oblasti neokognitivnih nauka donose velike napretke i sagledavaju vrlo kompleksne biološke nerualne sisteme od baznih, senzornih, poput retine oka, preko nižih i srednjih nivoa korteksa raznih bioloških vrsta, pa sve do najviših kognitivnih nivoa ljudskog mozga. Međutim, kompleksnost tih sistema onemogućava direktno matematičko modelovanje, kako na funkcionalnom tako i na bihevioralnom nivou, kako zbog njihove inherentne fizičke složenosti tako i zbog fundamentalnih nepoznanica u domenu prirode sinergije samih kognitivnih procesa ([50]). Suštinski, većina novih naučnih istraživanja, teoretskih i eksperimentalnih, počiva na metodi analize „crne kutije“ odnosno reverznog inženjeringu bioloških struktura. To je i razumljivo obzirom da je empirijska i eksperimentalna biotehnologija značajno uznapredovala, te su se stvorili uslovi da se dubinski prodre u sve elemente anatomije i fizologije neurostruktura. Međutim, i dalje ostaje problem da se izmereni rezultati interpretiraju i generalizuju, odnosno da se matematički, funkcionalno i procesno opišu i stave u kontekst viših kognitivnih funkcija i same svesti kao filozofskog a ne naučnog pojma.

U ovoj disertaciji analizirani su brojni rezultati istraživanja sprovedenih u svetu i kod nas u oblasti veštačkih i bioloških nerualnih mreža odnosno neurokognitivnih sistema u opštem smislu. Posebno je stavljen akcenat na aktuelizaciji koncepta fraktalne modularizacije u veštačkim celularnim neuralnim mrežama, u svetu novih rezultata istraživanja i saznanja u

domenima neuroanatomije, neurfizologije i neuropsihologije. Ovi rezultati su upotrebljeni kao polazna osnova za istraživanje koje je sprovedeno i izneto u ovoj disertaciji.

Očekuje se da će analizirani rezultati više istraživanja, kao i istraživanje u okviru ove disertacije poslužiti kao polazna osnova za dalja istraživanja i produbljivanje ove teme.

Analogije veštačkih fraktalno-modularnih struktura, posebno nekih konkretnih klasa CNM, mogu dati nove smernice za dalje analize, proučavanja i formulisanja funkcionalnih i strukturalnih modela bioloških kognitivnih struktura. Takođe, uočavanje fraktalno-modularnih svojstava u ponašanjima i strukturalnim svojstvima biloških struktura mogu poslužiti kao osnove za formulisanje novih klasa veštačkih neuralnih mreža koje bi mogle imati praktične primene u raznim domenima inteligentne obrade podataka i informacija.

Tema doktorske disertacije je aktuelna, a doprinos je u dubljem povezivanju inženjerskih i biomedicinskih nauka, uspostavljanju bilateralnih osnova za razmenu saznanja i iskustava, što je vrlo izražen trend u najširoj naučno-istraživačkoj zajednici.

Očekivani rezultat, odnosno ishod koji će se dobiti nakon sprovedenog istraživanja jeste da će se postavljene hipoteze dokazati ili opovrgnuti.

2 Fraktalna modularizacija u veštačkim Celularnim neuralnim mrežama (CNM)

U ovom poglavlju je dat uvod u veštačke celularne neuralne mreže (CNM) i posebno u klasu fraktalno-modularnih CNM. Na početku su date definicije i objašnjenja ključnih pojmoveva bitnih za razumevanje paradigme i koncepta fraktalne modularnosti u CNM. Obzirom da su ovi pojmovi kompleksni, da u literaturi postoje različite interpretacije zavisno od konteksta primene, izvršena je sveobuhvatna analiza i izneti su glavni aspekti koji određuju definicije i interpretacije tih ključnih pojmoveva u kontekstu teme ove disertacije a na osnovu literature iz oblasti neurokognitivnih nauka. Obzirom da su CNM prvenstveno inženjerska paradigma, ovakav pristup u multidisciplinarnom definisanju i interpretaciji ključnih aspekata fraktalne modularizacije u njima je od velike važnosti da bi se mogla uspostaviti utemeljena analogija sa biološkim kognitivnim sistemima, kao što će biti razmatrano u narednim poglavljima.

U delu koji se tiče uvoda u CNM i posebno fraktalnu modularnost kao koncept, korišćen je metodološki pristup izvorno uveden u magistarskom radu i referencama samog autora ove disertacije. Obzirom da deo tih referenci, zbog vremena publikacije (pre 2000. godine), nije dostupan u elektronskoj formi, pojedini delovi su preneti u prilogu kako bi se čitaocu olakšalo praćenje i referenciranje na ključne elemente i posebno matematičke relacije.

2.1 Ključni pojmovi i definicije

2.1.1 Topologija

Termin „*topologija*“ u smislu matematičke definicije, specifičnije geometrijske topologije, odnosi se na karakteristike i svojstva oblika *stvari* i *prostora* uopšte, što uključuje osobine *povezanosti*, *kontinuiteta*, *granica* i sl. ([51]). Specifično u kontekstu analogije veštačkih i bioloških neurokognitivnih struktura, posmatra se sličnost ovih osobina i ona ne mora biti i formalno matematički dokaziva već će se primenjivati kriterijumi neformalne logike koja je u skorije vreme korišćena upravo za dokazivanje sličnosti i analogija u domenu strukturalne topologije ([52]).

U kontekstu teze ove disertacije akcenat se stavlja na topologiju *mreža*, bilo da su u pitanju veštačke ili biološke neuronske mreže. U tom smislu razlikuju se dve vrste topologije: fizička i logička. Fizička topologija predstavlja strukturalni pojavn oblik, prostorni raspored i povezanost (interkonekcije) među fizičkim elementima mreže. Logička topologija odslikava tokove signala odnosno protok informacija među elementima mreže ili čak na višem apstraktnom nivou među krajevima (portovima) mreže.

U tehničkim naukama najbliži koncepti se sreću u računarskim mrežama i električnim kolima (bilo da se radi o elektronskim ili pak elektroenergetskim sistemima, teorija električnih kola se univerzalno može primeniti) u kojima je lako definisati i prepoznati i fizičku i logičku topologiju. U biološkim strukturama posmatraju se takođe razni pojavn oblici mreža, od kojih su za ovo razmatranje od interesa posebno neuralne (neurokognitivne) mreže mozga, ali se takođe mogu razmatrati i druge biološke mreže kao što su: proteinske interakcione mreže, genetičke regulatorne mreže, metaboličkemreže, signalne mreže, sociološke itd. ([53]). Značajno je naglasiti da je proučavanja mreža u biološkim strukturama odavno prisutno (neuroanatomija je nastala gotovo sa začetkom medicinske nauke), ali da je tek u poslednjih desetak godina nastao ozbiljan proboj u ovoj oblasti sagledavanjem značaja ne samo fizičke već i logičke topologije u biološkim mrežama. Tako, ako neuroanatomiju možemo vezati za fizičku topologiju neurokognitivnih struktura, oblasti kao što su neurofiziologija i neuropsihologija su bliže logičkim topologijama i imale su upravo značajan napredak u poslednjih par decenija.

Dakle, opšta svojstva i karakteristike povezanosti, kontinuiteta (neprekidnosti) i granica strukture mogu se usvojiti kao opšte karakteristike topologije i veštačkih i bioloških mreža bez obzira da li se razmatraju na fizičkom ili logičkom (funkcionalnom) nivou.

2.1.2 Modularnost

„Modularnost“ je pojam koji se često sreće u raznim stručnim i naučnim oblastima ali koji nema jedinstvenu definiciju već se najčešće tumači shodno kontekstu discipline u kojoj se primenjuje. Tako Schilling u svojoj komparativnoj analizi [54] uočava nekoliko ključnih koncepata koji se provlače kroz definicije i kontekste u kojima se modularnost interpretira u nekoliko bitnih naučnih disciplina koje su od interesa upravo u kontekstu ove disertacije (Tabela 1). Važno je istaći da je ovakav pristup analizi i sintezi definicije pojmove saglasan

napred iznetim smernicama naučnih metodologija zasnovanih na meta-analizi i posebno primeni neformalne logike u metodologijama naučnog istraživanja. Dakle, iako se može pretpostaviti da je definicija modularnosti matematički koncept, veoma intenzivna istraživanja i publikovani naučni rezultati ukazuju da je pitanje daleko složenije i ne može se rešiti samo formalnim matematičkim razmatranjem.

Tabela 1: Primena termina "modularnost" u različitim naučnim disciplinama od interesa za temu ove disertacije (preuzeto iz [54]). Simbol „?“ označava da koncept nije potpuno definisan ili potvrđen u određenoj disciplini.

Koncept ²	Psihologija	Biologija	Matematika	Tehnologija i organizacija
Domenska specifičnost (funkcionalna specijalizacija)	X	X		X
Urođeno svojstvo (svrha ili struktura modula su predeterminisani)	X	X		
Hijerarhijska ugnježdenost (prepoznatljiva rekurzivna dekompozicija do nivoa pojedinačnog modula)	X	X	X	X
Primarno interna integrisanost (lokализовано procesiranje i autonomija, interna interakcija nadmašuje eksternu)	X	X	?	X
Informaciona enkapsulacija (modul ima sopstveno informaciono stanje)	X			X
Bliska razgradivost (lokalna povezanost, segmentiranost, prepoznatljiva razgraničenost modula ili razgradivost kompleksnosti putem dekompozicije)	X	X	X	X
Zamenjivost (modul nije fizički jedinstven i unikatan sistem, može se proizvesti ponovljivo)	X	?	?	X
Rekombinabilnost (moduli se mogu rekombinovati u nekim dimenzijama sistema, npr. u prostoru i/ili vremenu a bez da to utiče na ukupnu funkciju odnosno ponašanje sistema)		X		X
Proširivost (sistem se može širiti dogradnjom modula po šablonu)		X	X	X
Homolognost (moduli su srodni odnosno imaju zajedničke karakteristike koje ih čine srodnim)		X	X	X
Raznolikost (moduli ne moraju biti svi identični ali se mogu razvrstati po srodnosti - homolognosti)	X	X		X
Evolutivnost sistema (sistem može evoluirati od višeg stepena integracije ka većoj modularnosti)	X			X

² Opširnije interpretacije navedenih koncepata su date u izvornom radu [54]. Ovde su uz originalan naziv dati sažeci (u zagradi pored svakog koncepta) koji bliže interpretiraju pojedine koncepte u kontekstu potreba teme ove disertacije.

Modularnost se često vezuje za matematičke koncepte, obzirom da je istorijski gledano sam termin *modulus* i nastao odnosno prvi put je uveden u matematici u delu *Disquisitiones Arithmeticae* publikovanog 1801. godine od strane čuvenog matematičara i filozofa K. F. Gaus-a (Carl Friedrich Gauß, 1777–1855). Sam termin „moduo“ koji se izvorno pojavio u kontekstu numerike odnosno aritmetike (teorije kongruentnih brojeva), vrlo brzo je prihvaćen kao paradigma u mnogim drugim disciplinama ne samo matematike već i drugih nauka. Iz gore navedene analize (Tabela 1) može se zapaziti da su koncepti modularnosti često ekstenzivniji (razvijeniji i brojniji) u drugim naučnim oblastima osim matematike. To ukazuje da je čisto matematičko posmatranje i definisanje ovog koncepta preusko za razmatranje od interesa u ovoj disertaciji. Stoga će u nastavku biti izložen detaljniji pregled koncepta i definicija u oblastima od interesa. Cilj je da se izvede definicija primenjiva u svim oblastima od interesa za temu i ciljeve ove disertacije, konkretno za analogiju između veštačkih i bioloških neurokognitivnih struktura.

Obzirom da se modularizacija primenjuje u inženjerigu već veoma dugo (decenijama se ovaj termin sreće u literaturi i praksi), da je termin već ušao u opštu upotrebu bez da je bio formalno matematički definisan, može se zaključiti da je njegova definicija šira od formalno matematičke a takođe i fleksibilnija.

Modularnost se tako često podrazumeva u tehničko-organizacionim disciplinama i kontekstima, gde postoje intuitivno jasni, merljivi i logički konzistentni kriterijumi. Iako ovo izgleda kao jednostavan zadatak, da se od tako opšte prihvaćenog i intuitivnog koncepta izvede i jasna definicija, činjenica je da postoje brojne varijacije interpretacije i tumačenja u različitim kontekstima bez striktne definicije ili sa definicajama koje su usko vezane za datu primenu (dovoljno aplikabilan za praktične primene) ([55], [56]). Primera radi, tek vrlo nedavno (2006. godine, dakle više od dva veka od izvorne pojave termina u Gausovim radovima) je objavljen veoma citiran rad koji predlaže jednu matematičku definiciju modularnosti u mežnim strukturama (i tzv. komunama – grupama, klasterima) [57]. Newman u ovom radu zapaža da se mnoge mreže od interesa u raznim oblastima nauke, uključujući društvene mreže (dakle, sociološke ili biološke kolektivitete), računarske mreže ili metaboličke i regulatorne mreže (dakle, biološke strukture), mogu *prirodno* podeliti u zajednice tj. module. Konstatuje da je problem otkrivanja i karakterizacije ovih zajednica struktura (modula) jedno od preostalih pitanja u proučavanju umreženih sistema (iako je

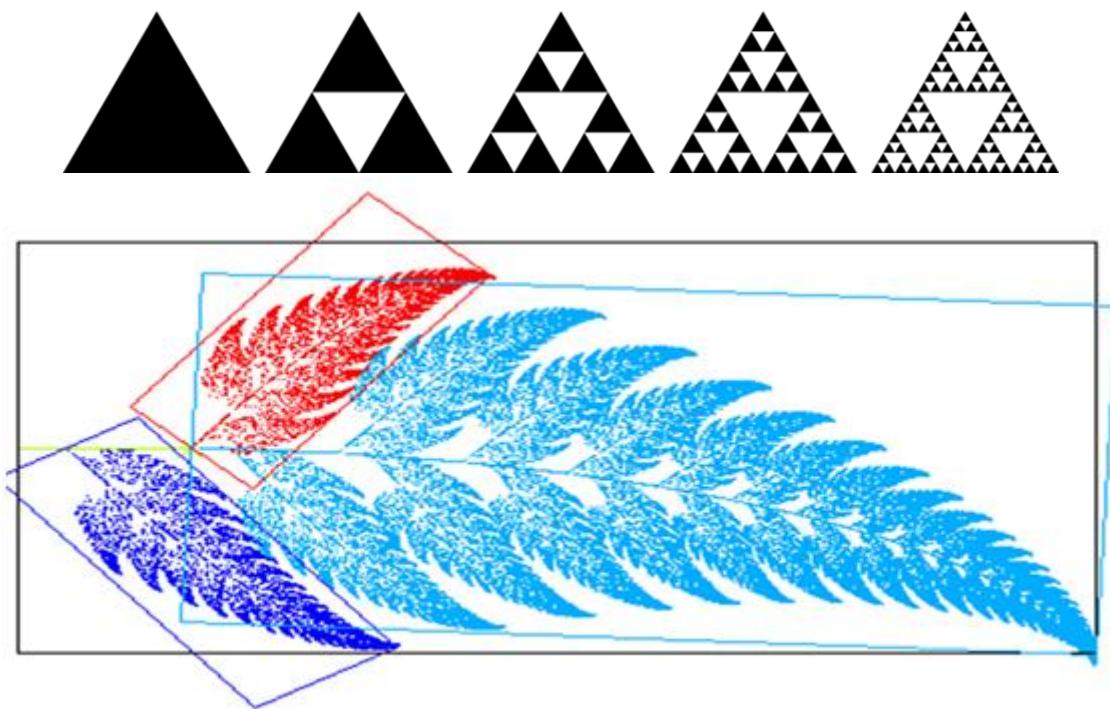
upotreba termina u masovnoj primeni). Takođe, konstatuje da je jedan veoma efikasan pristup u rešavanju srodnih problema optimizacija funkcije kvaliteta - u ovom kontekstu podrazumevana „modularnost“ - nad mogućim divizijama (strukturnim zajednicama, modulima) jedne mreže. On pokazuje da se tako modularnost može izraziti u smislu karakterističnih vektora (*eigenvectors*) matrice mreže, koje naziva „matricom modularnosti“, i izvodi jedan efikasan algoritam izračunavanja. Ne ulazeći u detalje ove definicije, posebno ne u matematički aparat i efikasnost samog algoritma, važno je razumeti da se modularnost može definisati kao optimalan skup kriterijuma u nekoj mrežnoj strukturi. Ovo podupire napred izložen (Tabela 1) *neformalno-logički* pristup definiciji modularnosti u konceptualnom smislu što je upravo od interesa za razmatranje hipoteze i ciljeva ove disertacije koja se bavi sličnostima i analogijama veštačkih i bioloških modularnih struktura a ne utvrđivanjem i istraživanjem same modularnosti u njima (iako je modularnost neosporno inherentna fraktalno-modularnim veštačkim celularnim neuralnim mrežama čak i u formalnom-matematičkom smislu kako je izloženo u [57]).

2.1.3 Fraktalnost

„*Fraktal*“ je pojam pod kojim se najčešće podrazumevaju strukture, prirodne ili apstraktne (matematičke), koje imaju svojstvo da sadrže ponovljive (reptetitivne) dezene, šablone ili podstrukture koje se javljaju na svim nivoima posmatranja (uvećanjima, skalama). Ta osobina da iz različite perspektive i daljine izgledaju prepoznatljivo (isto) ih je od davnina činila privlačnim kao dekorativni element u arhitekturi ali i drugim primenjenim umetnostima i vizuelnim izražajima čoveka. Nova istraživanja potvrđuju i da fraktalni oblici imaju pozitivna psihološka dejstva, da smanjuju stres odnosno da „prijaju ljudskom oku“ [58].

Jedna od često citiranih definicija je data od strane B. Mandelbrot-a (koji je inače i izveo ovaj termin od latinskog prideva *fractus* što znači razlomljen, slomljen) [59]: „fraktal je fragmentirani geometrijski oblik koji se može podeliti na delove od kojih svaki (bar približno) ima strukturu sličnu umanjenoj kopiji celine“. Iako je ova definicija veoma rasprostranjena i široko prihvaćena, ona je i limitirana jer npr. matematičke definicije fraktala idu daleko dalje od geometrijske sličnosti i odnose se često na funkcije (Kochov-a kriva), redove (Fibonacci-jevi brojevi), algebarske strukture (Cantor-ov skup) i mnoge druge apstrakcije (Lindenmayer-ov sistem). U prirodi imamo razne fizičke (npr. kristalizacija vode odnosno leda [60] ili polimerizacija plastike) ili biološke (struktura DNK lanca, fraktalna

fiziologijai sl. [61], [62]) procese koji u pojavnom smislu dovode do fraktalnih struktura. Konačno i u durštvenim naukama se javljaju fraktali, npr.u razmatranju organizacija, evolucija i drugih prostorno-vremenskih procesa i interakcija jedinki i grupa [53].



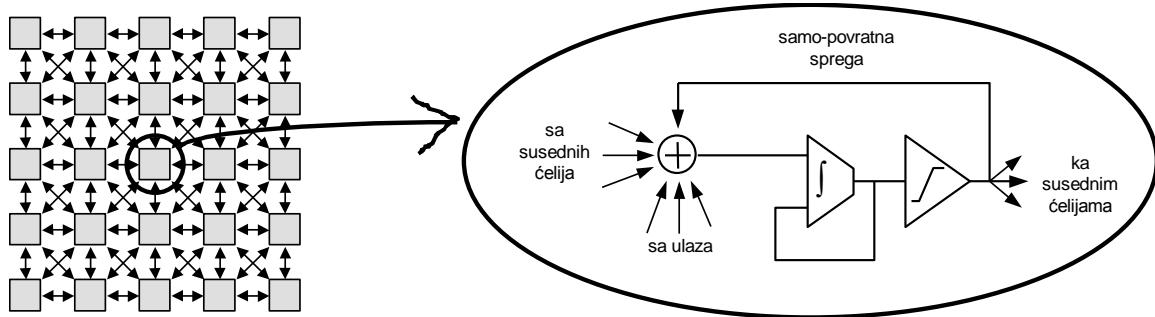
Slika 2: Vizuelni primer samosličnosti fraktalne matematičke - geometrijske strukture (nulta i prve četiri iteracije trougla Sierpiński) i primer biološke strukte (list paprati).

U literaturi ne postoji jedinstvena definicija fraktala jer slično kao i prethodni termini (topologija, modularnost) interpretacija i karakterizacija variraju zavisno od konteksta odnosno konotacije i polja primene. Ipak, većina autora se slaže da je jedno od osnovnih svojstava fraktala *samosličnost* odnosno svojstvo da se sastoje od „umanjenih verzija sebe“ (Slika 2).

2.2 Celularne neuralne mreže (CNM)

Celularne neuralne mreže (CNM, eng. *Cellular Neural Networks*), predstavljaju klasu veštačkih neuralnih mreža koju su razvili još 1987. godine Chua i Yang ([19], [20], [21]). Zanimljivo je naglasiti da u prvo vreme mnogi autori nisu ove mreže prohvatali kao „prave“ veštačke neuralne mreže, prvenstveno iz razloga što na način na koji su ih uveli Chua i Yang

(odeđene su fiksnim parametrima interkonektivnosti) one nisu imale sposobnost „učenja“ što je u vreme njihovog nastanka bio glavni trend i shvatanje „inteligencije“ u veštačkim kognitivnim sistemima. Međutim, geometrijska struktura koja ima više sličnosti sa biološkim neuralnim sistemima (lokalna povezanost) kao i kasniji razvoj i otkrivanje novih mogućnosti primena ovih mreža u vrlo naprednim aplikacijama koje imaju mnoge bliskosti sa biološkim sistemima (uključujući i vrlo uspešnu realizaciju veštačke retine) uspostavile su CNM kao posebnu klasu veštačkih neuralnih mreža. Najnovija istraživanja čak produbljuju sličnosti i analogije CNM sa biološkim neurokognitivnim strukturama, što je upravo i fokus ove disertacije.



Slika 3: Celularne neuralne mreže (CNM): Ćelije su identični neliearni dinamički procesni elementi lokalno povezane sa svojim neposrednim susedima.

U najkraćem, CNM se prema osnovnom konceptu Chua-e i Yang-a sastoje od velikog broja prostih, nelinearnih, dinamičkih procesirajućih elemenata, takozvanih ćelija (engl. *cells*), koje su lokalno povezane sa svojim susedstvom, na identičan način (Slika 3). Veza se ostvaruje konduktansama (sinapsama) čije vrednosti određuju ponašanje mreže. Takva struktura, koja je, uobičajeno, planarna i pravuogaone forme, je pogodna za VLSI realizaciju. U osnovi to su analogne mreže (mada ima i varijanti u digitalnom vidu), tako da se odlikuju velikom brzinom rada. Naime, mada pojedinačni elementi ne moraju biti naročito brzi (vreme uspostavljanja ravnotežnog stanja je određeno vremenskom konstantom ćelije i uobičajeno su reda veličine oko jedne μ s u realnim implementacijama), zahvaljujući paralelnom radu svih procesirajućih elemenata, brzina rada ukupne mreže je veoma velika (reda veličine nekoliko vremenskih konstanti ćelije) i, u velikom broju primena, nezavisna od broja procesirajućih elemenata.

Detaljnija definicija, opis strukture i dinamički model bazične klase CNM dati su u Prilogu (sekcija 9.1, Prilog 1: Celularne neuralne mreže – osnovni pojmovi i definicije).

Iako je veoma brzo po njihovom nastanku pokazano da CNM imaju procesna (komputaciona) svojstva ekvivalentna Tjuringovoj mašini [63], nije nađen efektivan mehanizam za „programiranje“ odnosno kreiranje „šablonu“ sinaptičkih parametara (sinaptičkih topoloških matrica A i B u modelu, jednačina (23)). Dakle, nedostatak metodologije sinteze CNM za datu željenu primenu je bio i ostao glavni faktor koji ih ograničava u širokim primenama. Iako su i tu postojali neki pokušaji ([64], [65], [66], [67]), čak i rezultati koji su delovali izgledno, nažalost nije se pokazalo da postoji univerzalni mehanizam koji bi bio približno fleksibilan i generaliziran kao što je to slučaj u drugim klasama, posebno *Back-propagation* (BP) veštačkim neuralnim mrežama, gde postoje dobro fundirani, u teoretskom i praktičnom smislu, algoritmi i metode obučavanja (koje imaju i uporišta u sličnostima i analogijama i sa biološkim neurokognitivnim i psihološkim procesima, poput Bayesian-ovog učenja i sl.).

Brojne CNM su tako u literaturi predložene kao partikularni slučajevi koji su manje ili više empirijski ili deduktivno sintetizovani i pokazane su razne njihove funkcionalne primene, ali je domen tih primena uglavnom ostao vezan za jednostavnije procese koji su najbliži niskim nivoima neurokognitivnih struktura, popu senzorskih mreža i prvih nivoa vizuelnog korteksa (retine oka i primarnih procesa obrade senzorskih ulaza). Tako, veliki broj radova je pokazao da CNM mogu vršiti širok spektar logičkih funkcija, posebno u domenu obrade slike, gde se u stabilnom režimu postižu odgovarajuće logičke funkcije odnosno kompjutacije ulaznih signala veoma slične funkcijama koje obavljaju diskretni konvolucioni filtri koji se klasično primenjuju u digitalnoj obradi slike (npr. izoštravanje, traženje ivica, logičke obrade poput traženja „rupa“ ili popunjavanja površina i sl.). Ipak, sve ove funkcije se mogu vrlo lako podvesti pod jednostavne kompjutacione radnje koje imaju, ako uopšte, inteligentna ili kognitivna svojstva.

Napredniji primeri primene CNM u sistemima koji se mogu dovesti u vezu sa stvarnim kognitivnim procesima su uočeni u ranim 90-tim godinama ([68], [69], [70]) ali su konkretniji rezultati razvijeni tek deceniju kasnije, npr. u sklopu projekta veštačke retine koji je oko 2000. godine pokrenuo tim profesora Roska-e ([71], [72], [71]). Nažalost, iako su

izneti mnogi važni argumenti i analogije sa biološkim neurosenzorskim sistemima (dakle, naglašavamo senzorskim a ne kognitivnim, što je bitna razlika na nivou stepena složenosti funkcionalnih i behavioralnih karakteristika sistema) praktične implementacije i dalji rezultati su bili ograničeni prvenstveno problemima u implementaciji masivnih mreža koje bi imale realne praktične primene. Naime, iako su CNM izvorno zamišljene kao upravo pogodne za VLSI implementaciju, zbog svoje lokalne povezanosti i pravilne topologije, pokazalo se da njihova realizacija u dostupnim VLSI tehnologijama, posebno silikonskim, nije praktično moguća za velike sisteme jer postoje dva velika ograničavajuća efekta:

1. energetska efikasnost je daleko manja od biološke, odnosno potrebna energija i dispacija po jedinici površine je daleko veća nego kod bioloških sistema, što praktične VLSI realizacije čini nemogućim za velike mreže; i
2. prostorna efikasnost je daleko manja od biološke, odnosno veličina prostora potrebnog za implementaciju pojedinačne ćelije i mreže sinapsi je daleko veća nego kod bioloških sistema³.

Iz ovih razloga, iako je u početku CNM paradigma pružala veoma izazovne perspektive ([73]), čak su nalaženi i efikasniji modeli VLSI implementacije sa relativno malim brojem komponenti ([74]), došlo je do efektivnog zastoja u razvoju i primeni ove arhitekture, prvenstveno jer nisu nađene šire praktične primene najviše zbog navedenih tehnoloških ograničenja implementacije. Međutim, teoretska istraživanja su nastavljena, posebno u sferama naprednijih funkcija koje sve više konvergiraju kao kognitivnim procesima (asocijativne memorije [69], prostorno-vremenska samoorganizacija [75], [76], modelovanje vizuelne spoznaje [77] i sl.).

³ Realne implementacije kopija bioloških sistema (sa milionima ćelija) bile nesrazmerno velike i morale bi biti raspodeljene na više silicijumskih jezgara što opet dovodi do problema sa eksternom integracijom odnosno potrebom za velikim brojem eksternih pinova na čipovima, što je u dostupnoj VLSI tehnologiji jedan od ključnih ograničavajućih faktora (čipovi uobičajeno imaju mali broj ulaznih pinova, i njihva tehnologija izrade je veoma složena i skupa). Sve ovo ukazuje da postojeća VLSI tehnologija konceptualno nije pogodna za implementacije biološki inspirisanih arhitektura, i veoma su aktuelni prvci istraživanja novih tehnologija, baziranih na nanostrukturama, biotehnologijama i kvantnim tehnologijama.

2.3 Fraktalna modularnost u veštačkim celularnim nerualnim mrežama

Bazične CNM, kako su ih uveli Chua i Yang, inherentno imaju strukturu za koju je i intuitivno jasno da poseduje fraktalne i modularne karakteristike prema napred iznetim definicijama tih pojmova. Pri tome, moduli su u stvari ćelije ili slojevi ćelija CNM a fraktalna topologija je inherentna definiciji lokalne povezanosti ćelija.

Ključni problem u CNM, što su razni autori i naglašavali kao njihov glavni nedostatak da se uopšte mogu smatrati neuralnim mrežama, je ograničena funkcionalna sposobnost ćelije odnosno osnovnog modula bazične CNM kako su je postavili Chua i Yang. Iako su oni ostavili mogućnost da se ćelija može „unaprediti“ uvođenjem složenijih nelinearnih karakteristika izlazne funkcije ili samih sinapsi, rudimentarna ćelija je ostala glavni limitirajući faktor funkcionalnosti CNM u smislu ukupnih mogućnosti implementacije kognitivnih funkcija koje su bliske biološkim ponašanjima (bihevioralna svojstva). Složenje CNM strukture su moguće, ali je osnovni problem složenost matematičkog modela koji onda postaje nepogodan za analizu i sintezu. Tu dolazimo do istog ograničenja koje već više od jednog veka predstavlja problem i u izučavanju bioloških neurostruktura – kompleksnost strukture i vremensko-prostorne dinamike sistema koja se ne može lako matematički modelovati.

Suštinsko pitanje koje se postavlja je da li ipak postoje kognitivne funkcije koje se mogu realizovati i modelovati strukturama koje su bazirane na veštačkim CNM ili srodnim strukturama? Obzirom da su same CNM nastale na bliskim konceptima na kojima su skoro deceniju ranije Hopfield, a kasnije se njemu pridružio i Tank, postavili svoje dobro poznate modele veštačkih nerualnih mreža sa izraženim dinamičkim svojstvima ([78], [79], [80]), za koje su pokazali da imaju značajna komputaciona svojstva koja gravitiraju kognitivnim procesima (poput mogućnosti da rešavaju razne optimizacione probleme npr. problem trgovackog putnika, linerano programiranje i sl.), logično se postavilo pitanje da li i CNM, ali sa novom, lokalnom topologijom, koja je bliža biološkim neurostrukturama, mogu ispoljavati slična bihevioralna svojstva odnosno da li mogu u komputacionom i funkcionalnom smislu imati slične kognitivne primene.

Dakle, Hopfield-ove mreže su pokazale da jednostavne dinamičke strukture u kolektivitetu mogu pokazivati složena bihevioralna svojstva koja imaju kognitivne funkcionalnosti i karakteristike, ali je njihov glavni nedostatak bio što je njihova topologija daleko od bioloških neurokognitivnih struktura (Hopfield-ove mreže imaju potpuno povezanost, dakle svaki neuron je povezan sa svim ostali u mreži što je potpuno suprotno biološkoj arhitekturi neuroanatomskih sistema, što će biti detaljnije razmatrano u narednom poglavlju). Na drugoj strani, CNM imaju upravo topologiju koja je bliska biološkim neuroanatomskim strukturama, lokalnu povezanost i fraktalnost, ali je njihova procesna sposobnost ograničena upravo na rudimentarne komputacione i logičke funkcije koje ni iz bliza nemaju bihevioralna svojstva viših kognitivnih funkcija bioloških neurostruktura.

Između ove dve krajnosi postoji veliki prostor koji, teoretski gledano, povezuje neurodinamička svojstva Hopfield-ovih mreža i neuroanatomske strukturu CNM i time određuje veštačke kognitivne sisteme koji imaju biološku arhitekturu i kognitivna svojstva (inteligentna ponašanja).

U svojoj magistarskoj tezi [27], kao i nizu vezanih radova u kojima je koautor a koji su joj prethodili (Milić i Kostić [28], Reljin i Kostić [29]), autor ove disertacije je izveo novi metodološki pristup u sintezi klase CNM koje funkcionalno mogu rešavati razne netrivijalne optimizacione probleme (metoda fraktalne modularizacije) i definisao koncept tzv. fraktalno-modularnih CNM koje upravo inkorporiraju i objedinjuju oba ova svojstva (biološki inspirisanu arhitekturu i bihevioralnu funkcionalnost), dodajući im i komponentu modularnosti koja, kako će u narednom izlaganju biti pokazano, daje još jedan značajan momenat analogiji sa biološkim kognitivnim neurostrukturama.

Metoda fraktalne modularizacije zasniva se ne dekompoziciji matematički formulisanog (optimizacijog ili srodnog) problema na načina koji omogućava sintezu CNM prema topološkim konceptima koje su postavili Chua i Yang (lokalna povezanost identičnih ćelija) a koja ima dinamička komputaciona svojstva kao Hopfield-ove mreže (spontanu optimizaciju) odnosno ima naprednije bihevioralna svojstva i komputacione funkcionalnosti od klasične CNM.

Treba praviti razliku između pojma *fraktalna modularizacija*, što je metoda odnosno matematički postupak, i *fraktalne modularnosti* što je organizaciona karakterizacija odnosno

strukturalna forma mreže (svojstvo koje korelira sa biološkim neurokognitivnim strukturama). Dakle, fraktalna modularizacija omogućava da sintetišemo fraktalno-modularne CNM koje imaju određenu, dobro definisanu dinamiku (asimptotska stabilnost i konvergentnost u smislu generalisane energije – funkcije Ljapunova) i koje, zahvaljujući toj dinamici, ispoljavaju složena ponašanja (bihevioralne karakteristike) koja se mogu iskoristiti za praktične primene u rešavanju raznih optimizacionih i srodnih naprednih komputacionih problema ([28], [29], [81], [82], [83], [84]) koji su daleko kompleksniji u odnosu na ponašanja i funkcionalnosti koje su pokazane u drugim primenama klasičnih, dakle ne fraktalno-modularnih, CNM (uglavnom logičke operacije, prostorne konvolucije i srodne komputacione funkcije koje se mogu svesti na jednostavne matematičke i/ili logičke operacije ili jednostavne senzorske obrade, dakle ne složene kognitivne funkcije).

Fraktalna modularnost CNM je upravo i ključna razlika u odnosu na Hopfield-ove mreže koje imaju nefraktalnu i nemodularnu strukturu (generalno, svaki pojedinačni neuron je u vezi sa svim ostalim neuronima u mreži, što je potpuno suprotno od fraktalne i modularne topologije). Dakle, fraktalna modularnost čini ovu klasu CNM specifičnom i u odnosu na druge poznate tipove tzv. rekurzivnih veštačkih neuralnih mreža (Hopfield-ovog tipa i sl.).

Detaljniji prikaz metodologije fraktalne modularizacije i koncepta fraktalno-modularnih CNM je dat u Prilogu (sekcija 9.2 „Prilog 2: Fraktalna modularizacija u CNM“).

Dakle, fraktalno-modularne CNM su određene sa dva osnovna inherentna svojstva:

1. fraktalno-modularnom strukturom koja se može okarakterisati topologijom koja u osnovi ima lokalne veze kako unutar samog modula tako i između modula,
2. optimizacionim ponašanjem koje proističe iz dinamičkih svojstava koja su bazirana na principu asimptotske stabilnosti kroz minimizaciju generalisane energije iskazane funkcijom Ljapunova.

Ova dva svojstva fraktalno-modularnih CNM su ključ za mnoge mogućnosti naprednijih primena, što će biti pokazano u nastavku.

2.4 Klase fraktalno-modularnih CNM sa složenim bihevioralnim karakteristikama

Kao što je u prethodnoj sekciji opisano, fraktalno-modularne CNM inherentno ispoljavaju napredne bihevioralne akrakteristike u smislu dinamičkog ponašanja koje se zasniva na procesu asymptotski stabilne minimizacije generalisane energije mreže koja se može predstaviti pogodnom funkcijom Ljapunova. Kako je u metodologiji fraktalne modularizacije pokazano, upravo izbor pogodne funkcije Ljapunova definiše vrstu optimizacije koju mreža spontano vrši, dakle ponašanje mreže u funkcionalnom smislu. Objedinjeno, dinamička i funkcionalna svojstva mreže možemo podvesti pod bihevioralne karakteristike, što se često i koristi u kognitivnim naukama. Dakle, vrstu optimizacije koju mreža spontano obavlja (npr. rešavanje sistema linearnih jednačina ili optimizacija ciljne funkcije kroz linearno programiranje, kako je pokazano u sekciji 9.2 „Prilog 2: Fraktalna modularizacija u CNM“) možemo „zadati“ kroz formulisanje pogodnog matematičkog modela (optimizacionog problema) koji onda metodom fraktalne modularizacije svodimo na iznalaženje parametara strukture fraktalno-modularne CNM koja ima upravo željene bihevioralne karakteristike (željeno ponašanje).

Upravo da bi pokazali univerzalnost i primenjivost koncepta fraktalne modularnosti CNM, izrađeno je više modela koji su sintetizovali i simulirali fraktalno-modularne CNM u složenijim primenama koje se mogu dovesti u vezu sa naprednjim inteligentnim prcesiranjem i u krajnjoj instanci sa kognitivnim procesima ([81], [28], [82], [83], [84]).

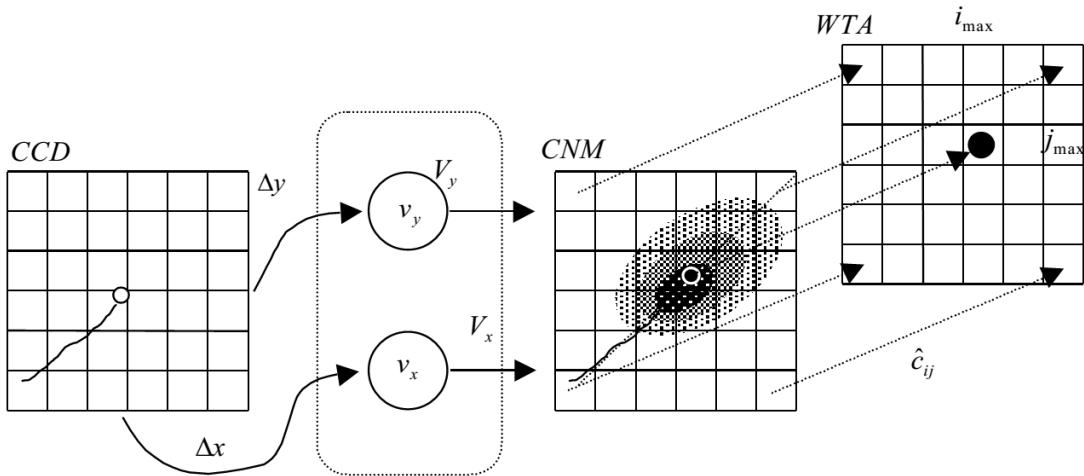
Prve primene fraktalno-modularnih CNM su ostvarene po ugledu na Hopfieldove mreže, za rešavanje sistema linearnih jednačina i linearno programiranje ([28], [84]). Iako samo rešavanje sistema linearnih jednačina naoko ne izgleda kao optimizacioni problem, brojne su primene u kojima se rešava optimizacioni problem „minimalnog odstupanja“ ili šire gledano problem koji se može formulisati u vidu nalaženja nekog rešenja u skupu pravila koja se mogu podvesti pod skup linearnih zavisnosti (tj. linearnih jednačina). Tako, na primer, jedan od važnih problema u neuronaukama je i problem mehaničke kontrole i upravljanja pokretima, u kojem je jedan od bazičnih problema upravo upravljanje odnosno kontrola pokreta ruke ([85]). Obzirom da se upravljanje rukom može prevesti u problem optimizacije (optimalno upravljanje) odnosno konkretno u problem linearog programiranja (inkrementalno adaptivno upravljanje linearnim programiranjem [86]), možemo reći da se

napred opisanim fraktalno-modularnim CNM može vršiti ta funkcija odnosno upravljanjti pokretom ruke. Tako se dovode u vezu naizgled apstrakne bihevioralne karakteristike fraktalno-modularne CNM (koje spontano rešavaju sisteme linearnih jednačina i/ili vrše optimizaciju linearog programiranja) i realnih funkcionalnih procesa koji tesno koreliraju sa ponašanjem i bihevioralnim karakteristikama bioloških neurokognitivnih sistema (konkretno neuromotoričke kontrole i upravljanja pokretima).

Nešto drugačiji pristup u primeni fraktalno-modularnih mreža u problemima koji koreliraju sa neuromotoričkim funkcijama iznet je u radu [87]. Metodom fraktalne modularizacije, sintetisana je LTT (*Linear Trajectory Tracking*) celularna neuralna mreža koja na osnovu praćenja trajektorije kretanja vrši linearnu ekstrapolaciju tog kretanja odnosno vrši predikciju putanje upravo kroz formiranje pokretnog prostorno-vremenskog „oblaka“ („auto-talasa“ kako se još referišu u literaturi, [88]) energije u ćelijama CNM. Energetski maksimum „oblaka“ odnosno tačka najvišeg potencijala se kreće upravo u skladu sa početno zadatim pravcem kretanja. Iako naizgled trivijalna funkcija, ovakva mreža je od interesa sa aspekta kognitivnih procesa jer možemo smatrati da ova mreža „uči“ putanju (koju „snima“ npr. vizuelni ili neki drugi senzorski podsistemi⁴) i „uhvaćena“ trajektorija onda služi kao ulazni parametar za napred opisanu LP CNM koja može upravljati rukom koja će u vremenu i prostoru slediti tu putanju. Dakle, višeslojnom kombinacijom fraktalno-modularnih CNM mogu se formirati složeni sistemi koji ispoljavaju složene bihevioralne karakteristike odnosno funkcionalnosti koje se mogu dovesti u vezu sa realnim kognitivnim procesima prisutnim u biološkim sistemima (živim organizmima).

U skorijem periodu su se pojavili radovi koji se bave sličnim problemima. Tako, [89] iz 2005. godine koji u velikoj meri počiva na sličnoj postavci (analogna rekurentna mreža u CMOS implementaciji). Međutim, ovo nije mreža CNM tipa (jer nema 2D topologiju) i funkcionalnost joj se ne zasniva na principima energetske propagacije (auto-talasa). Samim tim, iako se referiše kao „rekurentna neuralna mreža“, ovaj rad samo u delu ima strukturalne i bihevioralne sličnosti sa biološkim sistemima, što je upravo glavni rezultat primene fraktalne modularizacije u LTT CNM opisanoj u [87].

⁴ U [211] je detaljno analiziran i opisan mehanizam gde kognitivni procesi koji izazivaju motoričke radnje, kao prilaz partneru za parenje ili bežanje od predadora, upravo koriste ulaz sa akustičkog aparata kod crvčaka ili bubašvaba, i to enkodovane upravo u formi ugaonih veličina koja je prisutna kao ulazni i kontrolni parametar i u opisanim faraktalno-modularnim CNM za praćenje i upravljanje trajektorijom pravolinijskog kretanja.



Slika 4: Fraktalno-modularna LTT (Linear Trajectory Tracking) CNM za praćenje i predikciju linearne trajektorije primenom koncepta energetske propagacije u prostorno-vremenskom domenu (preuzeto iz [87]).

Prostorno-vremenska energetska dinamika, energetski „oblaci“ odnosno „auto-talasi“ u CNM su istraživani i od strane drugih autora jer je ovaj fenomen uočen u ranim fazama analize ponašanja CNM u različitim primenama ([90], [76]). Tako, pažnju je privukla činjenica da pogodnim variranjem parametara mreže (veza između ćelija i ulaznih pobuda) je moguće formirati dvoslojne mreže koji imaju oscilatornu dinamiku koja u vremensko-prostornoj matrici topologije CNM formira propagaciju „talasa“ odnosno „oblaka“ energije. Izborom parametara interkonekcija tih modula moguće je dobiti stabilne „slike“ (stabilne izlaze ćelija odnosno modula nakon perioda tranzicije) koje veoma podsećaju na dezene odnosno šare koje se javljaju u biološkim sistemima (npr. tigrove šare ili zebrine pruge i sl.).

Dakle, i drugi autori su razmatrali slične topološke strukture kao što su napred opisane fraktalno-modularne CNM i pokazali su da takve strukture mogu imati kompleksnu oscilatornu dinamiku koja u prostorno-vremenskom domenu ispoljava složene bihevioralne karakteristike („auto-talase“). Važno je naglasiti da topološka sličnost proizlazi iz činjenice da takve, po pravilu dvoslojne ili višeslojne, CNM možemo posmatrati i kao fraktalno-modularne mreže ako se po jedna ćelija iz svakog sloja izdvojeno posmatra kao jedan modul. Ipak, takve strukture su nastale kao produkt topološke sinteze (prvo je postavljena struktura pa je analizirano ponašanje i nađeni su partikularni slučajevi koji ispoljavaju primenjive funkcionalnosti odnosno vrše određene procese koji imaju primenjiva svojstva, potput formiranja vizuelnih dezena i šara i sl.) a ne matematičke metodološke sinteze na bazi dobro

definisanog optimizacionog problema koji se rešava. To je fundamentalna razlika jer prvi pristup je empirijski (ne ciljano za konkretnu primenu, već iskustveno se pokazaolo da mreže takve strukture imaju u partikularnim slučajevima određena „zanimljiva“ ponašanja), dok je fraktalna modularizacija metodološki pristup koji egzaktno vodi sintezi mreže sa ciljanim bihevioralnim karakteristikama (asimptotski stabilna konvergencija rešenju unapred dobro definisanog problema). Ipak, detaljna analiza ponašanja CNM sa kompleksnom dinamikom, koje imaju fraktalno-modularnu arhitekturu, koju su sproveli i drugi autori (npr. Ermentrout u [91]) je od koristi jer se mogu povući i dodatne paralele fraktalno-modularnih CNM sa biološkim kognitivnim neuro-strukturama, što će biti detaljnije razmatrano u narednim poglavljima (npr. sličnost sa nekim modelima bioloških neurona kao upravo osculatornih sistema u kojima je histerezis prepoznat kao ključna bihevioralna karakteristika i sl.).

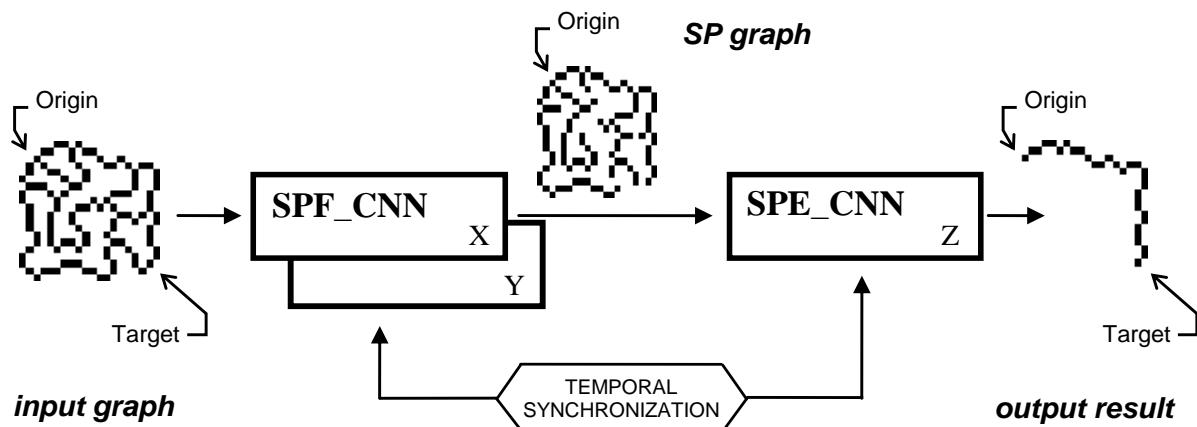
Neka novija istraživanja su dovela u vezu upravo fenomene autotalasa i asocijativne memorije, kao primer naprednijih kognitivnih funkcija, u CNM. Tako Xavier-de-Souza et al. [87] izvode novu metodologiju sinteze CNM koja ima sposobnost „učenja“ (memorisanja) prostorno-vremenskih šablonu („šara“, oblika) a koja se zasniva na sličnim principima kao i fraktalno-modularna LTT CNM za praćenje i predikciju trajektorije. Sličnost je veoma izražena i u samoj metodi, jer se slično kao kod fraktalne modualrizacije polazi od optimizacionog problema koji se „mapira“ u generalisanu energetsku funkciju CNM, kao i u topološkim i bihevioralnim karakteristikama same mreže (koja ima dvoslojnu strukturu, odnosno dve ćelije koje se mogu smatrati da formiraju modul, kao i auto-talase koji su osnova predikcije trajektorija koje formiraju memorisane oblike). Iako je sličnost velika, treba naglasiti da je fraktalna modularizacija izneta kao generalni koncept, primenjiv i primjenjen u širokom spektru kongitivnih procesa, dok je u radu Xavier-de-Souza et al. u pitanju specijalizacija odnosno primena na konkretnu klasu problema. Ipak, ovaj rad upravo daje potporu konceptu fraktalne modularizacije odnosno pokazuje da i drugi autori prepoznaju da osnovni postulati fraktalne modularizacije (energetska optimizacija) imaju prepozнату ne samo teoretsku već i praktičnu ulogu. Sa durge strane, upravo koncept fraktalne modularizacije potencira i samu modularnost, što npr. Xavier-de-Souza et al. ne prepoznaju niti potenciraju, a kao što će biti pokazano u narednim poglavljima upravo je modularnost jedna od ključnih karakteristika odnosno svojstava koje opredeljuje bliskost odnosno analogiju fraktalno-modularnih CNM sa biološkim neurokognitivnim sistemima.

Drugi primer je rad Szatmari et al. [92] koji iznosi novu metodu za primenu auto-talasa u prepoznavanju objekata odnsono separaciji partikula (metalnih parčića i vazdušnih mehura u metalurškom procesu) u realnim slikama. Ovakva primena je jedan od primera naprednijih kognitivnih funkcija koje se mogu realizovati primenom sličnih koncepata (i konačno i sličnih topoloških struktura) kao napred opisane fraktalno-modularne CNM.

U kontekstu teme ove disertacije, važno je naglasiti da ove CNM koje ispoljavaju kompleksnu prostorno-vremensku dinamiku dugo nisu dovedene u direktnu vezu sa kognitivnim procesima iako su još u ranoj fazi istraživanja uočena ponašanja koja mogu korelirati sa inteligentnim obradama (logičkim operacijama, naprednom obradom signala i sl.). Tako, u sklopu analize propagacije auto-talasa u napred opisanim dvoslojnim fraktalno-modularnim CNM, pokazano je da se auto-talasi mogu primeniti za nalaženje najkraćeg puta u lavirintu ([93]). Metoda koja je primenjena ipak nije potpuno bazirana na CNM arhitekturi već uključuje i eksterno procesiranje primenom drugih procesora (algoritam postprocesiranja koji memoriše stanje izlaza mreže i naknadno vrši klasičnu algoritamsku obradu nalaženja konkretne putanje). Dakle, iako predložena CNM mreža (koja ima sve odlike fraktalno-modularne strukture, kao što smo ranije objasnili) vrši važnu ulogu u procesu rešavanja ovog problema, ona nije sposobna da ceo problem reši samostalno bez dodatne klasične procesne komponente (računara von Neumann-ove arhitekture, jer zahteva i memoriju dakle ne može se prevesti na singularnu logičku operaciju, koji izvršava završnu fazu algoritma po definisanom programu). Iz ovog razloga, možemo reći da predložena arhitektura nije fraktalno-modularna CNM u potpunosti, niti je njena fraktalno-modularna CNM komponenta sposobna za samostalno izvršenje složenog kognitivnog procesa. Ipak, i ovaj početni rezultat je naznačio da fraktalno-modularne CNM možda mogu imati određena kognitivna bihevioralna svojstva.

Ispirisan ovom idejom, u radu [83] pokazano je da se primenom metode fraktalne modularizacije može ciljano sintetisati fraktalno-modularna SPF (*Shortest Path Finder*) CNM koja će samostalno, dakle bez ikakvih dodatnih podsistema procesiranja, rešiti kompletan problem nalaženja najkraćeg puta kroz lavirint (Slika 5). Ovaj rezultat pokazuje da naprednije kognitivne funkcije mogu biti implementirane u fraktalno-modularnim CNM strukturama što ih dovodi u direktnu vezu sa bihevioralnim karakteristikama i performansama biološkim sistemima. Jer pod problemom nalaženja najkraćeg puta u lavirintu se može podvesti

čitav niz vrlo naprednih kognitivnih procesa koji su prepoznati u biološkim sistemima, kao što je snalaženje u prostoru, određivanje optimalnih putanja kretanja, refleksne reakcije itd. ([94], [95], [96]) što je upravo i aktualizirano u nekim novijim radovima koji se sve više bave ovom problematikom (rad [83] je objavljen još 1996. godine, a citiran je i u skorije vreme u nekim novim referencama npr. [75], [97], [98], [99] koje se upravo bave biološki inspirisanim implementacijama vizuelnih sistema).



Slika 5: Fraktalno-modularna SPF CNM koja samostalno spontano nalazi najkraći put kroz labyrin (preuzeto iz [83]). U opštem slučaju primenjivo na razne klase problema uključujući optimizacije kretanja, rutiranje, snalaženje u prostoru itd.

Zanimljivo je istaći da je samo dve godine nakon objavljivanja fraktalno-modularne SPF CNM, objavljen i rad (Munuzuri i Chua, [100]) koji prestavlja realizaciju gotovo identičnog analogičkog algoritma (za nalaženje najkraćeg puta) ali primenom CNM u kojima su ćelije formirane na bazi Chuinh kola, dakle nelinearnih oscilatora. Značajna je upravo ova analogija - da napred opisana fraktalno-modularna SPF CNM ima identične bihevioralne karakteristike (ponašanje, odnosno funkciju koju vrši) kao i ova druga, znatno kompleksnija mreža. Dakle, fraktalna modularnost, na neki način, donosi kompleksniju funkcionalnost sistemu bez potrebe da se poveća interna kompleksnost pojedinačne ćelije⁵.

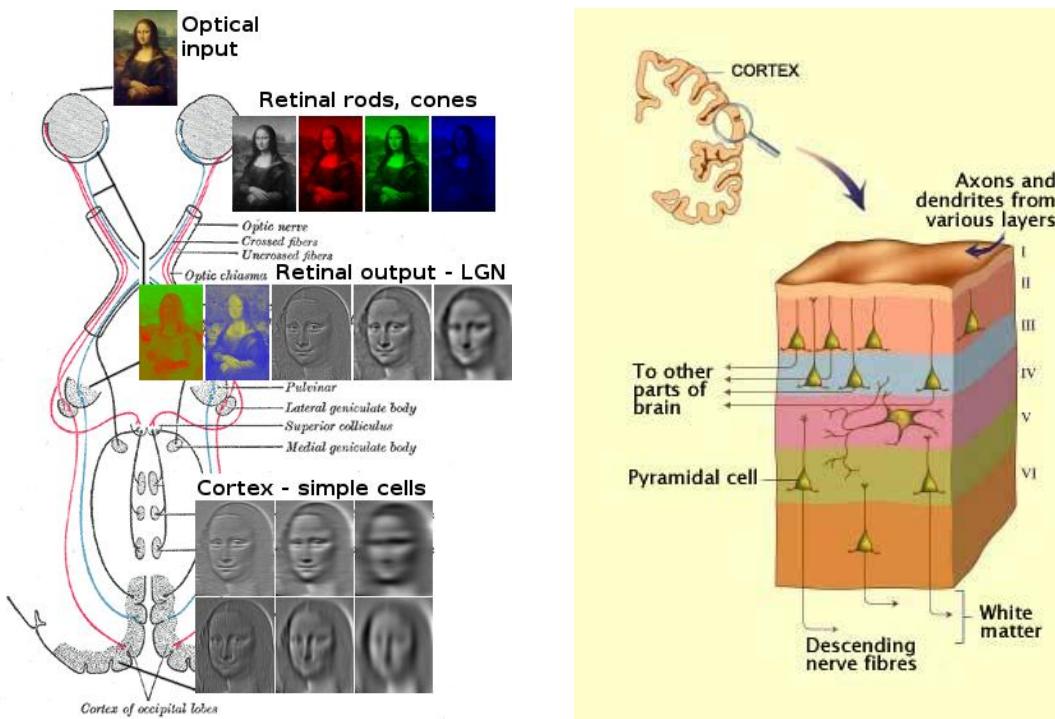
Ovi pravci istraživanja nisu usamljeni upravo jer je analogija i veza sa biološkim bihevioralnim procesima veoma atraktivna. Jedan turski tim, počevši od 2010. godine, radi na sličnim problemima i publikovao je radove koji na veoma sličan način, primenom

⁵ Iako je ovo nerofmalan zaključak, važno ga je istaći jer može biti od interesa kao inspiracija za buduća istraživanja.

višestepenih algoritama baš kao u SPF CNM (Slika 5), realizuju robotski sistem za praćenje i navigaciju u prostoru (Yeniceri et al. [101]). Naglasimo da je jedno veliko ograničenje pomenutog metoda Yeniceri et al. iskazano kroz striktno ograničenje da se njihov algoritam može primeniti samo na ravni labyrin, dok je SPF CNM upravo univerzalna jer se uz pogodno modelovanje (varijabilnost, plasticizam) sinaptičkih veza može primeniti i na tzv. neravni (engl. *wrinkled*) labyrin. Dakle, zahvaljujući fraktalnoj modularnosti, možemo spekulisati da je SPF CNM univerzalnija i naprednija u (kognitivnoj) funkcionalnosti.

Ovi primeri ukazuju da su i drugi autori prepoznali da mreže koje imaju fraktalno-modularne karakteristike (mada ih tako ne referišu) mogu ispoljavati složene funkcije i realizovati napredne kognitivne procese upravo na principima koji su postavljeni konceptom fraktalne modularnosti (uključujući i koncepte analogičkih algoritama, odnosno višestepene i sinhronizovane dinamičke obrade, koji su takođe uvedeni upravo u sklopu fraktalno-modularne sinteze SPF CNM).

Kao što je ranije napomenuto, zbog planarne 2D topologije, CNM pa i fraktalno-modularne CNM se često koriste za primene u kojima se vrši obrada ili prikaz rezultata u vizuelnoj formi (ulazi signali mreže i njena stanja se prikazuju kao matrice piksela odnosno digitalne slike). Takođe, već je napomenuto, da je izvorna CNM kako su je predstavili Chua i Yang upravo i primenjena u oblastima procesiranje slike ([20]) i to je i dugo ostala ključna oblast primene i razmatranja bihevioralnih performansi mnogih klasa CNM. Iako te primene mogu imati širok spektar kompleksnosti u smislu inteligencije odnosno kognitivnih svojstava koja se kreću od trivijalnih senzorskih obrada ulaznig signala (detekcija ivica, supresija šuma, detekcije prostijih struktura i sl.) pa do vrlo naprednih kognitivnih funkcija (poput prepoznavanja tekstura, nalaženja najkraćeg puta kroz labyrin ili asocijativnih memorija koje prepoznaju složene oblike i sl.) uvek se postavlja pitanje odnosa bihevioralnih karakteristika CNM i bioloških vizuelnih sistema.



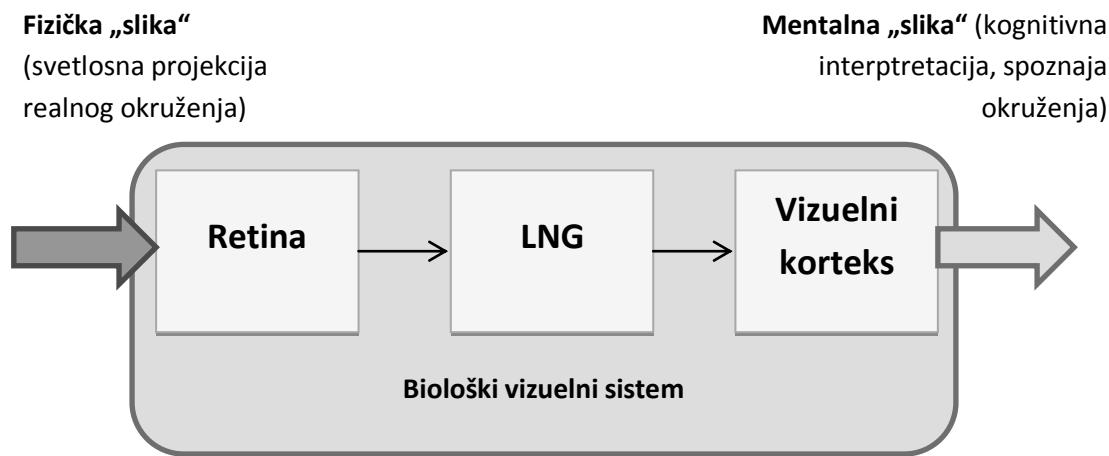
Slika 6: Biološki vizuelni sistem se sastoji od retine (levo, preuzeto sa http://en.wikipedia.org/wiki/Visual_system) i vizuelnog korteksa (desno, preuzeto sa http://thebrain.mcgill.ca/flash/d/d_02/d_02_cl/d_02_cl_vis/d_02_cl_vis.html).

Vizuelni sistem u biološkim vrstama, npr. u primatima, je složen i smatra se da se neuroanatomski sastoji od tri komponente:

1. retina je sastavni deo oka, sastavljen od niza ulančanih ćelijskih podstruktura, i funkcionalno služi kao senzorski ulaz koji vrši konverziju svetlosne pobude u neuroimpulse koji se očnim nervom prenose u LNG;
2. LNG (*lateral geniculate nucleus*) je međusistem koji dodatno obrađuje signale sa retine i transofrmiše ih (projektuje ih) na prvi sloj vizuelnog korteksa gde se u stvari prvi put formira spoznaja o slici (dakle, LNG nema kognitivnu funkciju u uskom smislu te reči već je neki međustepen i predobrada „sirovih“ signala koji stižu sa retine oka);
3. vizuelni korteks, koji je deo cerebralnog korteksa mozga, je složen, višeslojan (smatra se da postoji 6 slojeva vizuelnog korteksa), hijerarhijski povezan (veze nižih nivoa prema višim su dominantne) neurofizološki sistem za koji se

smatra da je pravi kognitivni sistem odnosno da se tek u njemu formira spoznaja o slici (u prvom sloju, često označenom kao V1) kao i da je on zadužen za dalje obrade informacija iz sadržaja slike (što se odvija hijerarhijski, kroz slojeve V2-V6 pri čemu viši slojevi imaju naprednije kognitivne funkcije koje idu od prostog razumevanja scene do prepoznavanja oblika, lica, predmeta, spoznaje 3D prostora itd.).

Ne ulazeći dalje u neuroanatomiju i neurofiziologiju vizuelnog sistema, možemo ga sistemski posmatrati kao kaskadnu vezu tri segmenta koja (pod pretpostavkom da se radi o linearnom sistemu, što se uobičajeno koristi i mnogi autori smatraju ispravnim [102]–[105]), u celini posmatrano, čine jedan prenosni informacioni sistem „ulaz-izlaz“.

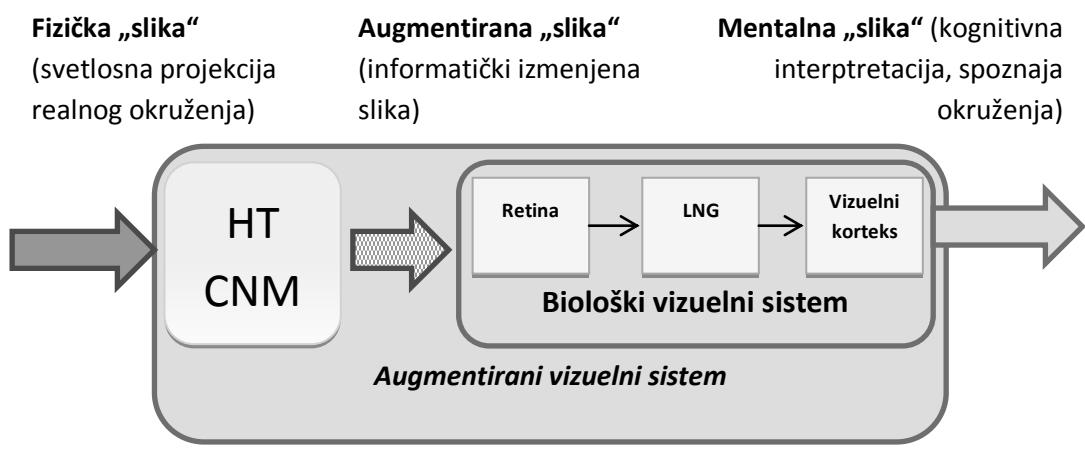


$$MI = T_R * T_{LNG} * T_{VC} * FI = T_{BVS} * FI$$

Slika 7: Informacioni model „ulaz-izlaz“ vizuelnog sistema. Ulagni fizički signal, svetlosna projekcija realnog okruženja, se preko retine, LNG-a i 6 slojeva vizuelnog korteksa transformiše u mentalnu sliku odnosno informaciju unutar mozga koja predstavlja interpretaciju fizičke slike i spoznaju realnog okruženja. Prenosna funkcija ovakvog sistema može se izraziti kao kaskadna konvolucija prenosnih funkcija podsistema.

U radovima [81], [82] i [106] pokazano je kako se CNM, koja upravo ima svojstva fraktalne modularnosti i vrši definisani optimizacionu funkciju, može primeniti na vizuelno unapređenje slike, odnosno transformaciju ulazne slike uz zadržavanje ili čak poboljšanje subjektivne spoznaje sadržaja. Jedna od primena je i tzv. polutoniranje slike. Ova primena je inače odavno poznata u klasičnoj digitalnoj obradi slike (odavno se koristi za štampanje slike u crno-beloj tehnici uz subjektivni osećaj nijansi sive), i bazira se na transofrmacija ulazne

slike u sliku koja ima redukovani informacioni sadržaj (meren kroz borj bitova kojim se može kodovati, što u slučaju npr. crno-belog polutoniranja znači da se svaki piksel može kodirati sa jednim bitom na izlazu bez obzira što je ulazna slika, uobičajeno, kodirana sa 8 bita odnosno 256 nivoa sive boje na ulazu). Iako ova funkcija na prvi pogled možda izgleda trivijalno, važno je zapaziti da je njena primena upravo jedna vrsta eksperimentalne mogućnosti da se uloga i mesto fraktalno-modularne CNM uključi u napred definisani informatički model biološkog vizuelnog sistema (Slika 8).



Slika 8: Informacioni model „ulaz-izlaz“ vizuelnog sistema u kojem je uključena i halftoning (HT) celularna neuralna mreža.

Sistemski posmatrano, pošto je izlaz sistema isti u oba slučaja (subjektivni osećaj posmatrača je da su slike iste ili gotovo iste, odnosno da nema bitne degradacije mentalne slike u slučaju kada se primeni polutoniranje originalne slike primenom HT CNM), možemo smatrati da je prenosna funkcija HT CNM koja redukuje informacioni kapacitet ulazne slike meren binarnim kodovanjem piksela (dakle klasičnim informacionim modelom) invarijantna u odnosu na informaciono procesiranje koje vrši biološki vizuelni sistem. Odnosno, da se može izvući neformalni zaključak da informatičko enkodiranje unutar biološkog vizuelnog sistema nije direktno ekvivalentno klasičnom enkodiranju koje se primenjuje u digitalnoj obradi slike (dakle u klasičnim informatičkim sistemima koje koristimo u računarskim sistemima) ali i da HT CNM enkodira informacije na kompatibilan način kao i biološki vizuelni sistem.

3 Pregled savremenih istraživanja iz oblasti neuronauka

U ovom poglavlju će biti dat sistematski pregled istraživanja i rezultata iz oblasti neuronauka a koja su izvršena u poslednjih desetak-dvadeset godina, dakle u periodu nakon ranije navedenih rezultata u oblasti fraktale modularizacije u celularnim neuralnim mrežama. Akcenat je na praćenju progresa u sagledavanju topoloških i funkcionalnih svojstava na različitim nivoima korteksa i neurofizioloških struktura, identifikaciji funkcionalnih i procesnih modela, kao i interpretaciji tih rezultata u smislu približavanja matematičkom modelovanju kao osnovi za egzaktno posmatranje i razumevanje bihevioralnih svojstava kognitivnih procesa. Obzirom da se radi o veoma širokom polju, nije moguće obuhvatiti sve rezultate i istraživanja te će ovde biti izložen pregled ključnih rezultata koji će biti selektovani po kriterijumima kvaliteta publikacije (po kriterijumima citiranosti na *Google Scholar*, *ISI Ranking-a*, *Science Citation Index-a* i/ili *Impact Factor-a* publikacije i sl.).

3.1 Metodologija sistematskog pregleda i meta-analize

Sistematski pregled i meta-analiza literature i naučnih rezultata je često primenjena metoda naučno-istraživačkog rada u oblastima medicine gde je eksperimentalno i observabilno istraživanje ispred teoretskog i matematičkog modelovana. Upravo oblasti neuronauka, kognitivnih nauka, neurologije, posebno neurofiziologije i neuropsihologije, su primeri oblasti gde se u zadnjih desetak godina zapaža sve veće prisustvo ove metodologije u sagledavanju i razmatranju obilja rezultata koji se objavljaju ili interpretiraju sa različitim aspekata.

Značaj ove metode je doveo do formulisanja nekoliko metodoloških pristupa, koji su formalno opisani i sistematizovani od strane nekoliko referentnih naučno-istraživačkih organizacija i fondacija širom sveta. Tako, *Cochrane Collaboration* fondacija već više od deset godina razvija i održava svoju preporučenu metodologiju sistematskih pregleda i meta-analize naučnih rezultata u oblasti medicine i bionauka, koja je publikovana u vidu javno dostupnog priručnika „*Cochrane Handbook for Systematic Reviews of Interventions*“ ([107]).

Drugi primer je uputstvo (priručnik) Centra za pregled i diseminaciju Univerziteta u Jorku, Velika Britanija, koji je posebno profilisan za oblasti medicine i zdravstva, pod nazivom „*Systematic Reviews: CRD's guidance for undertaking systematic reviews in health care*“ ([108]). Postoje i mnoge druge slične metodologije i uputstva za primenu sistematskog pregleda i meta-analize naučnih rezultata, koje su profilisane za druge naučne oblasti izvan polja medicine i bionauka, kao i koje se specifično profilisane za pojedine segmente ovih oblasti uzimajući u obzir specifičnosti raspoloživih sredstava, metoda kao i samih ciljeva istraživanja u tim specijalnostima. Tako Centar za kognitivnu zrelost i kognitivnu epidemiologiju (*Centre for Cognitive Ageing and Cognitive Epidemiology - CCACE*), Univerziteta u Edinburgu, Velika Britanija je formulisao vlastitu specijalizovanu metodologiju ([109]) na osnovu sublimacije prethodne dve opšte metodologije. Ova metodologija je pogodna jer je formulisana od strane referentnog naučno-istraživačkog centra, koji ima dugu tradiciju uspešnog naučno-istraživačkog rada i to baš u oblasti kognitivnih nauka koje su od interesa za temu ove disertacije. Ona je bazirana na gore navedenim opštim metodologijama, ali je profilisana za neurokognitivne oblasti medicine što je za ovu disertaciju od posebnog značaja.

Konačno, mada je to opšte poznata činjenica, treba naglasiti da se u meta-analizi vrlo često primenjuju mehanizmi tzv. neformalne logike. Dok je formalna, matematička, logika doživela buran razvoj posebno tokom 20. veka, paralelno se razvijala i u poslednjim decenijama veoma intenzivirala primena neformalne logike (koja se još referiše i kao *dijalektička logika* ili pak samo kao *logika* u opštoj naučnoj metodologiji) naročito kao metodologija naučnog istraživanja u realnim i prirodnim naučnim oblastima ([110], [111]).

3.2 Modularnost i fraktalnost u neurokognitivnim strukturama

Modularnost je koncept koji je od velikog značaja za sve biološke sisteme, počevši od sub-celularnih nivoa [112] pa sve do najviših kognitivnih nivoa [113]. Brojni su radovi koji se upravo bave definisanjem i razmatranjem koncepta modularnosti kako u biološkim tako i u veštačkim kognitivnim sistemima. Iako se radi o veoma širokoj oblasti, raspona od gotovo potpuno opipljivih - fizičkih (neuroanatomija, genetika) pa sve do gotovo apstraktnih (psihologija, sociologija) istraživanja i razmatranja, veliki broj autora se referiše na fundamentalne postavke koje su iznete u referentnom radu J. Fodora [114] objavljenog još

1983. godine, a koje se tiče teorije / hipoteze o modularnosti neurokognitivnih struktura (moždanih struktura) u kontekstu psihologije. Novija istraživanja i objavljeni rezultati su doneli nova saznanja, čak i opovrgavaju neke izvorne Fodorove premise, ali suštinski se modularnost neurokognitivnih struktura čak štaviše utvrdila kao stav koji je opšte prihvaćen ([31], [115], [39]).

U sklopu progra u razvoju shvatanja i istraživanja važnosti i uloge modularnosti u kognitivnim strukturama, važno je da se pomene da je Fodor 2001. godine, dakle skoro dve decenije posle objavljanja fundamentalnog rada [114], objavio knjigu [116] u kojoj iznosi izvesnu rezervu u odnosu na široko prihvaćeno shvatanje modularnosti (masovne modularnosti kao pretpostavljene strukture kognitivnih sistema) kao osnove kognitivnih neuropsiholoških procesa posebno na višim nivoima svesti. On prihvata *komputacionu teoriju* svesti kao najbolju teoriju kognicije koju trenutno imamo na raspolaganju, ali takođe podvlači da je razumevanje stvarne uloge modularnosti u tim procesima još daleko od punog naučnog razumevanja. Drugim rečima, on ne opovrgava tezu modularnosti bioloških kognitivnih struktura (koja je uostalom sve više dokazana neposrednim eksperimentalnim istraživanjima i proučavanjem kako neuroanatomskih struktura tako i neuropsiholoških procesa), ali skreće pažnju da postoji ozbiljan prostor u kojem nije naučno objasnjena veza i mehanizmi kojima modularne strukture ispunjavaju funkcionalne zahteve kognitivnih procesa posebno u kontekstu komputacione teorije svesti. Iako je ovaj Fodorov rad sada već star gotovo 15 godina, značajno je primetiti da ova oblast još ni iz daleka nije do kraja istražena niti je dat definitivan naučni stav po ovom pitanju. Dakle, odnos modularnosti i kognitivnih procesa, mehanizmi i aspekti koji utiču da modularne strukture mogu imati kognitivna svojstva, upravo su i dalje aktuelni i tema ove disertacije upravo ima za cilj da ponudi neke odgovore na ova pitanja.

Jedna od ključnih primedbi Fodorovog odnosa prema masovno-modularnoj teoriji kognitivnih sistema je da su moduli po (njegovoj izvornoj) definiciji „rigidni“ dok je svest po definiciji „fleksibilna“ (tj. sposobna da se nosi sa promenljivošću ambijenta odnosno varijabilnošću konteksta stvarnosti) te stoga dovodi u pitanje hipotezu masivne (rigidne) modularnosti. Treba imati u vidu da je Fodor psiholog te da su njegova poimanja „rigidnosti“ i „fleksibilnosti“ ali i korelacija tih svojstava više filozofskog nego praktičnog odnosno

inženjerskog karaktera. Zato su tokom poslednje decenije nastali mnogi pravci teorijskog ali i praktičnog razmatranja koji daju odgovor na ovaj naizgled nepremostiv paradoks.

Jedan vrlo izražen trend je da se modularnost i moduli posmatraju šire od uskog, rigidnog, Fodorovog gledišta, koje je izvorno bilo primereno ranim sagledavanjima i saznanjima o neuroanatomskoj strukturi nižih slojeva, prvenstveno ulaznih (senzorskih) struktura. Nova shvatanja modularnosti neurostruktura podrazumevaju da moduli mogu imati adaptivna i kontekstno osetljiva svojstva i/ili strukturu, a da time ne budu narušena osnovna priroda karakterizacije koja definiše modularnost odnosno samu modularnu arhitekturu.

Jedna takva teoriju je razvio Sperber [117] i ona daje novu klasifikaciju modularnih struktura koja ne samo da pomiruje „rigidnost“ i „fleksibilnost“ već je stavlja u biološki opravdan kontekst evolutivnih prirodnih procesa razvoja (što je važno sa stanovišta opravdanja da se takve teorijske postavke zaista mogu smatrati inherentnim biološkim sistemima i strukturama, odnosno živim bićima u opštem kontekstu). Sperber iznosi biološke dokaze, kroz primere koji su direktno vezani za poznata i priznata eksperimentalna naučna istraživanja, da modularnost ne mora uvek biti rigidna već da postoji spektar kognitivnih modularnih formi koje variraju od rigidne, gentski determinisane, strukture („pre-wired“) pa do kognitivnih struktura koje ne mogu biti genetski determinisane jer su suviše „nove“ u biološkom razvoju čoveka da bi se moglo govoriti o evolutivnom razvoju specijalizovanog genetski diktiranog sistema. Primer, prve kategorije je npr. „usađeni“ refleksi i nagoni (dokazani kroz brojne eksperimente) a primer druge kategorije je npr. sposobnost čitanja koja se uči. Između ovih krajnosti, Sperber daje niz drugih važnih primera kognitivnih procesa koji se oslanjaju na modularnost strukture ali uvode i određene potrebe za fleksibilnošću odnosno kontekstnim učenjem (npr. prepoznavanje lica, gde je opšti kognitivni proces prepoznavanja lica inherentan ali se kontekstno prilagođava sredini u kojoj živimo – poznato je da npr. lakše prepoznajemo lica iz svog okruženja, iz svoje etničke grupe). On izvodi zaključak da to ukazuje da masivna modularna struktura ne mora biti rigidna već može prestavljati i neke *fleksibilne* balanse između strukturalnih i adaptabilnih faktora koja omogućavaju formiranje kognitivnih procesa na različitim nivoima svesti.

Sperber, načelno, fleksibilnost deli na kratkotrajnu i dugotrajnu u mentalnim modulima. Dok kratkotrajna, proračunata ili komputaciona fleksibilnost, predstavlja više

bihevioralno prilagođenje odnosno odgovor „modula“ (neuralne strukture u opštem smislu) na promenjive uslove sredine (okruženja), dugotrajna fleksibilnost je više vezana za sposobnost modularizacije strukture pod spoljnim uticajima sredine. Drugim rečima, prva vrsta (kratkotrajna fleksibilnost) je svrshodna za operativno upravljanje jedinke u konkretnim (promenjivim) uslovima životne sredine i interakciju sa okruženjem (u funkciji uspešnosti opstanka) - dakle neka vrsta operativne inteligencije. Druga vrsta, često referisana i kao „razvojna“ ili „evolutivna“ inteligencija, se formira dugotraјnim procesima i moguće da se utiskuje i prenosi putem genetskog nasleđa, a važna je za opšte prilagođenje jedinke ambijentalnim uslovima i okolini u kojoj dugoročno opstaje i razvija se (urođeno i kulturno nasleđe).

Sperber nije usamljen u ovim shvatanjima ([118], [7]) i sada se već može govoriti o vrlo široko prihvaćenom konceptu (poznatom pod nazivom „masivno modularna teorija“) koji se sve više reflektuje u novim istraživanjima i saznanjima o efektivnim ulogama modularne fleksibilnosti u kognitivnim procesima, posebno na višim nivoima svesti. Tako, Franks u knjizi koja se posebno bavi modernim psihološkim sagledavanjem pitanja ljudske kulture kao najvišeg kognitivnog nivoa svesti [119] posebno poglavlje je posvećeno upravo značaju fleksibilne modularnosti, i to upravo na način na koji je postavlja Sperber. Dakle, možemo govoriti o opšte prihvaćenom gledištu da se modularnost javlja na svim, od najnižeg do najviših, nivoa nurokognitivnih struktura i procesa.

Iz spektra ovih mogućih varijacija *fleksibilnosti* izdvojićemo dve koje imaju značajnu korelaciju sa temom ove teze odnosno sa osobenostima veštačkih fraktalno-modularnih celularnih neurlanih mreža:

1. Predeterminisana struktura (genetski „pre-wired“) koja imaju ugrađena ponašanja (instikte) i koji se ne menjaju u kontekstu biološkog (životnog) okruženja odnosno nema dodatnog učenja i prilagođavanja.
2. Genetski diktirana struktura koja ima mogućnost da se neki elementi mogu dodatno učiti u biološkom kontekstu (životnom okruženju) kroz podešavanje parametara veze između modula iako su veze predeterminisane.

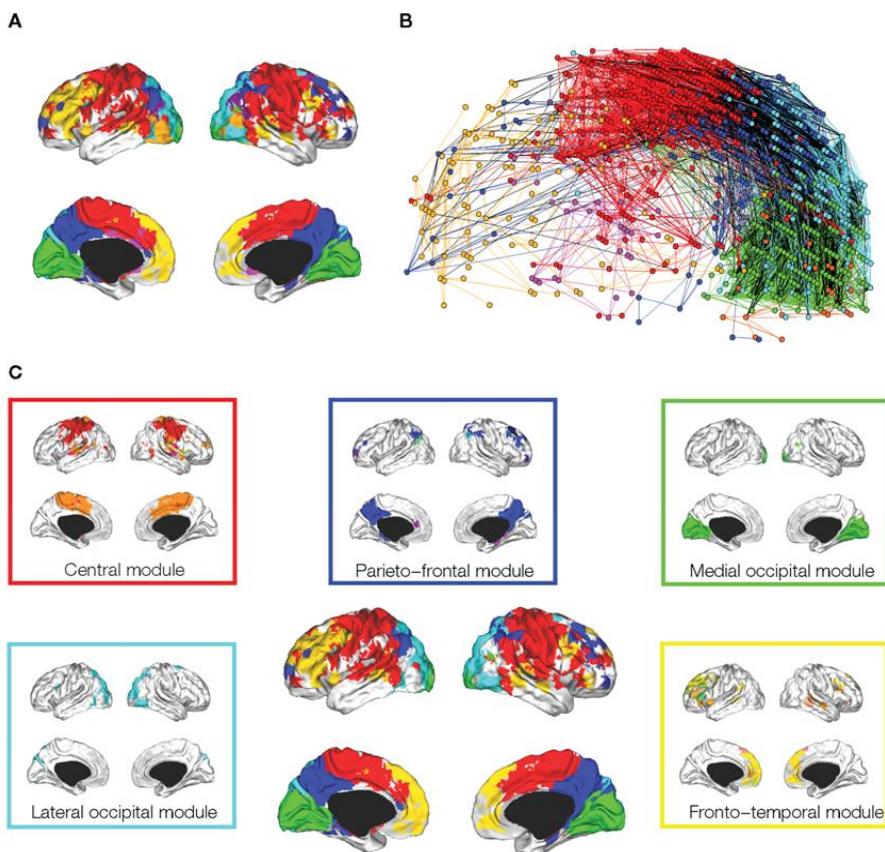
Iako će detaljna analiza biti data u narednim poglavlјima, važno je naglasiti da ove dve varijacije upravo koreliraju ne samo sa strukturalnim već i sa dinamičkim karakteristikama koje su vezane za klase fraktalno-modularnih CNM od interesa. U strukturalnom smislu, dakle, Sperber koristi i termin „šablon modula“ (*module template*) koji može u potpunosti identifikovati sa gotovo identičnim pojmom (šablon sinaptičkih konduktansi, veza) koji se sreće u klasama fraktalno-modularnih CNM koje su predmet ove teze. Naglašićemo ovde i da pod dinamičkim karakteristikama se podrazumeva prepoznata uloga eneregetskih optimizacija u samom mozgu. Iako Sperber iznosi više teoretska i spekulativna viđenja uloge energetskih optimizacija u kognitivnim procesima mozga, važno je napomenuti da ovakva viđenja su sve prisutnija upravo u oblastima izučavanja bhevioralnih karakteristika na visokim kognitivnim nivoima odnosno prepoznata je uloga energetske dinamike i optimizacije u njima iako jasni matematički modeli još ne postoje.

Najnovija istraživanja, bazirana na razvoju neuroimaging tehnologija poput magnetne rezonance (MRI) i sl., potvrđuju ove teoretske i empirijske koncepte koji su formulisani prvenstveno u psihologiji i tiču se najviših kognitivnih nivoa i same svesti. U zadnjih desetak godina, primena kompleksnih matematičkih alata u neuronaukama, i neuroimagingu posebno, doveli su do velikog napretka u razumevanju rada mozga na sistemskom nivou. Nekoliko nezavisnih istraživačkih timova je postiglo značajne rezultate i objavilo je niz radova ([1], [120], [121], [122]) koji su fokusirani na analitičke metode koje se mogu koristiti za proučavanje i sagledavanje kompleksne mrežne strukture iz neuroimaging skupova podataka (ali i drugih neurofizioloških posmatranja) i kvantifikacije topološke organizacije neurokognitivnih struktura.

Tako, Gallos et al. [123] izvode novu metodu koja omogućava da se eksperimentalni rezultati MRI snimaka dovedu u vezu sa matematičkim modelom koji opisuje modularizaciju mozga na principima optimizacije „cene“ informacionog protoka (citat: „maximizing information transfer with minimal wiring cost“). Struktura koja se izvodi je hijerarhijski modularna sa elementima fraktalnosti (o čemu će biti više reči u nastavku). Ovakva struktura pokazuje veliku korelaciju ne samo sa eksperimentalno utvrđenim ponašanjima i snimljenim eksitacijama u biološkim strukturama mozga, već značajno korelira i sa napred iznetim teorijama psihološkog ponašanja na višim kognitivnim nivoima.

U istom smeru idu i najnovija istraživanja pa tako npr. Russo et al. [124] dalje pokazuju ne samo održivost i utemeljenost prethodnih istraživanja modularnosti mozga, već i pokazuju biološku važnost modularnosti u tzv. kritičnim spontanim ponašanjima. Važno je naglasiti da njihov rad upravo korelira i sa napred navedenim pitanjima fleksibilnosti unutar modularizovane strukture neuralnog sistema, odnosno oni pokazuju da modularna struktura mora biti fleksibilna, sa sposobnošću ne samo adaptacije sinaptičkih jačina (veza među elementima modula - neuronima) već i strukturalne promena na širem planu (jačine i brojnosti sinaptičkih veza na intermodularnom nivou) da bi se održavalo prirodno (zdravo odnosno normalno) ponašanje i kritične funkcije mozga. Ovaj rad je značajan i zbog toga što se u njemu podvlači analogija između ovih rezultata i rezultata jedne studije stabilnosti u elektroenergetskom sistemu USA, gde su primenjeni slični matematički modeli. Dakle, kao što je ranije naglašeno, najnovija istraživanja u oblastima neuronauka formulišu matematičke modele koji su u ovom trenutku bazirani na strukturalnim odnosno topološkim karakteristikama nerokognitivnih bioloških sistema, a u naznakama se pojavljuje i veze i analogije sa energetskom dinamikom. Ovo je važno istaći jer će se u nastavku ove teze posebna pažnja posvetiti i matematičkom modelovanju energetsko-dinamičkih procesa u fraktalno-modularnim veštačkim celularnim neuralnim mrežama što upravo korelira sa ovim pitanjima na koja neuronauke u ovom segmentu nemaju jasan odgovor.

Jedan od zapaženijih radova je i [39] u kojem Menuir et al. izvode opšti pregled trenutno aktuelnih matematičkih koncepta za kvantitativnu analizu hijerarhijske modularnosti neurokognitivnim mrežama moždanih struktura i sumiraju niz skorašnjih rezultata koji istražuju modularnost mozga na strukturalnom ali i na funkcionalnom nivou na bazi fMRI neuromimidžinga ljudi. U ovom vrlo citiranom radu, oni prikazuju i nekoliko impozantnih rezultata koji vizuelizuju modularnu strukturu ljudskog mozga i to ne na bazi samo teoretskih već, kako je naglašeno, eksperimentalnih rezultata obrađenih matematičkim alatima koji potvrđuju premise modularnosti kao inherentne strukturalne i funkcionalne karakteristike neurokognitivnih struktura na gotovo svim nivoima (Slika 9).



Slika 9: Vizuelizacija hijerarhijske modularnosti funkcionalne neuronske mreže ljudskog mozga (preuzeto iz [39]).

Iz napred navedenog, može se zaključiti da je modularnost prepoznata kao ključni koncept na svim nivoima bioloških a posebno kognitivnih struktura, počevši od sub-ćelijskih mreža pa sve do najviših kognitivnih nivoa svesti u ljudskom mozgu (najviših intelektualnih funkcija). Naučno su dokazane ne samo genetske prepostavke modularnosti već i dinamička ponašanja koja formiraju prostorno-vrmenske energetske raspodele za koje se veruje da upravljuju upravo kognitivnim procesima.

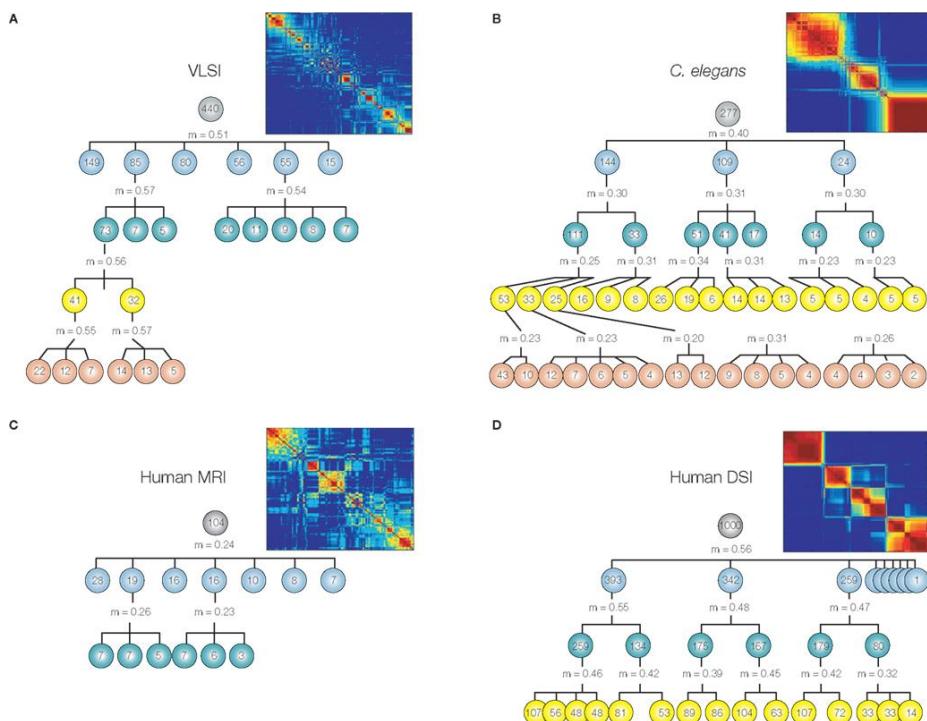
Nezavisno od modularnosti, fraktalne strukture su relativno davno prepoznate na raznim nivoima neuroanatomije. Prve naznake o mogućoj važnosti fraktala u samim neurokognitivnim procesima (dakle i sa funkcionalnog aspekta a ne samo strukturalnog) je naznačio King još 1991. godine imlicirajući da „fraktalna dinamika može biti od funkcionalne koristi u kognitivnim procesima centralnog nervnog sistema“ [125]. Potvrda ove teze je došla kasnije, 1998. godine, kada su nove neuroimaging tehnologije (PET, SPET)

dovele do mogućnosti sagledavanja fraktalne strukture u biološkim neuro sistemima [126]. Ipak, tek relativno nedavno, skoro dvadeset godina nakon Kingovog rada, sagledani su širi aspekti značaja fraktala u neuro-sistemima, posebno implikacije koje fraktalna struktura može imati u domenu samoorganizujućih kognitivnih (inteligentnih) bioloških sistema [40]. Werner tako u ovoj referenci podvlači da je upravo nedavni napredak u metodologiji merenja fraktalne povezanosti na višim organizacionim nivoima mozga doveo do novih saznanja koja povezuju upravo fraktalne karakteristike sa složenom kompleksnošću dinamičkih procesa na raznim kognitivnim nivoima. On referiše i najnovije teorije koje formulišu čak i „fraktalnu (samosličnu) logiku“ koja operiše nad skupovima identičnih pravila koja upravljuju interakcijam povezanih slojeva moždanih neurostruktura [127]. Agnati objašnjava ovaj princip upravo preko analogije sa „disipativnim sistemom koji se sastoji od više ugnježdenih hijerarhijskih nivoa“ pri čemu „svaki od nivoa je definisan samosličnim strukturama koje se sadrže same u sebi“. Ovakva struktura se po svim karakteristima poklapa sa ranije navedenim definicijama koncepta fraktalnosti, iako sami autori ne koriste taj termin. Konačno, u kontekstu teme ove disetacije, veoma je korisna i u ovoj referenci ekstenzivno razvijena definicija disipativnih bioloških sistema koji su „otvoreni termodinamički sistemi sposobani da održavaju stabilnost daleko od ekvilibruma“, a koja je u fizičkoj osnovi identična i definiciji disipativnih dinamičkih električnih kola (a time i samih celularnih neuralnih mreža, konkretno). Dalje, ova referenca je značajna i iz razloga što iznosi dokaze koji ukazuju da je fraktalna (samoslična) logika, i fraktalnost uopše, u biološkim strukturama inherentna evolutivnim principima. Dakle, fraktalnost ne samo da može pomoći u funkcionalnom razumevanju kognitivnih sistema i struktura, već je i moguće da je ona upravo inherentni uzrok postojanja tih struktura i kognitivnih (inteligentnih) procesa u njima.

Imajući sve ovo u vidu, možemo zaključiti da je fraktalnost bitna karakteristika bioloških neuro-struktura, i da postoje vrlo rasprostranjena istraživanja i teorijske postavke koje dovode u direktnu vezu funkcionalne procese kognitivnih struktura upravo sa fraktalno-dinamičkim karakteristikama ne samo na strukturalnom već i u dinamičkom domenu.

Veći broj referenci i fokus trenutno aktuelnih istraživanja je na strukturalnoj analizi fraktalnosti u biološkim neurokognitivnim strukturama primenom raznih neuroimaging tehnologija. Tako je primenom magnetne rezonance (MRI) istražena fraktalnost strukture i kvantifikovana fraktalna dimenzija bele mase ljudskog mozga [128]. Gallos et al. [123] su

takođe pokazali da postoji matematička pozadina koja daje opravdanost široko uočenoj fraktalnosti i sub-modulanosti unutar moždanih struktura. Važno je naglasiti da oni upravo pokazuju da frakalnost u strukturi i modularnost nisu sinonimi odnosno da modularnost može postojati i bez izražene ili uopšte prisutne frakalnosti (što se u njihovom modelu parametrizuje jednim koeficijentom u modelu, a to omogućava upravo strukturalnu fleksibilnost za koju se pretpostavlja, kako je to ranije opisano, da je jedna od premissa funkcionalne inteligencije na svim kognitivnim nivoima).



*Slika 10: Analogija nekoliko veštačkih i bioloških struktura (neuroanatomske mreže) koje imaju veoma sličnu fraktalnu strukturu tipa "modul-unutar-modula" (preuzeto iz [39], originalno publikovano u [120]). (A) VLSI integrisano kolo, (B) *Caenorhabditis elegans*⁶, (C) ljudska neuroanatomska mreža estimirana pomoći MRI snimaka 259 dobrevoljnih ispitanika, i (D) ljudska kortikalna mreža estimirana primenom DSI (diffusion spectrum imaging) na pet dobrevoljnih ispitanika. Primetna je vrlo slična fraktalna hijerarhijska ugnježđena struktura (modul-unutar-modula).*

⁶ *Caenorhabditis elegans* – Mali (1mm), bezbojni crvić, koji se često koristi kao referentni model za biomedicinska istraživanja. Brenner je još 1963. predložio da se *C. elegans* koristi za istraživanja u oblasti neurologije i neuronauka, a od 1974. su počeli molekularna i druga istraživanja (na genetskom razvojnom nivou) i od tada se *C. elegans* koristi kao referentni organizam za modelovanje živih bioloških sistema. *C. elegans* je prvi višećelijski organizam čiji kompletan genetski kod je u potpunosti dekodovan. Od 2012. *C. elegans* je i dalje jedini organizam čiji je neuronski sistem u potpunosti istražen i formiran je kompletan neuroanatomski model („wiring diagram“).

3.2.1 Strukture „malog sveta“ u neurokognitivnim mrežama

Kako je napred pokazano, mnogi autori sagledavaju frakatalnost i modularnost kao nezavisne ali povezane karakteristike neurokognitivnih struktura. Upravo tu se postavlja pitanje sinergije odnosno koji su to faktori koji diktiraju taj balans fraktalnih i modularnih karakteristika strukture koje su svojestvene biološkim neurokognitivnim sistemima.

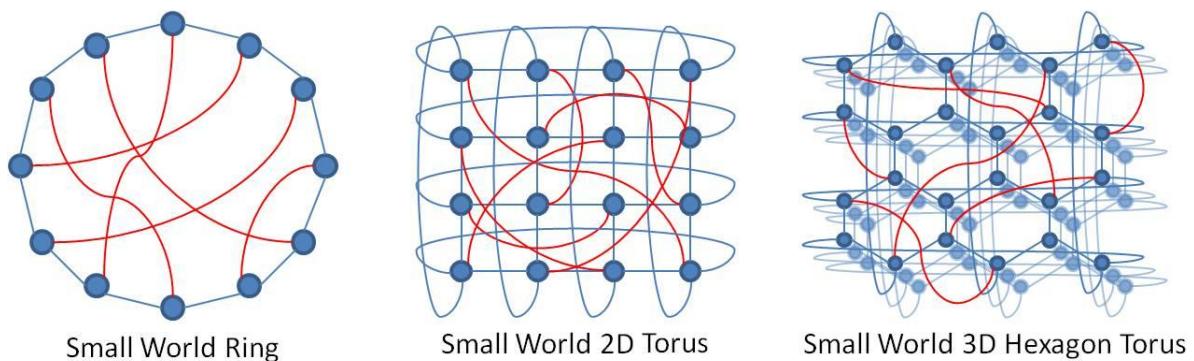
Teorija kompleksnih mreža, dakle ne usko gledano bioloških već generalno matematički posmatramo mreža uopšte, pruža teoretske osnove da se sagleda arhitektura neuronskih sistema uključujući i neurokognitivne biološke sisteme poput ljudskog mozga [39]. Tako, primenom formalnih matematičkih alata kako je to i objašnjeno u prethodnom izlaganju, sagledane su mnoge sličnosti odnosno podudarnosti neuroanatomske strukture mozga ali i drugih neuralnih struktura sa tzv. strukturama „malog sveta“ (*small-world*) ([120], [129], [130]). Strukture malog sveta su modularne strukture koje se karakterišu kratkim srednjim dužinama između svih parova čvorova mreže (što se često i referiše kao kratki prečnik mreže), zajedno sa visokim stepenom klasterizacije ili prenosnosti (*transitivity*). Watts i Strogatz su u svom veoma citiranom radu [131] dali ne samo matematičke definicije modela malog sveta već su i razradili nekoliko ključnih osobenosti koje su od interesa za praktične aspekte funkcionalnih i bihevioralnih karakteristika koje ovakve strukture mogu ispoljavati. Izvorno oni nisu bili fokusirani na neurokognitivne sisteme već na same generičke karakteristike i svojstva ovakvih struktura, te je ovaj njihov rad otvorio mnoge oblasti daljih istraživanja nezavisno od neuronauka (npr. savremene koncepcije u arhitekturi VLSI čipova, globalnih računarskih mreža, *data center-a* i *cloud-computing-a* u mnogome počivaju na modelu „malog sveta“).

Ovde je važno istaći dve karakteristike koje će kasnije biti posebno bitne za temu ove disertacije:

1. Ovakve mreže imaju regularne, rešetkaste (*lattice*), repetitivne topološke organizacije koje su diktirane svojstvom kratkih lokalnih veza. Ovakva topologija ima i važnu karakteristiku da ovakve, kratke lokalne veze koje dominiraju struktrom, imaju veliku ekonomičnost u pogledu „troškova“ povezivanja (*wiring costs*).

2. Definicija potencira da se strukture malog sveta karakterišu velikom većinom lokalnih veza (da bi se ispunio uslov iz definicije da su ukupne srednje dužine bliske minimalnim) ali to ne znači da su sve veze minimalne dužine. Upravo ovo svojstvo obezbeđuje da topologije struktura malog sveta imaju i određen, statistički gledano znatno manji broj ali ipak konačan, nelokalnih veza odnosno veza koje nisu bliske minimalnoj dužini. Time se obezbeđuju „prečice“ i veća efikasnost prenosa informacija između klastera čvorova (modula) mreže.

Kao što je naglašeno, struktura malog sveta topološki može biti ostvarena u različitim dimenzijama i organizacijama (Slika 11).



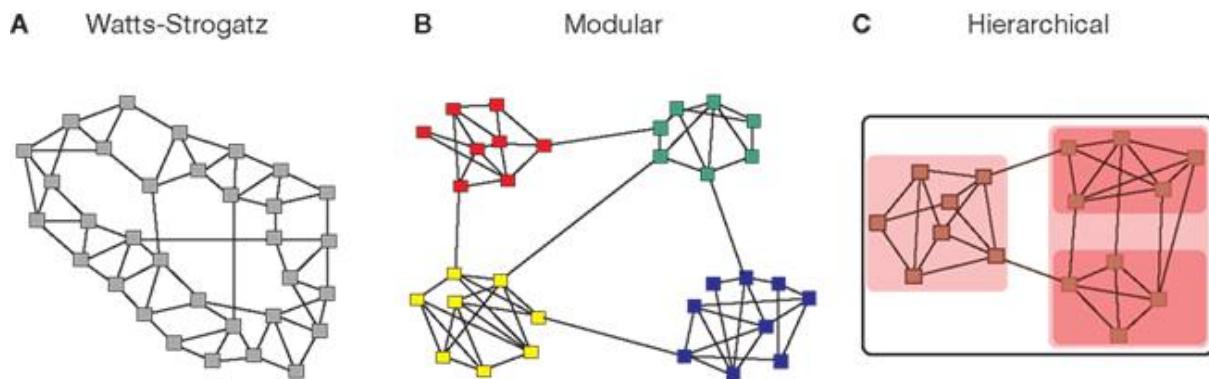
Slika 11: Ilustracija topologija 1D, 2D i 3D struktura malog sveta (preuzeto sa <http://www.cs.cornell.edu/~jyshin/proj/swdc>).

Ove dve navedene osobenosti su od izuzetnog značaja za fizičku opravdanost modela strukture malog sveta u neurokognitivnim sistemima. Njihova synergija obezbeđuje da se uz minimalne „troškove“ interkonekcija postiže veliki informacioni protok i procesna sposobnost u globalu (neurokognitivna funkcija). U neuoratomatskom domenu, to potpuno korelira sa eksperimentalno utvrđenim činjenicama da su veze neurona lokalne, da je neuron prosečno povezan sa vrlo malim brojem drugih neurona – u pitanju su desetine ili pak stotine zavisno od kortikalne strukture - u odnosu na ukupan broj neuronskih ćelija u npr. ljudskom mozgu – gde se radi o stotinu milijardi neurona u proseku [132].

Odnos modularnosti i svojstava malog sveta je kompleksan. Dok model malog sveta daje neka metamatičke, formalne, karakterizacije mrežne topologije na globalnom (dijametar ili prečnik mreže, odnosno najduže interkonekcije) i lokalnom nivou (karakteristika da je

prosečna dužina konekcije bliska minimalnoj – tzv. trijangularizacija jer je u trouglu to upravo idealan slučaj), on ne daje potpuni odgovor na pitanje modularizacije mreže koja je, kako je to ranije navedeno, u suštini bitna se funkcionalnog (bihevioralnog) stanovišta od interesa u neurokognitivnim sistemima. Moduli, koji se još mogu posmatrati i kao komune ili klasteri čvorova (neurona u biološkim neurološkim mrežama), se karakterišu i prepoznaju po tome što su veze unutar modula daleko izraženije (brojnije, prisutnije) nego veze izvan odnosno između modula (*sparcely connected*) [39]. Tako, kratke lokalne veze koje dominiraju unutar modula mogu formirati šablone, repetitivne strukture (motive) – za koje smo ranije pokazali da koreliraju sa fraktalnim topologijama. Matematički model Pana i Sinha [133] pokazuje da upravo zbog dominantne interkonektivnosti unutar modula (klastera čvorova, neurona) broj fraktalnih (triangularnih) motiva u modularnoj mreži je veći od broja u potpuno slučajnom grafu (mreži) iste veličine i gustine veza, dok postojanje malog broja veza između različitih modula (sporadična povezanost) igra ulogu topoloških prečica upravo u skladu sa napred iznetom arhitekturom modela malog sveta.

Dakle, mreže malog sveta imaju i fraktalne i modularne karakteristike, a upravo postojanje sporadičnih intra-modularnih veza omogućava da se ovakva struktura u potpunosti može smatrati fraktalno-modularnom a ne nasumičnom ili slučajnom. Drugim rečima, u kontekstu neurokognitivnih sistema, postoje fizička, neuroanatomska i biološka u opštem smislu, opravdanja za nastanak upravo ovakvih struktura. Modularni sistemi stoga prirodno teže da po topologiji odgovaraju mrežama malog sveta, sa visokom klasterizacijom i kratkim lokalnim vezama, ali obrnuto nije uvek tačno: neke mreže malog sveta - kao npr. originalni Watts–Strogatz model [131] - nisu modularne ([39]).



Slika 12: Modularni sistemi su topološki mreže malog sveta ali nisu sve mreže malog sveta i modularne. Originalni Watts–Strogatz model (A) nije modularan. Modularni sistemi (B) imaju karakteristike malog sveta ali ne moraju inherentno imati i fraktalne karakteristike. U biološkim neurokognitivnim sistemima sreću se strukture fraktalno-modularne topologije koje imaju hijerarhijsku ili multiskalarlu organizaciju, gde su moduli unutar sebe takođe modularizovani, što sve vodi do ugnježdene, repetitivne, fraktalne topološke hijerarhije (preuzeto iz [39], sa prilagođenim opisom).

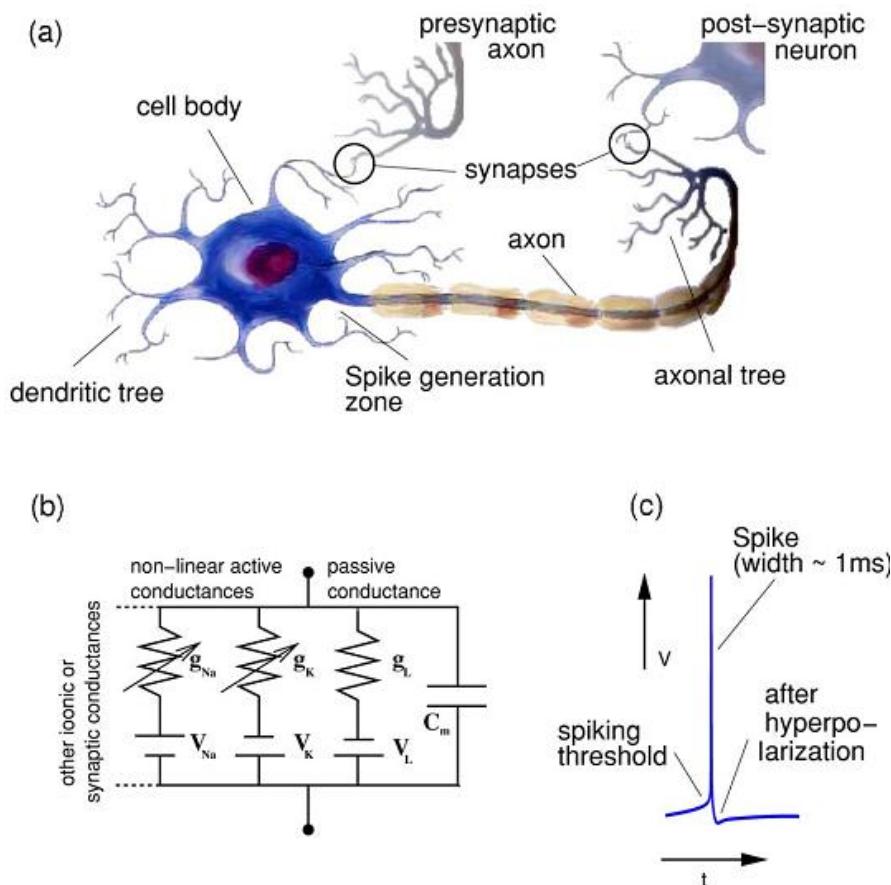
Ovde je važno naglasiti da u razmatranjima modela malog sveta, koji je prvenstveno topološki matematički model, gotovo da i ne dotiču funkcionalnu prirodu interkonekcija (jačinu, intenzitet), što je veliki prostor koji će upravo biti i razmatran u naredom poglavlju koje će se baviti analogijom fraktalno-modularnih veštačkih i bioloških struktura, a gde će upravo pitanje samih veza i njihovih karakteristika biti od izuzetnog značaja upravo u sklopu funkcionalnih odnosno bihevioralnih karakteristika koje su tesno vezane sa prostorno-vremenskom dinamikom u neurokognitivnim sistemima.

3.3 Prostorno-vremenska dinamika u neurokognitivnim sistemima

Već je napomenuto da su mnogi autori prepoznali da je nedostajući faktor u mnogim strukturalnim modelima verovatno povezan sa vremensko-prostornom dinamikom, ili kako se još u literaturi referiše – neurodinamikom, koja u stvari predstavlja funkcionalnu osnovu neurokognitivnih procesa.

U istraživanjima dinamičkih procesa u neurokognitivnim biološkim sistemima, uglavnom postoje dva pristupa, kako su to definisali Rabinovich et al. u veoma citiranom radu „Dynamical principles in neuroscience“ [134]:

Bottom-up dinamički modeli počivaju na opisu individualnih neurona i njihovih sinaptičkih veza na osnovu potvrđenih činjenica iz eksperimentalnih istraživanja u oblasti neurofiziologije i neuroanatomije. Istaknut primer ovakvog modelovanja je tzv. (*Leaking*) *Integrate-and-Fire* (LIF/IF) model koji je uspešno oponaša dinamička svojstva tipičnog kortikalnog neurona koji se sreće u svim biološkim sistemima, od primitivnih organizama do ljudskog mozga (Slika 13). Ovakvi modeli uspešno su primjenjeni za sagledavanje i simuliranje funkcionalnih svojstava neuorkortikalnih struktura. Važno je naglasiti da ovakvi modeli, iako odlično emuliraju lokalnu dinamiku neurostruktura, mogu samo da daju neke poglеде na ulogu te lokalne dinamike u opštim dinamičkim procesima i ponašanjima koja se manifestuju na višim kognitivnim nivoima.



Slika 13: Ilustracija funkcionalnog modela neurona i električnih svojstava (preuzeto iz [134]). (A) Funkcionalna anatomija neurona. (B) Pojednostavljeni električno kolo membrane neurona prema Hodgkin-Huxley modelu u kojoj su nelinearne jonske konduktanse naponski kontrolisane i odgovaraju raličitim jonskim kanalima (Na^+ – natrijum i K^+ – kalijum). (C) Tipičan fiziološki električni naponski impuls aktivacije neurona (amplituda oko $100mV$, trajanje $1-2ms$).

Top-down dinamički modeli počivaju na analizi onih aspekata biološkog ponašanja koja se uočavaju na višim kognitivnim nivoima i koja imaju robusne, reproducibilne karakteristike važne za opstanak i razvoj vrste⁷. Ovaj pristup je istorijski krenuo od razmatranja globalne slike (filozofske ali i psihološke) mozga i vodio je ka raslojavanju na različite nivoe analize i posmatranja u neorukognitivnim naukama. Ovi modeli posmatraju ceo neurokognitivni sistem ili pojedine njegove delove kao celine („crne kutije“) i primenjuju različite matematičke, uglavnom statističke, modele za kreiranje hipoteza o očekivanom ponašanju. Podvlačimo termin „očekivano ponašanje“ jer ne treba nikako smetnuti s umu da ovi modeli počivaju na implicitnoj nepoznanici a to je stvarna bihevioralna logika mozga ili čak i jednostavnijih neurokognitivnih struktura koja se samo pretpostavlja.

Rabinovich et al. stoga potenciraju da modelovanje lokalne dinamike, počevši od strukture i dinamike samog neurona, i modelovanje globalne prostorno-vremenske dinamike neurokognitivnih sistema idu paralelno i još uvek se nisu sreli na širokom planu koji daje odgovore na mnoga važna pitanja [134]. Ovo je važno naglasiti jer, kako će u narednim poglavljima biti pokazano, upravo jedna od karika koje nedostaju je veza između lokalne dinamike neurostruktura, odnosno malih grupa ili ansambala (modula), i kognitivnih procesa koji su svojstveni višim nivoima odnosno neurokognitivnim strukturama sa velikim brojem neurona. Drugim rečima, *bottom-up* pristup je dao objašnjenja kako neuron funkcioniše (njegovu strukturu i model funkcije) a *top-down* nam je pokazao da veliki skupovi neurona na višim nivoima imaju određena kognitivna ponašanja i bihevioralna svojstva. Kako od toga „kako radi“ pojedinačni neuron nastaje proces koji ima kognitivne odlike, upravo je ključno nerazjašnjeno pitanje u ovom trenutku.

3.3.1 Modeli biološkog neurona (*Bottom-up* modeli)

U literaturi se sreće više desetina modela biološkog neurona [135]. Prvi i najpoznatiji poznat kao „Integrate-and-Fire“ (IF) razvio još 1907. godine Lapicque ([136]) i baziran je na jednostavnom modelovanju po ugledu na električna kola (Slika 14). Modifikacija izvornog Lapicque-vog modela je tzv. „Leaky Integrate-and-Fire“ (LIF) model koji uvodi dodatno

⁷ Ovde u stvari govorimo o kognitivnim procesima koji se mogu psihološki dovesti u vezu sa inteligencijom odnosno ponašanjem koje je korisno za opstanak i/ili evolutivni napredak jedinke i/ili vrste. Važno je naglasiti da u modelovanju neurokognitivnih sistema svi autori polaze od ove logične pretpostavke a to je da je funkcija odnosno ponašanje u konstruktivnoj funkciji u odnosu na biološku jedinku (njen opstanak i napredak u prirodnom okruženju).

„oticanje“ potencijala na membrani some, što se modeluje karakterističnom vremenskom konstantom membrane (u električnom modelu RC kolo na izlazu). U literaturi se i pod IF i pod LIF najčešće podrazumeva „leaky“ varijanta, jer je ona daleko realnija. LIF model definiše potencijal membrane $V(t)$ u terminima integralne sume sinaptičkih ulaza, intercelularne injektovane struje I_{inj} koju neuron prima nezavisno od sinaptičkih ulaza I_{syn} i struje otoka I_{leak} koja je posledica „curenja“ membrane.

$$C \frac{dV(t)}{dt} = I_{leak}(t) + I_{syn}(t) + I_{inj}(t) \quad (1)$$

Akcioni potencijal (impuls) se generiše kada potencijal membrane dosegne predefinisani nivo praga V_{th} i modeluje se Dirakovom delta funkcijom (Dirakovim impulsom):

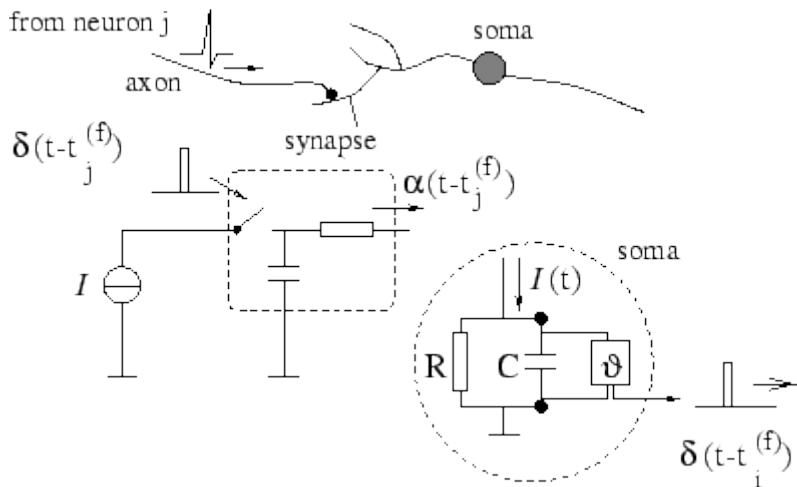
$$V_{out}(t) \cong \delta(t - t_f) \quad (2)$$

gde je t_f trenutak „okidanja“ odnosno aktivacije neurona, što se dešava kada potencijal membrane V prevrši nivo praga V_{th} :

$$t_f: \quad V(t_f) = V_{th}, \quad \left. \frac{dV(t)}{dt} \right|_{t=t_f} > 0 \quad (3)$$

Iako je modelovanje Dirakovim impulsom veoma pojednostavljena reprezentacija stvarnog oblika izlaznog signala aktivacije neurona, ona je pogodna prvenstveno zbog luke matematičke manipulacije kao i vrlo efikasne numeričke simulacije (što je od interesa u složenim simulacijama u kojima se posmatra odziv neuronskih ansambala koji mogu brojati i desetine hiljada neurona, gde je velika efikasnost numeričkih algoritama kojima se mogu simulirati LIF neuroni od izuzetnog značaja u pogledu potrebnih resursa ali i realnog vremena u kojem se rezultati mogu dobiti).

Ovaj model je i dan danas jedan od načešće primenjivanih ([137]), jer u osnovi odražava sve bitne neurofiziološke karakteristike bioloških sistema a zbog svoje jednostavnosti je veoma pogodan kako za matematičku analizu tako i za ekstenzivne kompjuterske simulacije (jer je „jeftin“ u smislu potrebih procesorskih resursa).



Slika 14: „Integrate-and-Fire“ model neurona (preuzeto iz [135]). Na desnoj strani (u krugu) je prikazano električno kolo kojim je modelovano „telo“ naurona, dok su na levoj strani modeli sinapsi (veza između neurona). Izlazna funkcija je modelovana impulsnim generatorom.

U literaturi se danas može naći više desetina modela, koji su uglavnom nadogradnje osnovnog LIF modela, ali postoje i znatno kompleksniji modeli koji su uzeli u obzir i neke nedostatke LIF modela. Tako, tek relativno nedavno, 2004. godine Meffin et al. uvode realniji dinamički model konduktanse izlaznog kola tj. impulsnog generatora aktivacionog potencijala [138]. Oni tako uvode dodatnu struju I_{spike} kojom se modeluje odliv energije odnosno smanjenje potencijala membrane usled generisanja impulsa (što je bliže realnim uslovima koji su potvrđeni i neurofiziološkim istraživanjima). Takođe, razni autori su predložili naprednije modele u kojima se izlazni aktivacioni impuls modeluje ne Dirakovim impulsom već Hevisajdovim ili pak još složenijim modelima koji uzimaju u obzir kompleksniju izlaznu konduktansu impulsnog generatora i samih sinapsi, uključujući i tzv. vreme relaksacije (vremenski period u kojem se minimizira verovatnoća nastanka novog impulsa, posle prethodnog), karakterističnu vremensku konstantu sinapsi i sl., što izvorni LIF model ne predviđa ([137], [138]).

Kao što je već naglašeno LIF model je nastao pre skoro jednog veka i u uslovima kada su eksperimentalna istraživanja, neurofiziološka i neuroanatomska posebno, bila u rudimentarnim fazama zbog tehnoloških i drugih ograničenja. Razvoj biomedicinskog inženjeringu i novih tehnologija omogućio je da se tokom 50-tih i 60-tih godina 20. veka sprovedu naprednija istraživanja u kojima se duboko prodrlo u neorofiziološke ali i

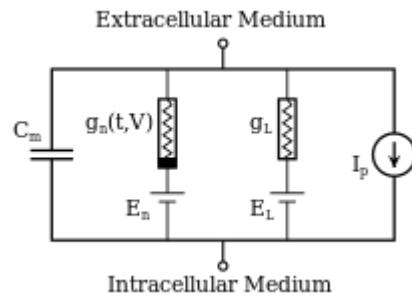
biohemijske procese, te je takvo sveobuhvatno sagledavanje mehanizama i uslova funkcionalnih karakteristika bioloških neurona donelo nova saznanja i naprednije modele koji su daleko bliži realnim fiziološkim procesima. U to vreme je nastao i do danas najkomplksniji ali i najrealniji Hodgkin–Huxley model (rad je objavljen 1952. godine, a 1963. su Hodgkin i Huxley dobili Nobelovu nagradu za ovaj rezultat).

$$I = C_m \frac{dV_m}{dt} + \bar{g}_K n^4 (V_m - V_K) + \bar{g}_{Na} m^3 h (V_m - V_{Na}) + \bar{g}_L (V_m - V_L),$$

$$\frac{dn}{dt} = \alpha_n(V_m)(1 - n) - \beta_n(V_m)n$$

$$\frac{dm}{dt} = \alpha_m(V_m)(1 - m) - \beta_m(V_m)m$$

$$\frac{dh}{dt} = \alpha_h(V_m)(1 - h) - \beta_h(V_m)h$$

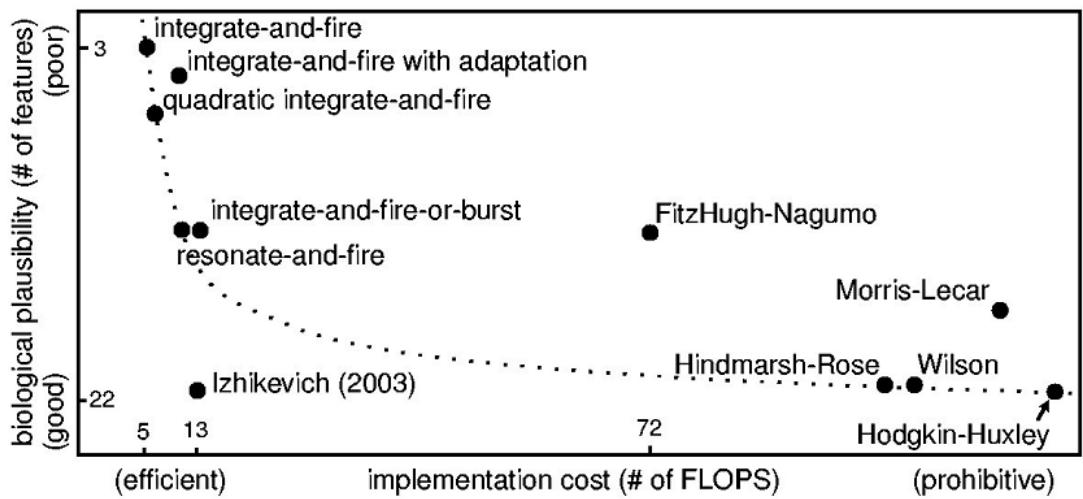


Slika 15: Hodgkin–Huxley model. Matematički model i ekvivalentno električno kolo membrane (preuzeto iz [139]).

Hodgkin–Huxley (HH) model [139] je tzv. konduktansni model koji biološki neuron predstavlja matematičkim modelom koji opisuje kako se aktivacioni potencijal u neuronu inicira i propagira. Model predstavlja skup vremenski kontinualnih nelinearnih diferencijalnih jednačina koje aproksimiraju električne karakteristike koje ispoljavaju neuronske ćelije (ali i neke druge ćelije u biološkim organizmima, kao npr. srčani miociti koje su oni takođe analizirali). Obzirom da se radi o modelovanju električnih svojstava i funkcionalnosti, Hodgkin–Huxley se najčešće vizuelno reprezentuje električnim kolom sa promenjivim konduktansama (Slika 15) i to je osnovni nivo apstrakcije, što će biti od značaja upravo u analizi uslova i kriterijuma analogije sa veštačkim fraktalno-modularnim CNM (koje su takođe u osnovnom nivou apstrakcije električna konduktansna kola).

Kao što je već naglašeno, izvorni LIF model i Hodgkin–Huxley model su na suprotnim stranama spektra kompleksnosti i kvaliteta. LIF je najjednostavniji, sa brojnim ograničenjima i pretpostavkama koje odstupaju od realnih fizioloških svojstava biološke ćelije neurona. Ali njegov jednostavan matematički model (linerana jednačina prvog reda) omogućava ne samo relativno jednostavnu matematičku manipulaciju (jer se može lako izračunati odziv za klase ulaznih povorki signala) veći veoma efikasnu numeričku simulaciju. Hodgkin–Huxley model je izuzetno kvalitetan, i gotovo da je pouzadno reći da predstavlja

vrlo realan model svih biohemijskih i električno-fozioloških procesa u ćeliji (i to ne samo neurona, već i drugih bioloških ćelija što mu daje univerzalnost koja potvrđuje njegov kvalitet) ali je izuzetno kompleksan. U matematičkom smislu, iako naoko kompaktan, on nije pogodan za manipulaciju (u pitanju je sistem od četiri nelinerane diferencijalne jednačine koji se ne može analitički rešiti odnosno nije poznato njegovo rešenje u zatvorenoj formi – slično kao Maxwell-ove jednačine).



Izhikevich 2004

Slika 16: Spektar poznatijih modela neurona - odnos kvaliteta modela i „cene“ implementacije numeričke simulacije u FLOPS-ovima (preuzeto iz [48])

Između ova dva kraja spektra, nalazi se nekoliko desetina modela ([140], [141], [142]), koji su mahom u različiom stepenu modifikacije LIF modela, a koji imaju različite stepene složenosti i samim tim pogodnosti za primenu (matematičku ili numeričku manipulaciju, simulacije, analize i sl. - Slika 16). Nedavno, 2012. godine, pojavio se i doduše ne mnogo citiran rad ([143]), u kojem Basu i Hasler primenjuju metodu analize električnih kola u režimu malih signala na izvorni Hodgkin–Huxley model i izvodi se jednu interesantnu aproksimaciju (doduše u vrlo ograničenom, pod-aktivacionom delu modela) koja će biti od interesa za temu ove disertacije odnosno u razmatranju modela analogije koji će biti izveden u narednim poglavljima, te ga zato ovde i referišemo.

Jedan od novijih modela koji je postao vrlo poluparan u zadnjih desetak godina je Izhikevich-ev model koji ima osobine gotovo idealne kombinacije kvaliteta modela i jednostavnosti (Slika 16, donji levi ugao). Izhikevich je prvi 2001. godine uveo model tzv. rezonantnog neurona [144], mada su i drugi autori došli gotovo nezavisno do vrlo sličnih koncepata (Richardson, Brunel i Hakim [145]). I jedni i drugi autori su inicijalno nazvali ovaj novi model „Resonate-and-Fire“, ali su nakndano odustali od ovog termina i danas je ovaj model poznat pod nazivom „generalizovani IF“ (GIF). Dakle, ovaj model je ipak generalizacija klasičnog IF/LIF modela, ali uz neka značajna unapređenja koja zaslužuju da se ovo smatra novim modelom.

GIF model je, iako se vezuje za IF, izведен je primarno iz Hodgkin–Huxley modela primenom matematičkih transformacija i linearizacije u cilju pojednostavljenja izvornog sistema nelinaernih diferencijalnih jednačina stanja potencijala membrane. Izhikevich je primenio Hartman-Grobman-ovu teoremu i teoremu o redukciji invarijantnih prostora, dok su Richardson, Brunel i Hakim primenili aproksimativnu linearizaciju pod uslovima malih injektovanih struja. Tako, Izhikevich pokazuje da se pod određenim uslovima, Hodgkin–Huxley model može svesti na sistem od dve linearne diferencijalne jednačine:

$$\dot{x} = bx - \omega y, \quad \dot{y} = \omega x + by \quad (4)$$

koji se može napisati i u ekvivalentnoj kompleksnoj formi:

$$\dot{z} = (b + i\omega)z, \quad z = x + iy \in \mathbb{C} \quad (5)$$

gde je z kompleksna varijabla stanja.

Oba pristupa su dakle dovela do *de facto* istog modela, koji je opisan jednom kompleksnom lineranom diferencijalnom jednačinom prvog reda:

$$\dot{z} = (b + i\omega)z + \sum_j c_j \delta(t - t_j), \quad z = x + iy \in \mathbb{C} \quad (6)$$

gde je z kompleksna varijabla koja opisuje oscilacije neurona (gde realni deo x predstavlja komponentu koja ima svojstva električne struje, a imaginarni deo y ima svojstva napona u analogiji sa Hodgkin–Huxley konuktansnim električnim modelom), $(b + i\omega)$ je unutrašnji parametar strukture neurona (može se posmatrati kao konuktansa i karakteristična

učestanost, u analogiji sa električnim modelom), δ je Dirakova funkcija (Dirakov impuls), $j=1..n$ je indeksirani susedni neuron koji ima sinaptičku vezu sa predmetnim neuronom koji se posmatra i t_j je poslednji trenutak aktivacije (okidanja) susednog neurona j .

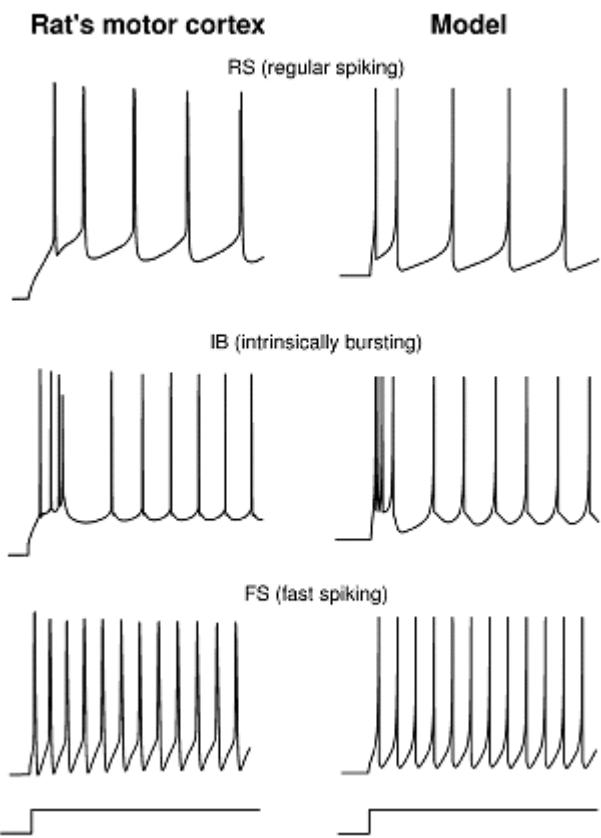
Izhikevich je 2003. godine izveo još jednu varijaciju ovog modela [146] koju je nazvao trivijalno „Simple model“ (SM) i koja se karakteriše kvadratnom diferencijalnom jednačinom umesto linearne u IF odnosno GIF modelima:

$$\begin{aligned} v' &= 0.04v^2 + 5v + 140 - u + I \\ u' &= a(bv - u) \end{aligned} \tag{7}$$

sa pomoćnim post-impulsnim (post-aktivacionim) resetovanjem potencijala membrane:

$$(v \leftarrow c, u \leftarrow u + d)|_{v \geq 30mV} \tag{8}$$

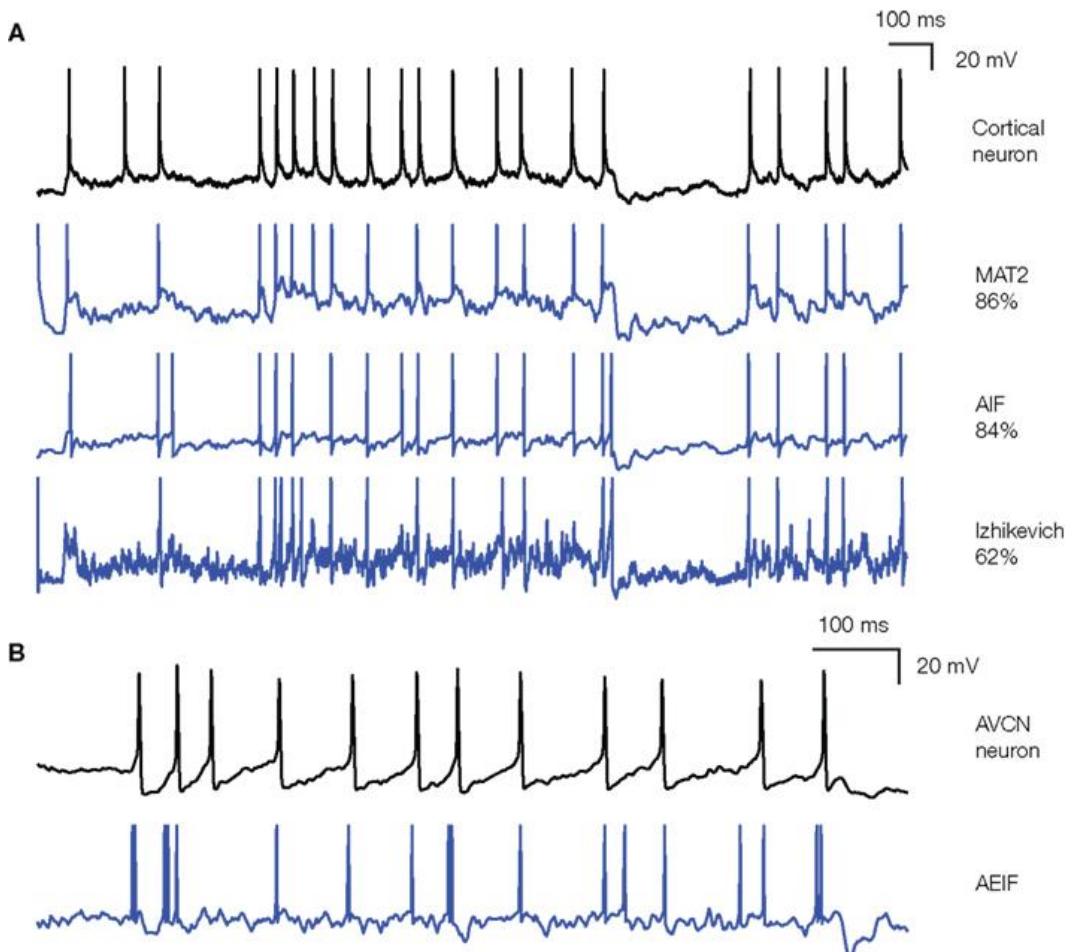
gde su a , b , c i d konstante kojima se mogu parametrizovati modeli raznih tipova bioloških neurona (Slika 17).



Slika 17: Izhikevich-ev „Simple model“ može da reprodukuje povorke impulsa veoma bliske stvarnim eletkrofiziološkim impulsima različitih tipova neurona u motornom kortekstu pacova (preuzeto iz [146]).

Kao što se može primetiti, kvadratni član u prvoj diferencijalnoj jednačini ima veoma mali težinski faktor i zato je i razumljivo da je u mnogim modelima, od IF/LIF pa do GIF, on zanemarivan. Ipak, simulacije pokazuju da iako je taj faktor veoma male težine, on im veoma bitnu ulogu u oscilatornom režimu rada neurona a posebno u uspešnom generisanju povorke impulsa (Slika 18). Kao što je naglašeno, postoje i složeniji modeli koji su bliži biološkim signalima po obliku ali je njihova složenost daleko veća pa i resursna „cena“ za implementacije odnosno simulacije. Primento je da Izhikevich-ev SM kao i GIF ima veoma visok stepen „šuma“ u odnosu na izvorni signal, mada postoje i izvori koji tvrde da treba biti i vrlo oprezan u ovim konstatacijama jer nije jasno ni da li stvarni elektrofiziološki signali imaju ovako „glatke“ oblike ili su u pitanju ograničenja instrumentacije kojom se snimanja vrše odnosno niskopropusni opsezi samih mernih sondi i sl. Sve u svemu, mnogi autori se slažu da je Izhikevich-ev SM dobar balans kvaliteta i jednostavnosti i da je njegov nejvažniji

kvalitet onaj koji je i najbitniji – da uspešno i sa velikom pouzdanošću generiše povorku impulsa veoma blisku stvarnim elektrofiziološkim signalima.



Slika 18: Poređenje kvaliteta nekih modela neurona (preuzeto iz [147]). (A) Stvarni elektrofiziološki signal kortikalnog neurona i simulirani odziv nekoliko popularnih naprednijih modela (B) Elektrofiziološki signal AVCN neurona pacova (Anteroventral cochlear nucleus neuron) i simulirani odziv AEIF modela („Adaptive Exponential Integrate-and-Fire“, Brette i Gerstner, 2005. [141]).

Iako je Izhikevich objavio veći broj radova ([148], [149], [150]) u kojima je primenio ovaj novi model neurona, i ti radovi imaju visoku citiranost, još nije moguće govoriti o opštoj prihvaćenosti jer i dalje u većini novih publikacija LIF figurira i dalje kao referentni model. Napomenjemo da je od nastanka LIF modela prošlo više od jednog veka, da je od Hodgkin–Huxley modela prošlo oko pola veka, tako da je još rano govoriti da li je Izhikevich napravio novi veliki proboj ali takođe ne treba ni odbaciti tu mogućnost obzirom na veliku citiranost njegovih radova. U svakom slučaju, obzirom da je i Izhikevich-ev model, kao i ostali

popularni modeli, baziran na osnovnim konceptima LIF modela, u daljim razmatranjima sa stanovišta teme ove disertacije možemo ova modela posmatrati paralelno jer ključne karakteristike za tezu kojom se mi ovde bavimo nisu vezane za njihove različitosti već upravo za njihove sličnosti.

3.3.1.1 Komputacioni i informacioni modeli (Firing-rate modeli)

Bez obzira koji modeli pojedinačnog neurona se koristili, koliko su oni manje ili više kompleksniji i daju li manje ili više kvalitetnije odzive na simulirane pobude, samo modelovanje ponašanja pojedinačnog neurona, kao što je ranije naglašeno, ne daje odgovor šta je funkcionalna uloga neurona, odnosno kako on vrši složenje kognitivne funkcije u kolektivitetu sa drugim neuronima.

Najnoviji pravci istraživanja i modelovanja se stoga okreću ne više toliko modelovanju stanja samog neurona, njegoveunutrašnje dinamike, već prvenstveno ka modelovanju komputacionih svojstava pojedinačnog neurona (modelovanje funkcije „ulaz-izlaz“) gde se akcenat stavlja na „informacionom“ procesiranju. Ovakvi modeli se još nazivaju i „komputacioni modeli“ i postaju sve značajniji jer ne samo da pokazuju kako neuron radi već i šta radi (u smislu obrade informacija). Ovo posebno naglašavamo jer će u narednim poglavljima upravo ovaj aspekt biti posebno analiziran i stavljen u kontekts napred iznetih komputacionih svojstava fraktalno-modularnih CNM.

Prvi teoretski radovi u ovoj oblasti nastali su početkom 70-tih godina prošlog veka ([151], [152]), dakle desetak godina nakon Hodgkin–Huxley modela, kada je postalo jasno da se iz samog dinamičkog modela fizičkih veličina (stupa i napona) ne može sagledati stvarna uloga odnosno funkcija neurona u kolektivitetu. Možda je najbolja analogija sa radio talasima: iz matematičkih jednačina ili grafičkih prikaza samih talasa nije moguće „čuti“ muziku. Dakle, izneđu modelovanja neurona sa aspekta fizičkih procesa i modelovanja sa aspekta kognitivnih funkcija postoji veliki jaz.

Pionirski radovi u ovoj oblasti su vezani za tzv. Wilson-Cowan model [151] i nisu posli od modelovanja pojedinačnog neurona, već od *top-down* modelovanja populacija (što će detaljnije biti obrađeno u narednoj sekciji) ali su vremenom nastale razne derivacije iz ovih kolektivnih modele i polako se dolazi i do modela pojedinačnog neurona u terminima koji nisu više vezani samo za fizičke signale već prvenstveno za informacione i komputacione

funkcionalnosti ([153], [154], [155], [156], [157], [154]). Suština ovih modela je da se, teoretski posmatrano, pod određenim prepostavkama i aproksimacijama (koje su inače primenjene i u prethodno iznetim modelima, od LIF do HH – aproksimacije sinaptičkih veza linearnim težinskim koeficijentima, aproksimacija izlaznih aktivacija povorkama Dirakovih impulsa itd.), može se uspostaviti relacija „ulaz-izlaz“ i populacije i pojedinačnog neurona u terminima tzv. učestanosti okidanja⁸ (engl. *firing-rate*). Za populacione modele (*top-down*) bilo je lakše uspostaviti realne statistički bazirane matematičke modele i pokazati njihovu korelaciju sa fiziološkim odzivom bioloških neurostruktura na raznim kortikalnim nivoima, te je decenijama to i bio glavni pravac istraživanja i razvoja. Tek od nedavno, poslednjih desetak godina, pojavljuju se novi radovi koji fundamentalno obrću fokus interesa i modelovanje spuštaju na nivo pojedinačnog neurona. Tome su doprinela i nova eksperimentalna istraživanja, koja su omogućena novim bioinženjerskim tehnologijama, da se mogu pouzdano i precizno snimati signali na nivou pojedinačne neuronske ćelije, što ranije nije bilo moguće.

Tako, nekoliko autora je relativno nedavno, u periodu posle 2000. godine (što je kako smo naglasili u istorijskom rasponu od preko jednog veka istraživanja u ovoj oblasti, relativno nedavno), razvilo modele koji opisuju statistička učestanost okidanja pojedinačnog neurona za modelovanje ulazno-izazne dinamike ([158], [159], [160], [161], [162], [163]). Nezavisno od polaznih prepostavki, koje se sve baziraju na postavkama Wilson-Cowan modela [151] statističke prirode neuorodinamike u kolektivitetima neurona, kao i bazičnih postavki HH i LIF modela pojedinačnog neurona (kojima je zajednička prepostavljena Poisson-ova raspodela u procesu generisanja sekvence aktivacionih impulsa izlaza neurona, koji se modeluju Dirakovim impulsom), dolazi se do jednostavne dinamičke relacije koja se može formulisati linearnom diferencijalnom jednačinom prvog reda (detaljna matematička evolucija je data u prilogu, sekcija 9.3, “Prilog 3: Firing-rate (FR) model neurona“):

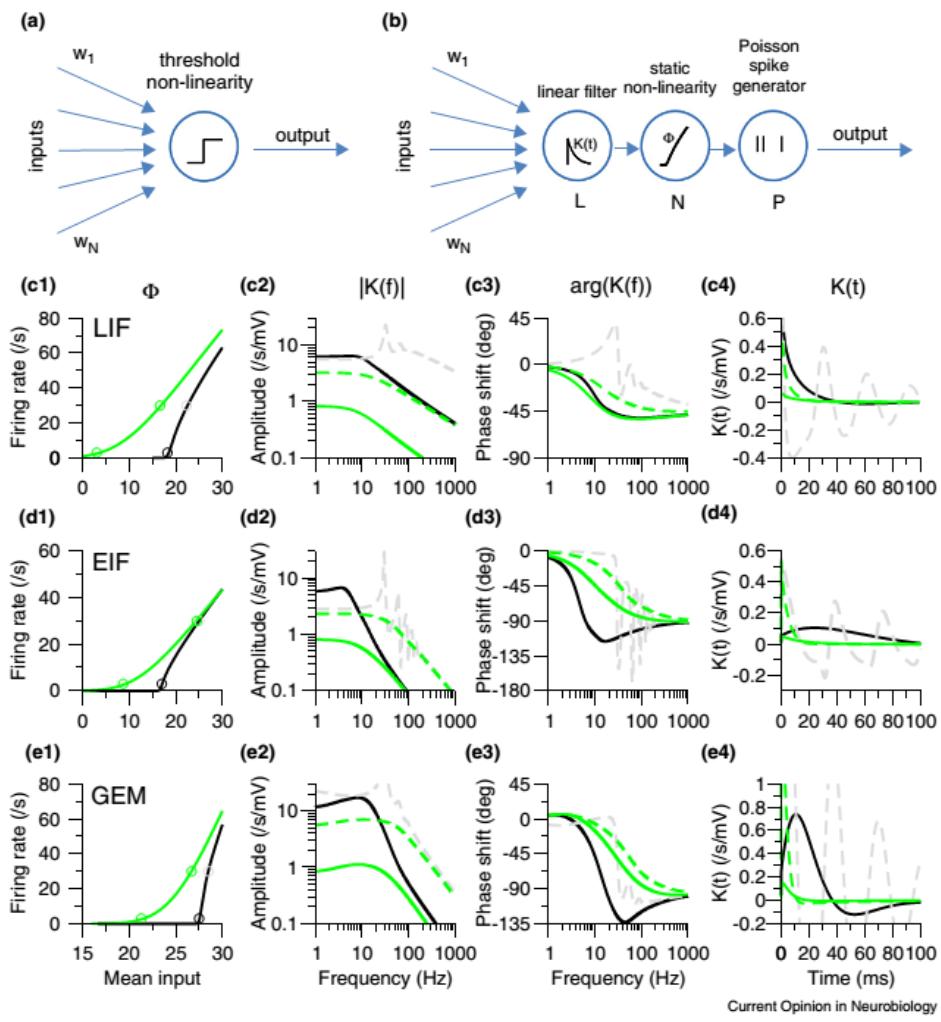
$$\tau \frac{dr}{dt} = -r + f(Wr + I) \quad (9)$$

gde je τ vremenska konstanta, r učestanost okidanja, f je nelinearna statična funkcija, W matrica sinapsi a I intracelularna eksitacija neurona (intercelularna injektovana struja). Ova relacija, iako naoko veoma jednostavna, predstavlja veoma važnu kariku u povezivanju *top-*

⁸ Učestanost okidanja se u ovom kontekstu definiše kao verovatnoća aktivacije (impulsa) u jedinici vremena.

down, kolektivnih, statističkih modela (koji će biti detaljnije razmatrani u narednom poglavlju) i *bottom-up* modela pojedinačnih neurona. Treba još jednom naglasiti da za razliku od klasičnih *bottom-up* modela gde se posmatraju fizičke veličine prostora stanja (naponi membrane, izlazne i sinaptičke povorke strujnih i naponskih impulsa itd.), ovaj model ima primarno informacioni karakter (jer se modeluje verovatnoća kroz učestanost okidanja, dakle informacija a ne fizička veličina) i dinamičkog modela koji modeluje potencijal membrane. Miller i Fumarola su nedavno, 2012. godine, uspostavili vezu između ova dva domena i pokazali da se matematički posmatrano, uz napred iznete pretpostavke i aproksimacije (Poisson-ova rapsodela Driakovih imuplsa), informatička dinamika i fizička dinamika u pojedinačnom neuronu mogu posmatrati matematički ekvivalentno odnosno da postoji opravdana analogija između fizičkog i informatičkog modela [163].

Ovakva analogija bi bila čisto teoretski interesantna da u najnovijim istraživanjima nisu napravljeni značajni pomaci koji je opravdavaju odnosno koji pokazuju da postoje formalne ali i praktične metode kojima se iz postojećih neurofizioloških (fizičkih) modela može doći do modela veoma bliskog napred navedenom informacionom modelu. Brunel et al. [164] izvode pregled najnovijih rezultata do 2014. godine u modelovanju „ulaz-izlaz“ neurona upravo na bazi modela koje smo ranije naveli (LIF, GIF i EIF). Oni se prvenstveno bave modelovanjem zavisnosti izlazne učestanosti okidanja u odnosu na ulazne signale sinapsi, i pokazuju da se pogodnim modelovanjem može uspostaviti upravo relacija koja ceo neuron posmatra kao jedan nelinearni prenosni sistem u smislu ulaznih i izlaznih povorki imuplsa. Fokus njihove pažnje je na novom, apstraktnom, modelu neurona koji su razvili 2011. godine Ostojić i Brunel [157], i koji je baziran ne na fizičkim varijablama prostora stanja (kao što su napon membrane ili ulazne struje sinaptičkih veza i sl. u napred izvedenim modelima koji su, počevši od LIF pa do HH bili bazirani na modelovanju fizičkog prostora stanja) već na matematičkom modelu u kojem se posmatra učestanost aktivacije (impulsa) neurona u zavisnosti od učestanosti signala na ulaznim sinapsama. Dakle, možemo govoriti o informatičkom modelu „ulaz-izlaz“ gde se posmatra prenos informacije enkodovane u učestanosti povorki impulsa. Na osnovu matematičke transformacije (Furijeovom transformacijom u analitičkoj i/ili numeričkoj formi) oni pokazuju da se ovakav apstraktни komputacioni model može dobiti iz nekoliko popularnih modela neurona pogodnim izborom parametara modela (Slika 19).



Slika 19: Komputaciona svojstva pojedinačnog neurona (preuzeto iz [164]). (a) Klasični McCulloch-Pitts neuron koji vrši linerano sumiranje sinaptičkih ulaza i zatim vrši odsecanje na izlazu (thresholding). (b) LNP neuronski model je složenija kaskada: (L) je linearni filterski stepen, koji vrši težinsku konvoluciju sinaptičkih ulaza sa vremenskom konvolucionom funkcijom $K(t)$, (N) je statička nelinearna prenosna funkcija F i (P) je generator impulsa Poissonove raspodele sa frekvencijom okidanja $F(K)$. (c-e) Statička nelinearna prenosna funkcija F i vremenski filteri nekoliko izabranih modela neurona (c - LIF, d - EIF, e - GEM). Prva kolona predstavlja nelinearnost F (koja kontroliše frekvenciju okidanja), druga i treća kolona predstavljaju amplitudsku i frekventnu karakteristiku vremenskog konvolucionog filtra u Furijeovom domenu (za dve frekvencije okidanja, 3 Hz i 30 Hz) a četvrtka kolona predstavlja impulsni odziv istog konvolucionog filtra (alternativna reprezentacija filtra).

Model koji su predložili Ostojić i Brunel ([157]), izvorno je nazvan „Linear-Nonlinear“ (LN) prema kaskadama koje ga formiraj: linearni filter i statička nelinearnost (Slika 20). LN model se zasniva na dve kaskade:

1. Linearni ulazni stepen, koji se modeluje linearnim filtrom odnosno konvolucijonom funkcijom koja sumira ulazni signal, i
2. Nelinearnim prenosnim stepenom, koji se modeluje statičkom nelinearnošću.

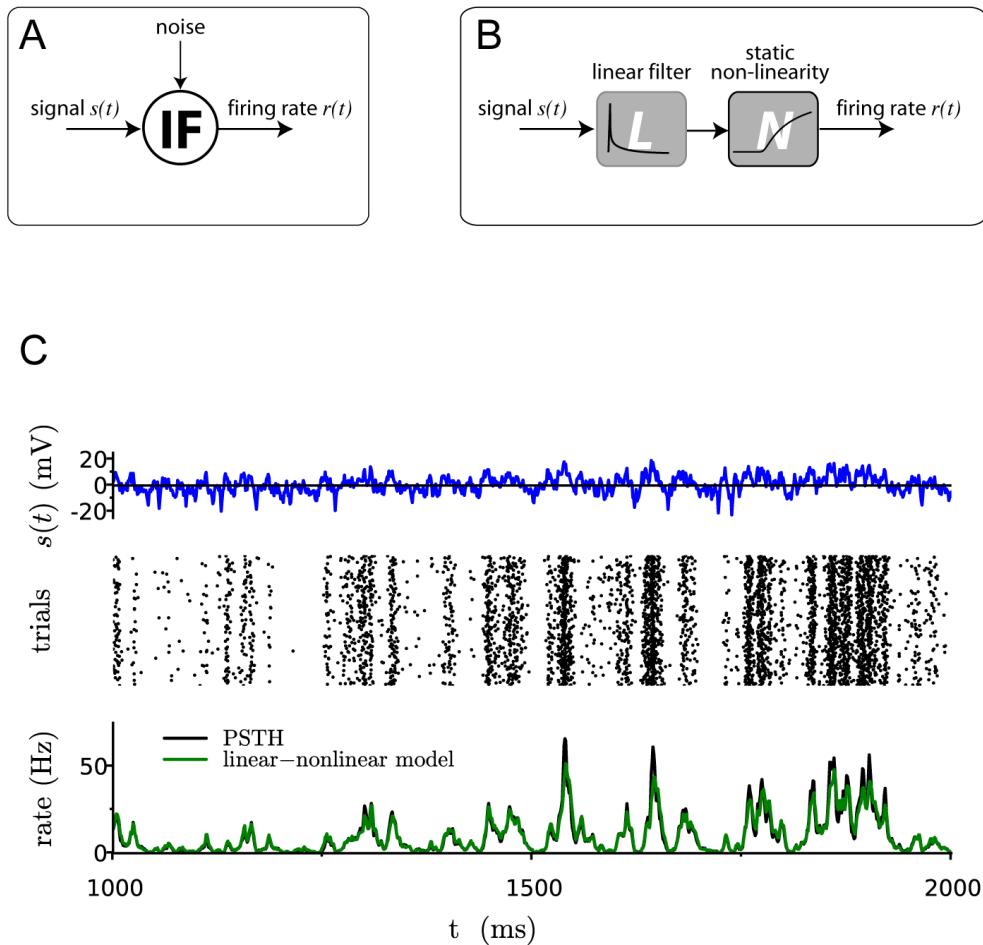
Ovaj model se može opisati sledećom prenosnom funkcijom koja odgovara učestanosti impulsa na izlazu („rate of fire“):

$$r(t) = F(K * s(t)) \quad (10)$$

gde je $*$ operator konvolucije:

$$K * s(t) = \int_0^{\infty} K(\tau)s(t - \tau)d\tau \quad (11)$$

Kao što je napred navedeno, Brunel et al. [164] izvode modifikaciju LN modela dodajući još jednu izlaznu kaskadu P: Poisson-ov generator tj. generator impulsa učestanosti $r(t)$ (Slika 19b). Na taj način ovaj model se naoko ponovo vraća na klasične modele u kojima se modeluju fizički a ne informatički procesi.



Slika 20: Komparacija „ulaz-izlaz“ mapiranja IF modela i NL kaskade (preuzeto iz [157]). (A) IF model u kojem se posmatraju ulazne struje i izlazni impulsi. (B) LN model u kojem se posmatra učestanost ulaznih impulsa i izlaznih impulsa. (C) poređenje rezultata simulacije⁹.

Iako to u svom radu Brunel et al. [164] nisu eksplisitno izneli, primetno je da se lako ceo model može prevesti u apstraktnu informatičku formu ako se ulazni signal s zameni upravo izlazom LNP modela (ako se ulazni signal zameni reprezentacijom koja predstavlja učestanost impulsa a ne sam vremenski signal):

$$r_i(t) = F(K * P(r_j)) \quad (12)$$

gde su r_i i r_j učestanosti okidanja posmatranog neurona i i sinaptički povezanog neurona j a $P()$ je simbolička reprezentacija Poissonovog procesa. naglašavamo da ovu relaciju ne treba

⁹ Izlazna učestanost IF modela se preračunava pomoću PSTH (Peri-Stimulus Time Histogram) da bi se dobila uporediva trenutna učestanost radi korelacije sa učestanošću koja se posmatra u LN modelu

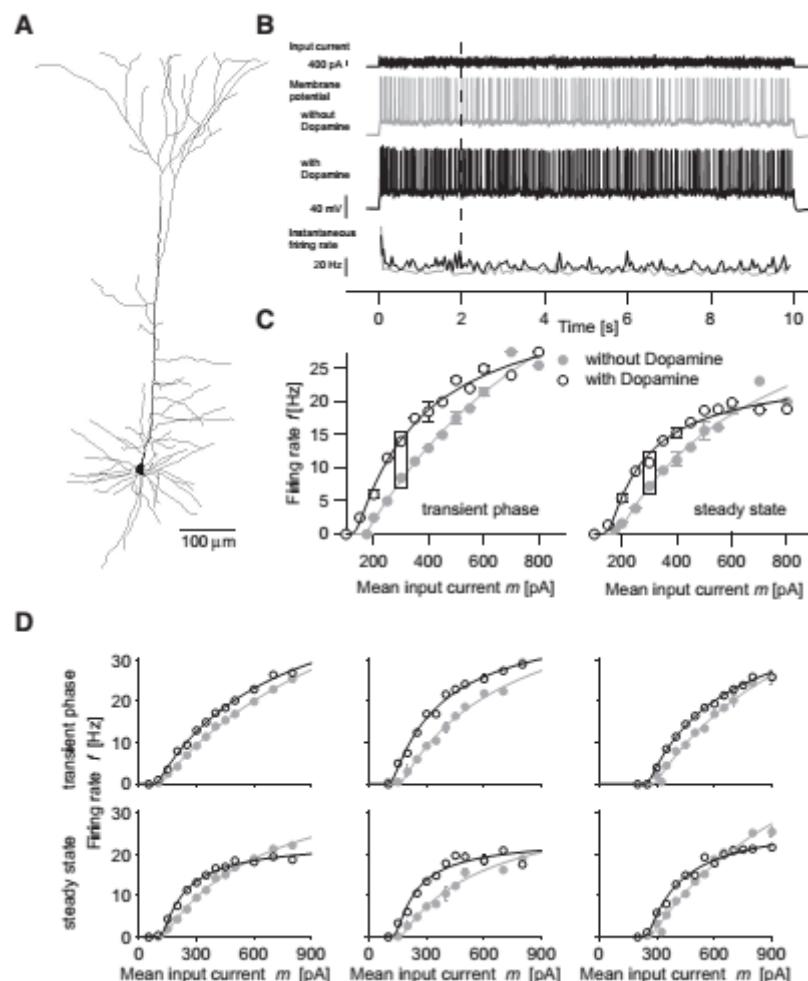
posmatrati kao matematički formalnu već simboličku radi predstavljanja povezanosti ulaznih i izlaznih veličina, u ovom slučaju učestanosti okidanja. Time je formiran informatički model koji uspostavlja relaciju „ulaz-izlaz“ i povezuje informaciju enkodovanu u učestanosti okidanja.

Primetimo da se ova relacija, pod određenim uslovima i aproksimacijama ([160], [165]), može relativno lako transformisati u relaciju nalik (9). Time se zatvara krug: sa jedne strane pokazano je da može biti izведен informatički dinamički model „ulaz-izlaz“ preko učestanosti okidanja ([161], [162]) a sa druge strane je pokazano da se taj model može realizovati upravo pogodnim prilagođenjem (izborom parametara) poznatih fizičkih odnosno konduktansnih modela (LIF, EIF i drugih) ([157], [164]). Dakle, pokazana je realna ostvarivost¹⁰ modela „ulaz-izlaz“ što je veoma važan zaključak koji otvara potpuno nove mogućnosti analize funkcionalnog ponašanja neurokognitivnih struktura.

Kao što je navedeno, radovi koji se bave modelovanjem izlazne učestanosti u funkciji ulaznog signala su se pojavili nedavno i za očekivati je nove rezultate u ovoj oblasti. Treba istaći da je ovim teoretskim istraživanjima prethodio proboj u eksperimentalnim, neuorfiziološkim oblastima, u kojima je pokazana eksplicitna veza između izlazne učestanosti okidanja neurona i srednje ulazne struje ([166], [167]) odnosno gde se pokazalo da postoji nelinearna ali glatka, sigmoidalna, statična, zavisnost od ulazne struje (sinaptičkih ulaza i intracelularne eksitacije) i učestanosti aktivacije neurona (tzv. f-I kriva,) tj. izlazne povorke impulsa što korelira sa LNP modelom (gde je ulazna struja upravo „usrednjena“ linearnim filtriranjem na ulazu a prenosna statička nelinearnost F modeluje upravo uočenu zavisnost u biološkom neuronu). Zanimljivo je napomenuti i da su neka istraživanja išla i dalje od uticaja samo ulaznih signala (struja) tako da su pokazane i zavisnosti od izmene biohemijske strukture odnosno uticaji pojedinih medikamenata koji svakako menjaju fizičke karakteristike sredine (odnosno subcelijske strukture neurona, sinapsi i dendrita) što se u konduktansnim modelima odražava upravo na izmene električnih parametara modela. Tako, Thurley et al. su izvršili ekstenzivna klinička ispitivanja i precizna merenja uticaja prisustva

¹⁰ Jer ako poznati modeli koji aproksimiraju biološki neuron mogu modelovati ovaku relaciju „ulaz-izlaz“ pogodnim izborom parametara, što su Brunel et al. i pokazali, onda je moguće da i stvarni biološki neuroni upravo i realizuju neke ovake prenosne funkcije.

dopamina¹¹ na f-I prenosnu funkciju zavisnosti učestanosti okidanja od ulaznih struja (Slika 21).



Slika 21: Uticaj dopamina na f-I krivu odnosno zavisnost učestanosti aktivacije in vitro piramidalnih neurona 5. nivoa prefrontalnog kortexa (L5 PFC) (preuzeto iz [168]).

Vema važan rezultat je postignut i u istraživanjima Yaksi-a i Friedrich-a [169] koji su razvili novu neuroimaging metodu za snimanje učestanosti okidanja pojedinačnog neurona, posmatranjem indikatora kalcijuma (Ca^{2+}) primenom multifotonske mikroskopije. Iako se ova nova metoda pokazala kao veoma korisna za dalja eksperimentalna neurofiziološka

¹¹ Dopamin je hormon koji ima nekoliko značajnih uloga u telu (u mozgu ali i u drugim organima poput kardiovaskularnog sistema, bubrežima i sl.) gde mahom služi kao prenosilac signala – neurotransmiter. Mnogi lekovi imaju ulogu da kontrolišu nivo dopamina i time pomažu u lečenju (npr. psihijatricka oboljenja, neurološka oboljenja ali i neka imuno oboljenja). Sa druge strane, mnogi narkotici imaju svoje efekte upravo zahvaljujući svojstvu da remete odnosno podižu nivo dopamina (i time stvaraju prijatan osećaj, halucinacije i druge efekte izmenjenje svesti).

istraživanja, i sam rad je fokusiran prvenstveno na samu metodu, veoma veliku pažnju je privukao i „nusproizvod“ koji sami autori rada nisu potencirali kao značajan rezultat – cela metoda je bazirana na matematičkom modelu koji počiva na konvoluciji/dekonvoluciji signala (poklapanje odnosno kroskorelacija između Ca^{2+} indikatora i učestanosti okidanja neurona, dakle „firing-rate“ a ne stvarnog vremenskog oblika izlaznog signala tj. struje aktivacije neurona) odnosno upravo prema napred iznetim „firing-rate“ (FR) modelima. Sama eksperimentalna potvrda metode (tačnost i preciznost merenja, koje je poređeno sa drugim poznatim metodama) je indirektno dokazala i da napred opisani FR modeli imaju snažnu korelaciju sa eksperimentalno utvrđenim signalima odnosno ponašanjem pojedinačnog neurona i to *in vivo* i *in vitro*.

Na osnovu napred izloženog, možemo reći da svi ovi ali i drugi rezultati koji se mogu naći u literaturi, pokazuju visok stepen konvergencije eksperimentalnih i teoretskih istraživanja u ovoj oblasti odnosno potvrđuju ispravnost najnovijih komputacionih modela koji počivaju na relaciji „ulaz-izlaz“ posmatranjem informatičkih a ne fizičkih prostora stanja neurodinamike pojedinačnih neurona.

3.3.2 Modeli neurokognitivnih sistema (*Top-down* modeli)

Kao što smo naglasili, *bottom-up* modeli neurona nastoje da modueluju pojedinačan neuron odnosno njegovo neurofiziološko ponašanje (električni odziv pre svega). Iako postoji brojni modeli, čak i najsavršeniji poput Hodgkin–Huxley, samo posmatranje pojedinačnog neurona ne daje odgovor o *kognitivnoj* funkciji ne samo pojedinačnog već pre svega kolektiviteta neurona u kognitivnim strukturama viših nivoa mozga. Drugim rečima, iako znamo *kako* neuron radi, iz modela neurona nije moguće razumeti i još je teže modelovati *šta* rade skupovi povezanih neurona (kolektiviteti). Iako su brojne simulacije pokazale da kolektiviteti neurona pokazuju dinamička svojstva koja su veoma bliska neurofiziološkim merenjima *in vitro* (npr. Izhikevich je publikovao više rezultata simulacija sa čak i do 10 biliona neurona, koliko ih zaista ima u većim moždanim strukturama sisara, i potvrdio da se, uz određene parametre modela, dobijaju signali prostorno-vremenske dinamike koja je veoma bliska biološkim ponašanjima utvrđenim vrlo preciznim neurofiziološkim merenjima [150]), da postoje oscilacije, dinamika energije i elektromagnetskih talasa koja upravo ima sve karakteristike koje se uočavaju i u živim organizmima u različitim fazama koritikalne aktivnosti, svi ti rezultati pokazuju da „mozak tako radi“ ali ne i zašto i šta konkrento radi

pojedinačni neuron ili manji neurokolektivitet. Odnosno, na koji način neuroni međusobnim interakcijama formiraju funkcionalne celine (upravo module) koje obavljaju neke kognitivne uloge u ukupnom kognitivnom procesu viših nivoa.

Top-down pristup je stoga pošao od potpuno suprotnog nivoa apstrakcije, i postavio je cilj da proučavanjem viših kognitivnih funkcija i njihovih korelacija sa biološkim kognitivnim strukturama mozga, razvije modele koji bi upravo prvo dali odgovor na pitanje *šta* te strukture rade, *kako* to rade u međusobnoj interakciji odnosno *koji* moduli imaju koje funkcionalne uloge. Spoštajući se u dubinu, proučavanjem sve granularnijih moždanih kognitivnih struktura, „mapiranjem“ mozga i njegovih funkcionalnih delova, stvoreni su modeli koji daju neke odgovore na ova pitanja. Ipak, kao što ćemo u nastavku videti, ovi modeli uglavnom počivaju na statističkom posmatranju neurodinamičkih procesa, po ugledu na statističku termodinamiku, i u njima se ne vidi jasan odnos pojedinačnog neurona i kolektiviteta (kao što se u termodinamici ne posmatra pojedinačna čestica gasa ili fluida). Dakle, kao što smo u prethodnoj sekciji i naglasili, još uvek postoji veliki jaz između razumevanja uloge i funkcije pojedinačnog neurona u kolektivnom kognitivnom ponašanju, iako i na nivou lokalne i na nivou globalne prostorno-vremenske dinamike neurostruktura postoji veliki napredak u modelovanju i mnogi modeli pokazuju da mogu dati odzive sistema koji po mnogo čemu koreliraju sa neuropsihološkim aktivnostima i realnim neurofiziološkim signalima koji se mere *in vitro*.

Prvi radovi iz ove oblasti su nastali još 70-tih godina 20. veka. Poznat je tzv. Wilson-Cowan model [151] koji se smatra za jednim od najuticajnijih radova u ovoj oblasti a veoma je aktuelan i danas jer, kako će biti objašnjeno u nastavku, predstavlja i dalje osnov mnogih dinamičkih modela bioloških neurokognitivnih sistema. Sama činjenica da je ovaj model star 40 godina i dalje aktuelan, možda najbolje svedoči o relativno sporom progresu u ovoj oblasti.

Wilson-Cowan model [151] opisuje dinamiku interakcija unutar dosta jednostavne neuronske strukture sastavljene od samo dva tipa neurona – ekscitatornog i inhibitornog. Sam model povezuje, kroz sistem od dve diferencijalne jednačine, ekscitatornu i inhibitornu aktivnost sinaptički povezanih neurona sa prepostavljenom sigmoidalnom prenosnom funkcijom:

$$\begin{aligned}
v_i^E(t) &= \sum_{j=1, j \neq i}^{n_E} A_{ij}^{\text{EE}} \int_{-\infty}^t \alpha_j^E(t-\tau) f_i(v_j^E(\tau)) d\tau + \sum_{j'=1}^{n_I} A_{ij'}^{\text{EI}} \int_{-\infty}^t \alpha_{j'}^I(t-\tau) f_i(v_{j'}^I(\tau)) d\tau \\
&\quad + I_i^E(t), \quad i = 1, \dots, n_E \\
v_i^I(t) &= \sum_{j=1}^{n_E} A_{ij}^{\text{IE}} \int_{-\infty}^t \alpha_j^E(t-\tau) f_i(v_j^E(\tau)) d\tau \\
&\quad + \sum_{j'=1, j' \neq i}^{n_I} A_{ij'}^{\text{II}} \int_{-\infty}^t \alpha_{j'}^I(t-\tau) f_i(v_{j'}^I(\tau)) d\tau + I_i^I(t), \quad i = 1, \dots, n_I
\end{aligned} \tag{13}$$

Istorijska važnost ovog modela je što je pokazao da i ovako jednostavna struktura neuronske mreže (sastavljene od, dakle, samo dva tipa neurona) ima veoma kompleksnu dinamiku odnosno da pokazuje oscilatornu dinamiku, višestruka stabilna stanja (ekvilibrijume) i histerezis, svojstva koja su uočena i u biološkim strukturama. Wilson i Cowan su primenili metodu koja je analogna statističkoj termodinamici Brownian-ovog kretanja čestica i koja opisuje usrednjenu dinamiku celog fluida ili gasa i izveli su statistički model koji opisuje makroskopsko ponašanje velikih neuronskih mreža [170].

Ono što je važno naglasiti još jednom je da Wilson-Cowan model počiva na veoma pojednostavljenoj pretpostavci o postojanju samo dva tipa neurona – inhibitornih i ekscitatornih – kao i drugim prilično rigidnim uslovima pod kojima model važi (jednostavne, linearne, interkonekcije i prenosno funkcije sl.). I pored toga, ovaj model je i dalje vrlo aktuelan jer pruža bazično objašnjenje i sagledavanje ponašanja kolektiviteta u velikim neuronskim mrežama, i kao što će u nastavku biti pokazano, korelira sa novim saznanjima iz oblasti neurofiziologije i uopšte neurokognitivnih istraživanja koja su potvrđila da u biološkim neuralnim sistemima se uočavaju pojave veoma slične onima koje su opisane Wilson-Cowan modelom.

Na bazi Wilson-Cowan modela, uzimajući u obzir i Kuramotov oscilatori model ([171], [172]), koji kao što smo rekli je makroskopski statistički model koji ne ulazi u lokalnu dinamiku neurostrukture već opisuje globalno ponašanje sistema, 1995. godine Pasemann [173] je razvio i opisao jedan, tada veoma novi, dinamički model modularnih neurokognitivnih sistema („neruomodularnih“ kako ih je on nazvao). Rad je interesantna je jedan od prvih koji su izneli konkretne matematičke modele modularnih neurokognitivnih

struktura. Iako je postavljeni model u dobroj meri teoretski generalan, kako sam autor priznaje, njegova kompleksnost (posebno postojanje histerezisa i drugih efekata dinamike haosa) značajno otežava razmatranje i modelovanje složenijih neurostruktura, pa se Pasemann zadržao na samo veoma malim primerima (2-3 neurona). Ipak, ovaj rad je imao uticaj na dalje sagledavanje značaja neurodinamike u proučavanju neurokognitivnih struktura i procesa, posebno jer je Pasemann izneo snažne argumente da izneta teoretska zapažanja o mogućnosti i karakteristikama neurodinamike u modularnim neuronanatomskim strukturama treba posebno imati u vidu kada se vrše eksperimentalna istraživanja koja se baziraju na posmatranju procesa u biološkim, moždanim neurokognitivnim strukturama primenom savremenih tehnologija kao što su fMRI, EEG i sl. Time su postavljeni temelji za znatno kompleksnije razmatranje i analizu odnosa strukturalnih i funkcionalnih karakteristika u neurokognitivnim procesima posebno na višim nivoima svesti (jer na nižim je znatno jednostavnija i direktnija veza ulaza i posmatranih izlaza odnosno ponašanja neuroloških struktura, što je još ranije bila i osnova Fodorove koncepcije modularnosti ljudskog mozga, ali polazeći od terminalnih dakle najnižih kognitivnih nivoa, senzorskih ulaza, koji imaju veoma jednostavnu i determinisau funkcionalnost koja se lako mogla sagledati čak i ranim eksperimentalnim tehnologijama [114]).

U periodu od tih ranih radova do danas, napravljen je veliki progres u sagledavanju kompleksnosti ali i značaja dinamike u kognitivnim procesima. Postalo je jasno da su teoretski i eksperimentalno potvrđene strukturalne karakteristike (modularnost, fraktalnost i svojstva malog sveta) bioloških neurokognitivnih struktura na svim nivoima (od celine ljudskog mozga pa do ćelijskog neuroanatomskog nivoa primitivnih organizama poput *Caenorhabditis elegans*), tesno povezane sa energetskim dinamikama koje se odvijaju unutar i između ovih struktura.

Bassett i Gazzaniga u veoma citiranom preglednom radu “*Understanding complexity in the human brain*” [14] sumiraju istraživanja i progres u ovoj oblasti do 2011. godine. Po njima, progres razvoja u ovoj oblasti ide kroz faze i ključne prekretnice u koncepciji se mogu posmatrati kroz tranziciju od shvatanja odnosa topologije i strukture u odnosu na fukcionalne procese, preko shvatanja da se funkcionalna svojstva moraju posmatrati kao prostorno-vremenska dinamika pa do najnovijih shvatanja da je potrebno razviti i shvatiti generalnu dinamičku teoriju koja je neophodna za konačno razumevanje kognitivnih procesa na svim

nivoima. Oni takođe zaključuju da dok su strukturalne karakteristike neuorokognitivnih sistema veoma dobro istražene, primenom teorije kompleksnih mreža izvršeno je veoma kvalitetno matematičko modelovanje i objašnjena je struktura i topologija neurosistema na gotovo svim nivoima, dotele je pitanje dinamike u njima ostalo gotovo netaknuto.

Ipak, postoje neki novi radovi i koji su dotakli i ovo složeno pitanje. Tako Bassett i Gazzaniga citiraju zapažen rad Churchland et al. „Cortical preparatory activity: representation of movement or first cog in a dynamical machine?“ [174] iznose veoma značajne rezultate koji ukazuju da u motornom korteksu postoje aktivnosti ne samo tokom kretanja već i u tzv. pripremnoj fazi. Ovaj rad je značajan jer iznosti nove dokaze koji su donekle suprotstavljeni dosadašnjim shvatanjima, a posebno je značajno što autori uočavaju da se tzv. pripremno tjuniranje u neuralnoj mreži može korelirati sa pravcem preferirane direkcije (pravca) kretanja u abstraktnom prostoru koji opisuje stanje odnosno eksitacije neurona čak na nivou grupa. Oni izvode zaključak da ovi rezultati ukazuju da se u pripremnoj fazi u stvari vrši postavljanje početnog stanja dinamičkog sistema čija dalja evolucija (dinamika, odnosno odvijanje prostorno-vremenske dinamike energije) proizvodi kretanje. Napominjemo da je ova referenca posebno korelira sa napred opisanom LTT CNM (za praćenje trajektorije, [87]), a u narednim poglavljima će ona biti posebno razmatrana u kontekstu teme ove disertacije odnosno bihevioralne analogije sa posebnim klasama fraktalno-modularnih veštačkih CNM.

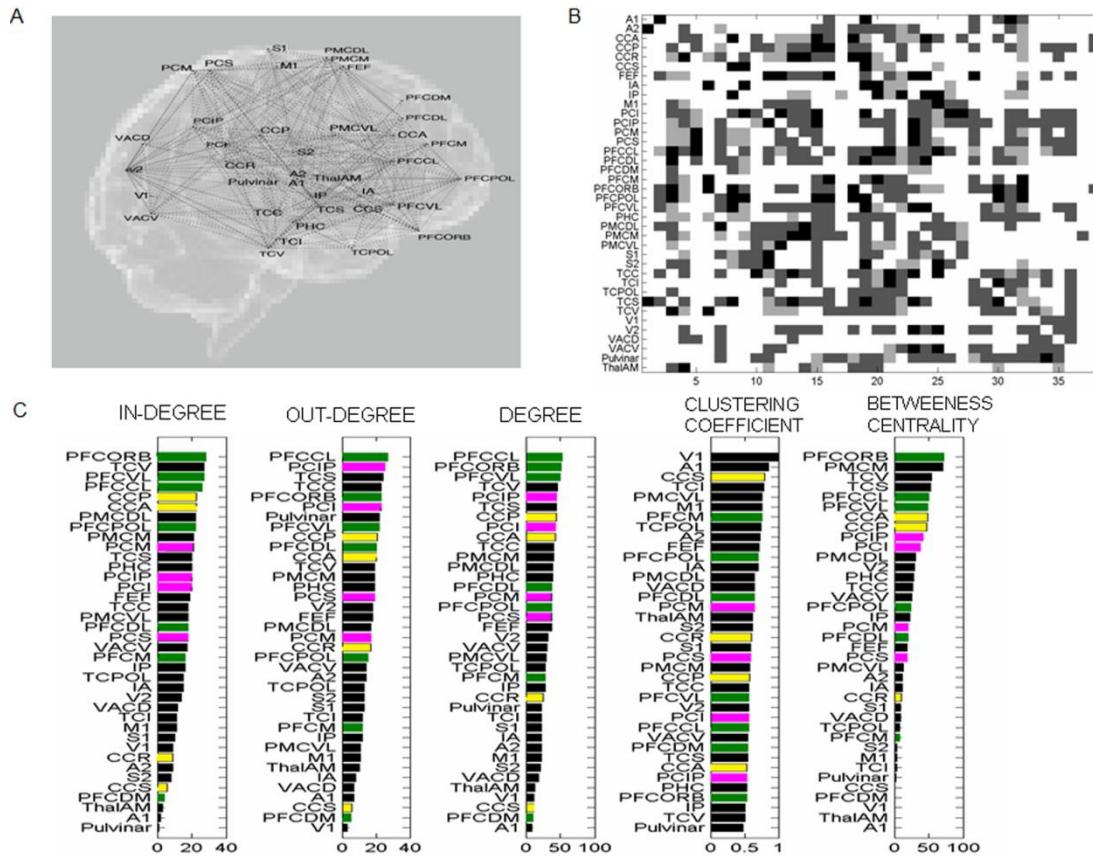
Drugi rad vezan za pitanja dinamike u neurokognitivnim mrežama koji su i Bassett i Gazzaniga istakli je rad Deco et al. [175] koji se bavi preglednom analizom i sintezom postojećih modela u novi jedinstven objedinjeni model spontane neurodinamike u RSN (*Resting-State Network*). Spontana neurodinamika je od posebnog značaja jer je većina istraživanja i radova, po rečima autora, zanemarivala spontanu aktivnost jer su eksperimentalna istraživanja, posebno neuroimaging tehnike poput fMRI, DTI, PET i sl., uglavnom bila zaokupljena aktivnostima koje su posledica nekih spoljnih stimulusa i koje zahtevaju neki kognitivni (inteligentni) odgovor. Ranije je već rečeno da je ovo osobeno reverznom inženjeringu koji se primenjuje u nurokognitivnim istraživanjima, gde se posmatra korelacija ulaza odnosno spoljnih stimulusa i odziva odnosno kognitivne funkcionalne reakcije sistema / moždanih struktura koje se mogu snimiti savremenim nuroimaging tehnologijama. Deco et al. stoga razmatraju upravo spontanu aktivnost koja je i sa stanovišta

reverznog inženjering kompleksniji problem, ali i daje neka veoma značajna usmerenja za shvatanje prostorno-vremenske dinamike neokorteksa¹² primata. Oni primećuju da je pitanje dinamike „karika koja nedostaje“ jer i pored veoma dobrog sagledavanja ne samo strukturalnih osobina, topološke arhitekture povezanosti malog sveta na globalnom nivou već i lokalne dinamike pojedinačnih neurona (LIF) i neuralnih ansambala, još uvek nije lako sagledati niti modelovati globalnu dinamiku bioloških neurokognitivnih sistema.

Tri modela koja analiziraju Deco et al. su:

Model 1: Honey et al. [176] su 2006. godine predložili model u kojem fluktuacije aktivnosti RSN odslikava povezanost lokalne dinamike i anatomske veza unutar mreže malog sveta. U ovom modelu je, slično kao u ranijim radovima npr. Pasemann [173] koji smo već referisali, haotični oslicatori se koriste za reprezentovanje moždanih regiona odnosno modula mreže dok su veze između njih slabe tako da se generišu sinhrone aktivacije između regiona (pojednostavljeni model, koji *de facto* zanemaruje prostornu dinamiku). Ovaj model nije uključio vremensko kašnjenje u propagaciji signala između regiona (modula) odnosno smatra da je veza između neurona trenutna. Takođe, šum nije uključen u model niti u simulacije. Stoga je ovaj model dosta ograničen, iako je otvorio neka veoma važna pitanja.

¹² Neokortex je kod ljudi najveći deo cerebralnog korteksa, koji pokriva obe cerebralne hemisfere, i uključen je u više kognitivne funkcije kao što su prostorna orijentacija i rezonovanje, motorna aktivnost, inteligentno rezonovanje i govor.



Slika 22: Anotamska konektivnost ljudskog mozga (preuzeto iz [177]). (A) Mapa kortikalne povezanosti kod primata, prikazana na ljudskom mozgu. (B) Matrica povezanosti (beli pikseli označavaju odsustvo veze a nivo sive boje pokazuje intenzitet veze). Matrica povezanosti ima karakterističnu dužinu puta 1.633 i indeks klasterizacije 0.568. (C) Statistička karakterizacija mrežne topologije.

Model 2: Ghosh et al. [177] su predložili model koji pokušava da bolje predstavi prirodu neuroanatomskih veza. Njihov model se bazira na preciznoj estimaciji fizičkih kortikalnih distanci (stvarnih dužina veza u mreži malog sveta), na osnovu poznatih CoCoMac studija, i mapiranje stvarne regionalne mape ljudskog mozga (Slika 22). Regionalna dinamika je modelovana takođe preko oscilatora ali su uključili i šum (prepostavljen je konstantan nivo šuma). Ipak, oni takođe prepodstavljaju konstantu brzinu prenosa signala, i aproksimiraju kašnjenja između povezanih regiona (modula) linearnom funkcijom njihove euklidske udaljenosti (podeljenom sa prepostavljenom brzinom). Drugi parametar njihovog modela je snaga veze (što smo u prethodnomj sekciji i naglasili da je jedan od ključnih aspekata koji se zanemaruje u strukturalno-topološkim modelima). U svom istraživanju, Ghosh et al. su sistematski posmatrali korelaciju varijacije ovih parametara i

eksperimentalnih rezultata, a posebno su se bavili pitanjima ekvilibrijuma odnosno stabilnosti povezanih sa varijacijom ovih parametara. Oni su izveli robusne matematičke modele, koji ovuhvataju i složenu analizu i identifikaciju domena stabilnosti odnosno nestabilnosti u funkciji varijabilnih parametara (brzine prostiranja signala i snage intekonencija) i pokazuju da postoji kritična linija koja deli ova dva domena. U stabilnim domenima, neurokognitivna mreža je u ekvilibrijumima (nakon spontane tranzicije), dok šum koji je inherentan u sistemu konstantno vodi mrežu izvan ekvilibrijuma. Oni su pokazali i da, bazirano na empirijski utvrđenim vrednostima varijabilnih parametara, mreža (tj. sistem) pokazuje oscilatorna svojstva upravo ako su ti parametri bliski liniji separacije stabilnog i nestabilnog domena. U tim slučajevima, simulacije modela koje su izveli Ghosh et al. uočavaju pravilne oscilacije $\sim 10\text{Hz}$ u kojima se sistem, pod dejstvom šuma koji ga izbacuje iz ekvilibrijuma stabiši i ponovo vraća u ekvilibrijum. Ovo ponašanje korelira sa dobro poznatim oblicima fizioloških merenja, uključujući elektroencefalografiju (EEG) i magnetoecefalografiju (MEG).

Ovo su izuzetno značajni rezultati jer pokazuju da se primičemo modelima koji ne samo da koreliraju sa eksperimentalnim fiziološkim pokazateljima, već i povezuju „ključnu kariku“ odnosno vezu između dinamike i strukturalnih karakteristika bioloških neorokognitivnih sistema. Naravno, treba imati u vidu i ograničenja ovog modela. On je ipak ograničen jer prepostavlja veoma pojednostavljen model parametara interkonektivnosti (brzine prenosa i intenziteta konekcija), ali je važan je prvi put povezuje oscilatorno ponašanje i lokalnu vremensko-prostornu stabilnost.

Model 3: Deco et al. [178] 2009. izvode još napredniji model, koji kao i prethodni (Ghosh et al. [177]) polazi od kompleksne mrežne dinamike koja potiče od proste lokalne dinamike koju diktiraju konektivnost, vremenska kašnjenja i šum, ali u ovom modelu je i uticaj šuma parametrizovan (dok je u prethodnom prepostavljen da je konstantan). Brza dinamika lokalnih oscilacija (oko 40 Hz) je iskazana Wilson-Cowan modelom uz modifikaciju da se prepostavlja da je svaki nezavisni, izolovani, čvor mreže (neuron) „miran“ (u režimu smanjenje aktivnosti). Model pokazuje da ako se parametri sistema nalaze blizu tzv. Hopfove bifrukacije (*Hopf bifurcation*), kada su čvorovi povezani – počinju da osciluju. Kao što je naglašeno, parametri modela su bazirani na prethodnom modelu Ghosh et al. [177] koji je zasnovan na fizičkim merenjima strukturalnih svojstava moždanih struktura primata (Slika 22) i pokazao je da pogodan izbor parametara daje rezultate koji koreliraju sa

fiziološkim oblicima signala, ali su prilagođeni i uveden je i parametrizovani nivo šuma, čime je postignut rezultat da se formirao oscilatorni režim i na višim učestanostima odnosno u tzv. gama opsegu od oko 40 Hz (dok je prethodni model Ghosh et al. [177] korelirao sa oscilacijama na nižoj učestanosti od oko 10 Hz). Pri tome, ovaj model ne opovrgava prethodni već uvodi i dodatnu učestanost odnosno pokazuje da globalna kompleksna dinamika u neorukognitivnoj mreži potiče od lokalnih veza prostih oscilatora a ne samo od kompleksne lokalne dinamike interkonekcija na višim nivoima strukture (i po tome se razlikuje od modela 1, Honey et al. [176]).

Dakle, model Deco et al. [178] pokazuje mrežnu dinamiku koja je rezultat povezanosti pojedinačnih čvorova, sa identičnom vremensko-prostornom strukturuom uključujući i matematički model, kao u modelu Ghosh et al. [177] ali njihov model, uvodeći i varijabilni parametar nivoa šuma, pokazuje da se za ordeđeni opseg brizan prenosa (prostiranja) signala pojavljuju matrice sinhronizacije klastera odnosno da pojedine oblasti mozga pokazuju veću međusobnu sinhronizaciju. Tako, za različite brzine prostiranja (npr. 1.5 m/s i 2 m/s) uočavaju se jasno različite klasterizacije odnosno grupe sinhronisanih regiona mozga.

Ne ulazeći u medicinske i kliničke implikacije ovih istraživanja, koja su kako navode brojni autori od velikog značaja jer pokazuju da neurološki i psihološki poremećaji mogu korelirati sa poremećajima u fizičko-dinamičkim a ne samo strukturalnim degenracijama (npr. da promene fizičkih karakteristika zbog starenja ali i drugih uticaja mogu poremetiti parametre modela i time dovesti do promene u opštem ponašanju), možemo primetiti da sva tri navedena model razmatraju pojednostavljenu prostorno-vremensku dinamiku baziranu na teoriji oscilatornih sistema uz vrlo rigidne prepostavke u pogledu modelovanja stvarne prostorno-vremenske propagacije na lokalnom nivou (modelovanje kašnjenja propagacije kroz prost linerani odnos brzine i rastojanja). Zato, sa inženjerskog stanovišta, moramo konstatovati da je ovakvo modelovanje podložno diskusiji uslova odnosno opsega važenja i primene modela, posebno što je pitanje prostiranja pojednostavljenog do nivoa koji u mnogim električnim mrežama i sistemima je poznato da nije dovoljno validan u širokim opsezima prostorno-vremenskih domena (frekvencije signala ali i dužine prostiranja npr. u energetskim sistemima, vodovima i drugim električnim kolima sa raspodeljenim parametrima).

4 Identifikacija bitnih karakteristika sličnosti bioloških neurostrukura sa fraktalno-modularnim CNM

U ovom poglavlju biće uporedno analizirana napred izneta svojstva bioloških neurokognitivnih struktura i fraktalno modularnih celularnih neuralnih mreža. Poređenjem identifikovanih bitnih svojstava moći će da se formira korelacioni model odnosno matrica sličnosti i da se identifikuju i rangiraju bitne karakteristike koje mogu biti od značaja za dalji razvoj modela analogije tih struktura.

4.1 Klasifikacija bitnih karakteristika i svojstava neurostruktura

Prvi korak u identifikaciji bitnih karakteristika sličnosti je njihova klasifikacija i grupisanje po domenima koji omogućavaju uporedivo razmatranje i analizu između bioloških i veštačkih neurostruktura. Iako su veštačke neurostrukture (veštačke nauralne mreže i drugi veštački neurokognitivni sistemi) upravo našle inspiraciju u biološkim strukturama, posebno neurologija i psihologija kao ključne grane u neuronaukama, daleko su zrelije naučne discipline od paralelnih obalsti inženjerskih nauka koje se bave ovim problemima. Stoga je opravdano da se upravo na bazi domenskih specijalizacija neurologije kao izvorne naučne discipline, izvrši i opšta klasifikacija i sistematizacija karakteristika koje ćemo u daljem razmatranju staviti u kontekst analogije sa inženjerskim disciplinama i samim veštačkim nerostrukturama od interesa.

Prema gotovo svim silabijusima vodećih akademskih institucija u svetu, neurologija koa grana medicine se deli i izučava na tri ključna domena odnosno naučne poddiscipline:

1. *Neuroanatomija*, koja je najstarija i samim tim bazična disciplina i bavi se strukturom i organizacijom mozga i neurostruktura na svim nivoima – od pojedinačnog neurona i njegove interne strukture, do moždanih struktura, senzorskih sistema, motoričkih sistema, kičmene moždine itd. ()

2. *Neurofiziologija*, je spoj fiziologije i neuronauka u domenu proučavanja funkcijanisanja neuroloških sistema prvenstveno sa aspekta fizičkih pojava i procesa (hemijskih, električnih, mehaničkih i drugih fizičkih procesa koji određuju funkcijanisanje neurona i tkiva).
3. *Neuropsihologija*, je nadgradnja prethodne dve discipline i proučava odnose i povezanosti strukture i funkcije mozga (odnosno neurokognitivnih struktura uopšte) u odnosu na psihološke procese i ponašanja živih jedinki.

Dakle, sa aspekta klasifikacije bitnih karakteristika i svojstava neurostruktura na svim nivoima bioloških sistema, možemo poći od sledeće domenske podele koja odgovara tradicionalnim naučnim disciplinama koje su opšte priznate u beomedicinskim neuronaukama:

Tabela 2 – Domenska podela karakteristika i svojstava neurokognitivnih struktura prema tradicionalnim neuronaučnim disciplinama

Neuronaučna disciplina	Domenski fokus
Neuroanatomija	Strukturalna i organizaciona svojstva, na različitim nivoima (i niskim i visokim)
Neurofiziologija	Funkcionalna i dinamička svojstva, na različitim nivoima (i niskim i visokim)
Neuropsihologija	Bihevioralna i kognitivna svojstva, koja proističu iz strukturalnih i funkcionalnih karakteristika, ali samo na višim i visokim nivoima

Polazeći od ove domenske klasifikacije, u narednim sekcijama će biti detaljno analizirane glavne karakteristike i svojstva po svakom od ovih domena. Uzimajući kao polaznu osnovu činjenice i saznanja iz meta-analize savremenih istraživanja u oblasti neuronauka, izložene u prethodnim poglavljima, biće sistematizovane ključne karakteristike po svakom od ovih osnovnih domena a koje se javljaju i u biološkim i u veštačkim neurokognitivnim strukturama od interesa (iako je fokus ove disertacije na fraktalno-modularnim CNM, smatramo da je postavljeni model karakterizacije je dovoljno opšti i u ovom obliku da se može primeniti i na druge neuro-strukture osim CNM).

4.2 Strukturalne karakteristike i organizaciona svojstva (neuroanatomske osobine)

Kao što je u prethodnim poglavlјima naznačeno (vidi sekciju 3.2), meta-analiza savremenih istraživanja i saznanja u oblasti neuroanatomije izdvaja tri osnove strukturalne karakteristike koje su identifikovane kao suštinski bitni u biološkim neurokognitivnim strukturama:

1. Topologija
2. Modularnost
3. Fraktalnost

U poglavlju 2 date su opšte definicije ovih pojmove i to u kontekstu paradigmе fraktalno-modularnih CNM. Dakle, fraktalno-modularne CNM po definiciji su karakterisane upravo ovim ključnim svojstvima koja su, meta-analizom savremnih istraživanja (poglavlje 3), identifikovane i kao ključne neuroanatomske karakteristike i bioloških neurokognitivnih struktura.

Iako su u sekciji 2.1 date opšte definicije ovih pojmove, potrebno je izvršiti sistematizaciju i bolje definisanje konkretnih konceptata (odlike) kojema se svaka od ovih karakteristika može bliže i preciznije definisati u smislu mogućnosti egzaktnijeg poređenja odnosno određivanja stepena sličnosti i/ili analogije između bioloških i veštačkih struktura.

Tako svaka od navedenih karakteristika se može bliže karakterisati sledećim ključnim odlikama:

Topologija: U sekciji 2.1.1 je naznačeno da se i kod biooloških i veštačkih struktura pod terminom topologija najčešće mogu razmatrati odlike susednosti i granica strukture, dok je u kontekstu bioloških sistema od interesa i vrsta veza odnosno da li se radi o fleksibilnim ili rigidnim strukturama (sekcija 3.2). Dakle, sa stanovišta topologije možemo smatrati da su identifikovane sledeće ključne odlike koje karakterišu strukturnu organizaciju neurokognitivne strukture:

- *Susednost* (lokalna / globalna / „malog sveta“) koja diktira organizacionu formu strukture, a koja je komplementarna modularnim i fraktalnim svojstvima, što je naznačeno posebno u sekciji 3.2.1 gde je objašnjeno da strukture „malog sveta“ ne moraju inherentno biti ni modularne ni fraktalne (Slika 12). Dakle, topološke karakteristike susedstva opredeljuju da određena struktura ima svojstva „malog sveta“, što je pokazano da je bitna karakteristika bioloških neurokognitivnih struktura, a modularnost i fraktalnost su nezavisna svojstva.
- *Ograničenost* (granični uslovi odnosno prostorna ograničenost strukture) je nesporno ključna odlika koja je prisutna u svim biološkim neurostrukturama. U veštačkim fraktalno-modularnim CNM osobina ograničenosti je inherentna metodi fraktalne modularizacije, gde je pokazano da upravo jedan od produkata metodološkog procesa sinteze fraktalno-modularne CNM je i skut tzv. graničnih uslova koji upravo definišu geometriju mreže i omogućavaju fizičku ograničenost strukture (sekcija 9.2.2).
- *Povezanost* (odlike veza, fiksne / adaptivne) su ključna odlika koja upravo u biološkim neruosistemima predstavlja osnovu kognitivnosti u funkcionalnom i bihevioralnom smislu. U sekciji 3.2 je tako naznačeno aktuelno naučno shvatanje da upravo balans između rigidnih i adaptabilnih faktora omogućavaju formiranje kognitivnih procesa na različitim nivoima svesti. Na drugoj strani, metoda fraktalne modularizacije upravo pokazuje da u fraktalno-modulanrim CNM koje imaju određena napredna funkcionalna svojstva (poptut LP CNM koja vrši linerano programiranje) dolazimo do egzaktnog topološkog model mreže koja ima upravo i jedne i druge tipove veza: postoje fiksne (rigidne) veze predeterminisanih vrednosti koje ne zavise od partikularnog problema koji se rešava ali postoje i promenjive (adaptivne) veze koje su definisane upravo vrednostima parametara matrice sistema jednačina problema koji se rešava. Dakle, i u biološkim neurostrukturama i u fraktalno-modularnim CNM funkcionalnost direktno zavisi od adekvatnog skupa fiksnih i fleksibilnih topoloških veza strukturne organizacije.

Modularnost: U sekciji 2.1.2 definisani su opšte odlike modularnih struktura dok je u sekciji 3.2 dat pregled savremenih pogleda na modularnost u biološkim neurokognitivnim strukturama. Tako, pod opštim pojmom modularnosti mogu se identifikovati sledeće ključne

zajedničke strukturalne¹³ odlike koje možemo smatrati bitnim i u biološkim i u veštačkim neurosistemima:

- *Interna integrisanost* je odlika koja je esencijalna za definiciju modula kao takvog u bilo kom sistemu (ukoliko unutar modula nema integrisanosti onda je pitanje da li i po kom kriterijumu se elementi modula uopšte smatraju modulom). Kod bioloških struktura ova integrisanost (povezanost) je prepoznatljiva odlika koja u neuroanatomskom smislu i definiše određene moždane odnosno strukture (broj internih sinapričkih veza unutar jedne strukture daleko je veći od broja veza sa drugim strukturama).
- *Proširivost* podrazumeva da se sistem može nadograđivati odnosno da se može širiti prostim dodavanjem modula. Drugim rečima ova odlika uslovljava povezanost funkcionalnosti (procesnog kapaciteta odnosno sposobnosti) i strukturne organizacije neurosistema. U biološkom neurosistemu, proširivost ima fizička ograničenja ali je u kontekstu funkcionalnosti onda tesno povezana sa mogućnošću da se u izabranoj fizičkoj topologiji (npr. u 2D ili 3D prostoru) može izvršiti proširenje sistema bez da se naruše druga topološka ograničenja (odnosno da ne mora da dođe do kršenja topoloških uslova, što je npr. slučaj kod štampanih kola u kojima određena proširenja ne mogu da se sprovedu bez presecanja ionija veza odnosno bez prelaska sa 2D na 3D topologiju realizacije).
- *Homolognost* podrazumeva da moduli imaju sličnu unutrašnju topologiju odnosno da prethodno definisane topološke odlike susednosti, ograničenosti i povezanosti važe kako na nivou celog sistema tako i na nivou pojedinačnog modula. Pri tome, ne moraju iste metrike ovih odlika da važe intramodularno i intermodularno. Homolognost definiše srodnost modula po strukturi odnosno mogućnost da se neurokognitivni sistem hijerarhijski razloži na klastere srodnih (homolognih) modula koji su prepoznatljivi po karakterističnoj strukturi.

¹³ U definicijama modularnosti treba primetiti da se ona često vezuje i za funkcionalne karakteristike sistema, kao što su funkcionalna specijalizacija ili informaciona enkapsulacija (sekcija 2.1.2, Tabela 1). Stoga u ovom kontekstu posmatramo samo strukturalne odlike modularnosti, dok će u nastavku biti uključene i funkcionalne.

- *Raznolikost* podrazumeva da moduli mogu (mada i ne moraju) imati neke odlike koje ih međusobno razlikuju iako su homologni (srodni). Dakle, moduli ne moraju biti identični već su dopuštene određene varijacije intramodularne strukture (npr. različite adaptivne veze ili pak strukturne specifičnosti npr. graničnih modula strukture itd.). Raznolikost i homolognost nisu isključive odlike već mogu upravo odrediti ukupnu fleksibilnost sistema da se strukturalno i organizaciono prilagođava promena funkcionalnih zahteva. Drugim rečima, homologni moduli se mogu prilagoditi različitim strukturalnim i/ili funkcionalnim potrebama sistema bez da menjaju svoju pripadnost klasi homolognosti. U biološkim neurosistemima ove odlike se mogu povezati sa sposobnošću neurostruktura da atrofiraju ili da se regenerišu (što se referiše i kao *neuroplastičnost* [179], [180]), zavisno od funkcionalne potrebe.

Fraktalnost: U sekciji 2.1.3 definisane su opšte odlike frakタルnih struktura dok je u sekciji 3.2 dat pregled savremenih pogleda na ulogu fraktalnosti u biološkim neurosistemima. Ključne odlike koje su svojstvene i biološkim i veštačkim frakタルno-modularnim su:

- *Samosličnost* je odlika prisutna u svim biološkim sistemima i posebno je uočena u neurokognitivnim strukturama gde je novim neuroimaging tehnologijama ne samo potvrđena uočljiva i lako prepoznatljiva samosličnost neuroanatomskih struktura na gotovo svim nivoima mozga, već je ta odlika direktno dovedena i u vezu sa genetskim mehanizmima i evolutivnim procesima. Na drugoj strani, u veštačkim neuralnim mrežama, bez obzira da li se radi o npr. perceptronskim, Hopfieldovim ili pak samim CNM (bez obzira da li se radio o frakタルno-modularnim ili nekim od posebnih tipova opisanih u literaturi), samosličnost je inherentna gotovo svim ovim arhitekturama jer se, zbog izvodljivosti, gotovo po pravilu javljaju uočljivi samoslični podsistemi ili elementarne strukture organizacionih jedinica (kod perceptronskih mreža imamo slojeve sastavljene od perceptorna – neurona, kod CNM imamo mreže – slojeve sastavljene od pojedinačnih ćelija itd.). Dakle, samosličnost je inherentna i biološkim i veštačkim neurokognitivnim sistemima i kao takva je prepoznata kao ključna odlika koja je od važnosti za efikasnost dizajna same neurokognitivne strukture (pod dizajnom se ovde podrazumeva efikasnost „zapisa“ informacija potrebnih za generisanje strukture, što je u biološkim sistemima dovedeno u direktnu vezu sa genetskim

zapisom i evolutivnim mehanizmima koji omogućavaju spontanu genezu tkiva i organa, dok je kod veštačkih struktura to inherentno definicijama koje polaze od inženjerskih principa u kojima je repetitivnost i šablonska organizacija osnov efikasnog i ostvarivog dizajna).

- *Hijerarhijska ugnježdenost* je odlika koja se nadovezuje na samosličnost u organizacionom i strukturalnom smislu, na jednoj strani, i na modularnost na drugoj strani. U sekciji 3.2 pokazano je da hijerarhijska ugnježdenost može biti prepoznata u gotovo svim biološkim sistemima, posebno neuroanatomskim strukturama, paralelno sa samosličnošću i da se te dve odlike često prepliću (hijerarhijski ugnježdene samoslične strukture upravo formiraju samoslične strukture). Ipak, važno je razumeti da sa stanovišta i bioloških ali i veštačkih sistema beskonačna rekurzivnost ovakvih fraktalnih struktura koje su hijerarhijski samoslične nema praktičnog smisla (mora postojati ograničenost). Tu dolazi do veze sa modularnošću odnosn, kako je u sekciji 3.2.1 opisano, do veze sa strukturama „malog sveta“ odnosno modularnošću. Hijerarhijska ugnježdenost je bitan preduslov da struktura ima karakteristike „malog sveta“ ali samosličnost mora biti ograničena na module (moduli unutar sebe mogu imati hijerarhijski ugnježdene module samoslične strukture) a ne prisutna u strukturi u celini (jer u suprotnom nema karakteristike „malog sveta“ već je u pitanju homogena, rekurzivna struktura koja nema prepoznatljive raznolike module). Dakle, hijerarhijska ugnježdenost je inherentna biološkim neurokognitivnim strukturama „malog sveta“ ali je treba razmatrati na različitim nivoima organizacije, i u kontekstu modularnosti i u kontekstu samosličnosti ali i drugih strukturalnih (ograničenost, razanlikost...) i funkcionalnih odlika i svojstava. Zato se ona i može determinisati kao bitna odlika nezavisna od drugih, iako se u biološkim ali i veštačkim strukturama često podrazumeva i vezuje uz druge karakteristike.

4.2.1 Model strukturalne analogije bioloških neurokognitivnih sistema i veštačkih fraktalno-modularnih CNM

Ovako sistematizovane bitne zajedničke neuroanatomske odnosno strukturalne i organizacione karakteristike mogu se sada primeniti na analogiju bioloških i veštačkih neurokognitivnih struktura. Model analogije se može formulisati kao matrica ili drugi model

korelacija navedenih karakteristika, bliže definisanih preko njihovih respektivnih ključnih odlika. Kvantifikacija ovih korelacija može biti logička (formalno i neformalno logička) ili kvantitativna (čak i fazi-logička) ukoliko se pojedine odlike mogu formalno matematički kvantifikovati ili empirijski odrediti (npr. susednost ili dubina hijerarhijske ugnježdenosti gde npr. kod vizuelnog korteksa primata je poznat tačan broj slojeva u hijerarhiji i sl.).

Upravo zavisno od mogućnosti da se pojedine karakteristike, odnosno njihove odlike, mogu predstaviti logičkim ili kvantifikovanim merilima (vrednostima) moguće je formirati različite modele analogije. Tako, na osnovu rezultata savremenih istraživanja koja su izneta u poglavlju 3 moguće je formulisati osnovni model analogije bioloških neurokognitivnim sistemima sa fraktalno-modularnim celularnim neuralnim mrežama kako su definisane u poglavlju 2. Pod „osnovnim“ modelom se podrazumeva da će većina karakteristika biti opisno ili neformalno determinisane (određene) a da neki napredniji modeli mogu biti razvijeni daljim usavršavanjem ove kvanitifikacije i boljim merenjima, sagledavanjima ili definisanjem dodatnih parametara koji bi model analogije činili kvalitetnijim i preciznijim. Cilj ove disertacije je razvoj modela a dalja istraživanja mogu upravo ići u pravcu njegovog poboljšanja ili daljeg razvoja. Model je razvijen na bazi trenutno aktuelnih saznanja i pogleda na strukturalne i organizacione karakteristike neurokognitivnih struktura, i za očekivati je da će u budućnosti doći ili do revizije nekih od ovih stavova ili do produbljenja saznanja, posebno u kvantitativnom sagledavanju mnogih bitnih odlika koje su sada samo identifikovane ili načelno determinisane (npr. prepoznato je da mnogi nivoi mozga imaju karakteristike „malog sveta“ ali je kvatifikacija tih odlika još uvek na niskom nivou pouzdanosti i preciznosti, ili grubo se zna koliko je susedstvo pojedinačnog neurona na nekim neuroanatomskim nivoima ali je izvesno da je to samo gruba procena na osnovu parcijalnih empirijskih saznanja i da je stvarno susedstvo varijabilno zavisno od mnogih faktora uključujući i funkcionalne a ne samo anatomske uloge konkretnog neurona).

Tabela 3: Model strukturalne analogije bioloških neurokognitivnih sistema i veštačkih fraktalno-modularnih CNM

Karakteristika / Odlika	Biološki neurokognitivni sistemi	Veštačke fraktalno-modularne CNM	Korelacija
Topologija			VISOKA
Susednost	Dominantno „malog sveta“ (lokalna po klasičnim neuroanatomskim modelima unutar određenih regiona ili nivoa korteksa)	Inherentno lokalna ali i „malog sveta“ u višeslojnim fraktalno-modularnim mrežama	VISOKA
Ograničenost	Inherentna (biološki i fizički uslovljena)	Inherentna (po definiciji)	VISOKA
Povezanost	Fiksna i adaptivna (osim na najnižim nivoima gde dominiraju fiksne veze)	Dominantno fiksne ali inherentno i adaptivne (zavisno od aplikacije)	VISOKA
Modularnost			VISOKA
Proširivost	Nije univerzalno dokazana ali se u načelu predpostavlja (učenje, trening, evolutivno prilagođenje)	Inherentna (fraktalno-modularne CNM imaju direktnu korelaciju sa dimezijom problema koji rešavaju pa je proširivost podrazumevana jer je parametar samog matematičkog modela)	SREDNJA
Interna integrisanost	Rasprostranjena (većina moždanih struktura se upravo i identificuje preko visoke interne povezanosti)	Inherentna (modul fraktalno-modularne CNM je određen upravo internom povezanošću ćelija koje ga čine)	VISOKA
Homolognost	Rasprostranjena (uočena na mnogim nivoima i u različitim delovima mozga, ali ne postoji dokaz univerzalne	Inherentna (direktno proističe iz matematičkog modela koji podrazumeva prostornu invarijantnost u jednačinama	VISOKA

	prisutnosti ¹⁴⁾	stanja iskazanu kroz šablone A i B matrica povezanosti ćelija koji imaju homolognu strukturu za sve ćelije odnosno module mreže)	
Raznolikost	Inherentna (postoje različite klase neuronskih ćelija, dakle raznolikost je inherentna na neuroanatomskom nivou mada po kortikalnim nivoima često postoje homogene strukture sastavljene od identičnih ćelija ili ansambala)	Rasprostranjena (zavisno od vrste mreže odnosno funkcionalnosti mreže mogu imati identične ćelije/module kao npr. SP CNM ili pak različite kao npr. LP CNM)	VISOKA
Fraktalnost			VISOKA
Samosličnost	Inherentna (biološki uslovljena, povezana sa genetskim mehanizmima)	Inherentna (po definiciji)	VISOKA
Hijerarhijska ugnježdenost	Rasprostranjena ¹⁵ (jako nema konačnog dokaza univerzalne prisutnosti, brojna nova istraživanja pokazuju da mozak ima strukturu „malog sveta“ a samim tim i hijerarhijsku ugnježdenost)	Rasprostranjena (osim u trivijalnim aplikacijama, moduli fraktalno-modularne mreže imaju najmanje dve ćelije ili ćelijska sloja a u svim složenijim aplikacijama i više)	VISOKA
UKUPNA KORELACIJA (ANALOGIJA)			VISOKA

¹⁴ Postoje primeri da različiti delovi mozga mogu preuzeti funkcije drugih oštećenih delova, dakle postoji funkcionalna homolognost u nekim slučajevima, ali ne postoje jasni dokazi univerzalne neuroanatomske homolognosti. Stoga, iako je jasno da u lokalnim regijama ili intraregionalno postoje i anatomski slične neurostrukture tj. homolognosti „modula“, to nije moguće univerzalno karakterisati bez dodatnih istraživanja i novih dokaza.

¹⁵ Iako bi se hijerarhijska ugnježdenost mogla i kvanitativno, npr. u vizuelnom korteksu primata postoji tačno 7 slojeva, ovde ćemo se zadržati na opisnom nivou jer je ovo bazični model analogije a u daljim istraživanjima je moguće ići ka kvalitetnijem i preciznijem determinisanju.

4.3 Funkcionalne karakteristike i dinamička svojstva (nurofiziološke osobine)

Funkcionalne karakteristike odnosno neurodinamička svojstva su već istaknuta kao jedno od ključnih polja savremenih istraživanja u oblasti neuronauka. U sekciji 3.3 je napomenuto da su mnogi autori prepoznali da je nedostajući faktor u mnogim strukturalnim modelima neurokognitivnih sistema upravo povezan sa vremensko-prostornom dinamikom, koja u stvari predstavlja funkcionalnu osnovu neuromodulativnih procesa (a samim tim i vezu sa neuropsihološkim domenom, osnono bihevioralnim procesima čije modelovanje se nikako ne može posmatrati samo sa strukturalnog aspekta).

U prethodnom poglavlju, u sekciji 3.3, meta-analizom savremenih istraživanja u ovoj oblasti pokazano je da zbog kompleksnosti problema ne postoji jedinstven pristup već se modelovanje razlaže na apstrakcione nivoe koji često nezavisno posmatraju pojedinačni neuron i njegovo lokalno okruženje (*bottom-up* modeli, sekcija 3.3.1) i kolektivitete neurona (*top-down* modeli, sekcija 3.3.2). I jedan i drugi pristup imaju zajedničku crtu da u stvari zanemaruju ili grubo aproksimiraju pojedine dimenzije stvarne kompleksnosti neurodinamike (upravo aspekti koji se zanemaruju ili aproksimiraju i određuju različite tipove i klase modela, njihov kvalitet i druge osobine koje su detaljno izložene i komparirane u sekciji 3.3). Tako, gotovo svi *bottom-up* modeli (modeli pojedinačnog neurona) zanemaruju prostorne dimenzije odnosno njihovi dinamički modeli tj. sistemi jednačina stanja se baziraju na posmatranju isključivo vremenske dinamike dok se prostorna zanemaruje (ni u jednom modelu ne figuriraju bilo kakve zavisnosti od prostornih parametara, posmatra se pojedinačni neuron i prepostavlja se prostorna invarijantnost odnosno da „mesto“ neurona u prostoru nema nikakvog uticaja na njegovu internu dinamiku).

Sa druge strane, *top-down* modeli u nekoj meri počinju da uključuju i prostornu dinamiku kroz npr. elemente koji modeluju konačnu brzinu prostiranja signala kroz sinaptičke veze i sl. (sekcija 3.3.2). Međutim, obzirom da *top-down* modeli statistički posmatraju kolektivitete neurona i da apstrahuju mnoge aspekte funkcionalnog ponašanja pojedinačnih neurona i njihovu lokalnu interakciju, oni su mnogo bliži nivou neuropsihološkog odnosno bihevioralnog modelovanja, gde se stvarna funkcionalnost pojedinačnog neurona („kako radi“) zanemaruje i posmatra se samo funkcionalno ponašanje kolektiviteta („šta radi“). Stoga, za razmatranje funkcionalnih svojstava i neurodinamike sa

aspekta neurofiziologije možemo zaključiti da fokus treba staviti upravo na *bottom-up* modele dok *top-down* ostaju više vezani za bihevioralno modelovanje koje smo svrstali u neuropsihološki domen (što će biti razmatrano u narednoj sekciji).

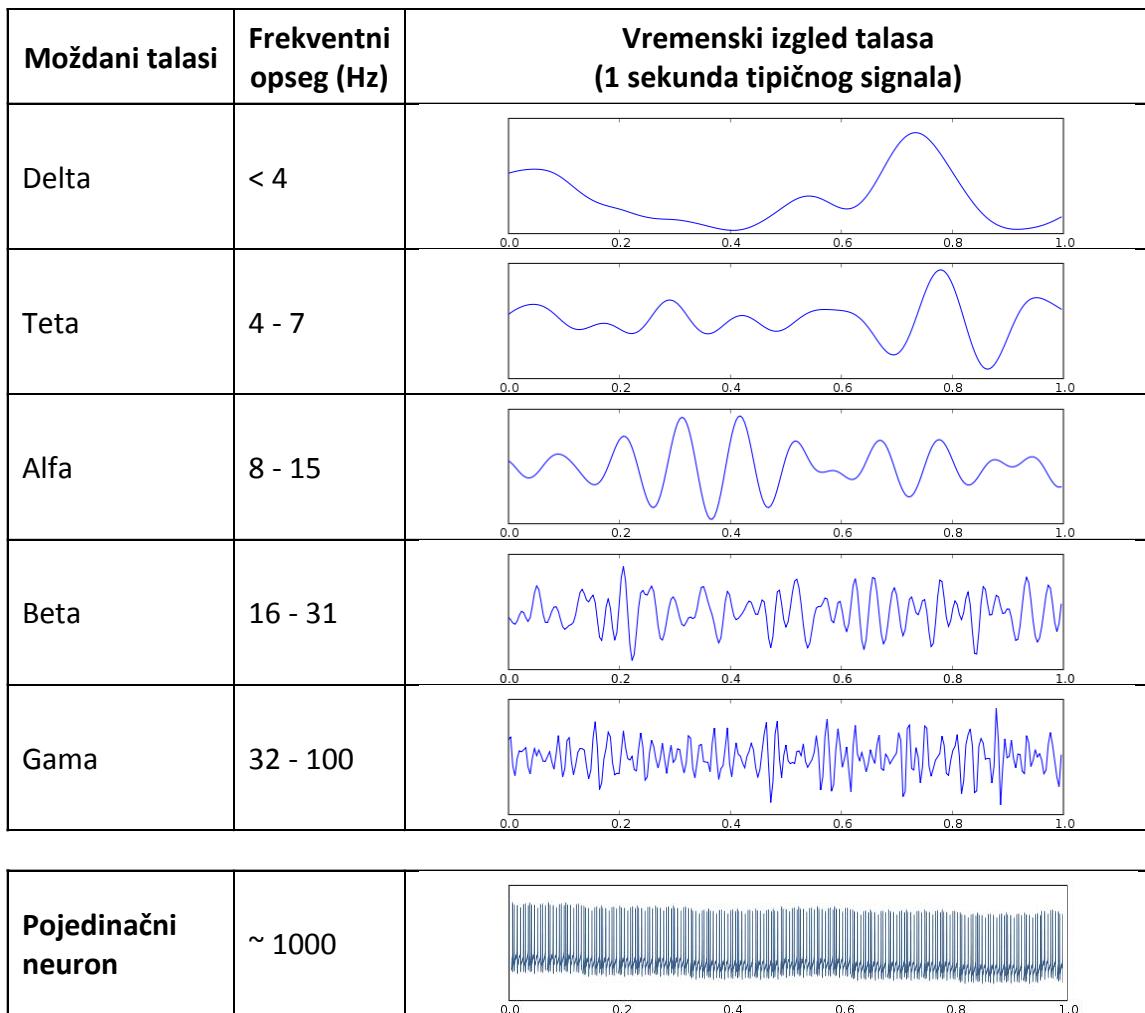
Imajući u vidu napred iznete argumente za fokusiranje posmatranja neurofizioloških odnosno neurodinamičkih modela na *bottom-up* modele, sada je moguće analizirati i identifikovati bitne karakteristike tih modela koje upravo određuju bitne funkcionalne i dinamičke karakteristike kako bioloških tako i veštačkih neurokognitivnih sistema:

Modularnost: U sekciji 2.1.2 definisani su opšte odlike modularnih struktura dok je u sekciji 3.2 dat pregled savremenih pogleda na modularnost u biološkim neurokognitivnim strukturama. U sekciji 4.2 je već naglašeno da modularnost obuhvata i strukturalne i funkcionalne karakteristike pa u ovom kontekstu posmatramo samo bitne odlike koje su vezane za funkcionalna svojstva zajednička i biološkim i veštačkim sistemima:

- *Funkcionalna specijalizacija* podrazumeva da moduli imaju prepoznatljivu funkciju odnosno ulogu u sistemu bez obzira da li se radi o fizičkim (napon, struja) ili logičkim / informatičkim (učestanost okidanja) veličinama kojima se formuliše matematički model koji definiše funkcionalnost („sta radi“).
- *Informaciona enkapsulacija* je odlika sistema da imaju sopstveno, interno, dinamičko stanje odnosno „memoriju“. Dinamičko stanje, slično kao i kod funkcionalne specijalizacije, može biti fizičko ili logičko (informatičko).

Dinamika: Prostorno-vremenska neurodinamika, kako je to objašnjeno u sekciji 3.3, je prepoznata kao suštinski bitno svojstvo neurokognitivnih struktura u funkcionalnom smislu a posebno sa spekta veze sa naprednim kognitivnim funkcijama viših nivoa svesti. Iako, kako je već naglašeno, dinamika može biti razmatrana na nižem (*bottom-up*) ili višem (*top-down*) apstrakcionom nivou, u ovom kontekstu se posmatraju ključne osobine i karakteristike *bottom-up* modela a posebno sa spekta pojedinačnog neurona i njegovog lokalnog prostorno-vremenskog okruženja. Meta-analiza poznatih modela iznvedena u sekciji 3.3.1, uključujući i fizičke (fiziološke) i komputacione (informacione) modele bioloških neurona omogućava da se identifikuju ključne zajedničke karakteristike:

- *Stacionarnost (vremenska invarijantnost)*, koja u ovom kontekstu podrazumeva da nijedan od parametara modela odnosno jednačina stanja ne zavisi od vremena, je konzistentno prisutna u svim poznatim modelima biološkog neurona, bez obzira na stepen složenosti modela (uključujući i HH model koji se smatra najkvalitetnijim poznatim). Ipak, treba imati u vidu da je stacionarnost prepostavljena u svim ovim modelima upravo zato što se u *bottom-up* modelovanju apstrahuju vremenski uticaji promena parametara sistema, što npr. kod *top-down* modela je upravo suprotno (jer se posmatraju i vremenske promene u parametrima sistema, kao što su npr. promene u sinaptičkim vezama koje nastaju kao posledice neuroplastičnosti odnosno procesa učenja, prilagođenja eksternim uticajima i drugih viših kognitivnih procesa koji se na nivou *bottom-up* modela zanemaruju). Inače, a to je dokazano mnogim eksperimentalnim neurofiziološkim istraživanjima, ovakve prepostavke su potpuno opravdane jer je neurodinamika pojedinačnog neurona daleko brža od dinamike kognitivnih procesa u kolektivitetima neuronskih struktura viših nivoa mozga (Slika 23).



Slika 23: Frekventni opsezi moždanih talasa i pojedinačnog neurona (na osnovu <http://en.wikipedia.org/wiki/Electroencephalography>)

- *Linearost* koja se može primeniti na formulisanje matematičkog modela odnosno sistema jednačina stanja uz opravdane prepostavke. Iako se ovakav stav može osporavati, mnogi *bottom-up* modeli neurona upavo polaze od ove prepostavke kao preduslova za efikasno matematičko opisivanje i primenu matematičkih i drugih inženjerskih alata i metoda u analizi i razmatranju modela (npr. upravo najčešće primenjivani LIF model je linearan). Treba naglasiti da pod linearnošću ne mora da se podrazumeva potpuna linearost, jer npr. i sam LIF model ili drugi izvedeni modeli koji se sreću u literaturi (poput komputacionog FR modela, sekcija 3.3.1.1) dozvoljavaju nelinearost u određenim segmentima, poput prenosnih ili aktivacionih funkcija i sl. Dakle, pod linearnošću u ovom kontekstu

možemo smatrati ne formalnu, matematičku definiciju linearnosti u modelu jednačina stanja, već neformalnu linearnost koja se vezuje za mogućnost da se model stanja može u velikoj meri linearizovati, svesti na sistem linearnih diferencijalnih jednačina ili u srodnom smislu dovesti u formu blisku linearnej (ovo svojstvo će posebno biti od značaja u analogiji dinamičkih modela nekih klasa bioloških i veštačkih neurosistema, što će biti detaljnije razmatrano u narednom poglavlju).

- *Stabilnost (konvergentnost)* je veoma važna osobina u mnogim dinamičkim sistemima a posebno je interesantna u kontekstu neurodinamike. Dok u mnogim inženjerskim sistemima je obezbeđenje stabilnosti sistema odnosno konvergentnosti stabilnim stanjima od ključne važnosti za funkcionalnu primenjivost, dotle je u biološkim sistemima globalna nestabilnost inherentna kognitivnim procesima odnosno stabilnost je upravo suprotna poželjnim i uobičajenim kognitivnim bihevioralnim svojstvima (normalna funkcija mozga podrazumeva upravo neurodinamičku nestabilnost odnosno postojanje raznih klasa moždanih talasa na svim nivoima pa i na nivou pojedinačnog neurona). Dakle, kada govorimo o stabilnosti u smislu biološke neurodinamike podrazumevamo ne globalnu (jer je biološki neurosistem jasno globalno nestabilan) već lokalnu stabilnost. N ulazeći u formalnu matematičku definiciju, lokalna stabilnost podrazumeva konvergenciju dinamičkog sistema, u ovom kontekstu pojedinačnog neruona, ka stabilnom stanju u kratkom vremenskom periodu u kojem se zanemaruju svi spoljni uticaji, uključujući i varijacije eksitacija (internih ili eksternih, što se još referiše i kao autonomija sistema). Dakle, upravo u skladu sa ranije naznačenim pretpostavkama *bottom-up* modela (gde se prepostavlja stacionarnost i linearnost) možemo smatrati da se pod stabilnošću (lokalnom u prostornom i vremenskom domenu) podrazumeva da sistem, pojedinačni neuron ili kolektivitet, ponaša stabilno odnosno da njegovo stanje konvergira stabilnom stanju u periodu vremena koje je dovoljno malo u odnosu na brzine (vremenske konstante) promene eksitacija i/ili drugih parametara dinamike sistema. Iako ovakva definicija stabilnosti nije formalno, sa aspekta ove teze odnosno analize sličnosti i analogije dinamičkih modela

smatramo da je ona prihvatljiva kao osnova za dalju matematičku i biheviralnu analizu (što će i biti izvedeno u narednom poglavlju).

Funkcionalnost: Funkcionalnost sistema je kompleksna osobina koja se može dovesti u vezu sa upotrebljivošću i svrshishodnošću odnosno sa kvalitetom, načinom i osobinama kojima sistem vrši određenu (korisnu) ulogu. U kontekstu neurokognitivnih sistema, funkcionalnost se može posmatrati usko, na nivou pojedinačnog neurona ili opšte, na nivou celog mozga ili pak moždanih struktura (koje imaju prepoznatljive uloge odnosno funkcionalnosti). Upravo nivo apstrakcije funkcionalnosti određuje i nivo modela koji se primenjuje (*bottom-up* modeli se fokusiraju na funkcionalnost pojedinačnog neurona dok *top-down* modeli posmatraju šire kolektivite odnosno moždane strukture). Analizom i razmatranjem strukture tih modela moguće je napraviti i funkcionalnu diferencijaciju iz koje proističu bitne odlike koje definišu funkcionalnost ne samo pojedinih modela već prevashodno neurokognitivnih struktura koje se modeluju odnosno posmatraju i čija funkcionalnosti su od interesa da se odrede. Kako je ranije naglašeno, dok *bottom-up* modeli govore „kako“ neurokognitivne strukture funkcionišu, odakle izvire njihova funkcionalnost, dotle *top-down* i bihevioralni modeli prvenstveno opisuju „šta“ određene neurokognitivne strukture ili delovi mozga rade. Veza između „kako“ i „šta“ je upravo ključno pitanje i karakterizacija funkcionalnosti, odlike koje su bitne za određene funkcionalnosti, je prepoznata kao važan aspekt u gotovo svim istraživanjima (sekcija 3.3.1.1).

- *Informaciono enkodiranje (logička reprezentacija)* je odlika koja je esencijalno bitna za uspostavljanje logičke veze između fizičkih procesa i veličina koje se modeluju na *bottom-up* nivou i logičkih, inteligentnih procesa obrade koji se podrazumevaju u bihevioralnom smislu kada se razmatra kognitivna funkcionalnost na *top-down* nivou. Dakle, kao što je u sekciji 3.3.1.1 to opisano, informacioni modeli predstavljaju vezu između fizičkih modela i dinamike sistema u terminima fizičkih / fizioloških veličina (poput sinaptičke ili intracelularne eksitacione struje, napona membrane ili aktivacionog potencijala neurona itd.), i logičkih odnosno informacionih veličina koje se posmatraju¹⁶ i

¹⁶ Npr. poput aktivnosti delova mozga putem detekcije moždanih talasa koji se mere EEG-om odnosno elektromagnetnom indukcijom a koja je posredna odnosno izvedena veličina iz osnovnih fizioloških veličina koje se posmatraju na niskom nivou pojedinačnog neurona (posledica električne struje i aktivacionih impulsa

interpretiraju na višim nivoima neurokognitivnih struktura. U tom smislu, pod enkodiranjem se podrazumeva da se sistem može modelovati prenosnim odnosno izvedenim veličinama, informacionim modelima u kojima se umesto fizičkih veličina i njihove dinamika („kako“ radi) posmatraju funkcionalne veličine odnosno veličine koje interpretiraju ili odslikavaju funkcionalnost sistema („šta“ radi). Informacija je ovde apstraktna ili pak izvedena (posredna) fizička veličina koja nam govori (nosi informaciju) o korisnoj ulozi odnosno funkciji koju neuron ili kolektivitet vrši. Tako, model učestanosti okidanja neurona (FR model izložen u sekciji 3.3.1.1) predstavlja prvu kariku u lancu tranzicije sa posmatranja fiziološke dinamike pojedinačnog neurona ka razmatranju odnosno sagledavanju njegove funkcionalne uloge u ukupnom kognitivnom procesu.

- *Komputacija* je prepoznata kao jedna od esencijalnih odlika neurokognitivnih sistema i već je naglašeno da postoji čitava oblast (komputaciona teorija, sekcija 3.2) koja se bavi izučavanjem uloge i modeliranju neurokognitivnih struktura sa komputacionog aspekta. U sekciji 3.3.1.1 je objašnjeno da su komputaciona svojstva, dakle funkcionalno opisivanje uloge neurona i njihovih kolektiviteta u logičkom odnosno informacionom smislu, postala značajna upravo jer se preko njih može dovesti u vezu fizička (biofiziološka) neurodinamika sa kognitivnim procesima koje može opisati na matematičko-logičkom nivou razumevanja. Drugim rečima, komputacija je odlika neurona ili neurostrukture (kolektiviteta) da vrši neke procese koji se u matematičkom smislu mogu prevesti (modelirati) logičkim i/ili aritmetičkim funkcijama odnosno transformacijama ulaznih u izlazne veličine stanja sistema (komputacione prenosne funkcije). Primeri takvih komputacionih funkcija mogu biti od osnovnih logičkih ili aritmetičkih operacija (sabiranje, oduzimanje, množenje, logičke operacije I/ILI i sl.), preko operacija koje su već svojstvene i nekognitivnim dinamičkim sistemima (diferenciranje, integraljenje) pa do složenih matematičkih operacija i čitavih algoritama koje po svojoj kompleksnosti spadaju u domen onoga što se mogu smatrati „inteligentne“ obrade informacija odnosno napredna kognitivna funkcionalnost (poput rešavanja

pojedinačnih neurona). Dakle, pod informacionim veličinama podrazumevamo indirektne interpretacije neurodinamike niskih nivoa posmatranjem procesa tj. ponašanja na visokim nivoima.

sistema jednačina, ili linearog programiranja što je pokazano upravo na primeru fraktalno-modularnih CNM opisanih u sekciji 2.4).

4.4 Bihevioralne karakteristike (neuropsihološke osobine)

U uvodnom delu ovog poglavlja je već naglašeno da neuropsihologija objedinjuje posmatranje i vezu strukturalnih (neuroanatomskih) i funkcionalnih (neurofizioloških) aspekata neurosistema na formiranje kognitivnih procesa. Takvi procesi, na višim nivoima svesti, još uvek su previše kompleksni za formalno matematičko modelovanje¹⁷ i stoga se uobičajeno koriste bihevioralne karakteristike za opisivanje i analizu ponašanja neurokognitivnih struktura i sistema. Kako je ovo veoma široka oblast, u kontekstu teme ove disertacije ograničićemo se na inženjerski aspekt odnosno bihevioralne karakteristike koje se mogu modelovati i dovesti u vezu sa prethodno izloženim organizacionim i neurodinamičkim osobinama bez ulazeњa u psihološke i druge biomedicinske aspekte.

Osnova bihevioralne karakterizacije u tom smislu se može se razmatrati na bazi *top-down* modela koji su izloženi u sekciji 3.3.2 kao i načelnim razmatranjima uloge i značaja modularnosti (kao organizacione forme) u biološkim neurokognitivnim sistemima što je izloženo u sekciji 3.2.

Neurodinamika: Već je naglašeno da je i teoretski i eksperimentalno potvrđeno da postoji tesna veza strukturalnih karakteristika (modularnost, fraktnost) bioloških neurokognitivnih struktura na svim nivoima (od celine ljudskog mozga pa do ćelijskog neuroanatomskog nivoa) sa energetskim dinamikama koje se odvijaju unutar i između ovih struktura. Pod energetskom dinamikom se podrazumeva upravo „slika“ odnosno mreljiva fiziološka reprezentacija kognitivnih procesa koji se odvijaju unutar neurostruktura, bez obzira da li se radi o elektromagnetnim talasima koji se snimaju EEG tehnologijama ili pak drugim fizičkim veličinama (biohemijske koncentracije i sl.) koji se mogu dovesti u vezu sa kognitivnim aktivnostima pojedinih neurostruktura. Takva energetska dinamika, kako je objašnjeno u sekciji 3.3.2, može se objasniti *top-down* modelima (odnosno simulacija tih modela upravo daje rezultate koji imaju bihevioralne karakteristike koje koreliraju sa ponašanjem bioloških

¹⁷ Izuzetak je možda u topološkom odnosno organizacionom domenu, gde je napredak neuroimaging tehnologija umogućio precizno formiranje “mape” mozga i posmatranje veze fizioloških i psiholoških procesa u prostorno-vremenskom domenu velike preciznosti i pouzdanosti.

struktura) ali oni ne daju i jasan odgovor zašto ta dinamika nastaje odnosno u funkcionalnom smislu šta je pozadina tih procesa („kako radi“). Upravo sličnost veštačkih struktura, koje imaju slična neurodinamička ponašanja u smislu prostorno-vremenske energetske dinamike i drugih karakterističnih bihevioralnih osobina (ponašanja), a koje imaju poznatu kognitivnu funkcionalnost koja se može i matematički modelovati, stvara prostor da se povežu ta dva nivoa apstrakcije odnosno da se stvore novi kombinovani modeli koji bi se zatim mogli eksperimentalno testirati i pomoći u procesu inverznog inženjeringu u proučavanju bioloških sistema. Dakle, sličnost neurodinamike može da posluži kao vodilja ili „otisak prsta“ za prepoznavanje analognih veštačkih struktura koje mogu imati funkcionalnu odnosno kognitivnu sličnost sa biološkim sistemima, a samim tim i omogućiti da se stvore novi funkcionalno-logički odnosno informaciono-procesni modeli koji bi povezali *bottom-up* (koji su prvenstveno funkcionalni) i *top-down* (koji su prvenstveno bihevioralni) modele. U tom cilju izdvojićemo neke ključne odlike koje su prepoznate i u biološkim i u veštačkim, poesbno fraktalno-modularnim, sistemima a koje određuju prepoznatljiv „otisak prsta“ bihevioralne neurodinamike:

- *Funkcionalna (komputaciona) energija* se može definisati kao odlika sistema da kroz eneretsku dinamiku odslikava neku naprednu funkcionalnu ulogu odnosno da se energetska dinamika (stvarne fizičke energije ili generalisane informacione ili „logičke“ što će biti razmatrano u narednim poglavljima) može matematički vezati za funkciju sistema. Ova odlika je na neki način generalizacija odnosno dizanje na viši apstraktni nivo komputacionog svojstva koje je u prethodnoj sekciji identifikovano kao jedna od ključnih odlika na funkcionalnom nivou. Dok se komputacija odnosi na funkcionalnost pojedinačnog neurona ili pak posmatranja funkcije kolektiviteta („šta radi“), dotle funkcionalna energija odslikava ponašanje odnosno daje „sliku“ „kako radi“ posmatrani neurokognitivni sistem. Tako, npr. u veštačkim CNM gde je model stanja definisan preko potencijala čelijskih kondenzatora (sekcija 9.1.2, jednačine stanja (27)) možemo „snimiti“ sliku energetskih potencijala čelijskih kondenzatora u npr. uobičajenoj 2D topologiji mreže i dobiti vizuelnu reprezentaciju ponašanja mreže tokom rada (obzirom da je energija kondenzatora direktno srazmerna kvadratu potencijala). Analogno, funkcionalne neuroimaging tehnologije snimaju aktivnosti odnosno

prostorno-vremensku dinamiku u biološkim neurokognitivnim strukturama upravo preko posrednih, energetskih, veličina (bilo da su npr. elektromagnetni talasi, koji nose energiju, ili pak biohemijске koncentracije npr. kalcijuma koji takođe ima hemijski energetski potencijal i sl.). Kako je to već objašnjeno u meta-analizi savremenih istraživanja (sekcija 3.3) bliskost simuliranog odziva i realnog biološkog signala se upravo koristi kao metoda evalucije kvaliteta mnogih veštačkih *bottom-up* modela neurona. Dakle, dignuto na viši apstraktni nivo i posmatranje kolektiviteta odnosno *top-down* modela, sličnost energetske dinamike odnosno „snimaka“ na višim nivoima se može smatrati indikacijom funkcionalne bliskosti bioloških i veštačkih kognitivnih struktura¹⁸.

- *Neurooscilacije* odnosno inherentno oscilatorno ponašanje su prepoznati u više *top-down* modela kao jedna od ključnih bihevioralnih odlika upravo jer biološki neurokognitivni sistemi ispoljavaju masovno oslicatorno ponašanje u mnogim kognitivnim domenima. Poznato je da su socalacije prisutne na gotovo svim nivoima neurofizioloških procesa, od pojedinačnog neurona koji upravo ima „oscilatornu“ aktivaciju odnosno generiše povorke aktivacionih impulsa dok se na višim nivoima identifikuju moždani talasi u jasno definisanim frekventnim opsezima (što opet ima „oscilatori“ karakter). Oscilatorno ponašanje na bihevioralnom nivou ne treba dovoditi u koliziju sa napred identifikovanim osobinama (lokalne) stabilnosti i konvergentnosti pojedinačnog neurona ili kolektiviteta u funkcionalnom smislu. Kao što je u prethodnoj sekciji i objašnjeno, zavisno od vremenske ili prostorne lokalizacije, stabilan sistem „u malom“ (u „malim“ vremenskim ili prostornim okvirima u odnosu na promene eksternih eksitacija i/ili druge promene parametara sistema, kada se može smatrati da su ti eksterni uticaji invarijantni na parametre sistema) može biti oscilatoran „u velikom“ domenu (kada se posmatraju i uticaji eksternih eksitacija i/ili neuroplastičnih promena koje mogu imati oscilatori karakter), što je upravo slučaj u realnim biološkim sistemima. U sekciji 3.3.2 je posebno iznet primer Pasemann-ovog oscilatornog „neruomodularnog“ modela a takođe treba napomenuti da, kako

¹⁸ U formalnom smislu, ako dva sistema imaju isti odziv oni se u funkcionalnom smislu mogu smatrati ekvivalentnim.

je izloženo, i drugi *top-down* modeli imaju odnosno potenciraju oscilatorna svojstva kao jednu od najbitnijih karakteristika koje ih kandiduju za bliskost sa biološkim neurokognitivnim sistemima.

- *Talasi*, iako se laički mogu podvesti ili zameniti za oscilacije, se odnose u širem smislu na prostorno-vremensku dinamiku koja ne mora obavezno biti oscilatorna (dakle ne mora postojati vremensko ponavljanje amplituda) već se može tumačiti i u smislu postojanja fenomena prostiranja energije ili drugih fizičkih ili logičkih (informacionih) veličina modela stanja sistema u vremenu i prostoru (u vizuelnom smislu, prostorno ili vremenski se mogu zapažati „talasi“ kao npr. u slučaju CNM za predikciju kretanja, Slika 4). U sekciji 2.4 je naznačeno da je postojanje „auto-talasa“ odnosno energetske propagacije koja vizuelno ima talasne oblike jedna od odlika određenih klasa CNM koje su prepoznali mnogi autori i ovo bihevioralno svojstvo je dovedeno upravo u vezu sa oscilatornim odlikama dvo-ćelijskih CNM. U biološkim neurosistemima, postojanje talasa odnosno prostorno-vremenske propagacije je prepoznato i potvrđeno na gotovo svim nivoima neurostruktura.

Modularnost: Iako se modularnost, kako je to objašnjeno u sekciji 2.1.2, može posmatrati na različitim nivoima apstrakcije (videli smo u prethodnim sekcijama da se ona ističe i u neuroanatomskom i na funkcionalnom domenu posmatranja), u sekciji 3.2 je posebno istaknut njen značaj sa aspekta razmatranja neuropsiholoških procesa odnosno bihevioralne karakterizacije neurostruktura na višim nivoima svesti. Ovde je još jednom važno naglasiti, kako je to izneo Fodor, da „postoji širok prostor u kojem nije naučno objašnjena veza i mehanizmi kojima modularne strukture ispunjavaju funkcionalne zahteve kognitivnih procesa posebno u kontekstu komputacione teorije svesti“. Dakle, modularnost je prepoznata kao nespora karakteristika bioloških neurokognitivnih struktura i na najvišem nivou svesti (mozga u celini) i dovedena je u vezu sa složenim bihevioralnim karakteristikama procesa koji se odvijaju na tim nivoima (psihologija). U sekciji 2.1.2, u definiciji pojma modularnosti, tako možemo prepoznati bitne odlike koje su vezane za upravo ove aspekte koji imaju vezu sa bihevioralnim karakteristikama mimo već ranije identifikovanih odlika koje smo doveli u vezu sa drugim domenima analogije (strukturalne i funkcionalne odlike):

- *Urođeno svojstvo* podrazumeva da na najvišim nivoima organizacije (strukture) bioloških kognitivnih sistema (mozga) jasno postoje definisani moduli odnosno podsistemi koji imaju predeterminisanu, urođenu (inherentnu), svrhu i/ili strukturu. Sa aspekta analogije sa veštačkim neurokognitivnim strukturama, možemo govoriti o mogućnosti da se napredni, inteligenčni procesi i obrade informacija mogu realizovati pomoću sistema sastavljenih od jasno funkcionalno i strukturalno različitih podsistema odnosno modula ili „slojeva“. Primetimo da baš neke klasične veštačke neuralne arhitekture, poput perceptron-a ili *back-propagation* (BP) mreža, imaju upravo odklon od ovog svojstva: u tim mrežama je arhitekturalno jasno da postoji više slojeva, poznato je i da od veličine slojeva zavisi funkcionalna sposobnost mreže da ispunjava određene zadatke ali uloga pojedinog od slojeva mreže nije jasno definisana već svi slojevi na neki način ravnopravno učestvuju u ukupnoj funkcionalnosti. Dakle, ovde se ne može govoriti o funkcionalnoj ili strukturalnoj podeli niti pak o urođenom svojstvu pojedinih slojeva sistema. Na drugoj strani, npr. kod fraktalno-modularnih mreža poput LP CNM ili SPF CNM opisanih u sekciji 2.4 jasno su determinisani segmenti, podmreže, koje imaju i prepoznatljivu strukturu i jasno određenu svrhu odnosno ulogu u ukupnom ponašanju sistema.
- *Evolutivno prilagođenje* ili evolutivna optimizacija strukture u odnosu na funkciju, podrazumeva da se sa bihevioralnog aspekta može dovesti u logičku vezu struktura u odnosu na funkcionalne zahteve. Pod tim se podrazumeva da se može objasniti ili čak modelovati npr. broj neurona i sinaptičkih veza u odnosu na aspekte povezane sa energetskom i informacionom odnosno komputacionom efikasnošću u određenoj strukturi koja ima definisano kognitivnu ulogu, i da se to prilagođenje, optimizacija, može objasniti genetskim i drugim biološkim procesima evolutivnog razvoja. U veštačkim sistemima se ova odlika može tumačiti kao mogućnost da se modularizacija odnosno integracija sistema može prilagođavati (povećavati ili smanjivati u

odnosu na dimenzije problema i potrebe tehnološke efikasnosti implementacije^{19).}

4.5 Rekapitulacija

U ovom poglavlju je uspostavljen metodološki model klasifikacije i karakterizacije bioloških neurokognitivnih sistema, sa apsekta sva tri domena koja se smatraju bitnim u neuronaukama: starukturanog (neuroanatomskog), funckionalnog (neurofiziološkog) i bhevioralnog (neuropsihološkog).

Za svaki od domen je, na osnovu ranije iznetih rezultata meta-analize važećih saznanja i stavova iz oblasti neuronauka, identifikovan skup ključnih karakteristika koje su detaljnije opisane odnosno određene konkretnim odlikama koje se smatraju da su bitne za karakterizaciju kako bioloških tako i veštačkih neurosistema.

Na primeru strukturalnih karakteristika, definisan je novi model analogije koji se bazira na (neformalnoj) logičkoj korelacji (određenju stepena sličnosti) po svim odlikama za sve ključne karakteristike i pokazano je da takav model na adekvatan način pokazuje visok stepen analogije odnosno korelacije (sličnosti) strukturalnih karakteristika (topologije, modularnosti i fraktalnosti) bioloških neurostruktura i fraktalno-modularnih celularnih neuralnih mreža.

¹⁹ Poznati problem VLSI implementacije gde je neophodno isuniti tehnološki balans stepena integracije, energetske efikasnosti i izvodljivosti eksternih veza odnosno pinova na čipu.

5 Analogije na nižim nivoima kognitivnih procesa (sličnost funkcionalnih modela nekih klasa fraktalno-modularnih CNM sa identifikovanim biološkim strukturama)

U prethodnom poglavlju su identifikovane bitne ključne karakteristike bioloških neurokognitivnih sistema, u strukturalnom, funkcionalnom i behavioralnom domenu, i pokazano je da na strukturalnom nivou postoji visoka analogija (sličnost u odnosu na ključne karakteristike i osobine) sa fraktalno-modularnim CNM (sekcija 4.2.1). U ovom poglavlju će biti pokazano da i na funkcionalnom nivou može biti izведен novi model analogije fraktalno-modularnih CNM sa biološkim neurostrukturama, upravo kroz korelaciju identifikovanih ključnih osobina funkcionalnih modela biološkog neurona i ćelije odnosno baznog modula fraktalno-modularnih CNM.

5.1 Model funkcionalne analogije bioloških neurokognitivnih sistema i fraktalnom-modularnih CNM

U sekciji 4.3 identifikovane su ključne funkcionalne odnosno dinamičke osobine koje se mogu smatrati zejdničkim i u biološkim i u veštačkim neurokognitivnim sistemima. Polazeći od istih premeta kao i u formulisanju modela strukturalne analogije (4.2.1), možemo izvesti jedan neformalno-logički model funkcionalne analogije koji je predstavljen u sledećoj tabeli:

Tabela 4: Model funkcionalne analogije bioloških neurokognitivnih sistema i veštačkih fraktalno-modularnih CNM

Karakteristika / Odlika	Biološki neurokognitivni sistemi	Veštačke fraktalno-modularne CNM	Korelacija
Modularnost			VISOKA
Funkcionalna specijalizacija	Rasprostranjena na svim nivoima	Inherentna (po definiciji fraktalne modularnosti, modul ima funkcionalnu specijalizaciju odnosno jasno definisanu ulogu saglasno problemu koji mreža rešava)	VISOKA
Informaciona enkapsulacija	Inherentna (biološki neuron poseduje interno dinamičko stanje - potencijal membrane kod fizičkih modela)	Inherentna (potencijal kondenzatora ćelije)	VISOKA
Dinamika			VISOKA
Stacionarnost (vremenska invarijantnost)	Po definiciji (za <i>bottom-up</i> modele)	Inherentna (za posmatrane klase fraktalno-modularnih CNM)	VISOKA
Linearost	Visoko rasprostranjena (najveći broj modela podrazumeva linearost parametara modela, sinaptičkih veza kao i rad neurona u linearnom režimu prenosne aktivacione funkcije)	Inherentna (za posmatrane klase fraktalno-modularnih CNM, uz isto ograničenje kao i kod bioloških modela da se podrazumeva rad u linearnom režimu)	VISOKA*
Stabilnost (konvergentnost)	Uglavnom podrazumevana (svi poznati modeli polaze od pretpostavke da je sistem lokalno stabilan)	Inherentna (stabilnost u fraktalno-modularnim CNM je garantnovana metodom fraktalne modularizacije koja upravo polazi od funkcije Ljapunova koja garantuje lokalnu stabilnost i samim	VISOKA

		tim je i sintetisana mreža stabilna)	
Funkcionalnost			VISOKA
Informaciono enkodiranje (logička reprezentacija)	Inherentna (u informacionim odnosno komputacionim modelima, koje su i osnova ovog modela analogije)	Inherentno (direktno ako se čelijski napon tretira kao informacija, što je slučaj u većini primen, ili pak preko energije ako se želi potpuna generalizacija modela)	VISOKA*
Komputacija	Rasprostranjena (na gotovo svim kognitivnim nivoima, osim na najnižim senzorskim strukturama gde je diskutabilno da li se radi o komputacionim svojstvima ili pak samo o pripremnoj obradi signala i informacionom enkodiranju)	Inherentna (komputacija je direktno vezana za problem koji se rešava – fraktalno-modularne CNM se sintetišu da bi rešavale konkretni kognitivni problem što se upravo postiže komputacijom)	VISOKA
UKUPNA KORELACIJA (ANALOGIJA)			VISOKA

* *Naznačene osobine će biti diskutovane u nastavku, gde će biti detaljno objašnjeno pod kojim uslovima se može smatrati da model visoke korelacije važi.*

Kao što se iz ovog modela vidi, dve osobine (linearnost i informaciono enkodiranje) zahtevaju da se detaljnije razmotre uslovi pod kojima izvedeni model važi, odnosno uslovi pod kojima se može smatrati da postoji visoka korelacija ovih odlika u modelima koji se posmatraju za biološke i veštacke sisteme (konkretno fraktalno-modularne CNM).

Metodološki, najegzaktniji način da se pokaže bliskost odnosno analogija ovih odlika je preko respektivnih matematičkih modela.

Dakle, prvi korak je izbor respektivnih modela biološkog odnosno veštackog neurokognitivnog sistema koji se posmatra. U sekciji 4.3, gde su izvedene i identifikovane ključne karakteristike modela, naznačeno je da se model primenjuje u funkcionalnom (neurofiziološkom) domenu odnosno da se modelovanje posmatra prvenstveno u domenu *bottom-up* modela bioloških neurona opisanih u sekciji 3.3.1. Dakle, u biološkom domenu na

raspolaganju imamo niz modela koje možemo primeniti ili odabrati kao osnovu modela analogije i postavlja se pitanje koji kriterijum treba primeniti da bi se izabrao referentni model za dalje razmatranje. Imajući u vidu da izabrani model mora biti kompatibilan sa postavljenim opštim modelom funkcionalne analogije (Tabela 4) odnosno da model treba da zadovolji postavljene kriterijume (modularnost, dinamiku i funkcionalnost). Tako, fizički modeli (koji posmatraju fizičke odnosno fiziološke a ne informacione veličine) nisu pogodni jer inherentno ne zadovoljavaju kriterijume funkcionalnosti (odnosno nemaju definisanu funkcionalnost u informacionom tj. komputacionom smislu, kako je to objašnjeno u sekciji 3.3.1.1). Konačno, imajući sve ovo u vidu, možemo zaključiti da je informacioni model, konkretno model učestanosti okidanja (FR model) pogodan kao referentni model biološkog neurona odnosno bioloških neurokognitivnih struktura u opštem smislu, posmatrano u kontekstu napred izloženog modela analogije sa fraktalno-modularnim CNM (Tabela 4).

5.2 Homogenizacija modela (informaciono enkodiranje)

Ovakav izbor referentnog biološkog modela povlači pitanje korelacije sa dinamičkim modelom frakタルno-modularnih CNM, odnosno pitanje respektivnih varijabli modela stanja. Osnovni dinamički model CNM pa i frakタルno-modularne CNM, kako je izloženo u sekcijama 9.1 i 9.2, baziraju se na varijablama modela stanja koje imaju fizičku prirodu (napon kondenzatora ćelije, ulazne i izlazne struje i naponi). Međutim, u primenama CNM uključujući i izvorne rade Chua i Yang [20], najčešće se te fizičke veličine interpretiraju kao informacije (nivo osvetljaja piksela u slici ili druge informatičke veličine). Dakle, iako se sam model zasniva na fizičkim veličinama (i sama realizacija se modeluje kao konduktansno električno kolo) funkcionalna interpretacija rada CNM se svodi na prevodenje fizičke veličine u logičku odnosno informacionu. Primetimo da sličan pristup postoji i u FR modelu biološkog neurona: biološki neuron se prvo modeluje fizičkim modelima (čak upravo konduktansnim električnim modelima, poput Hodgkin–Huxley modela, Slika 15) koji se zatim prevode u informacioni (komputacioni) model, poput FR modela, upravo pogodnom transformacijom fizičkih u informacione veličine (napona membrane u učestanost okidanja). Dakle, ako uspostavimo dodatnu logičku relaciju (preslikavanje, interpretaciju, enkodiranje) između napona ćelije CNM i apstraktne informacione veličine koja korelira sa učestanošću okidanja FR modela biološkog neurona, dolazimo do saglasnih (kompatibilnih) prostora stanja (vrste odnosno prirode varijabli dinamičkog modela tj. jednačina stanja) koji se sada

mogu matematički korelirati odnosno poređiti i dokazivati njihova sličnost. Ovakav metodološki model analogije odnosno dovođenja u uporedivu korelaciju bioloških i modela veštačkih fraktalno-modularnih CNM je prikazan u sledećoj tabeli:

Tabela 5: Homogenizacija odnosno preslikavanje bioloških i modela veštačkih fraktalno-modularnih CNM

	Biološki neuron	CNM ćelija
Izvor	Realan, biološki	Apstraktni, logički
Fizički model	Električni (konduktansni)	Električni (konduktansni)
Fizičko stanje	Napon membrane (kondenzatora)	Napon ćelije (kondenzatora)
Dinamički model	LIF, HH... sistem jednačina stanja	FM CNM sistem jednačina stanja, (27)
Informaciona transformacija	informacija = učestanost okidanja	informacija = napon ćelije (ili izlaza)
Logički (informacioni) model	FR model (gde se učestanost okidanja tumači kao informacija)	FM CNM sistem jednačina stanja (gde se napon tumači kao informacija)

Dakle, pogodnim usvajanjem apstrakcije „napona“ kao enkodirane informacije ćelije u dinamičkom modelu fraktalno-modularne CNM, moguće je uspostaviti potpunu korelaciju odnosno analogiju dinamičkih informacionih modela biološkog i veštačkog fraktalno-modularnog neurokognitivnog sistema (jer se uspostavlja identičan prostor stanja baziran na informacionim veličinama).

Usklađivanjem varijabli odnosno prostora stanja biološkog modela i modela veštačkih fraktalno-modularnih CNM moguće je sada izvesti matematičku analizu i poređenjem modela izvesti uslove ekvivalencije odnosno ograničenja pod kojima se modeli mogu smatrati bliskim (u smislu kriterijuma postavljenih u modelu funkcionalne analogije, Tabela 4).

Saglasno napred iznetom, sada možemo matematičke formulacije FR modela biološkog neurona (9) i „informatički“ model fraktalno-modularne CNM ćelije (27) predstaviti na homogenizovan način:

Biološki (FR) model:

$$\tau \frac{dv_i}{dt} = -v_i + f \left(\sum_j w_{ij} v_j \right) + I_{e1} \quad (14)$$

gde je:

- v informaciona varijabla stanja (učestanost okidanja neurona),
- $f(\cdot)$ prenosna funkcija aktivacije neurona (uobičajeno sigmoidalna),
- w_{ij} težinski koeficijent veze neurona sa svojim sinaptičkim sisedima i
- I_{e1} ekvivalentna eksitacija (koja zamenjuje sve interne ili eksterne).

Veštački (FM CNM) model:

$$\tau \frac{dv_i}{dt} = -v_i + \sum_j w_{ij} u_j + I_{e2}, \quad u_j = \lambda(v_j) \quad (15)$$

gde je:

- v informaciona varijabla stanja (napon ćelije),
- $\lambda(\cdot)$ izlazna (prenosna) funkcija ćelije (uobičajeno sigmoidalna ili deo-po-deo linearna),
- w_{ij} težinski koeficijent veze neurona sa svojim sinaptičkim sisedima (šablon A) i
- I_{e2} ekvivalentna eksitacija (koja zamenjuje sve interne ili eksterne - šablon B).

Poređenjem relacija (14) i (15) lako se zapaža da je oblik i struktura dinamičkih modela veoma slična a ključna razlika je u nelinearnoj prenosnoj funkciji koja kod biološkog neurona operiše nad celokupnom sumom sinaptičkih ulaza (pobuda) dok je kod veštačke CNM ćelije u stvari nelinearnost primenjena na same izlaze ćelija.

Imajući ovo u vidu, sada možemo formulisati uslov ekvivalencije ovih modela odnosno uslov pod kojem će prostorno-vremenska dinamika (vrednosti varijabli stanja v) biti identična u oba modela:

$$f \left(\sum_j w_{ij} v_j \right) = \sum_j w_{ij} \lambda(v_j) + \Delta I_e, \quad \Delta I_e = I_{e2} - I_{e1} \quad (16)$$

Dakle, ukoliko je ispunjen uslov ekvivalencije (16), dinamički modeli biološkog neurona i veštačke fraktalno-modularnog CNM ćelije su identični te će i rezultujuća dinamika odnosno funkcionalno ponašanje sistema biti identično.

Formalno matematički posmatrano, zavisno od prirode funkcija $f(\cdot)$ i $\lambda(\cdot)$ mogu se formulisati različiti partikularni uslovi odnosno aproksimacije i druge metode ili vrste matematičkih transformacija koje mogu u manjoj ili većoj meri obezbediti ispunjenje uslova ekvivalencije (16). U nastavku će biti pokazan jedan mogući model aproksimacije (linearizacija u režimu malih signala) koji se smatra da je neurofiziološki opravdan u uobičajenim uslovima koritkalne aktivnosti.

5.3 Linearizacija (aproksimacija u režimu malih signala)

Aproksimacija u režimu malih signala je veoma poznata metoda i široko primenjena u analizi i sintezi raznih vrsta elektronskih kola, gde se upravo sreću nelinearni prenosni i posebno i aktivni elementi (tranzistori i diode). Načelna analogija sa napred razmatranim modelima bioloških ili veštačkih neurosistema, baziranih upravo na modelima električnih kola (a interesantno je naglasiti da se upravo svi ovi modeli i baziraju na električnim kolima kao osnovnom nivou apstrakcije), upućuju na opravdanost primene ove metode i u ovom kontekstu.

Napomena: I drugi autori su nedavno primenjivali analizu u režimu malih signala na aproksimaciju modela biološkog neurona. Tako, u sekciji 3.3.1 je već napomenuto da su Basu i Hasler 2012. publikovali rad [143] ali su oni analizu u režimu malih signala koristili za fizičko modelovanje (izvođenje novog aproksimativnog modela na osnovu Hodgkin–Huxley modela), čak specifično usko posmatrano pod-aktivaciono (*sub-threshold*) modelovanja internog stanja odnosno potencijala membrane neurona, a ne funkcionalno odnosno informaciono modelovanja kao što je ovde slučaj.

Analiza u režimu malih signala odnosno model u režimu malih signala, se zasniva na pretpostavci da je varijacija (promena) signala, vrednosti varijabli stanja sistema, mala u odnosu na samu vrednost signala odnosno vrednost variabile stanja sistema u periodu posmatranja.

Aproksimacija koja se izvodi za neliearne prenosne karakteristike u suštini se zasniva na razvoju Taylor-ovog reda signala $x = X + \Delta x$ (iako je ovo opšte poznata metoda, za detalje videti [181]):

$$f(x) = f(X + \Delta x) \approx f(X) + \Delta x \frac{df}{dx} |_{x=X} = F_X + f_X \quad (17)$$

gde je X tzv. „veliki“ signal (odnosno mirne radne tačke, kako se još naziva, obziroma da je to tačka u prostoru stanja u kojoj se sistem nalazi u uslovima kada nema varijacije signala odnosno u režimu konstantnih eksitacija tj. „mirnog“ signala), Δx „mali“ signal odnosno varijacija signala a $f(\cdot)$ nelinearnost koja se aproksimira uz pretpostavku da se viši članovi Taylor-ovog reda mogu zanemariti jer je varijacija signala bliska nuli ($\Delta x \approx 0$) te viši članovi reda postaju zanemarljivi u odnosu na prva dva člana Taylor-ovog reda.

Druga pretpostavka koju uvodimo je da svi posmatrani neuroni rade u linearnom režimu odnosno izvan saturacije prenosne aktivacione funkcije. Kako je već ranije navedeno (sekcija 3.3), opšte prihvaćen stav je da kortikalni neuroni normalno operišu izvan režima saturacije tj. u linearnom segmentu prenosne aktivacione funkcije ([182]). Ovaj stav je potkrepljen i brojnim eksperimentalnim studijama. Npr. Reich et al. [183] su ispitivali klastere (do 6 neurona) u vizuelnom koretsku primata (V1) i, po njihovim rečima, nisu nađeni dokazi saturacije u tim eksperimentima. Takođe, polazeći od ove pretpostavke, mnogi poznati modeli (uključujući u Willson-Cowan *top-down* model) prepostavljaju linearnu aproksimaciju prenosne aktivacione funkcije neurona ([184], strana 295, citat: „...cortical neurons **usually** operate within linear regime of their gain function...“) odnosno i kada se za potrebe simulacija dozvoljava saturaciono ponašanje pojedinih neurona, sa aspekta analize ponašanja i modelovanja neurodinamike prepostavlja se rad van saturacije (dakle, u linearном režimu).

Dakle, imajući u vidu ove dve pretpostavke, prenosnu aktivacionu funkciju možemo linearizovati u okolici mirne radne tačke i to za sve neurone, i biološke i veštačke. Drugim rečima, u aproksimaciji u režimu lalih signala, možemo uzeti da je izvod prenosne aktivacione funkcije u radnoj tački konstantan:

$$\frac{df}{dx} |_{x=X} = k = \text{const.} \quad (18)$$

Prenosna odnosno izlazna funkcija CNM se uobičajeno uzima da je deo-po-deo linearna (PWL, Slika 28), a jedan od postula fraktalne modularizacije, iskazan uslovom (39) u sekciji 9.2.1, je da ćelije rade u ražimu izvan saturacije odnosno u linearном režimu:

$$\lambda(x) = lx \quad (19)$$

Primenjujući napred navedene prepostavke o linearnom režimu rada i biološkog neurona i ćelije frakタルno-modularne CNM, uslov ekvivalencije (16) u režimu malih signala, postaje:

$$v_j = V_j + \Delta v_j$$

$$f\left(\sum_j w_{ij}v_j\right) = f\left(\sum_j w_{ij}V_j\right) + k \sum_j w_{ij}\Delta v_j = l \sum_j w_{ij}V_j + l \sum_j w_{ij}\Delta v_j + \Delta I_e \quad (20)$$

Trivijalnom primenom teoreme ekvivalentnosti polinomijalnih funkcija (obzirom da su članovi u kojima figurišu veliki signali V_j i eksitacija ΔI_e konstantni, a da su promenjive veličine samo mali signali Δv_j) uslov ekvivalencije se svodi na:

$$f\left(\sum_j w_{ij}V_j\right) = l \sum_j w_{ij}V_j + \Delta I_e$$

$$k \sum_j w_{ij}\Delta v_j = l \sum_j w_{ij}\Delta v_j \quad (21)$$

Odakle dolazimo do vrednosti koeficijenta k , nagiba prenosne aktivacione funkcije u okolini mirne radne tačke, za koju važi ekvivalentnost modela biološkog neurona sa frakタルno-modularnom ćelijom CNM:

$$k = l \quad (22)$$

Ovaj uslov u stvari znači da se u okolini mirne radne tačke biološkog neurona ekvivalentija uspostavlja ako je nagib prenosne aktivacione funkcije jednak nagibu izlazne funkcije ćelije frakタルno-modularne CNM (kao i pogodnim izborom same radne tačke, primenom eksitacije ΔI_e). Primetimo da je uobičajeni nagib izlaza CNM ćelije jediničan ($l = 1$) i da je ovaj uslov korišćen u sintezi frakタルno-modularnih CNM - relacija (39) u sekciji 9.2.1. Međutim, ova prepostavka je samo formalna i u suštini isti matematički model frakタルno-modularnih CNM se izvodi i pod prepostavkom bilo kog drugog nagiba $l > 0$.

Dakle, možemo da zaključimo: ekvivalentnost neurodinamičkih modela biološkog neurona i fraktalno-modularne CNM ćelije se ostvaruje u režimu malih signala, kada se nagib izlaza ćelije CNM izabere da je jednak nagibu prenosne aktivacione funkcije biološkog neurona u okolini mirne radne tačke.

5.4 Rekapitulacija

U ovom poglavlju je pokazano da fraktalno-modularne CNM, opisane homogenizovanim dinamičkim modelima odnosno jednačinama stanja (u kojima se napon ćelije posmatra kao učestanost okidanja biološkog neurona – homogenizacija informacione enkapsulacije), imaju niz funkcionalnih i dinamičkih sličnosti i čak matematičku ekvivalenciju sa FR modelom biološkog neurona u režimu malih signala. Prepostavka o validnosti režima malih signala je utemeljena u trenutno važećem stavu u oblasti neuronauka da kortikalni neuroni uobičajeno rade u linearном delu prenosne aktivacione funkcije, koja je po pravilu sigmoidalna sa izraženim linearnim segmentom (Slika 21).

Na bazi ekvivalencije dinamičkih modela, izведен je i novi model funkcionalne analogije fraktalno-modularnih CNM sa biološkim neurokognitivnim strukturama i pokazan je visok stepen korelacije odnosno analogije.

Pokazana funkcionalna analogija omogućava sada da se na višem funkcionalnom odnosno bihevioralnom nivou mogu tražiti sličnosti i analogije procesa i ponašanja bioloških i veštačkih fraktalno-modularnih neurokognitivnih struktura, što će biti izloženo u narednom poglavlju.

6 Analogije na višim nivoima kognitivnih procesa (bihevioralna sličnost višeslojnih frkatalno-modularnih CNM i hijerarhijeske anatomije viših kognitivnih nivoa mozga)

Kao što je u poglavlju 3 naglašeno, neurofiziološki modeli u najvećoj meri apstrahuju prostorne parametre u neurodinamici, te možemo reći da su ovakvi modeli u stvari komplementarni sa neuroanatomskim modelima koji upravo modeluju strukturalne karakteristike (dakle, upravo se zasnivaju na prostornim parametrima). Sa druge strane, naglašeno je i da *top-down* modeli, koji više odgovaraju biheviroalnom modelovanju dakle modelovanju koje spada u domen neuropsihologije, obuhvataju i strukturalne i funkcionalne karakteristike. Dakle, prostor koji postoji između „kako radi“ tj. *bottom-up* modela (koji ne uključuju strukturalne karakterizacije) i „šta radi“ tj. *top-down* modela (koji ih uključuju) se moguće upravo treba „popuniti“ novim modelima sa objedinjenim posmatranjem i strukturalnih (neuroanatomske) i funkcionalnih (neurofizioloških odnosno neruodinamičkih) karakteristika.

U ovom poglavlju će biti uspostavljen jedan model analogije na bihevioralnom nivou odnosno nivou posmatranja sličnosti neurodinamičkih procesa odnosno kognitivnih funkcija i uloga koje ispoljavaju kolektiviteti neurostruktura, konkretno bioloških neurostruktura srednjih i viših kognitivnih nivoa i fraktalno-modularnih CNM. Pod time se podrazumeva da će se fokus staviti na funkcije i ponašanja koja se mogu dovesti u vezu sa kognitivnim procesima i funkcijama, dakle sa funkcijama koje se mogu tratrirati kao napredne, kompleksne i inteligentne u odnosu na rudimentarne komputacione funkcionalnosti koje su razmatrane na nižim nivoima odnosno funkcionalnim modelima pojedinačnih neurona i baznih neurostruktura u poglavlju 5.

Obzirom da je već naglašeno da neuroanatomija, odnosno sagledavanje strukturalnih svojstava i karakteristika bioloških neurokognitivnih struktura, brzo napreduje u eksperimentalnom istraživanju zahvaljujući novim neuroimaging tehnologijama a da u funkcionalnom domenu postoje brojne prepreke (*black-box* reverzni inženjering), dok se u

veštačkim neurokognitivnim sistemima daleko više napreduje upravo u funkcionalnoj odnosno neurodinamičkoj karakterizaciji (zahvaljujući inherentnom matematičkom modelovanju), stvara se mogućnost da se problem funkcionalnog modelovanja bioloških neurokognitivnih struktura približi prepoznavanju sličnih (analogih) veštačkih modela koji imaju bliske strukturalne ali i dinamičke karakteristike. Tako bi se stvorila mogućnost da se prepozna, eksperimentalno testiraju (potvrde ili opovrgnu) prepostavljene analogije sa veštačkim stukturama poznatih funkcionalnih (dinamičkih) svojstava.

Dakle, strukturalna analogija u kombinaciji sa analogijom dinamičkih modela može ukazati na funkcionalnu bliskost bioloških i veštačkih struktura. Drugim rečima, stvara se mogućnost da se prepozne (savremenim neuroimaging tehnologijama) neuroanatomske strukture "mapiraju" u bliske dinamičke modele veštačkih neurosistema (npr. fraktalno-modularnih CNM ali i drugih veštačkih neurokognitivnih arhitektura) i da se na taj način dođe do potencijalnog odgovora na pitanje funkcionalnosti bioloških neurokognitivnih struktura koje se inače ne može sagledati na trenutnom nivou mogućnosti neurofizioloških ispitivanja.

6.1 Model bihevioralne analogije bioloških i fraktalno-modularnih CNM na višim kognitivnim nivoima

Kao što je već naglašeno u poglavlju 3, savremena gledišta na pitanje bihevioralnih procesa viših i visokih nivoa mozga su tesno vezana za dva osnovna aspekta:

1. neurodinamiku kolektiviteta bioloških neurona, izraženu *top-down* modelima, koja podrazumeva statističku apstrakciju mnogih fizičkih procesa na nižim nivoima (koji su u fokusu *bottom-up* modela) i primat daje procesima koji imaju informacioni a ne fizički karakter, odnosno onome što možemo podvesti pod ponašanje ili bihevioralne karakteristike koje se mogu logički (informaciono) sagledavati i objasniti, i
2. strukturalnu organizaciju koja je sve fiše poznata usled napretka neuroimaging tehnologija i mogućnosti da se strukturalna i organizaciona svojstva sagledaju veoma detaljno i precizno na raznim nivoima neurokognitivnih struktura.

U sekciji 4.4 detaljno su identifikovane upravo ključne karakteristike po oba ova apekta i u nastavku će biti formulisan novi model analogije imajući u vidu ranije iznete karakteristike kako bioloških (na osnovu savremenih saznanja i važećih stavova iznetih u meta-analizi u poglavlju 3) tako i konkretnih klasa fraktalno-modularnih CNM (čija su ponašanja i bihevioralne karakteristike poznate):

Tabela 6: Model bihevioralne analogije bioloških neurokognitivnih sistema i veštačkih fraktalno-modularnih CNM

Karakteristika / Odlika	Biološki neurokognitivni sistemi	Veštačke fraktalno-modularne CNM	Korelacija
Neurodinamika			VISOKA
Neurodinamička (funkcionalna, komputaciona) energija	Prepostavljena (jedna od prepostavki svih savremenih gledišta, u kontekstu <i>top-down</i> statističkih modela, je da je energija direktno vezana sa kognitivnim aktivnostima na svim nivoima mozga)	Inherentna (fraktalna modularnost upravo polazi od generalisane energije, funkcije Ljapunova, u sintezi mreže, te je veza funkcionalne energije i samog ponašanja odnosno „rada“ mreže direktna i egzaktna – funkcionalno ponašanje mreže proističe iz ugrađene, prirodne, osobine sistema da spontano minimizira generalisanu energiju)	VISOKA*
Neurooscilacije	Inherentne (oscilacije odnosno neurooscilacije i moždani talasi su inherentno prisutni i u visokim i u niskim slojevima, u raznim mentalnim režimima, i smatra se da njihov nestanak predstavlja moždanu smrt)	Partikularno prisutne (u klasama fraktalno-modularnih CNM koje ispoljavaju napredna bihevioralna svojstva odnosno napredne funkcionalnosti, koje se mogu povezati sa složenijim kognitivnim funkcijama ili	VISOKA*

		inteligentnim procesimaobrađe informacija)	
Talasi	Rasprostranjeno na raznim nivoima (talasnna neurodinamika se zapaža od nivoa ansambala, koji broje nekoliko desetina neurona, pa do nivoa celog mozga gde se registruju neuroimaging snimci koji imaju sve karakteristike talasnih oblika prostiranja)	Partikularno prisutni (slično kao i oscilacije, energetski talasi se formiraju u klasama fraktalno-modularnih CNM koje imaju složene kognitivne funkcije odnosno koje vrše napredno, inteligentno procesiranje)	VISOKA*
Modularnost			VISOKA
Urođeno svojstvo	Inherentno (modularna struktura i organizacija mozga na višim i visokim nivoima je urođeno, genetski uslovljeno, svojstvo odnosno pojedine moždane strukture nastaju embrionalnim razvojem, imaju unpred definisanu strukturu i organizacionu i funkcionalnu ulogu, uključujući i internu neuroanatomsku strukturu odnosno vrste neurona od kojih se sastoje i sl.)	Inherentno (fraktalno-modularne CNM imaju strukturu odnosno modularnu organizaciju koja je uslovljena odnosno predeterminisana vrstom problem za koji se mreža sintetiše odnosno svojom funkcionalnom specijalizacijom i bihevioralnim karakteristikama koje su potrebne za rešavanje određenog problema odnosno izvršenje određenog zadatka)	VISOKA
Evolutivno prilagođenje	Prepostavljeno (savremena shvatanja podrazumevaju da se sa bihevioralnog aspekta može dovesti u logičku vezu struktura u odnosu na funkcionalne zahteve odnosno da se može objasniti ili čak modelovati npr. broj neurona i	Inherentno (fraktalna modularnost podrazumeva da se organizacija, topologija i struktura mreže mogu prilagođavati konkretno problemu odnosno funkcionalnoj ulozi mreže u određenom bihevioralnom i	VISOKA

	<p>sinaptičkih veza u odnosu na aspekte povezane sa energetskom i informacionom odnosno komputacionom efikasnošću u određenoj strukturi koja ima definisanu kognitivnu ulogu, i da se to prilagodenje, optimizacija, može objasniti genetskim i drugim biološkim procesima evolutivnog razvoja)</p>	<p>kognitivnom procesu – npr. mreža se može topološki prilagoditi stvarnom „obliku“ matrice koeficijenata nekog sistema uslova u linearном programiranju što u konkretnoj primeni za npr. kontrolu upravljanja trajektorijom ruke znači da se mreža može svesti na minimalnu strukturu odnosno optimalnu organizaciju za ovu vrstu zadatka)</p>	
UKUPNA KORELACIJA (ANALOGIJA)			VISOKA

* *Naznačene osobine će biti diskutovane u nastavku, gde će biti detaljno objašnjeno pod kojim uslovima se može smatrati da model visoke korelacije važi.*

Kao što se može primetiti, obzirom da se radi o bihevioralnim karakteristikama odnosno svojstvima i odlikama koje se ne mogu lako i egzaktno matematički formulisati, potrebno je dodatno diskutovati uslove korelacije odnosno uslove pod kojima možemo smatrati da na neurodinamičkom nivou postoje sličnosti u biheviralnim karakteristikama i ponašanjima u biološkim i fraktalno-modularnim strukturama.

Ti uslovi, kao što će u narednim sekcijama biti pokazano, nisu restukturativni u smislu da utiču na suštinu modela analogije već upravo podupiru tezu o analogiji upravo na onim nivoima za koje je ovaj model i fokusiran (pokazuje se da upravo model važi za napredne bihevioralne funkcije i procese koji su karakteristični za više kognitivne nivoe, dakle upravo za one nivoe gde *bottom-up* modeli nisu primenjivi a gde *top-down* modeli mogu biti korišćeni kao izvor uporišta za posmatranje neurodinamičkih osobina).

6.2 Funkcionalna (komputaciona) neurodinamička energija

U poglavlju 2 je objašnjeno da je jedno od osnovnih bihevioralnih svojstava CNM upravo spontana minimizacija generalisane energije koja se može izraziti funkcijom Ljapunova (prilog 2, jednačina (29)). Upravo ovaj bihevioralni proces (ponašanje), da mreža

spontano minimizira odnosno asymptotski konvergira lokalnom minimumu generalisane energije, je iskorišćeno kao osnovni „pogonski“ mehanizam fraktalne modualrizacije (prilog 2, sekcija 9.2.2). Stoga možemo tvrditi da je osnovno bihevioralno svojstvo fraktno-modularnih CNM upravo generalisana energija, a da je spontani proces njene minimizacije upravo glavni bihevioralni proces koji se u njima odvija. Drugim rečima, generalisana energija je inherentno svojstvo fraktno-modularnih CNM.

U biološkim sistemima energija je osobina koja je inherentna na bazičnom nivou (jasno je da biološki sistem bez energije nije živ) ali je njena funkcionalna uloga još uvek nerazjašnjena. Tako, u sekciji 3.3.2 je detaljno opisano kako savremena shvatnja, a posebno *top-down* modelovanje bioloških neurokognitivnih sistema, počiva upravo na koncepciji posmatranja prostiranja odnosno prostorno-vremenske dinamike energije (fizičke ili pak generalisane, odnosno funkcionalne ili komputacione, kako se još referiše) po ugledu na matematičke modele koji se primenjuju u statističkoj termodinamici (gde je opet energija centralni koncept tj. pojava koja diktira sve procese). Dakle, opšteprihvaćeno je stanoviše (prepostavka) da je energetska prostorno-vremenska dinamika (odnosno neurodinamika) direktno vezana za funkcionalno ponašanje neurokognitivnih struktura.

Ključna razlika u razumevanju uloge energije u veštačkim fraktno-modulanim CNM i biološkim neurokognitivnim strukturama je stoga upravo u činjenici da je u fraktno-modularnim CNM egzaktno (inherentno) poznato da sistem minimizira generalisanu energiju (iskazanu funkcijom Ljapunova) dok u biološkim sistemima postoje opšteprihvaćene prepostavke da je energija i energetska dinamika ključna za funkcionalne procese, na istim principima kao i u termodinamičkim sistemima. Dakle, pod prepostavkom da su *top-down* statistički modeli bioloških neurokognitivnih struktura validni, možemo povući visok stepen korelacije između koncepcije generalisane energije u fraktno-modularnim CNM i neurodinamičke energije (odnosno funkcionalne ili komputacione) u biološkim neurokognitivnim strukturama. Imajući u vidu i zakone termodinamike, možemo još proširiti ovu prepostavku i na bihevioralne karakteristike koje u osnovi imaju princip spontane minimizacije energije (odnosno povećanje entropije sistema).

Napomena: U prethodnom poglavlju, sekcija 5.2, povučena je korelacija između generalisane energije u fraktno-modularnim CNM i informacije, odnosno informacionog modela kojim

je izvršena homogenizacija sa FR modelom biološkog neurona. Sa druge strane, poznato je da postoji ekvivalencija između termodinamičke i informacione entropije (poznata Shannon-ova teorema informacione entropije [185]). Stoga, možemo reći da postoji snažna paralela između neurodinamičke energije (i u CNM i u biološkim sistemima) i informacije u bihevioralnom domenu, odnosno kao funkcionalna osnova kognitivnih procesa. Primetimo da se ovde informaciona energija pojavljuje kao zajednički koncept koji povezuje ne samo biološke i veštačke strukture u funkcionalnom i bihevioralnom smislu već uspostavlja i vezu između funkcionalnih *bottom-up* (kod kojih je informacija osnova homogenizovanog dinamičkog modela stanja, sekcija 5.2) i bihevioralnih *top-down* modela (kod kojih je energija osnovna funkcionalna bihevioralna karakteristika).

6.3 Neurooscilacije

Opšte je poznato da je jedna od osnovnih bihevioralnih karakteristika bioloških neurosistema postojanje oscilacija na raznolitim nivoima – od najviših, moždanih talasa, koji se registruju EEG-om, preko srednjih nivoa (neuronskih ansambala, u kojima se oscialcije mere LFP²⁰-om) pa do najnižeg, pojedinačnog neurona, koji generiše povorke aktivacionih impulsa (Slika 23). Dakle, oscilatorne pojave se zapažaju kako na najvišem tako i na najnižem nivou bioloških neurostruktura.

Same neurooscilacije, kako se u literaturi najčešće nazivaju, odnose se na varijacije odnosno vemenske oscilacije u neuralnoj aktivnosti. Zavisno od metode merenja, a najčešće su to EEG ili LFP, mogu se posmatrati oscilacije na različitim nivoima neurostruktura. Ipak, sve ove metode posmatraju oscilacije u lokalizovanim segmentima, u kojima se statistički vrši usrednjavanje u određenom prostoru (lokalitetu) odnosno kompaktnoj grupi neurona (kolektivitetu). To znači da kada se govori o neurooscilacijama treba imati u vidu da se pod njima podrazumeva apstrakcija prostorne dimenzije stanja neurosistema odnosno da se fokus stavlja samo na vremensku dimenziju (oscilacije u vremenu).

U poglavlju 3 naglašeno je da više modela, posebno *top-down* (poput Pasemann-ovog ili poput Kuramoto-vog modela [172]), polaze od pretpostavke da je oscilatorna priroda

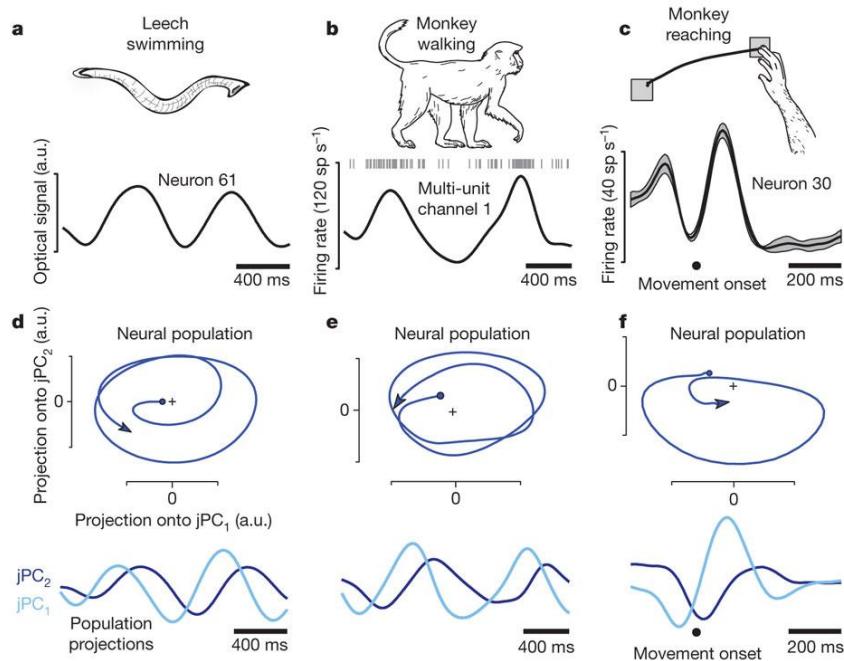
²⁰ LFP (Local Field Potential) je nurofiziološka metoda koja ekstracelularno meri fluktuaciju (promenu) membranskog potencijala lokalne grupe neurona (pod grupom se podrazumevaju menji kolektiviteti a ne veliki regiji mozga).

inherentna svim biološkim neurostrukturama odnosno da se već od osnovnih ansambala (sa po nekoliko neurona) mogu formirati modeli koji u svojoj osnovi imaju oscilatornu dinamiku. Ovi model pokazuju određenu korelaciju sa napred opisanih eksperimentalnim merenjima neurooscilacija.

Važno je naglasiti da napred navedene korelacije bioloških neurooscilacija i teoretskih modela podrazumevaju posmatranje fizičkih veličina (LFP meri naponske potencijale) a da se, saglasno homogenizovanom informacionom modelu opisanom u sekciji 5.2, u kontekstu bihevioralne analogije bioloških neurosistema i veštačkih fraktalno-modularnih CNM treba posmatrati informacioni model odnosno učestanost okidanja kao homogenizovana promenjiva stanja.

U nekim novijim istraživanjima, fokus se upravo pomera sa posmatranja fizičkih na posmatranje informacionih veličina prostora stanja. Npr. Churchland et al. u [186] su objavili veoma interesantne rezultate u kojima upravo ističu ključnu ulogu neurooscilacija u motornom korteksu i podvlače fundamentalnu razliku u bihevioralnim karakteristikama (upravo u oscilacijama) između ponašanja odnosno bihevioralnih karakteristika neurodinamike u motornom korteksu i vizuelnom korteksu. Oni podvlače razliku u upravo u tome da u vizuelnom korteksu oscilacije u učestanosti okidanja neurona nisu široko rasprostranjene (odnosno da ne postoje interne, spontane oscilacije, već odziv neuroaktivnosti zavisi od spoljne pobude tj. svetlosne stimulacije) dok u motornom korteksu postoje spontane, interno stimulisane, oscilacije koje u suštini obezbeđuju *pokret*.

Na drugoj strani, fraktalno-modularne CNM takođe ispoljavaju izvesna oscilatorna ponašanja. Ovde nećemo ulaziti dublje u analizu oscilatorne dinamike CNM, njegnih uzroka i drugih osobina koje bi se mogle analizirati iz dinamičkog modela, navešćemo samo da u literaturi postoje reference koje se bave ovom problematikom mnogo detaljnije od nivoa koji je potreban za pokazivanje bihevioralne korelacije u kontekstu teme ove disertacije. Tako, Chen i Cao [187] iznose veoma detaljnu analizu oscilatorne dinamike, uslove nastanka i održanja gotovo periodičnih neurooscilacija u CNM sa varijabilnim sinapsama sa konačnom brzinom propagacije (engl. *time-delayed*).



Slika 24: Oscilacije učestanosti okidanja pojedinačnog neurona tokom tri različita tipa pokreta (preuzeto iz [186])

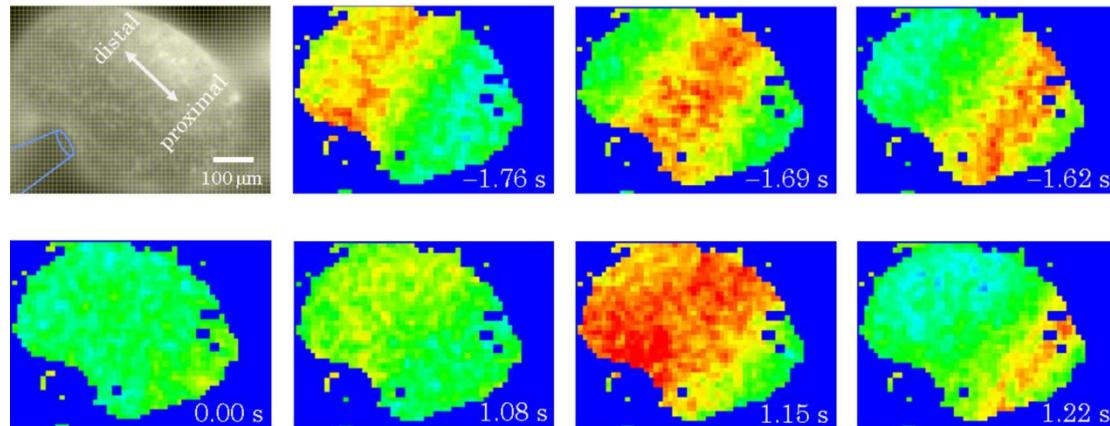
Treba naglasiti da u slučaju fraktalno-modularnih CNM postoji donekle jednostavnija situacija za egzaktno pokazivanje uslova odnosno mogućnosti da se formiraju oscilacije koje mogu imati bihevioralne sličnosti sa biološkim neurooscilacijama. Obzirom da je jedna od inherentnih karakteristika fraktalno-modularnih CNM upravo ta da se osnovni modul mreže sastoji od bar dve (moguće i više) „baznih“ ćelija CNM, moguće je i egzaktno izvesti uslove oscilovanja odnosno granice oscilatornog domena modula (dvoćelijski modul je opisan sistemom od dve diferencijalne jednačine, što je matematički potreban uslov za oscilatornu dinamiku). U skorije vreme, upravo su se pojavili radovi ([188], [189], [190], [191], [192]) japanskog tima koji analiziraju složenu oscilatornu dinamiku u dvoslojnim CNM (dakle ista topološka struktura kao npr. LSS CNM, Slika 29) i samim tim i matematički modeli imaju veliku analogiju sa fraktalno-modularnim CNM koje smo ranije opisali u sekciji 2.4.

Dakle, ne ulazeći u detaljnu analizu koja uostalom nije ni svrsishodna (jer nije poznat egzaktan matematički model bioloških neurostruktura sa kojima bi se moglo vršiti poređenje na nivou matematičkih modela), možemo tvrditi da fraktalno-modularne CNM imaju mogućnost da ispoljavaju oscilatornu neurodinamiku koja po biheviroalnim karakteristikama ima sličnosti sa neurooscilacijama uočenim u biološkim neurostrukturama.

6.4 Talasi

Oscilacije, iako se mogu posmatrati na različitim nivoima (od pojedinačnog neurona do moždanih struktura najvišeg nivoa pa i mozga u celini), najčešće se posmatraju u lokalizovanim kolektivitetima neurona (mereno LFP-om) i tako se i najčešće modeluju odnosno u modelima koji se smatraju relevantnim najčešće se apstrahuje prostorna dimenzija.

Talasi su, sa druge strane, varijacije koje se posmatraju u prostoru odnosno ne zanemaruje se prostorna dimenzija. Oscilacije i talasi se mogu posmatrati i objedinjeno, odnosno može se formalno reći da su talasi generalisano oscilacije u kojima se varijacija posmatra u prostorno-vremenskom (eng. *spatiotemporal*) domenu, međutim u neurokognitivnim istraživanjima i relevantnoj literaturi se najčešće te pojave odvajaju tako da se poda oscilacijama posmatraju lokalizovane (vremenske) varijacije dok se pod talasima više podrazumevaju vremensko-prostorne ili pak samo prostorne varijacije (ukoliko se vremenska dimenzija apstrahuje odnosno ako se posmatra samo stanje kolektiviteta u diskretnim vremenskim preseцима).



Slika 25: Predstava prostorno-vremenske neuroaktivnosti u procerebrumu (preuzeto iz [193]) kao posledica mirisnog stimulusa.

U biološkim neurosistemima, još u ranim istraživanjima (npr. Freeman je još 1959. primetio i opisao prostorno-vremenske talase u oflaktornom²¹ korteksu [194]), prepoznat je značaj talasa u višim kognitivnim funkcijama kao što su memorija i asocijacija (prepoznavanje). Nove neuroimaging tehnike su omogućile i nastavak ovih istraživanja

²¹ Oflaktorni korteks je zadužen za prepoznavanje mirisa

([195], [193], [196]), tako da je danas opšte prihvaćeno stanovište da su prostorno-vremenski oblici, talasi, inherentno prisutni u nerokognitivnim strukturama srednjih i viših nivoa i da je njihova uloga ključna upravo u memorijskim i asocijativnim procesima ([197]), mada se spektar potencijalnih bihevioralnih domena širi i na motoričke, auditorne i druge funkcije ([193], [198], [199]). Dakle, prostorno-vremenski talasi su prisutni u mnogim segmentima bioloških neurostruktura, na gotovo svim višim i visokim kognitivnim nivoima, i prepoznata je njihova uloga (mada ne i do kraja objašnjena) u mnogim biheviralnim funkcijama.

U veštačkim neuralnim mrežama pitanje talasa je otvoreno relativno kasnije u odnosu na druge domene interesovanja koji su imali konkretnije funkcionalne i praktične primene. Talasi, sami po sebi, nisu u prvo vreme prepoznati kao praktično korisan fenomen već više kao prateća pojava, posledica ili podloga funkcionalnostima mreže. Tako, većina radova na ovu temu se bavila više teoretskim aspektima, matematičkim modelovanjem ili pak simulacijama u kojima je pokazivano prisustvo ovog fenomena u različitim arhitekturama veštačkih neuralnih mreža. Npr. Ermentrout je objavio ekstenzivnu matematičku analizu prostorno-vremenskih oscilatornih i talasnih fenomena u teoretskim, dinamičkim veštačkim neurosistemima [91]. On je razložio mnoge oscilatorne i talasne pojave, klasifikovao ih po bihevioralnim karakteristikama i izveo matematičke uslove odnosno modele koji opisuju uslove pod kojima te pojave nastaju. Tako, on je prepoznao mnoge vrste pojave koje su uočene i u veštačkim CNM: propagaciju talasnog fronta, putujuće impulse (auto-talase) i stacionarne talase („šare“). Upravo ovi fenomeni su opisani i u sekciji 2.4 gde je ne samo napomenuto je da je i sam Chua opisivao ove fenomene (auto-talase i kompleksnu dinamiku u CNM, [76]) već smo pokazali i da određene klase fraktalno-modularnih CNM upravo pokazuju ove bihevioralne karakteristike (SPF CNM za nalaženje najkraćeg puta u labyrintru ima funkcionalnu podlogu u propagaciji talasnog fronta dok LTT CNM za predikciju i praćenje trajektorije ima podlogu u impulsnoj poragaciji). Zanimljivo je napomenuti da u radu Ermentrout nije navedena CNM kao arhitektura, mada se pominju Hopfieldove i mnoge druge klase veštačkih neuralnih mreža, dok Chua u svojim radovima ne citira Ermentrout-a (a radovi su publikovani u isto vreme, 1998. godine). Ipak, uvidom u Ermentrout-ovu analizu, može se primetiti da je ona izuzetno bliska modelima upravo fraktalno-modularnih CNM te da se mnoge teoretske postavke, modeli i formalizacije uslova nastanka i održanja talasnih pojava mogu upravo povezati i primeniti na njih (što može biti predmet daljih istraživanja, obzirom da je već napomenuto da je fokus fraktalne modularizacije na funkcionalnim

primenama odnosno na sintezi mreže sa određenu namenu a da je analiza stabilnosti i drugih biheviroalnih karakteristika ostavljena po strani).

U sekciji 2.4 je već naglašeno da su i drugi autori (npr. Xavier-de-Souza et al. [87], Arena et al. [90], Szatmari et al. [92]) prepoznali i primenili upravo auto-talase i srodne bihevioralne karakteristike u CNM na realizaciju naprednih kognitivnih funkcija i to na način koji je blizak, i po teoretskim i po praktičnim aspektima, nepred opisanim fraktalno-modularnim CNM (specifično SPF i LTT CNM).

Tako možemo konstatovati da su i drugi autori potvrdili da je jedna od bitnih karakteristika fraktalno-modularnih CNM upravo složena prostorno-vremenska neurodinamika odnosno da su talasi jedna od ključnih bihevioralnih odlika nekih klasa fraktalno-modularnih CNM. Ovde treba naglasiti da se ovo odnosi na određene klase fraktalno-modularnih CNM, odnosno da to nije opšta karakteristika svih klasa fraktalno-modularnih CNM već samo onih koje, zavisno od kognitivnog problema odnosno funkcije za koji se sintetišu, imaju predispozicije za oscilatornu vremensko-prostornu dinamiku (čiji parametri sinaptičkih interkonekcija odnosno topološke strukture modula to omogućavaju, a što se može dovesti u vezu i sa formalno-matematičkim modelima Ermentrout-a i sl.). Dakle, ne moraju sve fraktalno-modularne CNM imati talasnu dinamiku ali je fraktalno-modularne mreže mogu imati (što ima daje opštost u teoretskom i praktičnom smislu). Ovo je važno naglasiti upravo iz razloga analogije sa biološkim sistemima gde talasna neurodinamika jeste prisutna u nekim segmentima, i ima važnu ulogu u složenim kognitivnim procesima, ali to ne implicira da je talasna neurodinamika prisutna u svim segmentima i na svim nivoima. Dakle, i u bilološkim neurokognitivnim sistemima i u veštačkim fraktalno-modularnim CNM talasna neurodinamika je rasprostranjena i prisutna u nekim, ali ne svim, segmentima odnosno klasama neurostruktura.

6.5 Rekapitulacija

U ovom poglavlju je izведен novi model bihevioralne analogije, dinamičkog i kognitivnog ponašanja, bioloških i fraktalno-modularnih CNM. Analiza karakteristika bioloških neurosistema je otežana iz razloga što se radi o upravo višim moždanim odnosno kognitivnim nivoima, na kojima je matematičko modelovanje otežano i većina biheviroalnih

procesa se više posmatra kroz empirijska istraživanja nego kroz teoretske modele. Stoga je i direktna, matematička, korelacija sa fraktalno-modularnim strukturama otežana (u odnosu npr. na funkcionalnu korelaciju koja je izvedena preko matematičkih modela u prethodnom poglavlju) ali je moguća, kao što je i pokazano, upravo preko identifikovanih biheviroalnih karakteristika odnosno odlika neurodinamičkog ponašanja (i inherentne modularnosti, koja se pokazuje kao konstanta na svim nivoima posmatranja).

Pokazano je da određene klase fraktalno-modularnih CNM imaju visok stepen korelacije u domenu neurodinamike, posebno neurooscilacija i prostorno-vremenskih talasa, sa sličnim fenomenima koji su prepoznati i u biološkim neurokognitivnim sistemima. Posebno je naglašeno da su i drugi autori došli do sličnih rezultata, koji upravo potvrđuju da ove identifikovane bihevioralne karakteristike u fraktalno-modularnim CNM tesno koreliraju upravo sa naprednim bihevioralnim karakteristikama i procesima koje se sreću na višim kognitivnim nivoima u biološkim sistemima (npr. nova istraživanja stavljuju problem nalaženja najkraćeg puta u laverintu upravo u kontekst naprednih kognitivnih funkcija poput orijentacije u prostoru ili planiranja odnosno svesnog određivanja kretanja [200], [96]).

Ne pledirajući da se povlači decidna korelacija, ovde se zadržavamo na nivou koji ukazuje na postojanje (izvesne) sličnost u bihevioralnom domenu kao i da te sličnosti koreliraju sa naprednim kognitivnim funkcijama koje se zapažaju kako u biološkim tako i u veštačkim sistemima.

7 Zaključak i završna razmatranja

Osnovna teza ove disertacije je da postoji značajna analogija u strukturalnom (neuroanatomskom), funkcionalnom (neurofiziološkom) i bihevioralnom (neuropsihološkom) domenu, između veštačkih fraktalno-modularnih CNM i bioloških neurokognitivnih sistema. Svaki od ovih domena je veoma složen i kompleksan i predstavlja predmet višedecenijskih istraživanja brojnih naučnika i timova. Iako je moderna neuronauka, posebno zahvaljujući novim biomedicinskim tehnologijama, ostvarila veliki napredak u razumevanju i sagledavanju ne samo strukturalnih već i neurodinamičkih procesa u mozgu (i neurosistemima uopšte) još uvek nismo u mogućnosti da tvrdimo da je pitanje funkcionalnih osnova kognitivnih procesa ni iz daleka rasvetljeno. Dakle, u samoj osnovi ove teze leži problem kompleksnosti i ograničenih ljudskih znanja i zato je u najmanju ruku primereno naglasiti da se i svi rezultati koji su izloženi trebaju uzeti sa izvesnom naučnom rezervom jer su bazirani na trenutno poznatim znanjima i savremenim stanovištima u oblasti neuronauka.

Ipak, upravo zbog tako velikog „neznanja“ o neurokognitivnim procesima i njihовоj funkcionalnoj prirodi, što je jedna od ključnih karika koja trenutno nedostaje da se povežu modeli na niskim i visokim nivoima neurokognitivnih struktura, ova teza je od značaja jer ukazuje na jednu mogućnost da se uspostavi ta relacija odnosno da se približimo razumevanju funkcionalnih osnova u složenim neurokognitivnim procesima.

Postojanje analogije veštačkih fraktalno-modularnih sistema i bioloških neurokognitivnih struktura omogućava da se čitav niz poznatih, matematički dobro definisanih, modela i alata primeni na proučavanje i modelovanje funkcionalnih procesa u biološkim sistemima. Time se otvara nova mogućnost da se stari problem reverznog inženjeringu „crne kutije“ mozga polako počne da „otvara“ primenom novih inženjerskih metoda imajući kao polaznu osnovu neke pretpostavke o strukturi, dinamičkim modelima i opštim neurodinamičkim i bihevioralnim karakteristikama koje se po analogiji mogu preslikati iz veštačkih neurosistema koji su nam poznati.

7.1 Konceptualne postavke i izvorište teze

Ideja odnosno koncepcija fraktalne modularizacije je nastala početkom 90-tih godina 20. veka, u vreme kada je u svetu bio trend i veliki rezultati su ostvareni u oblasti veštačkih neuralnih mreža inspirisanih strukturom i dinamičkim karakteristikama bioloških neurona i neurostruktura niskog nivoa. Ovo je, može se reći, bio drugi veliki „talas“ naučnog interesa i entuzijazma u oblasti veštačkih neuralnih mreža i veštačke inteligencije uopšte (prvi je bio par decenija ranije, kada su se pojavile prve veštačke neuralne mreže, perceptroni i sl.). Tzv. rekurentne mreže, među koje spadaju i Hopfield-ove mreže i klasične celularne neuralne mreže (CNM) koje su uveli Chua i Yang, pokazale su neke potencijale koji su animirali mnoge istraživače da se upuste u veoma široka istraživanja kako njihovih teoretskih tako i aplikativnih aspekata. Početni rezultati su bili više nego obećavajući. Pokazane su razne praktične osobine i primene ovih mreža, u složenim obradama signala (posebno slika) kao i u nekim primenama u kojima se pokazalo da paralelna procesna dinamika ovakvih mreža može da višestruko prevaziđe procesni kapacitet klasičnih računara. CMOS VLSI implementacije čipova sa CNM mrežama su omogućili početkom 2000-tih godina da se realizuju veoma napredni vizuelni procesni sistemi koji su u realnom vremenu mogli da vrše veoma složene obrade, poput segmentacije i prepoznavanja oblika, slova i sl. što je bilo daleko efikasnije i brže nego klasičnim algoritmima koji se izvršavaju na mikroprocesorskim računarima. Konačno, pokazani su mnogi praktični i teoretski aspekti u kojima se CNM ponašaju veoma slično biološkim neurosistemima, posebno na niskim odnosno senzorskim nivoima vizuelnog korteksa. Poznat je projekat „veštačke retine“ u okviru kojeg su prof. Roska i njegov tim realizovali i pokazali da CNM analogički računar (spoj klasičnog računara, koji vrši kontrolu i upravljanje po određenom algoritmu, sa CNM mrežom implementiranom u CMOS VLSI čipu) može da emulira procese koji se odvijaju na retini oka odnosno u senzorskim i nižim slojevima vizuelnog korteksa.

Nakon ovih početnih uspeha, početkom 2000-tih godina, došlo je i do zasićenja u razvoju i istraživanjima u ovoj oblasti. Osnovni uzroci su bili ti što su primene i dalje ostale vezane za rudimentarne kognitivne funkcije i procese, kao i to što VLSI tehnologija ima realna ograničenja u pogledu veličine mreže koja se može implementirati na čipu. Ali, ovakvi periodi uspona i padova naučnog entuzijazma su prirodni u kompleksnim multidisciplinarnim oblastima u kojima upravo progres u raznim inženjerskim i naučnim disciplinama diktira

ukupan tempo progrusa. Najnoviji progres npr. u oblastima nenotehnologija odnosno novih tehnologija implementacije dinamičkih modela koji opisuju veštačke CNM, aktuelizirali su zadnjih godina ponovo ovu oblast (npr. praktična mogućnost implemenatcije memristora u sinaptičkim vezama otvorila je potpuno nove mogućnosti zbog velike bliskosti sa neuroplasicizmom u biološkim sinapsama).

Mnogi rezultati koji su do sada postignuti, posebno teoretski radovi i koncepti koji modeluju dinamičke i funkcionalne karakteristike ovih sistema, ponovo postaju aktuelni zbog novih saznanja i sve više dokaza da se u biološkim neurosistemim javljaju slične pojave i pojavljuju slični modeli i zakonitosti koje su u veštačkim CNM identifikovane kroz teoretska ali i, čak češće, empirijska istraživanja i primene. U vreme „buma“ interesovanja za CNM, saznanja o biološkim neurosistemima i kognitivnim procesima su bila daleko manja, sličnosti su bile moguće da se naslućuju ili prepostavljaju, ali je egzaktna analiza i analogija bila nedovoljno naučno neutemeljena da bi se egzaktno uspostavila jer nisu postojali čvrsti dokazi za ključne elemente hipotetičkog modela.

Danas, posle skoro 25 godina od uvođenja koncepta fraktalne modularizacije u CNM (ali je ovaj koncept i šire primenjiv, mada u kontekstu CNM ima najviše elemenata analogije sa biološkim neurokognitivnim sistemima) nova saznanja omogućavaju da se sistematizovano izvede i evaluira novi model analogije ovakvih veštačkih neruostruktura u odnosu na, sada već dobro istražene i poznate, karektristike i svojstva bioloških neurokognitivnih struktura. Obzirom da su fraktno-modularne CNM definisane egzaktnim matematičkim modelima, kao i da su u međuvremenu od njihovog uvođenja do danas ne samo detaljno razmatrani razni aspekti njihove funkcionalne primene u kognitivnim procesima (kompleksnim, inteligentnim procesiranjima, koja imaju mnoge sličnosti i odlike kognitivnih funkcija koje se sreću u biološkim sistemima) već su i se pojavili i noviji teoretski i praktični rezultati i drugih istraživačkih timova koji su potvrdili ne samo primenjivost već i dali određene potpore teoretskim konceptima na kojima počiva fraktna modularizacija kako je inicijalno definisana.

Koncept fraktalne modularizacije je, dakle, prepoznat i u radovima drugih istraživača, mada ga oni ne nazivaju tako niti ga izdvajaju kao koncept, već se on više provlači kao

podloga, funkcionalna odnosno bihevioralna osnova funckionalosti mreža koje su primenjene u nekim specifičnim kontekstima.

Suština koncepta fraktalne modularizacije se, bez ulaženja u matematički model i formalno izvođenje koji su dati u poglavlju 2, može opisati kao metoda sinteze odnosno kreiranja (izborom sinaptičkih i drugih internih parametara modela) veštačke CNM za tačno određenu optimizacionu funkciju (problem koji rešava) a čija topološka struktura ima modularnu formu i čije dinamičko ponašanje spontano realizuje željenu kognitivnu funkciju (spontana minimizacija generalisane energije unutar mreže dovodi stanje mreže ka optimumu postavljenog problema). Dakle, dve ključne karakteristike fraktalno-modularnih CNM su da one imaju modularnu (fraktalnu) topološku strukturu i da je njihova bihevioralna funkcija određena spontanom, inherentnom, optimizacijom (generalisane) energije.

Razlika između metodologije fraktalne modularizacije i drugih primena CNM koje su opisane u literaturi je upravo u ovom konceptu da se polazi od problema (funkcije) i da se zatim dobijaju parametri (sinteza, geneza) mreže koja vrši tu konkretnu funkciju. Većina drugih autora je ili polazila od teoretskih razmatranja uslova dinamičkih ponašanja mreža generalno, dakle bez konkretne funkcije odnosno primene u kognitivnom smislu, ili pak su vršene sinteze mreža za partikularne primene (empirijskim i intuitivnim izborom parametara da bi se postigla određena funkcija) ili primene koje se baziraju na rudimentarnim logičkim ili procesnim funkcijama a koje se samo relativno mogu svrstati u kognitivnih procesa (obrade slike koje se mogu definisati logičkim operacijama po ugledu na konvolucione filtre ili druge obrade koje više postećaju na „informacione predobrade“ na niskim kortikalnim nivoima i sl.).

Na drugoj strani, fraktalno modularne CNM su specifična klasa u odnosu na klasične CNM, odnosno njihova nadgradnja i generalizacija u određenom smislu.

Jedna od ključnih razlika fraktalno-modularnih mreža i klasičnih CNM, posebno za obradu slike ili druge primene koje su uglavnom imale vizuelnu reprezentaciju (nalaženje puta kroz labyrin i sl.), je u činjenici da je režim rada fraktalno-modularnih CNM uglavnom vezan za linearni režim odnosno izvan zasićenja dok je upravo rad u zasićenju jedna od ključnih prepostavki i čak ciljnih funkcija klasičnih CNM (najčešće se rezultat rada klasične CNM posmatra u stabilnom stanju gde su izlazi ćelija u zasićenju, što je i bila osnovna

bihevioralna karakteristika koju je čak Chua potencirao i dokaziva u svojim izvornim radovima). Dakle, fraktalno-modularne mreže imaju širi i „bogatiji“ radni režim u odnosu na klasične CNM, što je u tesnoj analogij i sa biološkim sistemima – na nižim kortikalnim nivoima, senzorskim i niskim kognitivnim slojevima, preovladava saturisani režim rada i bioloških neurona. Na višim nivoima – i biološki neuroni rade uobičajeno (normalno) izvan saturacije. Imajući u vidu da fraktalno-modularne mreže upravo imaju fokus na naprednim, složenim, optimizacionim i kognitivnim funkcijama, dok klasične CNM imaju uglavnom jednostavnije funkcionalnosti, ovo je još jedan argument za načelno pitanje o hipotetičkoj analogiji sa biološkim sistemima.

Druga ključna razlika je što se kod klasičnih CNM uglavnom posmatra slojevita struktura, ako je mreža višeslojna, dok je u frakatlno-modularnim CNM osnovna organizaciona, funkcionalna i bihevioralna, jedinica posmatranja modul koji je sastavljen od, uobičajeno, dve ili više ćelija. Dakle, kod klasičnih CNM se u organizacionom i topološkom smislu sistem posmatra kao ćelijsko-hijerarhijski, a u fraktalno-modularnim mrežama posmatra se kao modularano-hijerarhijski (mnogo bliže topologiji „malog sveta“ koja je najpričližnija biološkim neurokognitivnim strukturama). Iako se i fraktalno-modularne mreže mogu posmatrati u stvari kao višeslojne (ćelije koje čine modul mogu se posmatrati kao da pripadaju različitim slojevima), ključna odlika je upravo što se modul odnosno sprega i interakcija dve ili više ćelija iz različitih slojeva stavlja u kontekst konkretnе funkcije mreže odnosno njene kognitivne funkcionalnosti. Osnovni modul mreže funkcionalno implementira rudimentarnu / primitivnu kognitivnu funkcionalnost iz date klase odnosno rešava, spontanom minimizacijom interne generalisane energije, rudimentarni / primitivni optimizacioni problem iz klase optimizacionih problema za koji je mreža sintetisana (npr. fraktalno-modularna LSS CNM za rešavanje sistema linearnih jednačina proizvoljne veičine sastoji se od pojedinačnih modula koji svaki rešava rudimentarni problem iz ove klase odnosno jednu linearu jednačinu sa jednom nepoznatom). Drugim rečima, fraktalna modularizacija u odnosu na klasičnu slojevitu topologiju CNM (iako su one ekvivalentne) omogućava da se topološka struktura, u modularizovanoj organizacionoj formi, direktno veže za biheviralnu odnosno kognitivnu funkciju mreže – modul rešava primitivni problem odnosno implementira rudimentarnu kognitivnu funkciju iz date klase. Suštinski, fraktalno-modularna mreža može se posmatrati kao generalizacija koncepta lokalne povezanosti klasičnih CNM ali sa modulima (koje takođe definiše lokalna povezanost ali i specifična

kognitivna funkcionalnost) kao osnovnim organizacionim entitetima (umesto samih ćelija, u slučaju klasične organizacije CNM).

Ove dve ključne osobine fraktalno-modularnih CNM ih čine specifičnim ne samo u organizacionom već i funkcionalnom smislu u odnosu na većinu CNM mreža (ali i drugih srodnih arhitektura, npr. Hopfield-ovih mreža) opisanih u literaturi. Ipak, one se u partikularnim slučajevima mogu svesti ili približiti nekim drugim CNM mrežama koje su drugi autori opisali odnosno sintetisali alternativnim metodama i koje imaju bliske funkcionalne (služe za slične svrhe, odnosno rešavaju slične probleme) ili bihevioralne karakteristike (ispoljavaju slično dinamičko ponašanje, bez obzira na konkrentu funkciju). Time se potvrđuje generalnost koncepta fraktalne modularizacije jer je on formulisan kao metodologija a prtkularne primene samo potvrđuju njegovu šиру primenjivost.

7.2 Rezultati i potvrda teze

Iako su dve napred navedene ključne osobenosti, modularnost i optimizaciona (inteligentna, kognitivna) funkcionalnost, fraktalno-modularnih CNM u načelu intuitivno bliske u organizacionom i bihevioralnom smislu biološkim neurokognitivnim sistemima, uspostavljanje jasne analogije odnosno modela analogije koji se bazira na sistematizovanim i nučno utemeljenim kriterijumima i potvrđenim činjenicama (prvenstveno vezanim za karakteristike isvojstva utvrđena u biološkim sistemima) omogućava da se može formirati i predložiti i jedan novi dinamički model u određenim klasama bioloških neurokognitivnih struktura koji bi mogao da poveže strukturalne i funkcionalne karakteristike na srednjim i višim nivoima koji su do sada upravo ostali najveći prazan prostor u razumevanju veze između „kako radi“ i „šta radi“ određena neurostruktura.

Dakle, u ovoj disertciji je kao osnovna teza postavljena prepostavka da fraktalno-modularne CNM imaju analogiju odnosno značajne sličnosti u bitnim karakteristikama sa biološkim neurokognitivnim strukturama. Metodom meta-analize savremenih istraživanja i saznanja iz ključnih oblasti neuronauka (neuroanatomije, neuofiziologije i neuropsihologije u biomedicinskom domenu i komputacione neuronauke i teorije električnih kola, u inženjerskom domenu) identifikovane su ključne karakteristike i analogna svojstva, detaljnije definisane nizom odlika koje određuju svaku od njih, koje se mogu smatrati da su potvrđene

kao bitne i široko prisutne u različitim neurokognitivnim strukturama (slojevima i kolektivitetima neurona različitih bioloških vrsta, od neuroloških sistema primitivnih organizama do ljudskog mozga). Time je formulisan meta-model analogije odnosno korelacije (sličnosti) koji omogućava da se na sistematizovan i naučno utemeljen način može povući paralela odnosno izvršiti validacija i kvalifikacija (vrednovanje nivoa korelacije odnosno sličnosti) po svakom od ovih kriterijuma, u svakom od ključnih domena (strukturalnom – neuroanatomskom, funkcionalnom – neurofiziološkom i biheviralnom - neuropsihološkom).

Dataljnom analizom po svakom od navedenih kriterijuma analogije, uzimajući u obzir ne samo savremna shvatanja i istraživanja već i izvođenjem matematičkih modela ekvivalencije, pokazano je da postoji visoka korelacija odnosno analogija po gotovo svim postavljenim kriterijumima, uz određene uslove odnosno pretpostavke i ograničenja koja su posebno određena, razmotrena i istaknuta. Tako, na primer, postavka celog modela funkcionalne analogije se zasniva na pretpostavci da se dinamički model fraktalno-modularne CNM i bioloških neurokognitivnih sistema može homogenizovati u domenu funkcionalno-logičkog / informacionog posmatranja neurodinamike dnosno da se analogija odnosi na posmatranje dinamike informacionih veličina (informacija enkodovanih u učestanostima okidanja odnosno aktivacije neurona u biološkim strukturama) a ne na same fizičke veličine unutar sistema (potencijala membrane ili pojedinačnih aktivacionih impulsa). Ovakve pretpostavke nisu restruktivne, u odnosu na cilj ove teze, jer ne ograničavaju već upravo podižu i fokusiraju model analogije na više kognitivne funkcije odnosno analogiju na višim nivoima neurokognitivnih struktura i bihevioralnih procesa koji su upravo i najveći izazov i najveći oportunitet sa inženjerskog aspekta kroz mogućnosti da se realizuju napredni veštački kognitivni sistemi po uzoru na biološke koji su, i dalje, superiorni uzori u svakom pogledu.

Dakle, cilj ove disertacije odnosno osnovna teza je potvrđena striktnim metodološkim pristupom - analizom, sintezom i evaluacijom - predloženog novog modela analogije veštačkih fraktalno-modularnih CNM i bioloških neurokognitivnih sistema.

7.3 Primenjivost rezultata

Kao što je istaknuto, trenutno važeća naučna stanovišta prepoznavaju dva pristupa u modelovanju bioloških neurokognitivnih sistema: *bottom-up* pristup, koji polazi od fizičke dinamike i u fokusu ima modelovanje funkcionalnih procesa pojedinačnog neurona („kako radi“), i *top-down* pristup koji polazi od statističkih modela koji su vezani za posmatranje kolektiviteta, većih neurostruktura u celini, odnosno fokusiraju se na modelovanje bihevioralnih karakteristika neurodinamike viših kognitivnih procesa („šta radi“).

Sami *top-down* modeli mogu poslužiti kao osnova ili izvor objašnjenja za neke neurodinamičke procese koji se uočavaju u neurostrukturama, ali je suštinska interpretacija bihevioralnih karakteristika više vezana za organizacione i neuropsihološke aspekte nego za formalno matematičko modelovanje, koje je suviše složeno da bi moglo biti pozdano i efektivno primenjeno na funkcionalno objašnjenje tih kompleksnih struktura i procesa. Drugim rečima, kako je to već više puta naglašeno u prethodnim poglavljima, *top-down* modeli mogu dati neka objašnjenja za neurodinamičke procese koji se zapažaju na višim kognitivnim nivoima („šta radi“) ali je i dalje velika nepoznanica suštinskih mehanizama koji obezbeđuju to ponašanje („kako radi“).

Primetimo da se ovde radi o klasičnom problemu reverznog inženjeringu „crne kutije“ (engl. *black box*). Sa jedne strane, savremene neuroimaging, neurofiziološke i neuropsihološke metode omogućavaju blisku identifikaciju bihevioralnih i organizacionih karakteristika (neuroanatomije u kontekstu neuropsihološke aktivnosti pojedinih struktura) u biološkim neurosistemima, koje su povezane sa kompleksnim kognitivnim procesima pa i samom svesti, ali veza tih procesa i svojstava određenih struktura sa neurodinamikom nižih nivoa (pojedinačnih neurona i manjih grupa) je i dalje veoma neodređena.

Sa druge strane, u fraktalno-modularnim CNM postoje određene i organizacione (modularnost) i bihevioralne (optimizacija) karakteristike koje upravo određuju napredne, kognitivne, funkcionalnosti sistema. Dakle, u fraktalno-modularnim CNM je interpretacija ponašanje i veze sa nižim apstraktnim nivoima (ulogom i strukturom pojedinačnog modula odnosno svake pojedinačne ćelije) predeterminisano i poznato iz samog neurodinamičkog modela, jer je geneza (sinteza) mreže upravo vođena kognitivnom ulogom odnosno funkcionalnošću (problemom koji mreža u celini treba da rešava) a ne samom strukturom na

nižim nivoima (koja je pak izvedena odnosno posledica je metode sinteze - fraktalne modularizacije).

Uspostavljanjem novog modela analogije omogućava da se ova dva domena približe. Odnosno da se iz analogije dođe do novih teoretskih modela posmatranja i identifikacije eventualnih neurostruktura koje bi moglo da se opišu sličnim ili ekvivalentnim neurodinamičkim modelima kao izvesne klase fraktalno-modularnih CNM i da se ti modeli testiraju kako sa neurofiziološkog tako i sa neuropsihološkog aspekta i, ukoliko se potvrdi njihova validnost, da se suštinski uspostavi veza funkcionalnih uloga tih neurostruktura sa bihevioralnim svojstvima i kognitivnim procesima na srednjim i višim nivoima. Sa druge strane, ukoliko se pokažu sličnosti na funkcionalnom nivou, mogu se dizajnirati nove veštačke strukture koje bi organizacionim svojstvima bile slične biološkim (dakle, po uzoru na organizaciju bioloških struktura moglo bi se formirati nove veštačke, upravo na modularnim principima gde bi se moduli „slagali“ po uzoru na biološke neurostrukture).

7.4 Nastavak razvoja modela i pravci daljih istraživanja

Analogija između fraktalno-modularnih veštačkih CNM i bioloških neurostruktura, koja je u ovoj disertaciji pokazana, omogućava da se na novi način sagledava veza između naruodinamike, u neurofiziološkom smislu, i funkcionalnosti u logičkom odnosno kognitivnom smislu kako u veštačkim tako i u biološkim neurostrukturama.

Dalji razvoj i unapređenje kvaliteta modela se može postići dodatnim uvođenjem novih karakteristika u model, ali i iznalaženja egzaktnih kriterijuma korelacije nekih karakteristika koje se mogu, u manjoj ili većoj meri, kvantifikovati i meriti. Tu prvenstveno spadaju topološke odnosno neuroanatomske karakteristike, koje bi se moglo meriti u biološkim sistemima primenom najnovijih neuroimaging tehnologija (koje mogu dosta precizno identifikovati čak i pojedinačne neruone i nihove sinaptičke veze), identifikovati i kvatifikovati npr. veličine susednosti, matrice povezanosti, fraktalni indeks i druge topološke parametre. Na višim nivoima moždanih struktura takva snimanja i kvantifikacije su već realni (npr. u sekcijama 3.2 su prikazani rezultati kvantifikacije topološke i organizacione strukture mozga, ili i rezultati CoCoMac studije, anatomska konetivnost ljudskog mozga sa kvatifikovanom matricom povezanosti, Slika 22) a za očekivati je da će u bliskoj budućnosti

veoma precizna merenja biti moguća i na srednjim i nižim nivoima, dakle upravo u segmentima koji su bliski fokusu predloženog modela analogije (srednji nivoi organizacije neurokognitivnih struktura). Sa druge strane, matematičko modelovanje veštačkih fraktalno-modularnih struktura, može se vršiti na egzaktan način i tako doći do klasifikacije topoloških i strukturalnih parametara raznih klasa fraktalno-modularnih mreža (mreža za različite kognitivne funkcije odnosno optimizacije i probleme koje spontano rešavaju minimizacijom generalisane energije). Kvatifikacijom strukturalnih karakteristika, omogućila bi se egzaktnija i lakša identifikacija potencijalnih bioloških neurostruktura sa određenim funkcionalnim ulogama i bihevioralnim svojstvima. Drugim rečima, na osnovu topologije i modularnosti moglo bi se prepostaviti šta određena neurostruktura radi odnosno koja je njena funkcionalna i kognitivna uloga u širem kontekstu.

Obzirom da je analogija bilateralna relacija, možemo govoriti o mogućnostima koje predloženi novi model može doneti kako u biomedicinskim tako i u inženjerskim oblastima.

7.4.1 Mogućnost primene novog modela u funkcionalnom modelovanju bioloških neurokognitivnih struktura

U biloškim neurostrukturama tako se otvara mogućnost da se u segmentu upravo između poznatih *bottom-up* i *top-down* modela, dakle u domenu u kojem se posmatraju manji kolektiviteti neurona (više od pojedinačnog, jer nas interesuje biheviroalna i kognitivna funkcionalnost odnosno „šta radi“ određeni kolektivitet, ansambl ili određena neurostruktura manjeg ovuhvata), uspostave novi modeli koji bi na logičkom nivou, u informacionom smislu, mogli da posluže za reverzni inženjering odnosno pokazivanje stvarne veze između „kako“ i „šta“ radi određena neurostruktura.

Primena novog modela u eksperimentalnim neurofiziološkim i neuropsihološkim istraživanjima bi se mogla vršiti prema sledećoj metodologiji:

1. Identifikacija neuroanatomskim struktura koje imaju bliske strukturalne odnosno topološke karakteristike fraktalno-modularnim sistemima (sekcija 4.2). Ovo je osnovni korak i trenutno je realno izvodiv sa različitim dostupnim neuroimaging tehnologijama, koje omogućavaju veoma preciza snimanja neuroanatomskih struktura, do nivoa pojedinačnih neurona, kao i identifikacije njihovih sinaptičkih veza. Ovde je posebno interesantno vršiti identifikaciju modula odnosno tradicionalnu predstavu

neurokognitivnog sistema kao višeslojne strukture zameniti pogledom iz perspektive modula, odnosno identifikacije pojedinačnih, manjih neurokolektiviteta koji su povezani između slojeva a ne samo po slojevima. Time se omogućava da se posmatranje i dalja neurofiziološka opservacija fokusira na manje neurostrukture odnosno da se omogući smanjenje komplkesnosti (veličine) posmatranog nauroanatomskog domena, što bi trebalo da olakša i poveća efikasnost daljeg funkcionalnog posmatranja.

2. Snimanje odnosno identifikacija funkcionalnih odnosno neurofizioloških parametara u identifikovanoj fraktalno-modularnoj strukturi odnosno prvenstveno fokusirano na modul (koji je, prepostavljeno, sastavljen od interslojnih neurona). Snimanje aktivnosti intramodularnih neurona, odnosno njihovih učestanosti okidanja, i korelacija sa prepostavljenim dinamičkim modelima fraktalno-modularnih sistema (sekcija 6.1) može da ukaže na funkcionalnost („šta radi“) određenog modula odnosno neurstrukture (ako se prepostavi da je zahvaljujući fraktalnoj modularnosti funkcija strukture srodnna funkciji modula). Ovde je moguće primeniti mnoge poznate i u praksi potvrđene metode koje su poznate u inženjerskim oblastima a koje se koriste za testiranja i opservacije nedeterminisanih²² dinamičkih sistema („*black-box testing*“).
3. Fraktalna modularizacija pruža vezu između bihevioralnih odnosno fukcionalnih uloga („šta radi“) i strukturalnih odnosno funkcionalnih parametara mreže, što omogućava da se prethodno identifikovane i observirane neurostrukture (moduli odnosno manji neurokolektiviteti za koje se može prepostaviti da imaju određenu neurokognitivnu funkciju ili ulogu) modeluju dinamičkim modelima, jednačinama stanja, i odrede njihovi potencijalni parametri (sinaptičke veze i interne i eksterne ekscitacije).

Dakle, polazeći od hipoteze ili saznanja da neka neurokognitivna struktura ima određenu kognitivnu funkciju (ulogu) i potvrđivanjem da njeni naroanatomski imaju fraktalno-modularnu strukturu, može se postaviti hipotetički dinamički model koji se zatim može eksperimentalno neurofiziološki testirati, observirati i determinisati (određivati konkretni parametri – sinaptičke veze i drugi parametri modela).

²² Pod „nedeterminisanim“ se u ovom kontekstu podrazumevaju sistemi čija unutrašnja struktura i model nisu poznati ili određeni.

7.4.2 Inženjering novih klasa veštačkih fraktalno-modularnih neurokognitivnih sistema

Drugi pravac razvoja je mogućnost da se postavljeni model analogije primeni na sintezu veštačkih fraktalno-modularnih CNM upravo po ugledu na identifikovane biološke neurokognitivne strukture mozga. Kao što je u prethodnoj sekciji predloženo, identifikacijom modula (u smislu fraktalno-modularnih baznih modula, osnovnih neurokolektivita koji kao što je objašnjeno po konceptu fraktalne modularizacije vrše rudimentarnu kognitivnu funkciju iz date klase) unutar bioloških neurokognitivnih strukturama, njihovom opservacijom i modelovanjem, može se doći do novih funkcionalnih rešenja koja možda nisu direktno izvodiva na formalan, metodološki način odnosno direktnom sintezom mreže (mnogi optimizacioni problemi u matematičkom smislu su teški za reprezentaciju, posebno višedimenzionalni i nelinearni, i njihovo prevođenje odnosno mapiranje u generalisanu energiju odnosno funkciju Ljapuno fraktalno-modularne mreže je kompleksan a često i neizvodljiv zadatak). Polazeći od bioloških uzora, pak, mogu se kreirati analogne veštačke strukture koje bi imale istu ili sličnu kognitivnu funkcionalnost bez obzira da li nam je potpuno jasan matematički model koji iza nje стоји.

Ovakav, intuitivni odnosno empirijski pristup u sintezi veštačkih mreža nije stran koncept. U prethodnom izlaganju je opisano kako su mnoge klasične CNM (ali i druge rekurzivne mreže, u kojima „učenje“ nije inherentno) upravo nastale intuitivno ili na drugi empirijski način za određenu funkcionalnu primenjivost (npr. neke mreže za orijentaciju i nalaženje puta, koje funkcionišu na bazi auto-talasa, nisu nastale metodološki već su sintetisane empirijski odnosno prepoznato je i potvrđeno da one vrše određenu funkciju za određene parametre mreže, bez ulaganja u metodološki pristup genezi tih parametara²³). Dakle, i biološki inspirisana sinteza fraktalno-modularnih mreža može takođe biti potsticajna za dalja istraživanja i sinteze veštačkih neurokognitivnih struktura.

7.5 Zaključna diskusija

Na kraju, vredi priznati da izneti model analogije kao i sama metoda fraktalne modularizacije, su postavljeni na osnovama koje u mnogome imaju ograničenja u smislu

²³ Naknadno se za te mreže često vrše dodatne analize stabilnosti i pokazuje da one imaju sposobnost oscilovanja i održavanja auto-talasa, ali to je *post festum* analiza koja samo potvrđuje funkcionalnost ali je ne određuje.

prepostavki i aproksimacija na kojim popčivaju a što sve otvara pitanje njihove realne bliskosti sa stvarnim, prirodnim, biološkim sistemima.

Na prvi pogled, posebno ako se fokusiramo na segment modela analogije koji je vezan za matematičku korelaciju dinamičkih funkcionalnih modela (poglavlje 5), može se postaviti to pitanje odnosno diskutovati koliko model koji je izведен na osnovu dosta pojednostavljenih modela biološkog neurona (informacionog, FR modela, sa mnogim prepostavkama i linearizacijama na kojima počiva) realno omogućava da se govori o značajnoj analogiji. Međutim, ključno u predloženom novom modelu analogije je upravo to što se on ne bazira samo na ekvivalentnosti odnosno analogiji matematičkih dinamičkih modela (mada je i u njima objašnjeno da su sve prepostavke i aproksimacije bazirane na utemeljenim i naučno dokazanim svojstvima bioloških sistema – od pretežnog rada u linearnom režimu, izvan saturacije, do spektralne analize i opsega vremenskih konstanti dominantnih pojava i sl. što je sve detaljno elaborirano) već analogiju posmatra šire, uključuje i strukturalne i bihevioralne karakteristike koje su u daleko većoj meri ne samo prepoznatljivo već i merljivo bliske (npr. već je naglašeno da se mnogi strukturalni parametri, koji određuju topologiju „malog sveta“ mogu meriti savremenim neuroimaging tehnikama i time kvantifikovati raditi poređenja sa egzaktnim matematički proračunljivim parametrima organizacije i strukture veštačkih mreža koje imaju inherentnu topologiju i organizaciona svojstva koja su posledica fraktalne modularizacije).

Na ovaj način posmatrano, šire gledano od uskog pogleda samo na naurodinamiku i matematičke modele (koji u literaturi i mnogim istraživanjima deluju impozantno, kompleksno ali često i bez praktične primenjivosti upravo zbog kompleksnosti i apstraktnosti), predloženi model analogije je upravo u većini baziran na kriterijumima koji su dobro definisani (čak se mogu i matematički formulisati, poput topoloških), merljivi (fiziološkim ili drugim dostupnim metodama) i lako primenjivi (jer su observabilni odnosno mogu se prepoznati, izdvojiti od drugih pojava) u praktičnom posmatranju i analizi kako bioloških tako i veštačkih sistema. Polazeći od takvog kriterijuma kvaliteta modela analogije, možemo reći da je predloženi model upravo zbog toga robustniji, jer ne zavisi samo od fragilnih matematičkih modela, njihovih često diskutabilnih prepostavki i aproksimacija dinamičkih parametara i pojava u njima.

Da zaključimo, predloženi model je robustan upravo jer povezuje sve tri ključne paradigmе koje se provlače kroz sva neurokognitivna istraživanja i razmatranja - strukturu (fizičku odnosno anatomsku prirodu), dinamiku (energiju i fiziologiju) i konačno bihevioralnu prirodu (kognitivnu funkciju). U ukupnoj analogiji se ta robustnost odslikava u mogućnosti da se deo nesavršenosti i ograničenja u našim saznanjima o određenim segmentima (npr. dinamičkom modelovanju u uslovima kompleksne priorde bioloških struktura) može kompenzovati upravo produbljivanjem saznanja (novim eksperimentalnim i teoretskim metodama koje se razvijaju) u drugim segmentima (npr. u strukturalnoj bliskosti). Time se stvara mogućnost da se postepeno, kako se ostvaruje progres u različitim segmentima, model analogije razvija, proširuje (uvode novi kreiterijumi i osovine koje se posmatraju), povećava njegov kalitet i primenjivost na identifikaciju, modelovanje i približavanje bioloških i veštačkih neurokognitivnih sistema.

8 Literatura

- [1] E. Bullmore, E. Bullmore, O. Sporns, and O. Sporns, “Complex brain networks: graph theoretical analysis of structural and functional systems,” *Nat Rev Neurosci*, vol. 10, no. 3, pp. 186–198, 2009.
- [2] E. Byrne and C. Huyck, “Processing with cell assemblies,” *Neurocomputing*, vol. 74, no. 1–3, pp. 76–83, Dec. 2010.
- [3] A. Wohrer and P. Kornprobst, “Virtual Retina: A biological retina model and simulator, with contrast gain control,” *J. Comput. Neurosci.*, vol. 26, no. 2, pp. 219–249, Apr. 2009.
- [4] G. Deco and T. S. Lee, “The role of early visual cortex in visual integration: a neural model of recurrent interaction.,” *Eur. J. Neurosci.*, vol. 20, pp. 1089–1100, 2004.
- [5] B. J. Baars, S. Franklin, and T. Z. Ramsøy, “Global workspace dynamics: Cortical ‘binding and propagation’ enables conscious contents,” *Front. Psychol.*, vol. 4, p. 200, Jan. 2013.
- [6] G. Galizia and P.-M. Lledo, *Neurosciences - From Molecule to Behavior: a university textbook*. Springer Science & Business Media, 2013.
- [7] S. Pinker, “How the mind works,” in *Annals of the New York Academy of Sciences*, 1999, vol. 882, pp. 119–127.
- [8] O. Sporns and C. J. Honey, “Small worlds inside big brains.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 103, no. 51, pp. 19219–19220, Dec. 2006.
- [9] T. Neuroscope, “Human Brain Project (HBP).” [Online]. Available: <https://www.humanbrainproject.eu/>. [Accessed: 24-Mar-2015].
- [10] F. Hapgood, “Reverse-Engineering the Brain,” *MIT Technol. Rev.*, vol. 109, no. 3, pp. M12–M17, 2006.
- [11] J. O. Wilson and D. Rosen, “Systematic reverse engineering of biological systems,” in *19Th International Conference on Design Theory and Methodology/1St International Conference on Micro and Nano Systems, Vol 3, Part a and B*, 2008, pp. 69–78.
- [12] A. F. Villaverde and J. R. Banga, “Reverse engineering and identification in systems biology: strategies, perspectives and challenges.,” *J. R. Soc. Interface*, vol. 11, no. 91, p. 20130505, Feb. 2014.

- [13] R. H. Sturges, K. O'Shaughnessy, and R. G. Reed, “A Systematic Approach to Conceptual Design,” in *Concurrent Engineering*, vol. 1, ProQuest, 1993, pp. 93–105.
- [14] D. S. Bassett and M. S. Gazzaniga, “Understanding complexity in the human brain.,” *Trends Cogn. Sci.*, vol. 15, no. 5, pp. 200–9, May 2011.
- [15] I. Vlachos, Y. V Zaytsev, S. Spreizer, A. Aertsen, and A. Kumar, “Neural system prediction and identification challenge.,” *Front. Neuroinform.*, vol. 7, p. 43, Jan. 2013.
- [16] A. P. Alivisatos, M. Chun, G. M. Church, R. J. Greenspan, M. L. Roukes, and R. Yuste, “The brain activity map project and the challenge of functional connectomics.,” *Neuron*, vol. 74, no. 6, pp. 970–4, Jun. 2012.
- [17] S. E. Fisher, “Tangled webs: Tracing the connections between genes and cognition,” *Cognition*, vol. 101, no. 2, pp. 270–297, 2006.
- [18] O. Sporns and C. J. Honey, “Small worlds inside big brains.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 103, no. 51, pp. 19219–20, Dec. 2006.
- [19] L. O. Chua and T. Roska, “The CNN paradigm,” *IEEE Trans. Circuits Syst. I Fundam. Theory Appl.*, vol. 40, no. 3, pp. 147–156, Mar. 1993.
- [20] L. O. Chua and L. Yang, “Cellular neural networks: Applications,” *IEEE Trans. Circuits Syst.*, vol. 35, no. 10, pp. 1273–1290, 1988.
- [21] L. O. Chua and L. Yang, “Cellular neural networks: Theory.,” *IEEE Trans. circuits Syst.*, vol. 35, no. 10, pp. 1257–1272, 1988.
- [22] S. T. Ő. Kés, L. Orzó, A. Ayoub, T. Roska, and S. Tőkés, “Flexibly programmable opto-electronic analogic CNN computer (POAC) implementation applying an efficient, unconventional optical correlator architecture,” *J. Circuits, Syst. ...*, 2003.
- [23] A. N. Al-Rabadi, “New dimensions in non-classical neural computing, part II: quantum, nano, and optical,” *Int. J. Intell. Comput. Cybern.*, vol. 2, no. 3, pp. 513–573, Aug. 2009.
- [24] L.-J. Lin, C.-H. Cheng, K.-H. Huang, and C.-Y. Wu, “The quantum-dot large-neighborhood cellular nonlinear network (QLN-CNN) in nanotechnology,” *Proc. 2001 1st IEEE Conf. Nanotechnology. IEEE-NANO 2001 (Cat. No.01EX516)*, pp. 331–334, 2001.
- [25] J. Flak, “CNN cell with memcapacitive synapses and threshold control circuit,” in *2012 13th International Workshop on Cellular Nanoscale Networks and their Applications*, 2012, pp. 1–5.
- [26] A. Folch and M. Toner, “Microengineering of cellular interactions.,” *Annu. Rev. Biomed. Eng.*, vol. 2, pp. 227–256, 2000.

- [27] P. Kostic, “Rešavanje nekih optimizacionih problema pomoću celularnih neuralnih mreža (CNN) primenom fraktalne modularizacije,” Univerzitet u Beogradu, 2000.
- [28] M. Milic and P. Kostic, “Solving Systems of Linear Equations Using Cellular Neural Networks,” in *Proc. European Conference on Circuit Theory and Design (ECCTD93)*, 1993, pp. 774–777.
- [29] B. Reljin and P. Kostic, “Solving some optimization problems using Celular Neural Networks,” *J. Autom. Control*, vol. 5, pp. 73–82, 1995.
- [30] E. Segal, M. Shapira, A. Regev, D. Pe’er, D. Botstein, D. Koller, and N. Friedman, “Module networks: identifying regulatory modules and their condition-specific regulators from gene expression data,” *Nat. Genet.*, vol. 34, no. 2, pp. 166–76, Jun. 2003.
- [31] M. Arbib, “Modular models of brain function,” *Scholarpedia*, vol. 2, no. 3, p. 1869, Mar. 2007.
- [32] R. a. W. Galuske, “Interhemispheric Asymmetries of the Modular Structure in Human Temporal Cortex,” *Science (80-.)*, vol. 289, no. 5486, pp. 1946–1949, Sep. 2000.
- [33] C. J. Honey, J. P. Thivierge, and O. Sporns, “Can structure predict function in the human brain?,” *Neuroimage*, vol. 52, no. 3, pp. 766–776, Sep. 2010.
- [34] M. Breakspear, V. Jirsa, and G. Deco, “Computational models of the brain: From structure to function,” *Neuroimage*, vol. 52, no. 3, pp. 727–730, Sep. 2010.
- [35] S. Coombes, “Large-scale neural dynamics: Simple and complex,” *Neuroimage*, vol. 52, no. 3, pp. 731–739, Sep. 2010.
- [36] S. Feldt, P. Bonifazi, and R. Cossart, “Dissecting functional connectivity of neuronal microcircuits: Experimental and theoretical insights,” *Trends Neurosci.*, vol. 34, pp. 225–236, 2011.
- [37] F. Ramus, “Genes, brain, and cognition: a roadmap for the cognitive scientist.,” *Cognition*, vol. 101, no. 2, pp. 247–69, Sep. 2006.
- [38] R. Cossart, “The maturation of cortical interneuron diversity: How multiple developmental journeys shape the emergence of proper network function,” *Curr. Opin. Neurobiol.*, vol. 21, no. 1, pp. 160–168, Feb. 2011.
- [39] D. Meunier, R. Lambiotte, and E. T. Bullmore, “Modular and hierarchically modular organization of brain networks.,” *Front. Neurosci.*, vol. 4, no. December, p. 200, Jan. 2010.
- [40] G. Werner, “Fractals in the nervous system: Conceptual implications for theoretical neuroscience,” *Front. Physiol.*, vol. 1 JUL, 2010.

- [41] X. Wang, E. Dalkic, M. Wu, and C. Chan, “Gene module level analysis: identification to networks and dynamics.,” *Curr. Opin. Biotechnol.*, vol. 19, no. 5, pp. 482–91, Oct. 2008.
- [42] H.-M. Kaltenbach and J. Stelling, “Modular analysis of biological networks.,” *Adv. Exp. Med. Biol.*, vol. 736, pp. 3–17, Jan. 2012.
- [43] K. Friston, “A theory of cortical responses.,” *Philos. Trans. R. Soc. Lond. B. Biol. Sci.*, vol. 360, no. 1456, pp. 815–36, Apr. 2005.
- [44] S. Sevush, “Single-neuron theory of consciousness,” *J. Theor. Biol.*, vol. 238, no. 3, pp. 704–725, Feb. 2006.
- [45] H. R. Wilson and J. D. Cowan, “A mathematical theory of the functional dynamics of cortical and thalamic nervous tissue.,” *Kybernetik*, vol. 13, no. 2, pp. 55–80, 1973.
- [46] W. Gerstner and W. Kistler, *Spiking Neuron Models*. Cambridge University Press, 2002.
- [47] B. U. Forstmann, E.-J. Wagenmakers, T. Eichele, S. Brown, and J. T. Serences, “Reciprocal relations between cognitive neuroscience and formal cognitive models: opposites attract?,” *Trends Cogn. Sci.*, vol. 15, no. 6, pp. 272–9, Jun. 2011.
- [48] E. Izhikevich, “Which model to use for cortical spiking neurons?,” *IEEE Trans. neural networks*, vol. 15, no. 5, pp. 1063–1070, 2004.
- [49] C. Bundesen, T. Habekost, and S. Kyllingsbaek, “A neural theory of visual attention: bridging cognition and neurophysiology.,” *Psychol. Rev.*, vol. 112, no. 2, pp. 291–328, 2005.
- [50] H. Haken, *Principles of Brain Functioning: A synergetic approach to brain activity, behavior, and cognition*. Springer Publishing Company, 1996.
- [51] B. Smith, “Topological Foundations of Cognitive Science,” *Topological Foundations of Cognitive Science*, 1994. [Online]. Available: <http://ontology.buffalo.edu/smith/articles/topo.html>. [Accessed: 24-Dec-2014].
- [52] D. Gentner and A. B. Markman, “Structure mapping in analogy and similarity.,” *Am. Psychol.*, vol. 52, pp. 45–56, 1997.
- [53] S. R. Proulx, D. E. L. Promislow, and P. C. Phillips, “Network thinking in ecology and evolution,” *Trends Ecol. Evol.*, vol. 20, no. 6, pp. 345–353, Jun. 2005.
- [54] M. a Schilling, “Modularity in multiple disciplines,” in *Managing in the Modular Age: Architectures, Networks and Organizations*, R. Garud, A. Kumaraswamy, and R. Langlois, Eds. Blackwell Publishers, 2002, pp. 203–214.

- [55] J. a. Bolker, “Modularity in Development and Why It Matters to Evo-Devo1,” *Am. Zool.*, vol. 40, no. 5, pp. 770–776, Oct. 2000.
- [56] G. Gass and J. Bolker, “Modularity,” in *Keywords & concepts in evolutionary developmental biology*, B. K. Hall and W. M. Olson, Eds. Harvard University Press, 2003, pp. 260–267.
- [57] M. E. J. Newman, “Modularity and community structure in networks.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 103, no. 23, pp. 8577–8582, Jun. 2006.
- [58] R. P. Taylor, “Reduction of Physiological Stress Using Fractal Art and Architecture,” *Leonardo*, vol. 39, no. 3, pp. 245–251, Jun. 2006.
- [59] B. B. Mandelbrot, “The Fractal Geometry of Nature,” *American Journal of Physics*, vol. 51, no. 3. Henry Holt and Company, p. 286, 1983.
- [60] C. G. Schmitt and a. J. Heymsfield, “The Dimensional Characteristics of Ice Crystal Aggregates from Fractal Geometry,” *J. Atmos. Sci.*, vol. 67, no. 5, pp. 1605–1616, May 2010.
- [61] S. Havlin, S. V Buldyrev, a L. Goldberger, R. N. Mantegna, S. M. Ossadnik, C. K. Peng, M. Simons, and H. E. Stanley, “Fractals in biology and medicine.,” *Chaos. Solitons. Fractals*, vol. 6, pp. 171–201, 1995.
- [62] N. a. Peppas, “Fractal physiology,” *Journal of Controlled Release*, vol. 39, no. 1. Oxford University Press, pp. 105–106, 1996.
- [63] L. O. Chua, T. Roska, and P. L. Venetianer, “The CNN is universal as the Turing machine,” *IEEE Trans. Circuits Syst. I Fundam. Theory Appl.*, vol. 40, no. 4, pp. 289–291, Apr. 1993.
- [64] T. Kozek, T. Roska, and L. O. Chua, “Genetic algorithm for CNN template learning,” *IEEE Trans. Circuits Syst. I Fundam. Theory Appl.*, vol. 40, no. 6, pp. 392–402, Jun. 1993.
- [65] C. R. Y. N. Brett Chandler, “Adaptive Simulated Annealing in CNN Template Learning.”
- [66] P. Szolgay and K. Tömördi, “The art of CNN template design,” *Int. J. Circuit Theory Appl.*, vol. 27, no. 1, pp. 5–23, 1999.
- [67] I. Fajfar, F. Bratkovič, T. Tuma, and J. Puhan, “A rigorous design method for binary cellular neural networks,” *Int. J. Circuit Theory Appl.*, vol. 26, no. 4, pp. 365–373, 1998.
- [68] T. Roska, J. Hamori, E. Labos, K. Lotz, L. Orzo, J. Takacs, P. L. Venetianer, Z. Vidnyanszky, and A. Zarandy, “The use of CNN models in the subcortical visual

pathway,” *IEEE Trans. Circuits Syst. I Fundam. Theory Appl.*, vol. 40, no. 3, pp. 182–195, Mar. 1993.

- [69] D. Liu and A. N. Michel, “Cellular neural networks for associative memories,” *IEEE Trans. Circuits Syst. II Analog Digit. Signal Process.*, vol. 40, no. 2, pp. 119–121, 1993.
- [70] T. Akiduki, Z. Zhang, T. Imamura, and T. Miyake, “Design of multi-valued cellular neural networks for associative memories,” *Int. J. Innov. Comput. Inf. Control*, vol. 8, no. 3 A, pp. 1575–1589, 2012.
- [71] D. Bálya, B. Roska, T. Roska, and F. S. Werblin, “A CNN framework for modeling parallel processing in a mammalian retina,” *Int. J. Circuit Theory Appl.*, vol. 30, no. 2–3, pp. 363–393, Mar. 2002.
- [72] D. Bálya, B. Roska, T. Roska, and F. Werblin, “A CNN model framework and simulator for biological sensory systems,” *15 IEEE Eur. Conf. Circuit Theory Des. ECCTD 2001*, 2001.
- [73] L. O. Chua and T. Roska, Eds., *Cellular Neural Networks and Visual Computing*. Cambridge, UK: Cambridge University Press, 2005.
- [74] B. Reljin, P. Kostić, T. Serdar, and A. Pavasović, “Single-amplifier CNN cell suitable for VLSI CMOS implementation,” *Int. J. Circuit Theory Appl.*, vol. 24, no. 6, pp. 649–655, Nov. 1996.
- [75] C. Rekeczky and L. O. Chua, “Computing with Front Propagation: Active Contour And Skeleton Models In Continuous-Time CNN,” *J. VLSI Signal Process.*, vol. 23, no. 2, pp. 373–402, 1999.
- [76] L. O. Chua, *CNN: A Paradigm for Complexity*. World Scientific Press, 1998.
- [77] A. Zafeiris, “Modeling Visual Attention,” Pázmány Péter Catholic University, Budapest, HU, 2008.
- [78] J. J. Hopfield and D. W. Tank, “Computing with neural circuits: a model.,” *Science*, vol. 233, no. 4764, pp. 625–633, 1986.
- [79] J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 79, no. 8, pp. 2554–2558, 1982.
- [80] J. J. Hopfield, “Neurons with graded response have collective computational properties like those of two-state neurons.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 81, no. May, pp. 3088–3092, May 1984.

- [81] P. R. Bakic, N. S. Vujovic, D. P. Brzakovic, P. D. Kostic, and B. D. Reljin, “CNN paradigm based multilevel halftoning of digital images,” *IEEE Trans. Circuits Syst. II Analog Digit. Signal Process.*, vol. 44, no. 1, pp. 50–53, 1997.
- [82] P. R. Bakic, B. D. Reljin, N. S. Vujovic, D. P. Brazakovic, and P. D. Kostic, “Multilayer transient-mode CNN for solving optimization problems,” in *1996 Fourth IEEE International Workshop on Cellular Neural Networks and their Applications Proceedings (CNNA-96)*, 1996, pp. 25–30.
- [83] B. D. Reljin and P. D. Kostic, “Novel analogic algorithm for finding the shortest-path using simple CNN structure,” in *1996 Fourth IEEE International Workshop on Cellular Neural Networks and their Applications Proceedings (CNNA-96)*, 1996, pp. 423–426.
- [84] B. Reljin and P. Kostic, “Fraktalna modularizacija i njena primena u rešavanju nekih optimizacionih problema pomoću celularnih neuralnih mreža,” in *Zbornik radova 3. Seminara o primeni neuralnih mreža u elektrotehnici - NEUREL 95*, pp. 217–222.
- [85] Y. Uno, M. Kawato, and R. Suzuki, “Formation and control of optimal trajectory in human multijoint arm movement,” *Biol. Cybern.*, 1989.
- [86] D. of M. Zhou, Lei (Massachusetts Institute of Technology, “A linear programming approach for dynamic system control with inequality constraints,” *18.086 Project Report*, 2014. [Online]. Available: <http://math.mit.edu/classes/18.086/2014/reports/LeiZhou.pdf>. [Accessed: 26-Mar-2015].
- [87] P. Kostić, B. Reljin, V. Papić, D. Dujković, and N. Dragan, “Praćenje i predikcija trajektorije primenom celularne neuralne mreže,” in *Zbornik radova XLI Jugoslovenske konferencije ETRAN*, pp. 207–209.
- [88] V. I. Krinsky, Ed., *Self-Organization Autowaves and Structures Far from Equilibrium*, vol. 28. Berlin, Heidelberg: Springer Berlin Heidelberg, 1984.
- [89] G. Kothapalli, “An analogue recurrent neural network for trajectory learning and other industrial applications,” in *2005 3rd IEEE International Conference on Industrial Informatics, INDIN*, 2005, vol. 2005, no. 2005, pp. 462–467.
- [90] P. Arena, R. Caponetto, L. Fortuna, and G. Manganaro, “Cellular neural networks to explore complexity,” *Soft Comput. - A Fusion Found. Methodol. Appl.*, vol. 1, no. 3, pp. 120–136, Sep. 1997.
- [91] B. Ermentrout, “Neural networks as spatio-temporal pattern-forming systems,” *Reports Prog. Phys.*, 1998.
- [92] I. Szatmári, A. Schultz, C. Rekeczky, T. Kozek, T. Roska, and L. O. Chua, “Morphology and autowave metric on CNN applied to Bubble-Debris classification,” *IEEE Trans. Neural Networks*, vol. 11, no. 6, pp. 1385–1393, 2000.

- [93] V. Perez-Munuzuri, “Autowaves for image processing on a two-dimensional CNN array of excitable nonlinear circuits: flat and wrinkled labyrinths,” *Circuits Syst. I ...*, 1993.
- [94] T. Garling, A. Book, and E. Lindberg, “Cognitive Mapping of Large-Scale Environments: The Interrelationship of Action Plans, Acquisition, and Orientation,” *Environ. Behav.*, vol. 16, no. 1, pp. 3–34, Jan. 1984.
- [95] R. Golledge, “Human wayfinding and cognitive maps,” in *Wayfinding Behavior: Cognitive Mapping and Other Spatial Processes*, JHU Press, 1999, pp. 5–45.
- [96] F. Ponulak and J. J. Hopfield, “Rapid, parallel path planning by propagating wavefronts of spiking neural activity.,” *Front. Comput. Neurosci.*, vol. 7, no. July, p. 98, Jan. 2013.
- [97] K. Karahaliloglu and S. Balkir, “Bio-inspired compact cell circuit for reaction-diffusion systems,” *IEEE Trans. Circuits Syst. II Express Briefs*, vol. 52, no. 9, pp. 558–562, 2005.
- [98] U. Khan, “Development of a theoretical framework for the modeling and analysis of optimization issues with applications,” Alpen-Adria-Universität, Klagenfurt, AT, 2010.
- [99] K. Karahaliloglu, P. Gans, N. Schemm, and S. Balkir, “Pixel sensor integrated neuromorphic VLSI system for real-time applications,” *Neurocomputing*, vol. 72, no. 1–3, pp. 293–301, 2008.
- [100] A. P. Muñoz and L. O. Chua, “Shortest-Path-Finder Algorithm in a Two-Dimensional Array of Nonlinear Electronic Circuits,” *International Journal of Bifurcation and Chaos*, vol. 08, no. 12. pp. 2493–2501, 1998.
- [101] R. Yeniceri, V. Kilic, and M. Yalcin, “A new spatio-temporal wave based target tracking algorithm,” in *2010 IEEE 18th Signal Processing and Communications Applications Conference*, 2010, pp. 562–565.
- [102] M. S. Cohen, “Parametric analysis of fMRI data using linear systems methods.,” *Neuroimage*, vol. 6, no. 2, pp. 93–103, 1997.
- [103] G. Boynton and S. Engel, “Linear systems analysis of functional magnetic resonance imaging in human V1,” *J. Neurosci.*, vol. 16, no. 13, pp. 4207–4221, 1996.
- [104] D. Foster, “A model of the human visual system in its response to certain classes of moving stimuli,” *Kybernetik*, 1971.
- [105] O. V. Christian J. van den Branden Lambrecht, “Perceptual Quality Measure using a Spatio-Temporal Model of the Human Visual System,” in *Electronic Imaging: Science & Technology*, 1996, pp. 450–461.

- [106] P. R. Bakic and D. P. Brzakovic, “Extension of CNN based multilevel halftoning to color reproduction,” *Proc. Int. Conf. Image Process.*, vol. 1, pp. 826–829, 1997.
- [107] J. P. Higgins and S. Green, *Cochrane Handbook for Systematic Reviews of Interventions: Cochrane Book Series*. Chichester, UK: John Wiley & Sons, Ltd, 2008.
- [108] University of York, “Centre for Reviews and Dissemination website,” 2011. [Online]. Available: <http://www.crd.york.ac.uk>. [Accessed: 18-Dec-2014].
- [109] “Systematic reviews and meta-analyses: a step-by-step guide | www.ccace.ed.ac.uk.” [Online]. Available: <http://www.ccace.ed.ac.uk/research/software-resources/systematic-reviews-and-meta-analyses>. [Accessed: 18-Dec-2014].
- [110] M. Miljević, “Metodologija naučnog rada,” 2007. [Online]. Available: <http://www.singipedia.com/attachment.php?attachmentid=1625&d=1286898002>. [Accessed: 24-Dec-2014].
- [111] W. Sinnott-Armstrong and R. Fogelin, *Cengage Advantage Books: Understanding Arguments: An Introduction to Informal Logic*. Cengage Learning, 2014.
- [112] Y. Qi and H. Ge, “Modularity and dynamics of cellular networks,” *PLoS Comput. Biol.*, vol. 2, no. 12, pp. 1502–1510, Dec. 2006.
- [113] M. Coltheart, “Modularity and cognition,” *Trends Cogn. Sci.*, vol. 3, pp. 115–120, 1999.
- [114] J. Fodor, “The modularity of mind: An essay on faculty psychology (review).” MIT Press, 1984.
- [115] D. Bray, “Advances in Systems Biology,” *Adv. Exp. Med. Biol.*, vol. 736, pp. 193–198, Jan. 2012.
- [116] J. Sutton, “Review of Jerry Fodor, The Mind Doesn’t Work That Way: the scope and limits of computational psychology,” 2001. [Online]. Available: <http://cogprints.org/1360/>. [Accessed: 04-Feb-2015].
- [117] D. Sperber, “Modularity and relevance: How can a massively modular mind be flexible and context-sensitive?,” in *The Innate Mind: Structure and Content*, P. Carruthers, S. Laurence, and S. P. Stich, Eds. Oxford University Press, 2005, pp. 53–68.
- [118] J. Barkow, L. Cosmides, and J. Tooby, *The Adapted Mind: Evolutionary Psychology and the Generation of Culture*. Oxford University Press, 1992.
- [119] B. Franks, *Culture and cognition: evolutionary perspectives*. Palgrave Macmillan, 2011.

- [120] D. S. Bassett, D. L. Greenfield, A. Meyer-Lindenberg, D. R. Weinberger, S. W. Moore, and E. T. Bullmore, “Efficient physical embedding of topologically complex information processing networks in brains and computer circuits.,” *PLoS Comput. Biol.*, vol. 6, no. 4, p. e1000748, Apr. 2010.
- [121] Y. He, J. Wang, L. Wang, Z. J. Chen, C. Yan, H. Yang, H. Tang, C. Zhu, Q. Gong, Y. Zang, and A. C. Evans, “Uncovering intrinsic modular organization of spontaneous brain activity in humans,” *PLoS One*, vol. 4, no. 4, 2009.
- [122] C. Zhou, L. Zemanová, G. Zamora, C. C. Hilgetag, and J. Kurths, “Hierarchical organization unveiled by functional connectivity in complex brain networks,” *Phys. Rev. Lett.*, vol. 97, no. 23, p. 238103, Dec. 2006.
- [123] L. K. Gallos, H. A. Makse, and M. Sigman, “A small world of weak ties provides optimal global integration of self-similar modules in functional brain networks.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 109, no. 8, pp. 2825–30, Feb. 2012.
- [124] R. Russo, H. J. Herrmann, and L. de Arcangelis, “Brain modularity controls the critical behavior of spontaneous activity.,” *Sci. Rep.*, vol. 4, p. 4312, Jan. 2014.
- [125] C. C. King, “Fractal and chaotic dynamics in nervous systems,” *Prog. Neurobiol.*, vol. 36, no. 4, pp. 279–308, Jan. 1991.
- [126] R. Porter, S. Ghosh, G. D. Lange, and T. G. Smith, “A fractal analysis of pyramidal neurons in mammalian motor cortex,” *Neurosci. Lett.*, vol. 130, no. 1, pp. 112–116, Sep. 1991.
- [127] L. F. Agnati, F. Baluska, P. W. Barlow, and D. Guidolin, “Three explanatory instruments in biology,” *Commun. Integr. Biol.*, vol. 2, no. 6, pp. 552–563, Nov. 2009.
- [128] L. Zhang, “Quantifying Brain White Matter Structural Changes in Normal Aging Using Fractal Dimension,” 2006. [Online]. Available: https://etd.ohiolink.edu/ap/10?0::NO:10:P10_ACCESSION_NUM:case1126213038.
- [129] D. S. Bassett, E. Bullmore, B. A. Verchinski, V. S. Mattay, D. R. Weinberger, and A. Meyer-Lindenberg, “Hierarchical organization of human cortical networks in health and schizophrenia.,” *J. Neurosci.*, vol. 28, no. 37, pp. 9239–48, Sep. 2008.
- [130] C. J. Stam, “Functional connectivity patterns of human magnetoencephalographic recordings: a ‘small-world’ network?,” *Neurosci. Lett.*, vol. 355, no. 1–2, pp. 25–28, Jan. 2004.
- [131] D. J. Watts and S. H. Strogatz, “Collective dynamics of ‘small-world’ networks.,” *Nature*, vol. 393, no. 6684, pp. 440–442, 1998.
- [132] F. A. C. Azevedo, L. R. B. Carvalho, L. T. Grinberg, J. M. Farfel, R. E. L. Ferretti, R. E. P. Leite, W. Jacob Filho, R. Lent, and S. Herculano-Houzel, “Equal numbers of

neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain,” *J. Comp. Neurol.*, vol. 513, no. 5, pp. 532–41, Apr. 2009.

- [133] R. K. Pan and S. Sinha, “Modularity produces small-world networks with dynamical time-scale separation,” *Europhys. Lett.*, vol. 85, no. I, p. 6, Mar. 2008.
- [134] M. I. Rabinovich, P. Varona, A. I. Selverston, and H. D. I. Abarbanel, “Dynamical principles in neuroscience,” *Rev. Mod. Phys.*, vol. 78, 2006.
- [135] W. Gerstner and W. M. Kistler, *Spiking Neuron Models: Single Neurons, Populations, Plasticity*. Cambridge University Press, 2002.
- [136] L. . Abbott, “Lapicque’s introduction of the integrate-and-fire model neuron (1907),” *Brain Res. Bull.*, vol. 50, no. 5–6, pp. 303–304, Nov. 1999.
- [137] A. N. Burkitt, “A review of the integrate-and-fire neuron model: I. Homogeneous synaptic input.,” *Biol. Cybern.*, vol. 95, no. 1, pp. 1–19, Jul. 2006.
- [138] H. Meffin, A. N. Burkitt, and D. B. Grayden, “An analytical model for the ‘large, fluctuating synaptic conductance state’ typical of neocortical neurons *in vivo*,” *J. Comput. Neurosci.*, vol. 16, no. 2, pp. 159–175, Jan. 2004.
- [139] A. L. HODGKIN and A. F. HUXLEY, “A quantitative description of membrane current and its application to conduction and excitation in nerve.,” *J. Physiol.*, vol. 117, no. 4, pp. 500–44, Aug. 1952.
- [140] R. Kobayashi, “Made-to-order spiking neuron model equipped with a multi-timescale adaptive threshold,” *Front. Comput. Neurosci.*, vol. 3, Jul. 2009.
- [141] R. Brette and W. Gerstner, “Adaptive exponential integrate-and-fire model as an effective description of neuronal activity.,” *J. Neurophysiol.*, vol. 94, no. July 2005, pp. 3637–3642, 2005.
- [142] W. Gerstner and R. Naud, “Neuroscience. How good are neuron models?,” *Science*, vol. 326, no. October 2005, pp. 379–380, 2009.
- [143] A. Basu and P. Hasler, “This document is downloaded from DR-NTU , Nanyang Technological Small-signal Neural Models and its Application to determining Model Parameters,” 2012.
- [144] E. M. Izhikevich, “Resonate-and-fire neurons,” *Neural Networks*, vol. 14, no. 6–7, pp. 883–894, 2001.
- [145] N. Brunel, V. Hakim, and M. Richardson, “Firing-rate resonance in a generalized integrate-and-fire neuron with subthreshold resonance,” *Phys. Rev. E*, vol. 67, no. 5, p. 051916, May 2003.

- [146] E. M. Izhikevich, “Simple model of spiking neurons,” *IEEE Transactions on Neural Networks*, vol. 14, no. 6, pp. 1569–1572, 2003.
- [147] C. Rossant, D. F. M. Goodman, B. Fontaine, J. Platkiewicz, A. K. Magnusson, and R. Brette, “Fitting Neuron Models to Spike Trains,” *Front. Neurosci.*, vol. 5, Feb. 2011.
- [148] E. Izhikevich, *Dynamical Systems in Neuroscience: The Geometry of Excitability and Bursting*, vol. 25. MIT Press, 2007.
- [149] A. K. Seth, E. Izhikevich, G. N. Reeke, and G. M. Edelman, “Theories and measures of consciousness: an extended framework.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 103, no. 28, pp. 10799–804, Jul. 2006.
- [150] E. M. Izhikevich and G. M. Edelman, “Large-scale model of mammalian thalamocortical systems.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 105, pp. 3593–3598, 2008.
- [151] H. R. Wilson and J. D. Cowan, “Excitatory and inhibitory interactions in localized populations of model neurons.,” *Biophys. J.*, vol. 12, no. 1, pp. 1–24, Jan. 1972.
- [152] B. W. Knight, “The relationship between the firing rate of a single neuron and the level of activity in a population of neurons. Experimental evidence for resonant enhancement in the population response.,” *J. Gen. Physiol.*, vol. 59, no. 6, pp. 767–778, 1972.
- [153] M. Mattia and P. Del Giudice, “Population dynamics of interacting spiking neurons.,” *Phys. Rev. E. Stat. Nonlin. Soft Matter Phys.*, vol. 66, no. 5 Pt 1, p. 051917, Nov. 2002.
- [154] O. Shriki, D. Hansel, and H. Sompolinsky, “Rate models for conductance-based cortical neuronal networks.,” *Neural Comput.*, vol. 15, no. 8, pp. 1809–41, Aug. 2003.
- [155] Y. Aviel and W. Gerstner, “From spiking neurons to rate models: a cascade model as an approximation to spiking neuron models with refractoriness.,” *Phys. Rev. E. Stat. Nonlin. Soft Matter Phys.*, vol. 73, no. 5 Pt 1, p. 051908, May 2006.
- [156] G. La Camera, A. Rauch, H.-R. Lüscher, W. Senn, and S. Fusi, “Minimal models of adapted neuronal response to in vivo-like input currents.,” *Neural Comput.*, vol. 16, no. 10, pp. 2101–24, Oct. 2004.
- [157] S. Ostoic and N. Brunel, “From spiking neuron models to linear-nonlinear models,” *PLoS Comput. Biol.*, vol. 7, no. 1, p. e1001056, Jan. 2011.
- [158] N. Brunel and S. Sergi, “Firing frequency of leaky integrate-and-fire neurons with synaptic current dynamics.,” *J. Theor. Biol.*, vol. 195, no. 1, pp. 87–95, 1998.
- [159] N. Fourcaud and N. Brunel, “Dynamics of the firing probability of noisy integrate-and-fire neurons.,” *Neural Comput.*, vol. 14, no. 9, pp. 2057–2110, 2002.

- [160] P. Dayan and L. F. Abbott, *Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems*. Massachusetts Institute of Technology Press, 2001.
- [161] O. Nordbø, J. Wyller, and G. T. Einevoll, “Neural network firing-rate models on integral form: effects of temporal coupling kernels on equilibrium-state stability.,” *Biol. Cybern.*, vol. 97, no. 3, pp. 195–209, Sep. 2007.
- [162] E. Nordlie, T. Tetzlaff, and G. T. Einevoll, “Rate Dynamics of Leaky Integrate-and-Fire Neurons with Strong Synapses.,” *Front. Comput. Neurosci.*, vol. 4, p. 149, Jan. 2010.
- [163] K. D. Miller and F. Fumarola, “Mathematical Equivalence of Two Common Forms of Firing Rate Models of Neural Networks,” *Neural Computation*, vol. 24, no. 1. pp. 25–31, Jan-2012.
- [164] N. Brunel, V. Hakim, and M. J. E. Richardson, “Single neuron dynamics and computation,” *Current Opinion in Neurobiology*, vol. 25. Elsevier Ltd, pp. 149–155, 2014.
- [165] T. Troyer, *An Introduction to Computational Neuroscience*. University of Texas at San Antonio, USA, 2007.
- [166] M. H. Higgs, S. J. Slee, and W. J. Spain, “Diversity of gain modulation by noise in neocortical neurons: regulation by the slow afterhyperpolarization conductance.,” *J. Neurosci.*, vol. 26, no. 34, pp. 8787–8799, Aug. 2006.
- [167] N. Fourcaud-Trocmé and N. Brunel, “Dynamics of the instantaneous firing rate in response to changes in input statistics,” *J. Comput. Neurosci.*, vol. 18, no. 3, pp. 311–321, Jun. 2005.
- [168] K. Thurley, W. Senn, and H.-R. Lüscher, “Dopamine increases the gain of the input-output response of rat prefrontal pyramidal neurons.,” *J. Neurophysiol.*, vol. 99, no. 6, pp. 2985–2997, 2008.
- [169] E. Yaksi and R. W. Friedrich, “Reconstruction of firing rate changes across neuronal populations by temporally deconvolved Ca²⁺ imaging.,” *Nat. Methods*, vol. 3, no. 5, pp. 377–383, 2006.
- [170] Z. Kilpatrick, “Wilson-Cowan Model,” in *Encyclopedia of Computational Neuroscience*, D. Jaeger and R. Jung, Eds. New York, NY: Springer New York, 2013, pp. 1–5.
- [171] J. A. Acebrón, L. L. Bonilla, C. J. P. Vicente, F. Ritort, and R. Spigler, “The Kuramoto model: A simple paradigm for synchronization phenomena,” *Rev. Mod. Phys.*, vol. 77, no. 1, pp. 137–185, 2005.
- [172] Y. Kuramoto, *Chemical oscillations, waves, and turbulence*. Springer, Berlin, 1984.

- [173] F. Pasemann, “Neuromodules: A dynamical systems approach to brain modelling,” in *Supercomputing in Brain Research - From Tomography to Neural Networks*, H. J. Herrmann, D. E. Wolf, and E. Poeppel, Eds. World Scientific Publishing, 1995, pp. 331–347.
- [174] M. M. Churchland, J. P. Cunningham, M. T. Kaufman, S. I. Ryu, and K. V Shenoy, “Cortical preparatory activity: representation of movement or first cog in a dynamical machine?,” *Neuron*, vol. 68, no. 3, pp. 387–400, Nov. 2010.
- [175] G. Deco, V. K. Jirsa, and A. R. McIntosh, “Emerging concepts for the dynamical organization of resting-state activity in the brain.,” *Nat. Rev. Neurosci.*, vol. 12, no. 1, pp. 43–56, 2011.
- [176] C. J. Honey, R. Kötter, M. Breakspear, and O. Sporns, “Network structure of cerebral cortex shapes functional connectivity on multiple time scales.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 104, no. 24, pp. 10240–10245, Jun. 2007.
- [177] A. Ghosh, Y. Rho, A. R. McIntosh, R. Kötter, and V. K. Jirsa, “Noise during rest enables the exploration of the brain’s dynamic repertoire,” *PLoS Comput. Biol.*, vol. 4, no. 10, 2008.
- [178] G. Deco, V. Jirsa, A. R. McIntosh, O. Sporns, and R. Kötter, “Key role of coupling, delay, and noise in resting brain fluctuations.,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 106, no. 25, pp. 10302–7, Jun. 2009.
- [179] A. Pascual-Leone, C. Freitas, L. Oberman, J. C. Horvath, M. Halko, M. Eldaief, S. Bashir, M. Vernet, M. Shafi, B. Westover, A. M. Vahabzadeh-Hagh, and A. Rotenberg, “Characterizing brain cortical plasticity and network dynamics across the age-span in health and disease with TMS-EEG and TMS-fMRI.,” *Brain Topogr.*, vol. 24, no. 3–4, pp. 302–15, Oct. 2011.
- [180] G. K. H. John M. Petitto, “Reversal of Neuronal Atrophy: Role of Cellular Immunity in Neuroplasticity and Aging,” *J. Neurol. Disord.*, vol. 02, no. 04, 2014.
- [181] “Small Signal Circuit Models.” [Online]. Available: <https://6002x.mitx.mit.edu/wiki/view/SmallSignalCircuitModels>. [Accessed: 14-May-2015].
- [182] R. Shapley, “Linear and nonlinear systems analysis of the visual system: Why does it seem so linear?. A review dedicated to the memory of Henk Spekreijse,” *Vision Res.*, vol. 49, no. 9, pp. 907–921, 2009.
- [183] D. S. Reich, F. Mechler, and J. D. Victor, “Independent and redundant information in nearby cortical neurons.,” *Science*, vol. 294, no. 5551, pp. 2566–2568, 2001.
- [184] M. A. Arbib, *The Handbook of Brain Theory and Neural Networks*. MIT Press, 2003.

- [185] J. Gleick, *The Information: A History, a Theory, a Flood*. Knopf Doubleday Publishing Group, 2011.
- [186] M. M. Churchland, J. P. Cunningham, M. T. Kaufman, J. D. Foster, P. Nuyujukian, S. I. Ryu, and K. V Shenoy, “Neural population dynamics during reaching.,” *Nature*, vol. 487, no. 7405, pp. 51–6, Jul. 2012.
- [187] A. Chen and J. Cao, “Existence and attractivity of almost periodic solutions for cellular neural networks with distributed delays and variable coefficients,” *Appl. Math. Comput.*, vol. 134, no. 1, pp. 125–140, Jan. 2003.
- [188] I. Szatmari, “Pattern formation in oscillatory media: Beyond reaction-diffusion model,” *Cell. Nanoscale Networks Their Appl. (CNNA), 2010 12th Int. Work.*, 2010.
- [189] J. Fujii, Y. Hosokawa, and Y. Nishio, “Wave Phenomena in Cellular Neural Networks Using Two Kinds of Template Sets,” in *Proc. of NOLTA ’07*, 2007, pp. 23–26.
- [190] Z. Yang, K. Tsuruta, Y. Nishio, and A. Ushida, “Investigation of phase-wave propagation phenomena in second order CNN arrays,” *2004 IEEE Int. Symp. Circuits Syst. (IEEE Cat. No.04CH37512)*, vol. 3, 2004.
- [191] Y. Zonghuang, Y. Nishio, and A. Ushida, “Generation of various types of spatio-temporal phenomena in two-layer cellular neural networks,” *IEICE Trans. Fundam. Electron. Commun. Comput. Sci.*, vol. E87-A, no. 4, pp. 864–871, 2004.
- [192] Y. Zonghuang, Y. Nishio, and A. Ushida, “Image Processing of Two-Layer CNNs-- Applications and Their Stability--,” *IEICE Trans. Fundam. Electron. Commun. Comput. Sci.*, vol. E85-A, no. 9, pp. 2052–2060, 2002.
- [193] Y. Hamasaki, T. Shimokawa, K. Ishida, Y. Komatsuzaki, S. Watanabe, and M. Saito, “Coherency Evaluation of Spatiotemporal Neural Activities in the Molluscan Olfactory Center Applying Extracellular Recording with Wavelet Analysis,” *Open J. Biophys.*, vol. 03, no. 04, pp. 291–297, Jul. 2013.
- [194] W. J. FREEMAN, “Distribution in time and space of prepyriform electrical activity.,” *J. Neurophysiol.*, vol. 22, no. 6, pp. 644–665, Nov. 1959.
- [195] H. Spors and A. Grinvald, “Spatio-Temporal Dynamics of Odor Representations in the Mammalian Olfactory Bulb,” *Neuron*, vol. 34, no. 2, pp. 301–315, Apr. 2002.
- [196] T. J. Ellender, W. Nissen, L. L. Colgin, E. O. Mann, and O. Paulsen, “Priming of hippocampal population bursts by individual perisomatic-targeting interneurons.,” *J. Neurosci.*, vol. 30, no. 17, pp. 5979–91, Apr. 2010.
- [197] F. Maestú, A. Fernández, P. G. Simos, P. Gil-Gregorio, C. Amo, R. Rodriguez, J. Arrazola, and T. Ortiz, “Spatio-temporal patterns of brain magnetic activity during a memory task in Alzheimer’s disease.,” *Neuroreport*, vol. 12, no. 18, pp. 3917–3922, 2001.

- [198] L. E. Sergio and J. F. Kalaska, “Changes in the temporal pattern of primary motor cortex activity in a directional isometric force versus limb movement task.,” *J. Neurophysiol.*, vol. 80, no. 3, pp. 1577–1583, 1998.
- [199] E. Seifritz, F. Esposito, F. Hennel, H. Mustovic, J. G. Neuhoff, D. Bilecen, G. Tedeschi, K. Scheffler, and F. Di Salle, “Spatiotemporal pattern of neural processing in the human auditory cortex.,” *Science*, vol. 297, no. 5587, pp. 1706–1708, 2002.
- [200] R. Ivey, D. Bullock, and S. Grossberg, “A neuromorphic model of spatial lookahead planning,” *Neural Networks*, vol. 24, no. 3, pp. 257–266, Apr. 2011.
- [201] A. Cichocki and R. Unbehauen, “Neural networks for solving systems of linear equations and related problems,” *IEEE Trans. Circuits Syst. I Fundam. Theory Appl.*, vol. 39, no. 2, pp. 124–138, 1992.
- [202] W. E. Lillo, M. H. Loh, S. Hui, and S. H. Zak, “On solving constrained optimization problems with neural networks: a penalty method approach.,” *IEEE Trans. Neural Netw.*, vol. 4, no. 6, pp. 931–940, Jan. 1993.
- [203] D. Cvetković, D. Simić, D. Strukture, and U. Predavanje, “Metodi optimizacije,” in *Diskretna matematika*, Naučna knjiga, Beograd, Yugoslavia, 1990.
- [204] K. G. Murty, *Linear programming*. New York: John Wiley & Sons, Inc., 1983.
- [205] C. Y. Maa and M. A. Shanblatt, “Linear and quadratic programming neural network analysis.,” *IEEE Trans. Neural Netw.*, vol. 3, no. 4, pp. 580–594, 1992.
- [206] M. Kennedy and L. Chua, “Neural networks for nonlinear programming,” *IEEE Trans. Circuits Syst.*, vol. 35, no. 5, 1988.
- [207] D. Luenberger, “Penalty and Barrier Methods,” in *Introduction to linear and nonlinear programming*, Addison-Wesley, 1973.
- [208] N. Brunel, “Dynamics of neuronal networks,” *Third Annual French Complex Systems Summer School, Lyon and Paris, July 20-August 14, 2009*. [Online]. Available: <http://www.iscpif.fr/tiki-index.php?page=CSSS2009CourseBrunel>. [Accessed: 17-Mar-2015].
- [209] A. Grabska-Barwińska and P. E. Latham, “How well do mean field theories of spiking quadratic-integrate-and-fire networks work in realistic parameter regimes?,” *J. Comput. Neurosci.*, vol. 36, no. 3, pp. 469–481, 2014.
- [210] C. Stevens and A. Zador, “When is an Integrate-and-fire Neuron like a Poisson Neuron?,” in *Advances in Neural Information Processing Systems 8*, D. Touretzky, M. Mozer, and M. Hasselmo, Eds. 1996, pp. 103–109.
- [211] C. M. Comer and R. M. Robertson, “Identified nerve cells and insect behavior,” *Prog. Neurobiol.*, vol. 63, no. 4, pp. 409–439, Mar. 2001.

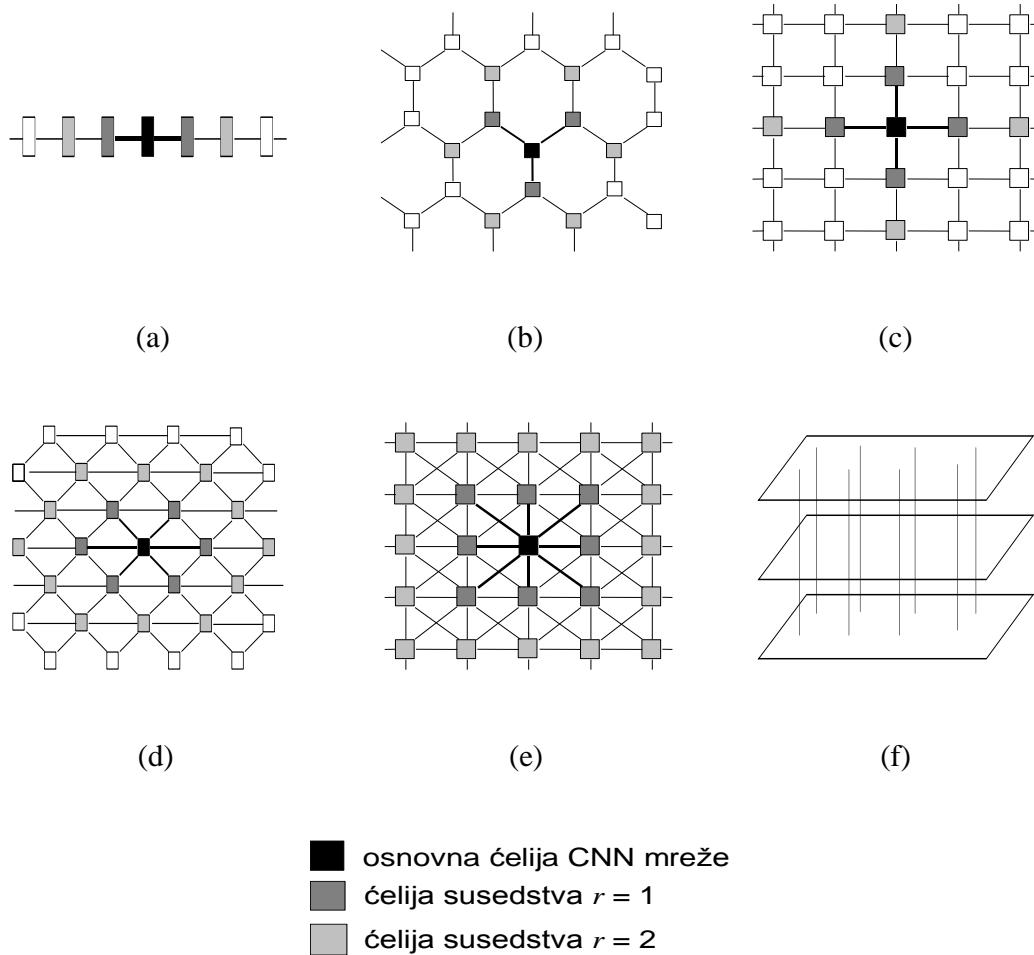
- [212] J. Zhang, “Global stability analysis in delayed cellular neural networks,” *Computers & Mathematics with Applications*, vol. 45, no. 10–11, pp. 1707–1720, 2003.
- [213] Y.-L. Lin, J.-G. Hsieh, and J.-H. Jeng, “Robust decomposition with guaranteed robustness for cellular neural networks implementing an arbitrary Boolean function,” *Neurocomputing*, vol. 143, pp. 339–346, 2014.
- [214] M. Di Marco, M. Forti, and A. Tesi, “On The Margin Of Complete Stability For A Class Of Cellular Neural Networks,” *Int. J. Bifurc. Chaos*, vol. 18, no. 05, pp. 1343–1361, 2008.
- [215] Y. Lin, J. Hsieh, and J. Jeng, “Robust Template Decomposition without Weight Restriction for Cellular Neural Networks Implementing Arbitrary Boolean Functions Using Support Vector Classifiers,” *Math. Probl. Eng.*, 2013.
- [216] G. Eyal, H. D. Mansvelder, C. P. J. de Kock, and I. Segev, “Dendrites impact the encoding capabilities of the axon.,” *J. Neurosci.*, vol. 34, no. 24, pp. 8063–71, Jun. 2014.

9 Prilozi

9.1 Prilog 1: Celularne neuralne mreže – osnovni pojmovi i definicije

Napomena: Preuzeto uz prilagođenja iz [27] (magistarska teza autora ove disertacije, koja nije dostupna u elektronskoj formi te se ovde prenose delovi na koje se referiše ova teza a kako bi se pomoglo čitaocu).

9.1.1 Osnovne strukture CNM mreža



Slika 26: Osnovni tipovi strukture CNM mreža: a) linjska, b)-e) različiti oblici površinske (2D) strukture, f) prostorna (3D) struktura. Različitom šrafurom je označeno susedstvo dimenzije $r = 1$ i $r = 2$, a veze čelija susedstva $r = 1$ su prikazane debljim linijama.

U svom osnovnom vidu ([20], [21]) CNM mreža predstavlja skup prostih, identičnih, nelinearnih, dinamičkih, procesirajućih elemenata - celija (engl. *cells*), prikazanih u vidu pravougaonika (Slika 26), koji su u pravilnom geometrijskom rasporedu. Mada raspored elemenata može biti različit, linijski (1D) ili površinski (2D) sa različitom strukturom rešetke, u praksi se, najčešće, koristi pravougaona rešetka (Slika 26 c-e). Površinska struktura se može proširiti na prostornu (3D), ukoliko međusobno povežemo pojedine ravnin, ili višedimenzionu (n D, sa $n > 3$).

Svaka celija direktno komunicira samo sa svojim susedstvom, što je simbolički prikazano linijama koje povezuju celije (Slika 26). Celije koje nisu direktno vezane utiču, takođe, jedna na drugu, ali posredno, na osnovu efekta prostiranja signala kroz mrežu. Definiše se dimenzija susedstva (naziva se i receptivno polje), r , u odnosu na posmatranu celiju, unutar kojeg celije direktno komuniciraju. Različitom šrafurom je označeno susedstvo dimenzije $r = 1$ i $r = 2$, a veze celija susedstva $r = 1$ su prikazane debljim linijama.

9.1.2 Osnovni pojmovi

Danas se CNM koristi kao generički pojam koji se odnosi na klasu nelinearnih mreža koje ispunjavaju sledeće uslove ([19]):

Definicija: Celularna neuralna mreža (CNM) je:

1. jedno-, dvo-, tro- ili n -dimenzionalni **niz od**
2. uglavnom **identičnih dinamičkih sistema**, nazvanih celije, koje zadovoljavaju sledeća dva uslova:
 - većina **interakcija je lokalnog karaktera** unutar konačnog radijusa r (susedstva N_r), i
 - sve **promenljive stanja su kontinualni signali**.

Interakcija između svake celije i njenog susedstva definisana je šablonima (engl. *templates*), nazvanih i sinapsama, koji opisuju vezu ulazne, izlazne i promenljive stanja, respektivno označene simbolima u , y i x . Uobičajeno se koriste naponski signali, ali to nije

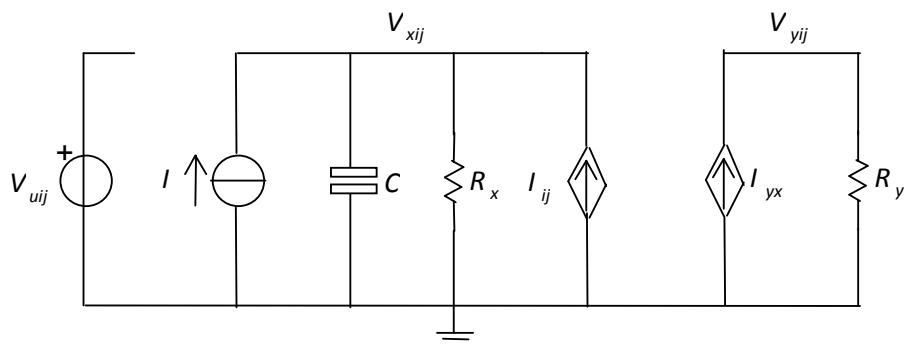
pravilo: mogu biti i strujni, svetlosni, a, verovatno, i neke druge prirode - možda hemijski, i slično.

Napomene:

- Svaka ćelija se identificuje u mreži pomoću 1, 2, 3, ili n , celih brojeva (i, j, k, \dots, n) - dakle, prostorna promenljiva je uvek diskretizovana.
- Vremenska promenljiva, t , može biti kontinualna, ili diskretna.
- Interkonekcioni efekat, opisan klonirajućim šablonom, može biti linearna ili nelinearna, vremenski promenljiva ili invarijantna funkcija promenljivih stanja, izlaza i ulaza svih ćelija unutar susedstva N_r , radijusa r . U opštem slučaju klonirajući šablon nije prostorno invarijantan, mada se, često, koristi u takvom obliku.
- Dinamički sistem je jedinstveno određen diferencijalnim, odnosno, diferencnim (za rad u diskretnom vremenu), jednačinama stanja kola.
- U nekim slučajevima dinamički sistem i/ili interkonekcije mogu biti podvrgnuti nekim izvorima šuma, poznate statistike.

9.1.3 Originalna struktura CNM

Originalna struktura CNM ćelije [21] predstavljena je kao električni konduktansni model po ugledu na model biološkog neurona (Slika 27). Podrazumeva se da je reč o proizvoljnom čvoru $C(i,j)$ pravougaone rešetke, dimenzije $M \times N$, koja je u uobičajenoj upotrebi. U svakom čvoru rešetke nalazi se po jedan identičan procesirajući element - ćelija (Slika 27).



Slika 27: Originalna CNM ćelija, prema modelu Chua i Yang ([21]).

Jezgro ćelije čine kondenzator kapacitivnosti C i otpornik otpornosti R_x : oni definišu dinamičko ponašanje i određuju brzinu rada ćelije, a time i ukupne mreže. Sa V_u i V_y su označeni ulazni i izlazni napon ćelije, a napon kondenzatora, V_x , je promenljiva stanja. Dodatni indeksi ij se odnose na položaj ćelije u rešetki. Nezavisni strujni izvor, konstantne struje I , definiše polarizaciju (engl. *bias*) ćelije. Kontrolisani strujni izvori (transkonduktansni pojačavači) obezbeđuju međusobnu komunikaciju ćelija u mreži i definišu nelinearnost ulazno-izlazne karakteristike²⁴. Konkretno, struja I_{ij} prvog kontrolisanog strujnog izvora je određena sledećim izrazom

$$I_{ij} = \sum_{(k,l) \in N_r(i,j)} A(i, j; k, l) V_{ykl} + \sum_{(k,l) \in N_r(i,j)} B(i, j; k, l) V_{ulk} \quad (23)$$

Sa $N_r(i, j)$ je označeno susedstvo (engl. *neighborhood*), radijusa r , date ćelije $C(i,j)$. Iz relacije (23) vidimo da ovu struju definišu ne samo sopstveni ulazni i izlazni napon ćelije $C(i,j)$, već i ulazni i izlazni naponi susednih ćelija $C(k,l)$, $(k,l) \neq (i,j)$. Izborom vrednosti konduktansi $A(i,j;k,l)$ i $B(i,j;k,l)$ definiše se uticaj izlaznog, odnosno, ulaznog napona ćelije $C(k,l)$ na struju I_{ij} . Za prepostavljenu pravougaonu strukturu mreže (Slika 26 c ili e), konduktanse $A(i,j;k,l)$ i $B(i,j;k,l)$ se efikasno izražavaju u formi matrica. Kako su sve ćelije mreže identične, to će i ove matrice biti istog oblika za bilo koju ćeliju, $C(i,j)$, date mreže²⁵. Dobijene matrice, označimo ih sa **A** i **B**, su, u ovom, najprostijem, vidu, invarijantne od položaja u mreži, a nazivaju se šablonima (engl. *templates*), kao što smo već napomenuli. Pri tome, kako matrica **A** iskazuje uticaj izlaznih napona na struju kontrolisanog izvora ćelije, ona se naziva i povratnim šablonom (engl. *feedback template*), a matrica **B**, koja opisuje uticaj ulaznih napona, jeste direktni (ili kontrolni) šablon (engl. *feedforward/control template*). Članovi ovih matrica, koji su po prirodi konduktanse, nazivaju se i sinapsama, a susedstvo ćelije se naziva i receptivnim poljem (po analogiji sa biološkim neuronskim mrežama), što je već napomenuto.

²⁴ Primetimo da se u realizaciji mreže mogu koristiti i naponski pojačavači.

²⁵ Izuzetak su ivične ćelije mreže, za koje ne postoji isto susedstvo sa svih strana, ali se, uobičajeno, smatra da je (i) mreža dovoljno velikih dimenzija, odnosno, da su (ii) ivičnim ćelijama, na pogodan način, obezbeđeni korektni granični uslovi.

Napon kondenzatora (promenljiva stanja), V_x , kontroliše struju drugog kontrolisanog izvora struje, I_{yx} , date ćelije i stvara na otporniku R_y potreban izlazni napon:

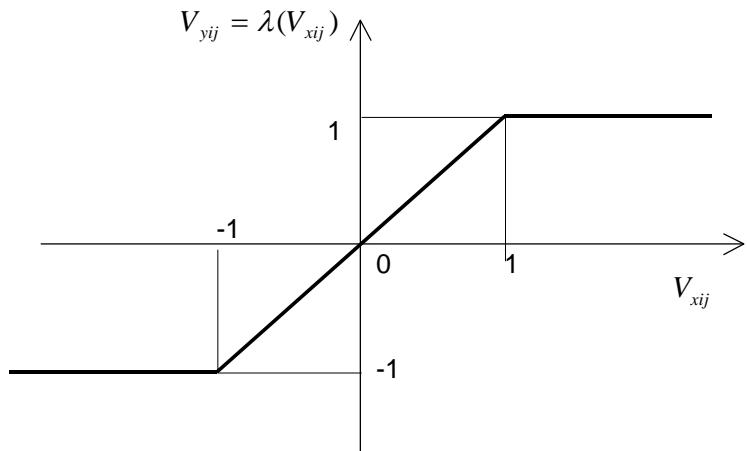
$$\begin{aligned} V_{yij} &= R_y I_{yx} \\ I_{yx} &= f(V_{xij}) \end{aligned} \quad (24)$$

i time je izlazni napon, zapravo, kontrolisan naponom stanja ćelije:

$$V_{yij} = g(V_{xij}) \quad (25)$$

Da bi ćelija došla u stabilno stanje ova veza mora biti nelinearna - uobičajeno je sigmoidnog oblika, mada se koriste i drugi vidovi nelinearne izlazne karakteristike ćelije. U analizi se, često, razmatra deo-po-deo linearna (*piecewise linear, PWL*) izlazna karakteristika jediničnog pojačanja u radnoj oblasti (Slika 28), koja je opisana sa

$$V_{yij} = \hat{V}_{xij} = g(V_{xij}) = \lambda(V_{xij}) = \frac{1}{2}(|V_{xij} + 1| - |V_{xij} - 1|) \quad (26)$$



Slika 28: Standardna nelinearna deo-po-deo linearna (*piecewise linear, PWL*) izlazna karakteristika CNM ćelije.

Jednačina stanja takve CNM ćelije je tada:

$$C \frac{dV_{xij}}{dt} = -\frac{V_{xij}}{R_x} + \sum_{(k,l) \in N_r(i,j)} A(i, j; k, l) V_{ykl} + \sum_{(k,l) \in N_r(i,j)} B(i, j; k, l) V_{ukl} + I \quad (27)$$

dok je izlazna promenljiva određena relacijama (25) i (26). Za dati skup ulaznih signala i početnih vrednosti promenljivih stanja, dinamičko ponašanje ćelije i vrednosti izlaza, određeni su samo sinapsama **A** i **B**, kao i strujom polarizacije, *I*. Ove veličine formiraju skup nazvan klonirajući šabloni (engl. *cloning templates*): $T(\mathbf{A}, \mathbf{B}, I)$. Rad CNM mreže se može simbolički opisati relacijom

$$\left. \begin{array}{c} V_{xij}(0) \\ V_{u_{ij}}(t) \end{array} \right\} \xrightarrow{F} V_{yij}(t) \quad (28)$$

gde *F* označava funkciju preslikavanja, koja je određena klonirajućim šablonom $T(\mathbf{A}, \mathbf{B}, I)$: $F = F(T)$. Nakon prelaznog stanja, što traje nekoliko vremenskih konstanti ćelije, mreža je u stabilnom stanju kada su izlazi ćelija vrednosti +1 ili -1, zavisno od izabranog klonirajućeg šablonu. Primetimo da se u mnogim slučajevima ne koriste posebne ulazne promenljive, već se početna stanja, $V_{xij}(0)$, tretiraju kao početne ulazne vrednosti, koje se obrađuju u mreži.

U slučaju pravougaone rešetke (Slika 26e), i za minimalno susedstvo: $r = 1$, ukupan broj parametara koji određuju ponašanje mreže - dakle, ukupan broj parametara klonirajućeg šablonu - maksimalno iznosi 19, bez obzira na veličinu mreže. To su: $2 \times 9 = 18$ konduktansi u matricama **A** i **B** (ili manje, jer su u mnogim primenama izvesni članovi matrica **A** i **B** jednaki nuli), i struja polarizacije, *I*. Ovo je veoma značajan podatak, jer pokazuje da se sa malim brojem kontrolnih parametara može upravljati radom mreže.

Napomenimo da u opštem slučaju nezavisni strujni izvor ne mora biti isti za sve ćelije, već može zavisiti od položaja ćelije u mreži. Time se povećavaju mogućnosti mreže, ali se i povećava broj kontrolnih promenljivih.

Za razliku od drugih standardnih analognih procesora, ili neuralnih mreža, u slučaju CNM sa pravougaonom rešetkom postoji jednoznačna korespondencija između procesirajućih elemenata i elemenata 2D signala (kao što je signal slike, čiji elementi su poznati kao pikseli), što je veoma korisno za primenu u obradi slike. Ujedno, tada su i šabloni **A** i **B** pravilne geometrijske strukture (koja, često, odgovara maskama, poznatim iz standardne digitalne obrade slike), što olakšava projektovanje mreže za datu primenu.

Chua i Yang su u [21] pokazali i ključno svojstvo CNM opisana jednačinama stanja (27): da ona spontano minimizira „generalisanu energiju“ koja se može predstaviti u formi funkcije Ljapunova oblika:

$$E = -\frac{1}{2} \sum_{(i,j)(k,l)} A(i, j; k, l) V_{ykl} V_{yij} + \frac{1}{2R_x} \sum_{(i,j)} V_{yij} V_{yij} - \sum_{(i,j)(k,l)} B(i, j; k, l) V_{ukl} V_{yij} - I \sum_{(i,j)} V_{yij} \quad (29)$$

i konvergira (asimptotski je stabilna) ako su veze između ćelija simetrične (matrica šablonu **A** ima simetričnu strukturu tj. $A(i, j; k, l) = A(k, l; i, j)$).

9.2 Prilog 2: Fraktalna modularizacija u CNM

Napomena: Preuzeto uz prilagođenja iz magistarske teze [27] i objavljenih radova autora ove disertacije ([81], [28], [82], [83]).

9.2.1 Rešavanje sistema linearnih algebarskih jednačina pomoću LSS CNM

Chickocki i Unbehauen su u radu [201] opisali nekoliko mreža Hopfieldovog tipa namenjenih za rešavanje sistema linearnih algebarskih jednačina. Iako su te mreže veoma brze i tačne, povezivanje svakog neurona sa svakim drugim u mreži je veoma nepogodna topologija za VLSI implementaciju. Ovde će biti pokazano kako se isti problem može rešiti pomoću LSS (engl. *Linear System Solver*) CNM mreže koja je, zahvaljujući svojim lokalnim vezama, upravo pogodna za VLSI realizaciju.

Pretpostavimo da je dat sledeći sistem linearnih jednačina:

$$\mathbf{Ax} = \mathbf{b} \quad (30)$$

gde je **A** matrica koeficijenata, **x** vektor promenljivih i **b** vektor konstanti:

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & & & \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix}$$

$$\mathbf{x} = [x_1 \quad x_2 \quad \dots \quad x_n]^T, \quad \mathbf{b} = [b_1 \quad b_2 \quad \dots \quad b_m]^T$$

pri čemu je, u opštem slučaju, $m \leq n$. Problem rešavanja sistema (30) može se svesti na nalaženje praktikularnog vektora vrednosti \mathbf{x}^e vektora \mathbf{x} tako da sistem (30) bude zadovoljen.

U [21] je pokazano da bazična CNM (Slika 27), opisana jednačinama stanja (27), minimizira funkciju Ljapunova koja je oblika:

$$E = -\frac{1}{2} \sum_{(i,j)(k,l)} A(i, j; k, l) V_{ykl} V_{yij} + \frac{1}{2R_x} \sum_{(i,j)} V_{yij} V_{yij} - \sum_{(i,j)(k,l)} B(i, j; k, l) V_{ukl} V_{yij} - I \sum_{(i,j)} V_{yij} \quad (31)$$

i konvergira (asimptotski je stabilna) ako su ispunjeni sledeći uslovi:

$$A(i, j; k, l) = 0, \text{ za } C(k, l) \notin N_r(i, j) \quad (32')$$

$$A(i, j; k, l) = A(k, l; i, j) \quad (32'')$$

$$C > 0, R_x > 0 \quad (32''')$$

Primetimo da uslov (32'), postojanje samo lokalnih veza, iziskuje drugačiji pristup realizaciji CNM mreže u odnosu na realizaciju mreže u kojoj su dozvoljene veze svakog neurona sa bilo kojim drugim - što je bio slučaj sa mrežama Hopfieldovog tipa u [201]. Tako, direktna primena kriterijuma najmanje kvadratne greška (engl. *Least Square - LS*) na (30):

$$\begin{aligned} E &= \sum_{i=1}^m r_i^2(\mathbf{x}) \\ r_i(\mathbf{x}) &= a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n - b_i \end{aligned} \quad (33)$$

slično kao što je to urađeno u [201], dovela bi do funkcije Ljapunova oblika (31) ali, u opštem slučaju, uslov (32') ne bi bio zadovoljen. Dakle, to ne bi bila funkcija Ljapunova CNM mreže jer sistem uslova (32) nije ispunjen. To je i razlog što moramo konstruisati novi sistem u kojem bi se u svakoj jednačini pojavljivale samo susedne promenljive (izlazi susednih celija prema uslovu (32')) i taj novi sistem mora biti ekvivalentan (proširen) u odnosu na (30). Proširivanje se podrazumeva da je izvršeno tako da rešenje tog novog sistema u sebi sadrži, kao podskup, rešenje \mathbf{x}^e polaznog sistema (30).

Razmotrimo, dakle, sledeći sistem linearnih jednačina ($i = 1 \dots n, j = 1 \dots m$):

$$S_{ij} = S_{i(j+1)} + a_{ij}x_{ij} \quad (34')$$

$$x_{ij} = x_{(i-1)j}, i \neq 1 \quad (34'')$$

$$S_{i(n+1)} \equiv 0, S_{i1} \equiv b_i \quad (34''')$$

Prostom zamenom može se dobiti sistem ekvivalentan ovome u smislu rešenja x_{ij} (za $i = 1 \dots m, j = 1 \dots n$):

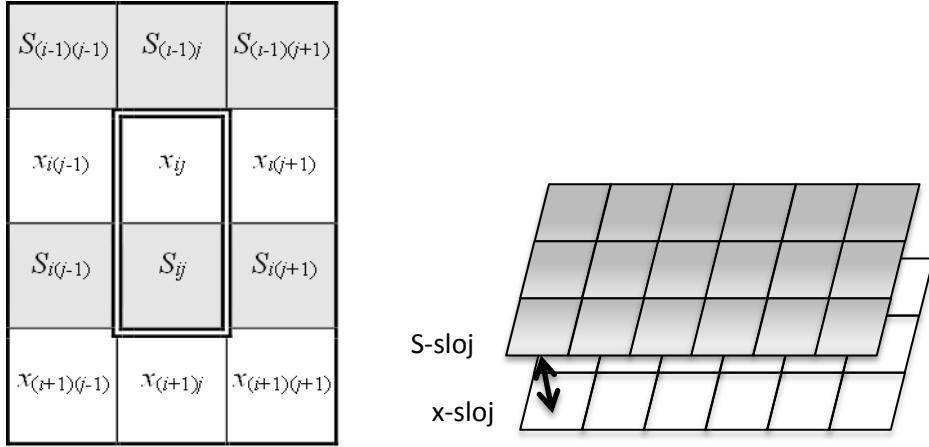
$$b_i = a_{i1}x_{i1} + \dots + a_{in}x_{in} \quad (35)$$

$$x_{1j} = x_{2j} = \dots = x_{mj}$$

Ako prepostavimo $x_j := x_{1j} = \dots = x_{mj}$ onda (35) postaje (30). Prema tome, kako je (35) ekvivalentan (u smislu rešenja) sa (34) i (30), onda je podskup rešenja x_{ij} sistema (34) ujedno i rešenje polaznog sistema (30) ($i \in \{1, \dots, m\}$):

$$\mathbf{x}^e = [x_1^e, \dots, x_j^e, \dots, x_n^e]^T = [x_{i1}, \dots, x_{ij}, \dots, x_{in}]^T$$

Svaka jednačina u (34) sadrži samo varijable čiji se indeksi razlikuju maksimalno za 1. To znači da će se primenom LS kriterijuma na (34) dobiti struktura u kojoj postoje veze samo između susednih celija. Naravno, dimenzija susedstva zavisi od konkretne geometrije CNM mreže i u slučaju proste kvadratne ravne topologije, celije se mogu rasporediti tako da je veličina susedstva $r = 2$ (Slika 29).



Slika 29: Raspored ćelija CNM mreže za rešavanje sistema linearnih algebarskih jednačina (LSS CNM). Po jedna korespondentna (i, j) x i S ćelija čine „modul“. Ovakva topologija se može predstaviti i kao dvoslojna mreža.

Dakle, primenom LS kriterijuma na (34), dobijamo funkciju sličnu (31) što je funkcija Ljapunova za CNM mrežu sa ekvilibrijumima korespondnim globalnom minimumu funkcije Ljapunova koji sadrže, kao podskup, vektor rešenja \mathbf{x}^e sistema (30).

Prvo, definišimo ostatke $r(\cdot)$ svih jednačina u (34):

$$r(S_{ij}) = -S_{ij} + S_{i(j+1)} + a_{ij}x_{ij}$$

$$r(x_{ij}) = \begin{cases} -x_{ij} + x_{(i-1)j} & , i \neq 1 \\ 0 & , i = 1 \end{cases} \quad (36)$$

Sada, funkcija Ljapunova se može formirati prema [202] kao

$$E = \mu \sum_{(i,j)} r^2(x_{ij}) + \sum_{(i,j)} r^2(S_{ij}) \quad , \mu > 0 \quad (37)$$

Razvojem (37) i upoređivanjem sa (31), dobijamo parametre CNM mreže i, time, jednačine stanja ćelija ($C = 1, R_x \rightarrow \infty$):

$$\frac{dx_{ij}}{dt} = -(a_{ij}^2 + 2\mu)\hat{x}_{ij} + a_{ij}\hat{S}_{ij} - a_{ij}\hat{S}_{i(j+1)} + \mu\hat{x}_{(i-1)j} + \mu\hat{x}_{(i+1)j} \quad (38')$$

$$\frac{dS_{ij}}{dt} = \hat{S}_{i(j-1)} - 2\hat{S}_{ij} + \hat{S}_{i(j+1)} - a_{i(j-1)}\hat{x}_{i(j-1)} + a_{ij}\hat{x}_{ij} \quad (38'')$$

sa graničnim uslovima:

$$\hat{S}_{i0} \equiv \hat{S}_{i1} \equiv b_i , \hat{S}_{i(n+1)} \equiv 0 , \hat{x}_{i0} \equiv 0 , \hat{x}_{0j} \equiv \hat{x}_{1j} , \hat{x}_{(m+1)j} \equiv \hat{x}_{mj} \quad (38'')$$

gde $\hat{x}_{ij}, \hat{S}_{ij}$ predstavljaju izlaze ćelija x_{ij}, S_{ij} respektivno. Prepostavljamo da je izlazna funkcija svih ćelija ista kao i u originalnoj CNM mreži – jedinična PWL (26). Relacije (38'') zovemo graničnim uslovima i njihova uloga će biti objašnjena u narednoj sekciji.

Na ovaj način je dobijena asimptotski stabilna CNM mreža, jer su uslovi (32) ispunjeni, i u ekvilibrijumu koji odgovaraju globalnom minimumu funkcije Ljapunova (37), vektor izlaza zadovoljava sistem (30), tj. $x_{ij}(t \rightarrow \infty) \rightarrow x_j^e, \forall i \in \{1, \dots, m\}$, ako rešenje sistema (34) leži u prostoru $[-1,1]^n$. Drugim rečima, ako u toku rada nema prekoračenja opsega linearnosti izlaza ćelija (rad u režimu izvan opsega saturacije):

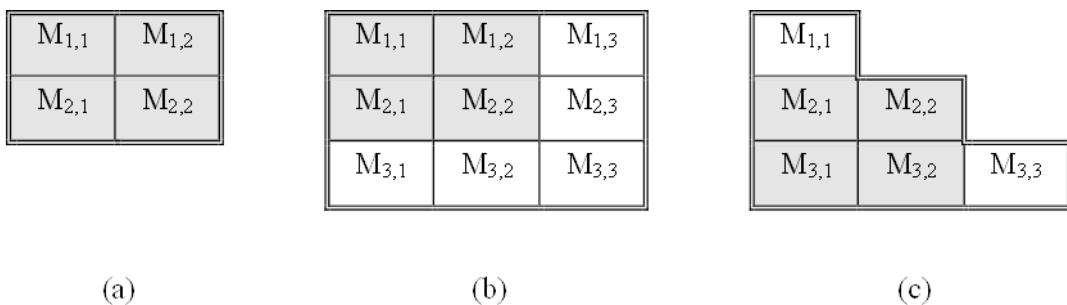
$$(\forall t) \quad |x_{ij}(t)| \leq 1 \quad (39)$$

CNM mreža opisana sistemom jednačina stanja (38) posle konačno dugog vremena rešava sistem jednačina (30).

9.2.2 Fraktalna modularnost u LSS CNM mreži

Kao što smo već naglasili, lokalna povezanost ćelija (neuronskih procesora) je jedna od glavnih karakteristika LSS CNM i razlog za dekompoziciju sistema (30). U prethodnoj sekciji smo opisali konstrukciju CNM za rešavanje sistema linearnih algebarskih jednačina (30) preko rešavanja proširenog, ekvivalentnog u smislu rešenja, sistema (34). Tako, (30) možemo podrazumevati kao problem a (34) kao dekompoziciju tog problema. Kao što je napomenuto, zavisnosti između varijabli čiji se indeksi razlikuju maksimalno za 1 u svakoj jednačini sistema (34) dovela je do strukture lokalnih veza CNM mreže. Zapazimo modularnost tog sistema: jednačine stanja (38) su prostorno invarijantne - samo se indeksi menjaju a struktura ćelije u mreži je svuda identična. To dozvoljava da shvatimo ovu mrežu kao skup **modula** $M_{i,j}$, od kojih je svaki definisan parom jednačina stanja (38') i (38'') i skupom graničnih uslova (38''). Sada je i značenje graničnih uslova jasno - oni predstavljaju 'zatvaranje' ivičnih ćelija CNM mreže. Drugim rečima, oni zamenjuju uticaj ostatka velike mreže na ograničen segment od interesa.

Prostim slaganjem ovakvih modula formira se mreža koja može rešavati sistem linearnih algebarskih jednačina (30) sa proizvoljnom geometrijom (Slika 30). Pod geometrijom podrazumevamo raspored nenultih elemenata matrice sistema \mathbf{A} . Iz (38) je očigledno da ako je $a_{ij} = 0$ onda je modul $M_{i,j}$ samo 'pasivan' prenosilac²⁶ signala između svojih suseda i tada je moguće takav modul jednostavno izbaciti i umesto preko njega, susedne module spojiti direktno. Naravno, ako se na taj način granice mreže promene treba promeniti i granične uslove tako da odgovaraju novoj geometriji.



Slika 30: Realizacija LSS CNM za rešavanje sistema (a) sa dve jednačine, (b) tri jednačine i (c) donje-trougaonog sistema.

Primetimo da je LSS CNM mreža (Slika 30a) pod-mreža u LSS CNM na (Slika 30 b i c). To znači da jedna pod-grupa modula rešava neki pod-problem zasebno kao da je sama i učestvuje u procesu rešavanja kompletног problema putem interakcije (razmene informacija) sa susednim grupama modula preko svojih rubnih modula (ćelija). Svaka ovakva grupa dalje se može razlagati u pod-grupe koje funkcionišu na identičan način. Takvo raščlanjivanje se može nastaviti sve do nivoa pojedinačnih modula. Sledeći tu filozofiju, a kao što se i iz jednačina stanja modula (38) može primetiti, modul je u stvari prosta 2-ćelijska CNM mreža koja rešava (radi na rešavanju) jednačine oblika

$$a_{ij}x_{ij} + S_{i(j+1)} = S_{ij} \quad (40)$$

Takvo ponašanje, sa fino strukturiranim lokalnom autonomijom, ekskluzivna je osobina CNM mreža i mi smo ga nazvali svojstvom **fraktalne modularnosti** (engl. *fractal modularity*). Mada se još uvek istaržuju, neke očigledne osobine i prednosti povezane sa

²⁶ Modul $M_{i,j}$ je 'pasivan' ne u energetskom nego u informacionom smislu što ne vrši kvalitativnu izmenu signala sem što unosi kašnjenje u propagaciji signala između njemu susednih modula.

fraktalnom modularnošću su: laka konstrukcija modula proste strukture čime se postiže jednostavan i jasan uvid u način funkcionisanja modula, mogućnost pojednostavljene analize konvergencije i stabilnosti, prirodna proširivost mreže, mogućnost efikasne VLSI implementacija kao posledica uniformnosti strukture i lokalne povezanosti modula itd.

U narednoj sekциji će biti pokazan način sinteze još jedne CNM mreže gde je primenom metode **fraktalne modularizacije** (engl. *fractal modularization*) rešen fundamentalni problem linearнog programiranja (engl. *Linear Programming - LP*).

Napomena: Između termina *fraktalna modularnost* i *fraktalna modularizacija* treba praviti razliku. Prvi (fraktalna modularnost) označava svojstvo modularne CNM mreže kao posledica njene specifične topologije dok drugi (fraktalna modularizacija) predstavlja metodu koja podrazumeva razlaganje (nekada čak i proširivanje i usložnjavanje u matematičkom smislu) polaznog problema (sistema) radi njegove pogodne transformacije u modularnu formu koja omogućava mapiranje u CNM topologiju.

9.2.3 Sinteza CNM mreže za linearно programiranje (LP CNM) primenom fraktalne modularizacije

Problem linearног programiranja (LP) je jedan od esencijalnih optimizacionih problema i mnoge se druge optimizacije mogu svesti na njega. Iz tog razloga je od interesa ispitati mogućnost linearнog programiranja pomoći CNM mreža jer se time pokazuje i generalna primenjivost CNM mreža u rešavanju optimizacionih problema. Primetimo da je, kako je to već naglašeno u prethodnom izlaganju, CNM mreža univerzalna procesna struktura u Turingovom smislu obrade informacija [63]. Optimizaciona sposobnost CNM mreže, u nealgoritamskom smislu, dodatni je kvalitet ove procesorske strukture što je čini potencijalno superiornijom u odnosu na klasične (digitalne) računare. Pod 'nealgoritamskim' smislim podrazumevamo da CNM mreža ne rešava optimizacioni problem putem nekog zadatog algoritma (niza radnji koje treba obaviti u cilju nalaženja rešenja putem sukcesivnih transformacija ulaznih podataka) već ona vrši optimizaciju sama po svojoj prirodi (u sekciјi 9.1 pokazano je da ona uvek minimizira svoju generalisanu energiju $E(t)$). Dakle, CNM mreža se ne 'programira' u smislu da je potrebno specificirati postupak rešavanja problema (algoritam) već samo, npr. primenom metode fraktalne modularizacije, problem treba u

pogodnoj formi mapirati u CNM mrežu. Pod time (mapiranjem) podrazumevamo određivanje parametara CNM mreže u funkciji parametara problema koji rešavamo.

LP problem, minimizacija funkcije cilja f u zavisnosti od datih ograničenja, obično se zadaje u sledećoj formi:

$$\begin{aligned} \min f(\mathbf{x}') &= \mathbf{c}'^T \mathbf{x}' = \sum_{i=1}^n c'_i x'_i \\ \mathbf{A}' \mathbf{x}' &\leq \mathbf{b} \end{aligned} \quad (41)$$

$$\mathbf{A} = \left[a_{ij} \right]_{i=1 \dots m, j=1 \dots n}, \mathbf{b} = \left[b_i \right]_{i=1 \dots m}^T$$

gde je $\dim \mathbf{b} = m < n$. Međutim, ovde će biti korišćena tzv. kanonična forma LP problema ([203], [204]) koja je pogodnija jer koristi jednakosti za specificiranje ograničenja:

$$\min f(\mathbf{x}) = \mathbf{c}^T \mathbf{x} = \sum_{i=1}^n c_i x_i \quad (42')$$

$$\mathbf{A} \mathbf{x} = \mathbf{b} \quad (42'')$$

gde je

$$\begin{aligned} \mathbf{c} &= \left[\mathbf{c}'^T \quad \mathbf{0} \right]^T \\ \mathbf{x} &= \left[\mathbf{x}'^T \quad \mathbf{z}^T \right]^T \\ \mathbf{A} &= \left[\mathbf{A}' \quad \mathbf{I} \right] \end{aligned} \quad (43)$$

Vektor $\mathbf{z} \geq \mathbf{0}$ je vektor tzv. izravnavaajućih promenljivih a \mathbf{I} je jedinična matrica odgovarajuće dimenzije.

U nizu radova (npr. [201], [205], [206], [202]) je pokazano kako se ovaj problem može rešiti koristeći potpuno povezane mreže (Hopfieldovog ili srodnog tipa) gde je svaki neuron, generalno, povezan sa svakim drugim u mreži. Naš cilj je, naravno, da ostvarimo fraktalno-modularnu CNM strukturu koja bi imala lokalnu povezanost. Tako, kao i u pomenutim radovima, osnova će biti metod kažnjavajuće funkcije (engl. *penalty function*) ali uz potrebnu dekompoziciju LP problema u maniru fraktalne modularizacije. Teorema

kažnjavajuće funkcije je dobro poznata u literaturi koja se bavi linearnim programiranjem i ovde će biti izložena u popularnoj formi²⁷ (za egzaktan iskaz i dokaz videti [207]):

Teorema „kažnjavajuće funkcije“: Minimum funkcije $E_1(\mathbf{x}') = f(\mathbf{x}') + \frac{\eta}{2} \sum_{i=1}^n [g_i^+(\mathbf{x}')]^2$, gde

je $g_i^+(\mathbf{x}') = \max\{b_i - \sum_{j=1}^n a_{ij}x'_j\}$, teži minimumu funkcije $f(\mathbf{x}')$ kada $\eta \rightarrow \infty$.

Nije teško pokazati da i funkcija:

$$E_2(\mathbf{x}) = \frac{1}{\eta} f(\mathbf{x}) + \sum_{i,j} [\mu \cdot r(x_{ij})^2 + r(S_{ij})^2] \quad (44)$$

takođe može biti upotrebljena u gornjoj teoremi „kažnjavajuće funkcije“ (a ovakva formulacija je pogodnija za LP problem u formi (42)). Primetimo da je drugi član, u stvari, funkcija Ljapunova LSS CNM mreže za rešavanje sistema linearnih jednačina (37), koja je opisana u prethodnoj sekciji, i koja rešava sistem jednačina uslova (42''). Ali sa gledišta teorije linearog programiranja, funkcionalni članovi $r(x_{ij})$ and $r(S_{ij})$ su kažnjavajući faktori koji se koriste za modelovanje prekoračenja ograničenja.

Izraz (44), ako se razvije i uporedi sa opštim oblikom funkcije Ljapunova CNM mreže (31), daje jednačine stanja osnovnog modula LP CNM mreže za linearno programiranje ($C = 1, R_x \rightarrow \infty$):

$$\frac{dx_{ij}}{dt} = -(a_{ij}^2 + 2\mu)\hat{x}_{ij} + a_{ij}\hat{S}_{ij} - a_{ij}\hat{S}_{i(j+1)} + \mu\hat{x}_{(i-1)j} + \mu\hat{x}_{(i+1)j} - \frac{c_j}{\eta} \quad (45')$$

$$\frac{dS_{ij}}{dt} = \hat{S}_{i(j-1)} - 2\hat{S}_{ij} + \hat{S}_{i(j+1)} - a_{i(j-1)}\hat{x}_{i(j-1)} + a_{ij}\hat{x}_{ij} \quad (45'')$$

uz pridružene granične uslove (38''), gde $\hat{x}_{ij}, \hat{S}_{ij}$ označavaju izlazećelija x_{ij}, S_{ij} respektivno a definisani su na sledeći način:

²⁷ Primetimo da je ova formulacija pogodna za LP problem u obliku (41)

$$\begin{aligned}\hat{x}_{ij} &= \begin{cases} \lambda(x_{ij}) & , j \leq m \\ \max\{0, \lambda(x_{ij})\} & , n \geq j > m \end{cases} \\ \hat{S}_{ij} &= \lambda(x_{ij})\end{aligned}\quad (46)$$

gde je $\lambda(\cdot)$ standardna izlazna PWL nelinearnost CNM ćelije (26).

Uklapanjem ovakvih modula formira se CNM mreža koja rešava problem linearнog programiranja (41) ako rešenje postoji i ne dolazi do prekoračenja tokom tranzijencije:

$$(\forall t) \quad |x_{ij}(t)|, |S_{ij}(t)| \leq 1 \quad (47)$$

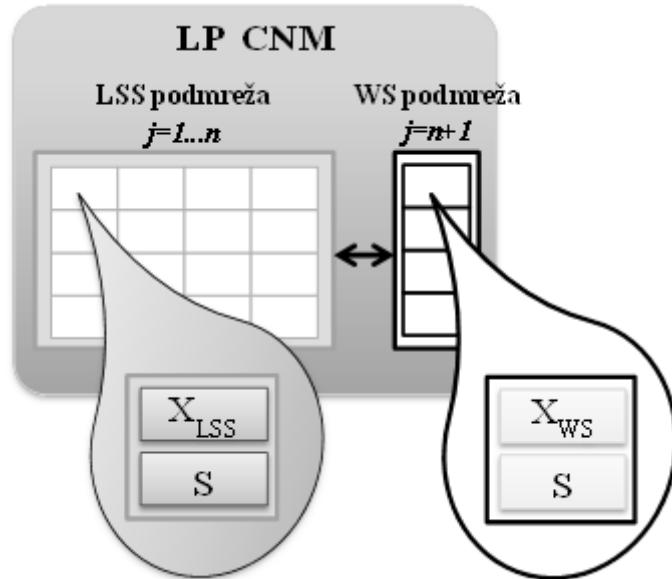
Uvođenjem izravnavajućih promenljivih u ograničenja, matrica A' se proširuje jediničnom matricom I (43). Kao što je u prethodnoj sekciji naglašeno, u ovom slučaju je svrsishodno, u smislu uštede na broju modula, izbaciti sve pasivne module $M_{i,j}$ gde je $a_{ij} = 0$. Primenom ove racionalizacije, LP CNM mreža, u znatno kompaktnijoj varijanti, može se definisati sledećim skupom jednačina stanja modula ($C = 1, R_x \rightarrow \infty$):

$$\begin{aligned}\frac{dS_{ij}}{dt} &= \hat{S}_{i(j-1)} - 2\hat{S}_{ij} + \hat{S}_{i(j+1)} - a_{i(j-1)}\hat{x}_{i(j-1)} + a_{ij}\hat{x}_{ij} \\ \frac{dx_{ij}}{dt} &= \begin{cases} -(a_{ij}^2 + 2\mu)\hat{x}_{ij} + a_{ij}\hat{S}_{ij} - a_{ij}\hat{S}_{i(j+1)} + \mu\hat{x}_{(i-1)j} + \mu\hat{x}_{(i+1)j} - \frac{c_j}{\eta}, & j \leq n \\ -a_{ij}^2\hat{x}_{ij} + a_{ij}\hat{S}_{ij} - \frac{c_{n+i}}{\eta}, & j = (n+1) \end{cases}\end{aligned}\quad 48$$

Iz jednačina stanja modula (48) može se zaključiti da pojedinačni modul rešava primitivni LP problem - posledica fraktalne modularnosti u ovoj mreži. Ali, dok je LSS CNM za rešavanje sistema linearnih jednačina bila homogena (svi moduli su imali jedinstvenu strukturu), LP CNM definisana sa (48) to očigledno nije: moduli za $j \leq n$, imaju različitu strukturu od modula za $j = (n+1)$ jer im se razlikuje struktura x-ćelija. Dakle, topološki gledano, LP CNM je sastavljena od dva dela, dve CNM mreže sa modulima slične topološke strukture ali sa bihevioralno²⁸ različitim x-ćelijama zbog razlike u dinamičkim jednačinama (48). Svaki od ova dva dela je homogen (ima identičnu topologiju i dinamičku strukturu

²⁸ Pod bihevioralnom razlikom podrazumevamo različitu dinamiku ćelije, zbog različitih dinamičkih modela jednačine stanja, što se takođe može smatrati i funkcionalnom razlikom jer je uloga te ćelije u ukupnoj kolektivnoj dinamici različita.

modula) i poseduje sva svojstva fraktalne modularnosti kako je to izloženo u prethodnoj sekciji (Slika 31).



Slika 31: Topološka arhitektura LPS CNM. Podmreža LSS sa leve strane (siva) sastoje se od identičnih modula tipa LSS (Linear System Solver CNM) dok se podmreža na desnoj strani (bela) sastoje od modula slične topologije ali sa različitom x -ćelijom. I jedni i drugi moduli imaju istu unutrašnju topologiju – sastoje se od dve ćelije (x i S tipa).

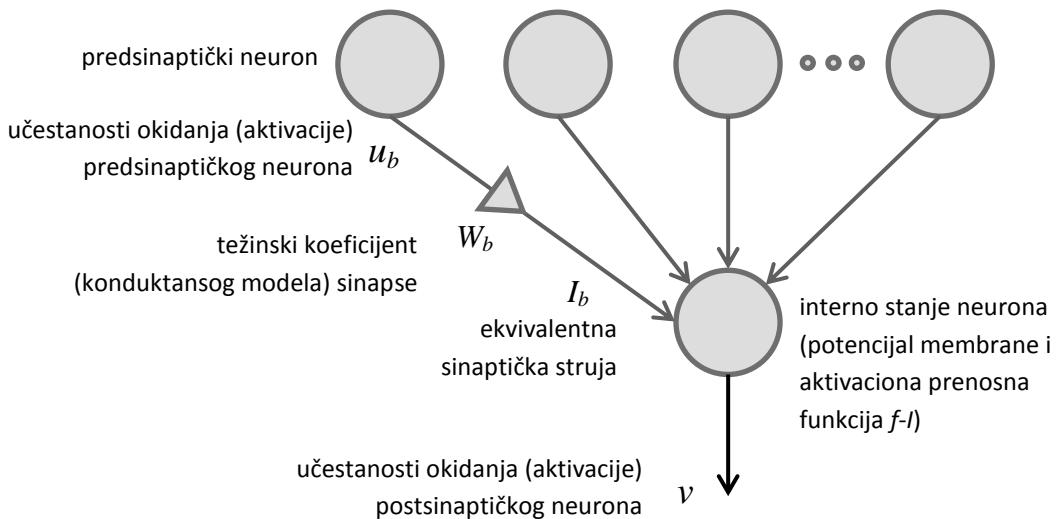
Napomena: Kako interkonekcije ove mreže zadovoljavaju uslove (32) i izlazna funkcija je monotono rastuća (25b), sledi da je LP CNM mreža asimptotski stabilna i ekvilibrijum koji odgovara globalnom minimumu generalisane energije (funkcije Ljapunova) je optimalno²⁹ rešenje LP problema (41).

9.3 Prilog 3: Firing-rate (FR) model neurona

Napomena: Kompilirano i prilagođeno na osnovu referenci [158] i [208].

Firing-rate (FR) model, ili model učestanosti okidanja, je relativno novi model koji pokušava da uspostavi relaciju koja povezuje ulazne i izlazne učestanosti okidanja odnosno aktivacije (engl. *firing-rate*) neurona (Slika 32).

²⁹ Od objavljivanja ovih rezultata publikovano je više radova u kojima je istraživana i dokazana globalna asimptotska stabilnost srodnih klasa ne samo celularnih već i drugih veštačkih rekurzivnih neuralnih mreža ([212], [213], [214], [215]). Time je ovaj raniji rezultat ne samo potvrđen već je i otvoren širok prostor za dopunsku analizu stabilnosti u realnim uslovima (prisustvo šuma, neidelnosti prenosnih i izlaznih funkcija i sl.).



Slika 32: Firing-rate (FR) model neurona povezuje ulazne i izlazne učestanosti okidanja (firing-rates) odnosno predstavlja neuron modelom prenosne funkcije „ulaz-izlaz“ u terminima apstrakntih informacionih umesto fizičkih veličina (prilagođeno na osnovu [208]). Ovakav model je pogodan za funkcionalnu, informatičku, analizu ponašanja neurokognitivnih struktura jer pokazuje „šta“ neuron radi a ne samo „kako“ radi.

FR model se može izvesti ako se uspostavi veza između ulaznih učestanosti okidanja sinaptički spregnutih neruona, somatske struje neruona i učestanosti okidanja (aktivacije) membrane na izlazu posmatranog neurona.

U konduktansnim modelima (što su gotovo svi priznati modeli neurona od HH do LIF-a) ova veza se uspostavlja najlakše preko izražavanja somatske struje posmatranog (postsinaptičkog) neurona kao sume partikularnih ekvivalentnih struja koje nastaju preko sinaptičkih veza presinaptičkih neurona povezanih sa posmatranim nevronom.

Presinaptička ekvivalentna struja koja nastaje na osnovu aktivacionog potencijala presinaptičkog neurona b može se izraziti sledećom relacijom:

$$I_b(t) = w_b K_s(t) \quad (49)$$

gde je K_s prenosna funkcija sinaptičke konduktansne veze³⁰ parametrizovana lineanim, vremenski nepromenjivim, težinskim koeficijentom sinaptičke veze w_b . Ova prenosna

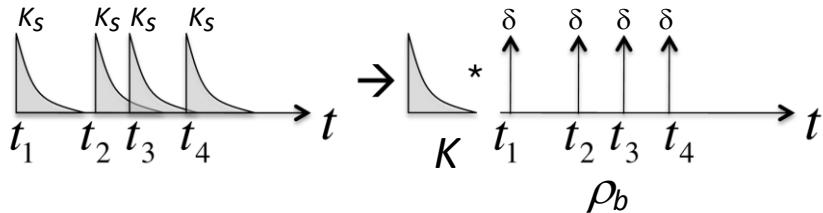
³⁰ Ovde se u novim radovima, u zadnjih desetak godina, uključuje i uticaji dendritskih stabal koja se mogu modelovati kao vodovi odnosno mreže sa raspodeljenim paramterima, kako je to poznato u teoriji električnih kola. Poznato je da se kola sa raspodeljenim parametrima mogu modelovati ekvivalentnim impedansama, što

funkcija je u priznatim konduktansnim modelima uobičajeno linearna niskopropusna filterska funkcija prvog reda (sa ekvivalentnom sinaptičkom vremenskom konstantom τ_s), a često se naziva i sinaptički kernel:

$$K_s(t) = \frac{1}{\tau_s} e^{-\frac{t}{\tau_s}} \quad (50)$$

U slučaju LIF neuronskog modela, dakle kada prepostavljamo da se izlazni aktivacioni potencijal modeluje povorkom Dirakovih impulsa Poisson-ove rapsodele (dakle, gde su impulsi međusobno nezavisnih verovatnoća u smislu Poisson-ove distribucije), ukupna ekvivalentna ulazna struja sinapse b može se predstaviti konvolucionom transformacijom kao:

$$\begin{aligned} I_b(t) &= w_b \sum_{t_i < t} K_s(t - t_i) = w_b \int_{-\infty}^t K_s(t - \tau) \rho_b(\tau) d\tau = w_b(K * \rho) \\ \rho_b(\tau) &= \sum_i \delta(\tau - t_i) \end{aligned} \quad (51)$$



gde je ρ_b povorka impulsa aktivacije presinaptičkog neurona b predstavljena Poisson-ovim procesom Dirakovih impulsa u trenucima t_i .

Predpostavljajući da su sinaptički ulazi nezavisni Poisson-novi procesi (da nema međusobnih uticaja i interakcija između sinaptičkih ulaza tj. sve sinapse i predsinaptički neuroni se posmatraju kao nezavisni procesi), ukupna somatska struja se može izraziti kao linearna suma pojedinačnih sinaptičkih struja:

omogućava da se ova dva modela objedine u jedan ekvivalentan model generičke "konduktanse" da bi se zadržala terminološka i logička veza sa klasičnim konduktansnim modelima poput LIF i HH koji nisu uzimali u obzir dendritska stabla već samo posmatraju usko gledano pojedinačnu neuronsku ćeliju sa pripadajućim sinapsama [216].

$$I_s(t) = \sum_b I_b(t) = \sum_b w_b(K * \rho) = \sum_b w_b \int_{-\infty}^t K_s(t - \tau) \rho_b(\tau) d\tau \quad (52)$$

Ključna pretpostavka FR modela je da se, u dovoljno dugom vremenskom intervalu posmatrano, Poissonovi procesi povorki aktivacija neurona mogu zameniti (aproksimirati) učestanošću okidanja:

$$\rho_b(\tau) \approx u_b(\tau) \quad (53)$$



Opravdanost ove pretpostavke (prema interpretaciji datoј u [160]) leži u pretpostavljenom velikom broju sinaptičkih ulaza ($b \gg 1$) kao i velikoj učestanosti okidanja u odnosu na posmatrani vremenski interval konvolucije t . Ako se sumiranje vrši preko velikog broja sinapsi, može se smatrati da srednja vrednost raspodele linearno raste sa brojem sinapsi, dok standardna devijacija sinaptičkih struja raste samo kvadratnim korenom broja sinapsi. Ova pretpostavka je analogna tzv. *mean-field* teoriji u fizici ([209]) i po mnogim autorima je opravdana jer:

1. biološki neuron ima veliki broj sinaptičkih ulaza (u proseku oko 10,000 sinaptičkih veza), i
2. nema jakih dokaza o direktnoj korelaciji odnosno međusobnoj zavisnosti sinaptičkih ulaza međusobno.

Dakle, kao što mnogi autori i smatraju, ovakva aproksimacija je biološki opravdana uz jednu ogragu: da takođe treba smatrati i da je broj sinhronisanih neuroaktivacija (impulsa različitih presinaptičkih neurona koji se dešavaju u istom vremenskom trenutku) zanemarljiv odnosno da ne postoji globalna sinhronizacija na nivou neurostrukture koja se posmatra³¹.

Ova dodatna pretpostavka je takođe biološki opravdana ako se smatra da je neurosistem *modularan* odnosno da pojedini moduli mogu biti međusobno sinhronisani ali da

³¹ Ovaj dodatni uslov je važan da bi se mogla primeniti Centralna granična teorema (engl. *central limit theorem*) koja načelno tvrdi da normirana i centrirana suma velikog broja nezavisnih i identično raspoređenih slučajnih promenljivih teži normalnoj raspodeli (http://www.statisticalengineering.com/central_limit_theorem.htm).

je intramodularna sinhronisanost pojedinačnih neurona statistički zanemarljiva. Nagalsićemo samo da je veliki broj eksperimentalnih radova koji potvrđuju ovakvo stanovište, posebno imajući u vidu uticaj šuma koji se u realnim biološkim neurostrukturama pojavljuje kao dodatni stohastički proces koji upravo modulira prenosne funkcije aktivacije neurona ([168]).

Pod svim ovim prepostavkama, sinaptička eksitacija membrane neurona odnosno somatska struja se može izraziti kao:

$$I_s(t) = \sum_b w_b \int_{-\infty}^t K_s(t-\tau) u_b(\tau) d\tau \quad (54)$$

$$K_s(t) = \frac{1}{\tau_s} e^{-\frac{t}{\tau_s}}$$

Derivacijom gornjeg izraza, dobijamo dinamičku jednačinu:

$$\tau_s \frac{dI_s}{dt} = -I_s + \sum_b w_b u_b \quad (55)$$

koja određuje vremensku dinamiku somatske struje u zavisnosti od učestanosti okidanja predsinaptičkih neurona, pod napred navedenim prepostavkama.

Konačno, radi formulisanja FR modela potrebno je izvesti vezu ove somatske struje i učestanosti okidanja odnosno aktivacije postsinaptičkog neurona v .

U opštem slučaju konduktansnog modela neurona (poput HH i LIF), potencijal membrane je određen kapacitivnošću i otpornošću membrane (RC kolom) odnosno može se posmatrati kao niskopropusni filter. Konačno, uzimajući u obzir ovu niskopropusnu dinamičku prenosnu funkciju, učestanost okidanja se može dovesti u vezu sa potencijalom membrane preko generalizovane vremenske konstante τ_r :

$$\tau_r \frac{dv}{dt} = -v + f(I_s) \quad (56)$$

gde je f nelinearna statična (vremenski nepromenjiva) zavisnost koja se može odrediti u ustaljenom režimu odziva za vremenski nepromenjive (konstantne) vrednosti ulazne somatske struje I_s (u literaturi poznata kao f - I karakteristika, aktivaciona ili prenosna):

$$v = f(I_s)|_{\frac{dv}{dt}=0} \quad (57)$$

Važno je napomenuti da vremenske konstante τ_r nije vremenska konstanta potencijala membrane odnosno postsinaptičkog RC kola prema poznatim konduktansnim modelima neurona, već generalizovana konstanta okidanja (aktivaciona konstanta ili konstanta okidanja) koja ima drugu apstraktnu prirodu jer povezuje učestanost okidanja i ulaznu sinaptičku struju. Matematička pozadina odnosno izvođenje ove vremenske konstante u terminima realnih fizičkih i bioloških parametara je ključni faktor u brojnim istraživanjima i mnogi autori su pokazali da se za razne režime (tipove neurona, vrste sinapsi, uslove šuma i eksternih uticaja i sl.) mogu izvesti manje ili više dobre estimacije ove konstante i dovođenje u vezu sa priznatim modelima biološkog neurona ([158], [208], [159], [145], [157], [160], [164], [210]). Iako sama vrednost ove konstante nije od presudnog značaja za dalje razmatranje funkcionalnog ponašanja neurona u smislu informatičkog modela „ulaz-izlaz“ važno je da postoji biološko opravdanje za ovakvo modelovanje.

Uobičajeno se prepostavlja da je ova nelinearnost sigmoidalna (što je od strane brojnih autora potvrđeno i eksperimentalno kvantifikovano za razne klase bioloških neurona i *in vitro* i *in vivo*, npr. Slika 21), mada se za potrebe lakše matematičke manipulacije koriste i deo-po-deo linearne (*piecewise-linear*, PWL, Slika 28) ili čak odsečne (*threshold*) funkcije kao najgrublja aproksimacija.

Bilo kako, pod pretpostavkom da je $f-I$ nelinearnost statična, zavisno od odnosa vremenskih konstanti sinaptičkih veza i okidanja (aktivacije), mogu se izvesti dva modela zavisnosti „ulaz-izlaz“:

Tabela 7: FR modeli neurona u zavisnosti od odnosa sinaptičke (τ_s) i aktivacione (τ_r) vremenske konstante

Model FR-A: $\tau_r \ll \tau_s$

$$v = f(I_s)$$

$$\tau_s \frac{dI_s}{dt} = -I_s + \sum_b w_b u_b$$

Model FR-B: $\tau_s \ll \tau_r$

$$\tau_r \frac{dv}{dt} = -v + f(I_s)$$

$$I_s = \sum_b w_b u_b$$

Model FR-A prepostavlja da izlazna učestanost okidanja trenutno prati promenu sinaptičkih ulaza (jer je vremenska konstanta sinaptičkog prenosa mnogo veća od vremenske konstante membrane) dok model FR-B prepostavlja da je prenos signala u sinapsama trenutan. Dakle, oba ova modela su oba aproksimacije realnih fizičkih procesa u biološkim neurostrukturama i njihova primena zavisi od dominantnog konteksta u kojem se može smatrati da jedna ili druga prepostavka važe.

Model FR- B je češće korišćen u literaturi jer se smatra da je bliži realnoj dinamici odnosno prirodi većine posmatranih bioloških nerualnih struktura (gde je zaista vreme propagacije signala kroz sinapse daleko manje od vremenske konstante membrane, što je osnova ne samo Hodgkin–Huxley model već je to i eksperimentalno potvrđeno za mnoge klase neurona). Međutim, i model FR-A se sve više koristi posebno kada se razmatraju neurostrukture sa dužim aksonskim vezama u kojima je propagacija signala kroz akson podložna dodatnom vremenskom kašnjenju i sl.