

Electronics and electrical engineering Elektronika ir elektros inžinerija

DIRBTINIŲ NEURONŲ TINKLŲ SU DINAMINĖMIS SINAPSĖMIS APŽVALGA

Martynas DUMPIS*

Vilniaus Gedimino technikos universitetas, Vilnius, Lietuva

Gauta 2023 m. liepos 9 d.; priimta 2023 m. spalio 12 d.

Santrauka. Dirbtinių neuronų tinklai (DNT) yra plačiai taikomi realaus pasaulio problemoms spręsti. Dauguma mūsų atliekamų veiksmų ir mus supančių procesų yra kintantys laike. Neuronų tinklai, turintys dinamines savybes, leidžia apdoroti laike kintančius duomenis ir spręsti tokius uždavinius kaip kalbos ir teksto apdorojimas, prognozių modeliavimas, veido ar emocijų atpažinimas, žaidimų strategijų kūrimas. DNT dinamika užtikrinama įėjimo duomenų apdorojimo procese, neuronų tinklo sandaroje ar atskiruose DNT elementuose – sinapsėse ar neuronuose. Skirtingai nuo statinių sinapsių, dinaminės sinapsės turi gebėjimą keisti savo ryšio stiprumą pagal gaunamą informaciją. Ši savybė leidžia joms mokytis ir adaptuotis prie kintančių situacijų. Tai yra esminis principas, leidžiantis DNT efektyviau atlikti sudėtingas užduotis, tokias kaip teksto apdorojimas arba veido atpažinimas. Dinaminės sinapsės atlieka svarbų vaidmenį formuojant DNT gebėjimą mokytis iš patirties ir keistis laikui bėgant, o tai yra vienas iš pagrindinių dirbtinio intelekto (DI) aspektų. Šiame straipsnyje nagrinėti moksliniai darbai parodo, jog nėra literatūros šaltinių, kuriuose būtų apžvelgti ir palyginti dinaminiai DNT pagal jų sinapses. Siekiant užpildyti šią spragą, straipsnyje apžvelgiami ir sugrupuojami DNT su dinaminėmis sinapsėmis. Apibūdinami dinaminiai neuronų tinklai pateikiant bendrinę matematinę išraišką. Apibūdinama dinaminė sinapsė nurodant jos pagrindines savybes ir pateikiant bendrinę matematinę išraišką. Nagrinėjama, kaip ši sinapsė gali būti modeliuojama ir integruojama į 11 skirtingų dinaminį DNT struktūrų. Išnagrinėtos dinaminį DNT struktūros palyginamos pagal dinaminį sinapsių savybes.

Reikšminiai žodžiai: dirbtinių neuronų tinklai, dinaminės sinapsės, dinaminiai ryšiai, laikui bėgant kintantys signalai.

Įvadas

XXI amžiuje, kai technologijų pažanga yra spartesnė nei bet kada anksčiau, DI tyrimai tapo viena iš svarbiausių mokslo sričių. DNT yra pagrindinis DI komponentas, kuris imituoja žmogaus smegenų darbą, naudodamasis neuronų ir sinapsių modeliais (Prisciandaro et al., 2023). Nors tradiciniai DNT yra sukurti su statinėmis sinapsėmis, tyrimai rodo, kad sinapsių dinamiškumas gali padidinti tinklo mokymosi efektyvumą ir prisitaikymą prie nuolat kintančių uždavinių (Zhao et al., 2022). Dinaminį sinapsių tyrinėjimas gali padėti išspręsti sudėtingas realaus pasaulio problemas ar suformuoti naują požiūrį į mašininio mokymosi metodų taikymą.

Vienas iš svarbiausių DNT su dinaminėmis sinapsėmis aspektų yra jų potencialas padidinti šių tinklų efektyvumą. Imituodamos biologinių neuronų tinklų plastiškumą, dinaminės sinapsės leidžia DNT veiksmingiau prisitaikyti

sprendžiant skirtingus realaus pasaulio uždavinius. Pavyzdžiui, sinapsės gali stiprinti ar slopinti perduodamą signalą reaguodamos į stimulų dažnumą (Lu et al., 2023). Tai gali paskatinti veiksmingesnių DI sistemų kūrimą, peržengiant ribas, kurias gali pasiekti dabartiniai mašininio mokymosi modeliai (Lin et al., 2021).

Dinaminės sinapsės dirbtiniuose neuronų tinkluose yra tarsi reguliuojamos jungtys, leidžiančios jiems keistis ir prisitaikyti – panašiai kaip žmogaus smegenų ląstelės, kurios jungiasi ir perduoda informaciją elektriniais impulsais. Šios adaptyvios jungtys gali padėti išspręsti pagrindinę DI problemą, vadinamą stabilumo ir plastiškumo dilema, kai sistema turi būti pakankamai stabili, kad išlaikytų žinias, įgytas iš ankstesnių pavyzdžių, ir pakankamai plastiška, kad išmokytų naujų pavyzdžių požymius (Huang et al., 2020).

*Autorius susirašinėti. El. paštas martynas.dumpis@vilniustech.lt

Nepaisant didelių galimybių, kurias atveria dinaminės sinapsės, vis dar reikia atsakyti į daugybę klausimų ir išspręsti daugybę problemų. Pavyzdžiui, vis dar nežinome geriausio būdo įgyvendinti šias sistemas – kaip padaryti jas efektyvesnes ir kaip standartizuoti jų kūrimo ir testavimo būdus.

Šiame straipsnyje pateikiama išsami įvairių DNT architektūrų su dinaminėmis sinapsėmis apžvalga, siekiant atskleisti jų unikalias savybes, stipriąsias puses ir iššūkius, kuriuos reikia įveikti. Analitiniu tyrimu tikimasi išsiaiškinti šių DNT sudėtingumą ir paruošti kelią naujiems tyrimams, kurie gali maksimaliai padidinti dinaminį sinapsių įgyvendinimo potencialą ir sukurti pranašesnes DI sistemas.

1. Tyrimo eiga

Tyrimui atlikti buvo atrinkami tematiškai aktualūs straipsniai pagal sudarytą paieškos strategiją ir nustatytus straipsnių atrankos kriterijus.

Paieškos strategija. Pagrindinis paieškos tikslas – rasti aktualius darbus, kuriuose apibūdinami DNT su dinaminėmis sinapsėmis, gebantys apdoroti laiko signalus. Paieška vykdyta naudojant *Clarivate Analytics Web of Science* straipsnių paieškos įrankį. Naudotos šios elektroninės duomenų bazės, kuriose buvo peržiūrėti atrinkti apžvalginiai straipsniai: *IEEE Xplore*, *Research Gate*, *ScienceDirect*, *SpringerLink*, *arXiv* ir *MDPI*.

Tyrimo pradžioje apibrėžti reikšminiai žodžiai, susiję su nagrinėta tematika. Reikšminiai žodžiai parinkti siekiant išskirti darbus, kurie atitiktų nagrinėjamą sritį. Elektroninių duomenų bazių paieškos laukuose naudotas reikšminių žodžių junginys: *Artificial neural networks dynamic (synapses OR connections) (survey OR review)*. Naudotas OR loginis operatorius siekiant paieškos rezultatuose apimti skirtingus terminus, vartojamus dinaminei sinapsei apibūdinti *synapse OR connection*, bei išskirti tik apžvalginis straipsnius *survey OR review*.

Straipsnių atranka. Atliekant straipsnių paiešką elektroninėse duomenų bazėse reikšminių žodžių buvo ieškoma straipsnio pavadinime, santraukoje, autoriaus pateiktuose reikšminiuose žodžiuose. Straipsnių publikavimo data paieškos imtyje nebuvo ribojama.

Straipsniai buvo atrinkami ir vertinami rankiniu būdu pagal šiuos atrankos kriterijus:

- tinkama straipsnio tematika;
- nurodytas tyrimo tikslas;
- apibūdintas tyrimo naujumas;
- pateikta panašių tyrimų apžvalga;
- pateikiami tyrime naudoti duomenys;
- pateikiami tyrimo rezultatai.

Remiantis reikšminiais žodžiais rasti 87 straipsniai, iš jų tik dalis – 25 straipsniai – atitiko atrankos kriterijus.

2. Dinaminiai dirbtinių neuronų tinklai

Pastaraisiais dešimtmečiais buvo atlikta daug tyrimų nagrinėjant statinius neuronų tinklus. Tačiau didelė da-

lis mus supančių signalų kinta laikui bėgant, tad šiomis dienomis dinaminį DNT tyrimai yra ypač populiarūs. Dinaminiai DNT, priešingai nei statiniai, pagal įėjimo pavyzdį gali keisti savo struktūrą ar parametrus formuodami atsaką (Han et al., 2022).

DNT teorijoje yra siūloma daugybė skirtingų būdų, kurie leidžia apdoroti netiesinius, bėgant laikui kintančius signalus. Siekiant apibrėžti neuronų tinklą kaip dinaminę sistemą šiame straipsnyje bus remiamasi globalaus tiesioginio DNT modeliu. Globalus tiesioginis DNT yra sudarytas pagal daugiasluoksnio perceptrono struktūrą. Globalų tiesioginį DNT kaip netiesinę dinaminę sistemą, gebančią apdoroti signalus laikui bėgant, galima apibūdinti šia matematine išraiška (Navakauskas, 1997):

$$\hat{y}(n) = \Phi^L \left\{ \Phi^{L-1} \left\{ \dots \Phi^1 \left\{ x(n), z^1(n); w^1 \right\} \dots \right\}, z^L(n); w^L \right\}, \quad (1)$$

čia n – diskretaus laiko indeksas; L – DNT sluoksnių skaičius; $\hat{y}(n)$ – neuronų tinklo atsakas n laiko momentu (tikrojo signalo aproksimacija); $\Phi\{\cdot\}$ – l -tojo sluoksnio perdavimo funkcija; $x(n) = [x_1(n), x_2, \dots, x_{N_i}(n)]$ – n laiko įėjimo pavyzdys, N_i – visų pavyzdžių skaičius; $z(n) = [z_1(n), z_2, \dots, z_{N_s}(n)]$ – n laiko būseną, čia N_s – visų būsenų skaičius; $w(n)$ – parametrų vektorius, nurodantis tikrąjį modelį modelių klasėje Φ .

Vieno neuroso išėjimo signalą dinaminiame DNT galima apibūdinti šia matematine išraiška:

$$s_h^l(n) = \Phi^l \left\{ z_h^l(n) \right\}, \quad (2)$$

čia $s_h^l(n)$ – neuroso išėjimas; l, h – sluoksnių, įėjimo ir išėjimo pavyzdžių indeksai atitinkamai; $z_h^l(n)$ – perdavimo funkcijos įėjimas, kuris apibūdina dinaminę sinapsę. Pagal tai, kaip $z_h^l(n)$ suformuojamas, DNT galima suskirstyti į tris grupes:

- lokalius tiesioginius;
- lokalius atgalinius;
- rekurentinius.

Toliau nagrinėsime šioms grupėms priklausančių dinaminį sinapsių savybes ir jų įgyvendinimą skirtingose DNT architektūrose.

3. Dinaminė sinapsė

Dirbtinių neuronų tinklai, grįsti dinaminėmis sinapsėmis, atveria naujas galimybes mašininio mokymosi ir DI srityse. Norint suprasti dinaminį sinapsių privalumus, būtina pradėti nuo pagrindinių dinaminį sinapsių charakteristikų.

Dinaminė sinapsė yra ryšys tarp dviejų neuronų, kuris didina tinklo efektyvumą bei plastiškumą. Dinaminės sinapsės, panašiai kaip biologinės žmogaus smegenų sinapsės, gali stiprinti ar silpninti ryšius tarp neuronų priklausomai nuo perduodamos informacijos. Šis procesas vadinamas sinapsiniu plastiškumu (Mei et al., 2022). Sinapsinis plastiškumas yra pagrindinis mechanizmas, kuris leidžia neuronų tinklui mokytis ir adaptuotis prie naujų informacijos srautų. Kiekviena sinapsė neuronų tinkle pasižymi reprezentatyvumu ir krypties savybėmis.

Reprezentatyvumas. Sinapsė gali turėti pastovų svorį arba būti sudaryta iš dinaminės sistemos. Dinaminė sinapsė gali būti apibūdinama šia bendrine išraiška:

$$z_h^l(n) = s_i^l(n)w_{ih}^l, \quad (3)$$

čia $s_i^l(n)$ – l -tojo sluoksnio i -tojo neurono išėjimo signalas; w_{ih}^l – sinapsės, jungiančios i -tąjį su h -tuoju neuronu, svoris. Dinaminė sinapsė gali būti įgyvendinama, pvz., naudojant ribotos impulsinės reakcijos (RIR), beribės impulsinės reakcijos (BIR) ar pynučių-kopėtėlių filtrus (Tsoi & Back, 1997). Taip pat sinapsė gali būti papildoma rekurentiniais ryšiais, kurie gali būti įgyvendinami neurone ar atminties celėse, kuriose naudojamos papildomos sinapsės tarp celės struktūros elementų – vartų.

Apimtis ir kryptis. Ryšiai tarp neuronų būna lokaliūs – esantys tame pačiame neuronų sluoksnyje, ar globalūs – jungiantys skirtingų sluoksnių neuronus. DNT ryšiai gali būti trijų kryptių: tiesioginiai (tarpsluoksniniai) – kai signalas iš įėjimo perduodamas į išėjimą, grįžtamieji (tarpsluoksniniai) – kai signalas iš išėjimo perduodamas į įėjimą, bei rekurentiniai (intrasluoksniniai) – kai signalas išėjime grįžta į tą patį neuroną.

4. Dirbtinių neuronų tinklai su dinaminėmis sinapsėmis

Apžvelgsime DNT, skirtus laiko signalams apdoroti. Kiekvienas iš šių tinklų turi dinamines savybes, kurios pasiūkia jų sinapsėse. 1 pav. pateikta DNT su dinaminėmis sinapsėmis klasifikavimo pagal sinapsės kryptį schema. Joje pateikiama 11 skirtingų DNT struktūrų, suskirstytų į 3 grupes.

Laiko delsos neuronų tinklas (LDNT). Siekiant apdoroti laiko signalus Waibel (1989) pasiūlė laiko delsos neuronų tinklą, kuris išsiskiria savo gebėjimu apdoroti duomenų sekas, todėl jis ypač tinkamas apdoroti signalus

laike. Tinklo ryšiuose naudojami vėlinimo elementai, kurie leidžia tinklui turėti atminties formą ir atsižvelgti ne tik į dabartinę įvestį, bet ir į praeities įvestis. Kiekvienas LDNT sluoksnio neuronas ne tik gauna įvestį iš ankstesnio sluoksnio neuronų, bet ir iš tų pačių neuronų išvesties ankstesniais laiko etapais. LDNT neurono išvestį sudaro dabartinių ir ankstesnių pavyzdžių informacija. Sinapsės LDNT tinkle galima apibūdinti šia išraiška:

$$z_h^l(n) = \sum_{j=1}^{M_l} s^{l-1}(n-j)w_{jh}^l, \quad (4)$$

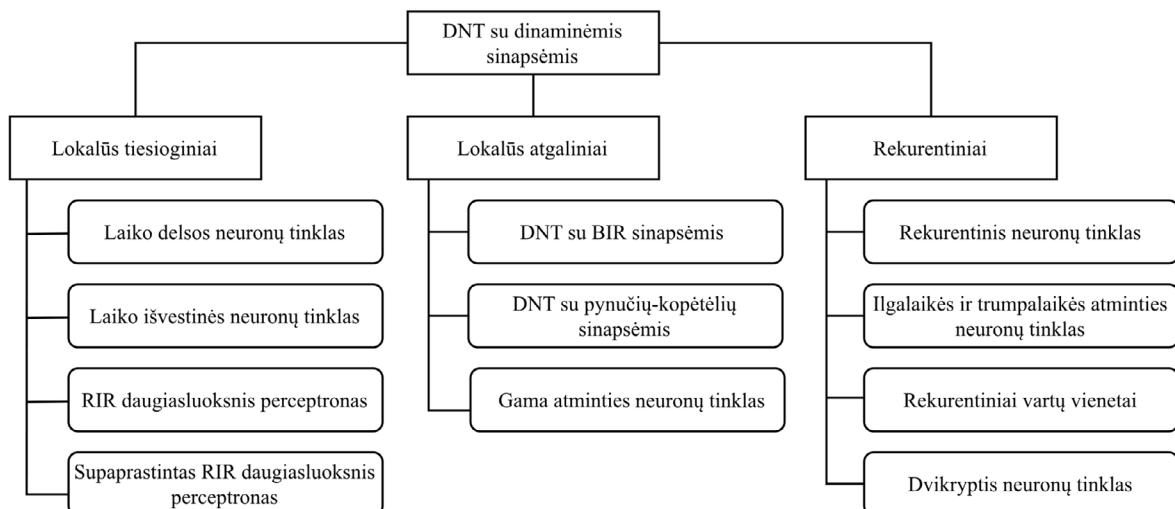
čia M_l – l -tojo sluoksnio maksimali delsos reikšmė; w_j^l – l -tojo sluoksnio svorių matrica, kuri apdoroja j kartų pavėlintą įėjimo pavyzdį; $s^{l-1}(n-j)$ – j kartų pavėlintas įėjimo pavyzdys.

Laiko išvestinės neuronų tinklas (LINT). Kaip analogas LDNT tinklui buvo pasiūlytas laiko išvestinės neuronų tinklas (Paliwal, 1991). Šis tinklas turi lokalius tiesioginius sąryšius, kuriuose įgyvendintas laiko išvestinės modelis. Pagrindinis privalumas naudojant laiko išvestines – laiko gylis yra nesusietas su neuronų skaičiumi. Sinapsės LINT tinkle apibūdinamos pagal šią išraišką:

$$s_h^l(n) = \Phi^l \left\{ \sum_{i=1}^{N_{l-1}} \sum_{j=1}^{M_l} w_{ijh}^l \left(s_i^{l-1}(n) \right)^{(j)} \right\}, \quad (5)$$

čia w_{ijh}^l – sinapsės svoriai, kurie apdoroja j -osios eilės išvestinės pavyzdį ir jungia i -tojo įėjimo ir h -tojo išėjimo neuronus; $\left(s_i^{l-1}(n) \right)^{(j)}$ – j -osios eilės įėjimo pavyzdžio išvestinė; N_{l-1} ir M_l – įėjimų skaičius ir maksimali išvestinės eilė l -tame sluoksnyje atitinkamai.

Ribotos impulsinės reakcijos (RIR) daugiasluoksnis perceptronas. Šie tinklai turi lokalius tiesioginius ryšius, kurių veikimo principas yra panašus į RIR filtrus signalų apdorojimo procese. RIR filtrai turi baigtinį atsaką į impulsų įvestį, tai reiškia, kad jie neturi grįžtamojo ryšio, o jų išvestį lemia tik dabartinės ir ankstesnės įvesties reikšmės.



1 paveikslas. DNT su dinaminėmis sinapsėmis klasifikavimo schema
Figure 1. Classification scheme of ANN with dynamic synapses

RIR neuronų tinklų sinapsėse yra saugoma ankstesnio įėjimo informacija tam tikrą laiko žingsnių skaičių. Pirmąją šio tinklo struktūrą pasiūlė Wan (1990, 1991), vėliau šią struktūrą papildė Back ir Tsoi (1991) pridėdami papildomus statinius svorius RIR sinapsių filtruose. RIR sinapsė gali būti apibūdinama pagal šią išraišką:

$$z_h^l(n) = \sum_{j=1}^{M_l} s^{l-1}(n-j)w_{jh}^l, \quad (6)$$

čia $w_{jh}^l(n)$ – RIR filtro koeficientai; M_l – įėjimų skaičius ir RIR filtro eilė l -tame sluoksnyje atitinkamai. Šių tinklų išvestis yra svertinė saugomų įėjimų suma. Ryšių svoriai RIR neuronų tinkluose yra išdėstyti vėlinimo linijoje ir yra atnaujinami mokymo metu.

Supaprastintas RIR daugiasluoksnis perceptronas.

Šis neuronų tinklas sujungia RIR filtro ir daugiasluoksnio perceptrono principus. Tinklą pasiūlė Diepenhorst et al. (1995) kaip supaprastintą RIR daugiasluoksnį perceptroną, kurio kiekvieno sluoksnio sinapsės yra aproksimuojamos pagal „vidutinę“ RIR sinapsę (skirtingų įėjimų svoriai yra beveik vienodi). Taip yra sumažinamas skaičiavimo operacijų kiekis. Supaprastinto RIR daugiasluoksnio perceptrono sinapsę galima apibūdinti šia formule:

$$z_h^l(n) = \sum_{j=0}^{M_l} \hat{w}_{jh}^l \sum_{i=1}^{N_l-1} s_i^{l-1}(n-j)\bar{w}_{ih}^l, \quad (7)$$

čia \hat{w}_{jh}^l , $j=1, \dots, M_l$ – h -tojo neuroono „vidutinė“ sinapsė l -tame sluoksnyje; \bar{w}_{ih}^l – statinis svoris, jungiantis l -tojo sluoksnio i -tąjį įėjimą su h -tuoju išėjimu. Lyginant su RIR daugiasluoksniu perceptronu kiekviename sluoksnyje w svorių matrica sumažinama nuo $N_{l-1}M_lN_l$ iki $(N_{l-1} + M_l)N_l$ elementų.

DNT su beribės impulsinės reakcijos (BIR) sinapsėmis.

Šie neuronų tinklai pasižymi lokaliais grįžtamaisiais ryšiais. BIR filtrų pranašumas lyginant su RIR filtrais yra tai, kad jie geba efektyviau apdoroti signalus, kuriems reikalinga įvertinti ilgas laiko sekas (Back & Tsoi, 1991). Pagrindinis šio DNT su BIR sinapsėmis skirtumas yra poslinkio elementas, kuris neleidžia sinapsėms prisistotinti. BIR DNT sinapsę galima apibūdinti pagal šią išraišką:

$$z_h^l(n) = \sum_{i=1}^{N_l} \tilde{s}_{ih}^l(n) + c_h^l(n); \quad (8)$$

$$\tilde{s}_{ih}^l(n) = \sum_{j=0}^{M_l} b_{ijh}^l(n) \cdot s_i^{l-1}(n-j) + \sum_{j=1}^{M_l} a_{ijh}^l(n) \cdot \tilde{s}_{ih}^l(n-j),$$

čia $\tilde{s}_{ih}^l(n)$ – BIR filtro išėjimas; $b_{ijh}^l(n)$ ir $a_{ijh}^l(n)$ – nerekursiniai ir rekursiniai BIR filtro koeficientai atitinkamai; c_h^l – poslinkio elementas.

Gama atminties neuronų tinklai. Šie tinklai turi grįžtamojo ryšio gama atminties sinapses, kuriose yra išsaugoma įvesties signalų laiko informacija. Gama filtrai buvo sukurti siekiant išspręsti BIR filtrų problemą – negarantuotą stabilumą (Lawrence et al., 1995; De Vries et al., 1991). Tai buvo įgyvendinta apribojant IIR filtro architektūrą bei panaikinant atminties gylį sąsają su filtro eile. Gama atminties neuronų tinklo sinapsė apibūdinama šiomis išraiškomis:

$$z_h^l(n) = \sum_{i=1}^{N_l} \tilde{s}_{ih}^l(n);$$

$$\tilde{s}_{ih}^l(n) = \sum_{j=0}^{M_l} w_{ijh}^l(n) \cdot s_{ijh}^{0l}(n); \quad (9)$$

$$s_{ijh}^{0l}(n) = \begin{cases} (1 - \eta_{ih}^l(n)) \cdot s_{ijh}^{0l}(n-1) + \eta_{ih}^l(n) \cdot s_{i,(j-1),h}^{0l}(n-1), & j=0, \\ s_i^{l-1}(n), & 1 \leq j \leq M_l, \end{cases}$$

čia $\tilde{s}_{ih}^l(n)$ – gama filtro išėjimas; $s_{ijh}^{0l}(n)$ – vienetinio šuolio signalas; $w_{ijh}^l(n)$ – gama filtro koeficientai; $\eta_{ih}^l(n)$ – gama filtro kontrolės parametrai.

DNT su pynučių-kopėtėlių sinapsėmis. Šio tinklo architektūroje į jungtis tarp sluoksnių įtraukiama pynučių-kopėtėlių filtro struktūra (Back & Tsoi, 1992). Pynučių-kopėtėlių filtras paveldi gerąsias BIR filtro savybes – begalinę atmintį ir stabilumą rekurentinėje filtro dalyje. Dėl specifinių šio tinklo savybių rekurentinės dalies stabilumo stebėjimas tampa paprastas, todėl šis filtras turi pranašumą lyginant su BIR DNT (Navakauskas et al., 2014). Pynučių-kopėtėlių sinapsė gali būti apibūdinama pagal šias išraiškas:

$$z_h^l(n) = \sum_{i=1}^{N_l} \tilde{s}_{ih}^l(n); \quad (10)$$

$$\tilde{s}_{ih}^l(n) = \sum_{j=0}^{M_l} v_{ijh}^l(n) \cdot b_{ijh}^l(n),$$

čia $\tilde{s}_{ih}^l(n)$ – l -tojo sluoksnio išėjimo signalas, kuris jungia i -tojo įėjimo ir h -tojo išėjimo neuronus; $v_{ijh}^l(n)$ – pynučių-kopėtėlių filtro dalys; $b_{ijh}^l(n)$ – tiesioginio filtro spėjimo klaidos įvertis.

Rekurentinis neuronų tinklas RNT. Šie tinklai vadinami rekurentiniais, nes atlieka tą pačią užduotį kiekvienam įėjimo signalo pavyzdžiui, o išvestis priklauso nuo ankstesnių laiko žingsnių (McClelland & Rumelhart, 1987; Biswas & Fitzgerald, 2022). RNT architektūroje yra įgyvendinti rekurentiniai ryšiai – kilpos, kurios perduoda informaciją iš vieno laiko sekos žingsnio į kitą. Taip sukuriami vidinės atminties forma, kuri gali apdoroti įėjimo duomenų sekas. Skirtingai nei IIR, gama atminties ar pynučių-kopėtėlių neuronų tinklai RNT įėjimo signalo laiko sekas apdoroja tame pačiame sluoksnyje pasitelkiant rekurentinius ryšius, o ne ryšyje tarp sluoksnių. RNT sinapsę galima apibūdinti šia formule:

$$z_h^l(n) = \sum_{i=1}^{N_l} w_{ih}^l \cdot s_i^{l-1}(n) + \sum_{j=1}^{M_l} w_{jh}^l \cdot h_{jh}^l(n-1), \quad (11)$$

čia $h_{jh}^l(n-1)$ – j -ojo neuroono išėjimas ankstesniame laiko žingsnyje n ; w_{ih}^l – h -tojo neuroono rekurentinio ryšio svoriai; w_{jh}^l – svoriai sinapsės, kuri jungia i -tojo įėjimo ir h -tojo išėjimo neuronus; N^l ir M^l – įėjimų ir rekurentinių ryšių skaičius l -tame sluoksnyje atitinkamai.

Dvikrypčiai neuronų tinklai. Šie buvo sukurti Schuster ir Paliwal (1997) siekiant patobulinti RNT tinklo

struktūrą. Pagrindinis dvikrypčio tinklo pranašumas yra tai, kad išvestis tam tikrame laiko sekos taške gali priklausyti ne tik nuo buvusių ir esamų įėjimų (kaip standarti- niame RNT), bet ir nuo būsimų įėjimų. Ši sąsaja įgyven- dinama apdorojant įvesties duomenis dviem kryptimis – iš praeities į ateitį ir iš ateities į praeitį. Įėjimo duomenų apdorojimas pirmyn ir atgal nepriklauso vienas nuo kito. Dvikrypčio neuronų tinklo sinapsę galima apibūdinti šia išraiška:

$$\begin{aligned} z_f^l(n) &= \sum_{i=1}^{N^l} w_{if}^l \cdot s_i^{l-1}(n) + \sum_{j=1}^{M^l} w_{jf}^l \cdot h_j^l(n-1); \\ z_b^l(n) &= \sum_{i=1}^{N^l} w_{ib}^l \cdot s_i^{l-1}(n) + \sum_{j=1}^{M^l} w_{jb}^l \cdot h_j^l(n+1), \end{aligned} \quad (12)$$

čia $h_{jf}^l(n-1)$ ir $h_{jb}^l(n+1)$ – j -ojo neuro- no išėjimas anks- tesniame ir vėlesniame laiko žingsnyje n atitinkamai; w_{if}^l ir w_{jb}^l – šių išėjimų svoriai; w_{if}^l ir w_{ib}^l – tiesioginės reku- rentinės ir grįžtamosios rekurentinės sinapsės svoriai ati- tinkamai; N^l ir M^l – įėjimų ir rekurentinių ryšių skaičius l -tame sluoksnyje atitinkamai. Skaičiuojant neuro- no atsaką $z_b^l(n)$ ir $z_f^l(n)$ sinapsėms taikoma perdavimo funkcija, kurios išėjimai yra sujungiami.

Dvikrypčiai neuronų tinklai yra ypač naudingi, kai reikalinga įvertinti įvesties duomenų kontekstą. Pavyz- džiai, atpažįstant rašyseną našumą galima pagerinti, jei atsižvelgiama ir į kairinį, ir į dešinįjį kontekstą, tačiau dvi- krypčiams tinklams reikia daugiau skaičiavimo išteklių ir atminties, palyginti su vienakrypčiais, nes jie iš esmės padvigubina skaičiavimų kiekį. Be to, jie negali būti nau- dojami realiojo laiko sistemose, kur ateities įvestis nepa- siekiama.

Ilgalaiškės ir trumpalaiškės atminties tinklas (ITAT).

ITAT yra rekurentinio neuronų tinklo tipas, gebantis įsiminti ilgas duomenų sekas. Ši tinklo struktūra buvo pasiūlyta Hochreiter ir Schmidhuber (1997) siekiant išspręsti nykstančių gradientų problemą, kuri pasireiš- kia įprastuosiuose rekurentiniuose neuronų tinkluose. ITAT tinklo neuronai pakeičiami atminties celėmis, kur kiekviena celė turi keturis pagrindinius komponentus: įvesties vartus, užmaršties vartus, kandidato nustatymą ir išvesties vartus (Zhang et al., 2019; Hashemi et al., 2023). Šie elementai nustato, kaip informacija patenka į celę, iš jos ir viduje. Įvesties vartai nustato, kiek informacijos iš dabartinės įvesties bus saugoma celės būsenoje. Užmarš- ties vartai nusprendžia, kokia celės būsenos informacijos dalis iš ankstesnio laiko žingsnio turėtų būti išsaugota arba pamiršta. Kandidato nustatymo metu yra apskai- čiuojama nauja atmintis, kuri gali būti įtraukta į celės bū- seną, remiantis dabartine įvestimi ir ankstesne paslėptąja būseną. Išvesties vartai kontroliuoja, kiek informacijos dabartinėje būsenoje naudojama celės išvesčiai apskai- čiuoti. ITAT celėje egzistuoja keturios sinapsės kiekvie- nam anksčiau paminėtam celės elementui. Kiekvieno elemento sinapsę galima apibūdinti šiomis išraiškėmis:

$$\begin{aligned} z_v^l(n) &= \sum_{i=1}^{N^l} w_{iv}^l \cdot s_i^l(n) + w_{jv}^l \cdot h_j^l(n-1); \\ z_f^l(n) &= \sum_{i=1}^{N^l} w_{if}^l \cdot s_i^l(n) + w_{jf}^l \cdot h_j^l(n-1); \\ z_c^l(n) &= \sum_{i=1}^{N^l} w_{ic}^l \cdot s_i^l(n) + w_{jc}^l \cdot h_j^l(n-1); \\ z_o^l(n) &= \sum_{i=1}^{N^l} w_{io}^l \cdot s_i^l(n) + w_{jo}^l \cdot h_j^l(n-1), \end{aligned} \quad (13)$$

čia $z_v^l(n)$, $z_f^l(n)$, $z_c^l(n)$ ir $z_o^l(n)$ – įvesties vartų, užmarš- ties vartų, atminties kandidato ir išvesties vartų sinapsės atitinkamai, kurios turi w_{iv}^l , w_{if}^l , w_{ic}^l , w_{io}^l įėjimo svo- rius ir w_{jv}^l , w_{jf}^l , w_{jc}^l , w_{jo}^l paslėptosios būsenos svorius; $s_i^l(n)$ – celės įėjimas; $h_j^l(n-1)$ – celės paslėptoji būseną.

ITAT tinkluose, skirtingai nei prieš tai aptartuose DNT su kiekvieno celės elemento perdavimo funkcija, yra iš anksto nustatyta – įvesties, užmaršties ir išvesties vartų sinapsės yra apdorojamos sigmoidine perdavimo funkcija, atminties kandidatas apdorojamas tangentine perdavimo funkcija. Siekiant suformuoti celės atmintį, kuri bus nau- dojama apdorojant kitą celės įėjimo pavyzdį, (13) formu- lėse apskaičiuotos sinapsės naudojamos šioje išraiškoje:

$$\begin{aligned} c_j^l(n) &= \sigma\{z_f^l(n) + b_f\} \odot c_j^l(n-1) + \\ &\sigma\{z_v^l(n) + b_v\} \odot \tanh\{z_c^l(n) + b_c\}, \end{aligned} \quad (14)$$

čia $c_j^l(n)$ – n įėjimo pavyzdžio celės atmintis; b_f , b_v ir b_c – užmaršties vartų, įėjimo vartų ir atminties kandidato poslinkis atitinkamai; σ ir \tanh – sigmoidinė ir tangentinė perdavimo funkcijos atitinkamai; \odot žymi elementų dau- gybos veiksmą, kai kiekvienas matricos elementas daugi- namas su to pačio indekso kitos matricos elementu.

Celės išėjimas yra vadinamas paslėptąja būseną, jis yra perduodamas į kitą neuronų tinklo sluoksnį bei grįž- tamuoju ryšiu perduodamas į pačią celę. Paslėptoji būseną naudoja išėjimo vartų sinapsę (13) ir celės atmintį (14) bei yra aprašoma šia matematine išraiška:

$$h^l(n) = \sigma\{z_o^l(n) + b_o\} \odot \tanh\{c_j^l(n)\}, \quad (15)$$

čia $h^l(n)$ – n -tojo įėjimo pavyzdžio paslėptoji būseną; b_o – išvesties vartų poslinkis; σ ir \tanh – sigmoidinė ir tangentinė perdavimo funkcijos atitinkamai.

Rekurentiniai vartų vienetai (RVV). RVV yra reku- rentinės architektūros neuronų tinklas, sukurtas siekiant įveikti nykstančio gradiento problemą, kuri gali kilti tra- diciniuose RNT, bei supaprastinti ITAT sinapsėse atlieka- mus skaičiavimus (Cho et al., 2014; Zhang et al., 2019). RVV kaip ir ITAT tinkluose yra įgyvendinti duomenų vartai, kurie moduliuoja informacijos srautą rekurenti- nio tinklo paslėptojoje būsenoje. Tačiau RVV naudoja paprastesnę struktūrą nei ITAT, sujungiant įvesties ir užmaršties vartus į vienus – atnaujinimo vartus. Taip pat naudojami atkūrimo vartai, kurie kontroliuoja atminties informacijos kiekį, kuris bus naudojamas kitam įėjimo

pavyzdžiui apdoroti. RVV tinklo sinapsės apibūdinamos pagal šią išraišką:

$$\begin{aligned} z_u^l(n) &= \sum_{i=1}^{N_l} w_{iu}^l \cdot s_i^l(n) + w_{ju}^l \cdot h_j^l(n-1); \\ z_r^l(n) &= \sum_{i=1}^{N_l} w_{ir}^l \cdot s_i^l(n) + w_{jr}^l \cdot h_j^l(n-1); \\ z_c^l(n) &= \sum_{i=1}^{N_l} w_{ic}^l \cdot s_i^l(n) + w_{jc}^l \cdot z_r^l(n) \odot h_j^l(n-1), \end{aligned} \quad (16)$$

čia $z_u^l(n)$, $z_r^l(n)$ ir $z_c^l(n)$ – atnaujinimo vartų, atkūrimo vartų ir atminties kandidato sinapsės atitinkamai, jos turi w_{iu}^l , w_{ir}^l , w_{ic}^l įėjimo svorius ir w_{ju}^l , w_{jr}^l , w_{jc}^l paslėptosios būsenos svorius; \odot žymi matricių atitinkamų narių daugybos veiksmą; $h_j^l(n-1)$ – kelės paslėptoji būseną.

RVV kelės išėjimas – paslėptoji būseną, apskaičiuojama pagal išraišką:

$$\begin{aligned} h^l(n) &= \left(1 - \sigma \left\{ z_u^l(n) + b_u \right\} \right) \\ &\odot h_j^l(n-1) + \sigma \left\{ z_u^l(n) + b_u \right\} \\ &\odot \tanh \left(z_c^l(n) + b_c \right), \end{aligned} \quad (17)$$

čia $h^l(n)$ – n -tojo įėjimo pavyzdžio paslėptoji būseną; b_u ir b_c – atnaujinimo vartų ir atminties kandidato poslinkis atitinkamai; σ ir \tanh – sigmoidinė ir tangentinė perdavimo funkcijos atitinkamai.

5. Dirbtinių neuronų tinklų su dinaminėmis sinapsėmis analizė

Išnagrinėjus skirtingų DNT sinapsių matematinės išraiškas galima nustatyti jų pagrindines savybes ir palyginti tarpusavyje. 1 lentelėje pateikiamos skyruije aptartų DNT sinapsių pagrindinės savybės. Lentelėje „+“ žymi savybę, kuri pasireiškia nurodytame tinkle.

Visuose išvardintuose DNT naudojamas signalo poslinkis laike, kuris leidžia apdoroti laiko sekas. Laiko išvestinės neuronų tinkle skaičiuojama įėjimo laiko išvestinė, todėl yra panaikinamas sąryšis tarp neuronų skaičiaus ir laiko žingsnių. Ši savybė leidžia apdoroti ilgesnes laiko sekas nekeičiant tinklo struktūros. Laiko žingsnių ir neuronų skaičiaus sąryšis taip pat yra panaikinamas sinapsėje įgyvendinant filtro struktūrą. RIR daugiasluoksniame perceptrone sukuriama atminties forma sinapsėje naudojant RIR filtro struktūrą. Supaprastintame RIR daugiasluoksniame perceptrone ne tik naudojama RIR filtro struktūra, bet ir kiekvieno sluoksnio sinapsės yra aproksimuojamos pagal „vidutinę“ RIR sinapsę. Taip yra atliekama mažiau matematinių veiksmų skaičiuojant tinklo atsaką. DNT su BIR sinapsėmis sukuriama atminties forma naudojant BIR filtro struktūrą. Gama atminties neuronų tinklo sinapsėje naudojamas gama filtras, kuris sprendžia BIR filtro problemą – negarantuotą stabilumą. Negarantuoto stabilumo problemą sprendžia ir DNT su pynučių-kopėtelių

1 lentelė. Dirbtinių neuronų tinklų su dinaminėmis sinapsėmis pagrindinės savybės
Table 1. Main features of dynamic synapses of artificial neural networks

Pavadinimas	Dirbtinių neuronų tinklo savybė									
	Gebejimas apdoroti signalą, kintantį laike	Netiesinis neuronų sk. ir laiko sąryšis	Sinapsėje taikoma filtro struktūra	Rekurentinė sinapsė	Dvikryptė rekurentinė sinapsė	Celės struktūra	Tinklo stabilumas	Nykstantys gradientai	Grįžtamieji tarpusluoksniiniai ryšiai	Skaiciavimų apimtis
Laiko delsos neuronų tinklas	+						+			$(M + 1) \cdot N_2$
Laiko išvestinės neuronų tinklas	+	+					+			$(M + 1) \cdot N_2$
RIR daugiasluoksnis perceptronas	+	+	+				+			$(M + 1) \cdot N_1 \cdot N_2$
Supaprastintas RIR daugiasluoksnis perceptronas	+	+	+				+			Mažiau už RIR
DNT su BIR sinapsėmis	+	+	+							$2(M + 1) \cdot N_1 \cdot N_2$
Gama atminties neuronų tinklai	+	+	+				+			$2(M + 1) \cdot N_1 \cdot N_2$
DNT su pynučių-kopėtelių sinapsėmis	+	+	+				+			$2(M + 1) \cdot N_1 \cdot N_2$
Rekurentiniai neuronų tinklai	+			+						$N_1 \cdot N_2 + N_2$
Dvikrypčiai neuronų tinklai	+			+	+				+	$N_1 \cdot N_2 + 2N_2$
Ilgalaikės ir trumpalaikės atminties neuronų tinklai (ITAT)	+			+		+	+	+		$N_2 (N_2 \cdot N_1 + N_2 \cdot N_2)$
Rekurentiniai vartų vienetai	+			+		+	+	+		Mažiau už ITAT

sinapsėmis. Šiuose tinkluose įėjimas ir svoriai pakeičiami pynučių-kopėtėlių filtro dalimis. Rekurentiniuose neuronų tinkluose atminties forma įgyvendinama naudojant rekurentinius sąryšius. Šiuose tinkluose neuronų skaičius priklauso nuo laiko žingsnių skaičiaus. Dvikryptis neuronų tinklas, lyginant su įprastu rekurentiniu tinklu, papildomai naudoja tiesiogines sinapses, kurios atsižvelgia į ateities įėjimo signalo pavyzdžius. Ilgalaikės ir trumpalaikės atminties neuronų tinkluose naudojama celės struktūra. Vienoje tinklo celės struktūroje naudojamos keturios sinapsės bei iš anksto nustatytos perdavimo funkcijos – sigmoidinė ir tangentinė. Ši celės struktūra sprendžia gradientų problemą, kuri pasireiškia RNT. Rekurentinių vartų vienetų tinkluose, lyginant su ITAT, įvesties ir išvesties vartai sujungiami į vienus atnaujinimo vartus, tad celės struktūroje naudojamos trys sinapsės. Ši struktūra taip pat sprendžia nykstančių gradientų problemą bei naudoja mažiau matematinių veiksmų skaičiuojant tinklo atsaką. 1 lentelėje pateikiama skaičiavimų apimtis, kurioje parodomas skaičiavimų kiekis viename neurone. Apibūdinant skaičiavimų apimtį naudojama M – filtro eilė, N_1 ir N_2 – pirmasis ir antrasis įėjimo signalo laiko žingsnis atitinkamai.

Išvados

Atlikus straipsnių atranką ir išanalizavus atrinktus straipsnius buvo rasta 11 DNT struktūrų (laiko delsos neuronų tinklas; laiko išvestinės neuronų tinklas; RIR daugiasluoksnis perceptronas; supaprastintas RIR daugiasluoksnis perceptronas; DNT su BIR sinapsėmis; gama atminties neuronų tinklai; DNT su pynučių-kopėtėlių sinapsėmis; rekurentiniai neuronų tinklai; dvikryptiniai neuronų tinklai; ilgalaikės ir trumpalaikės atminties neuronų tinklai; rekurentiniai vartų vienetai), kurios turi dinamines sinapses. Išnagrinėjus visų tipų sinapsių savybes nustatyta, kad:

1. Dinaminių sinapsių naudojimo DNT viena iš pagrindinių problemų yra tinko efektyvumas – kadangi įėjimo signalai yra apibūdinami laikui bėgant, tinklas turi atlikti skaičiavimus ne su vienu įėjimo pavyzdžiu, tačiau ir su ankstesniais ar vėlesniais įėjimo signalo pavyzdžiais. Lokalių tiesioginių tinklų grupėje šią problemą geriausiai sprendžia supaprastintas BIR daugiasluoksnis perceptronas, lokalių atgalinių tinklų grupėje – gama ir pynučių-kopėtėlių DNT, rekurentinių tinklų grupėje – rekurentiniai vartų vienetai.
2. Įgyvendinant DNT, turinčius lokalius atgalinius ryšius, pasireiškia filtrų stabilumo užtikrinimo problema, kai sinapsėse naudojami FIR, gama ar pynučių-kopėtėlių filtrai. Gama ir pynučių-kopėtėlių DNT sprendžia šią problemą, kadangi tinklo struktūroje naudoja papildomus koeficientus filtrų stabilumui užtikrinti.
3. Rekurentinius ryšius turinčiuose DNT pasireiškia nykstančių gradientų problema, dėl kurios gali būti prarandama signalo dalies informacija. Šią problemą sprendžia ilgalaikės ir trumpalaikės atminties DNT ir rekurentiniai vartų vienetai, kurie naudoja celės struktūrą ir užtikrina gradientų stabilumą.

Dinaminių sinapsių tyrimams numatomos kelios ateities kryptys. Visų pirma, tai optimizavimo metodai – dinaminės sinapsės gali padidinti modelio sudėtingumą, todėl tolesni tyrimai gali būti sutelkti į efektyvius optimizavimo metodus, kad būtų galima išnaudoti dinaminių sinapsių potencialą, neapsunkinant tinklo skaičiavimų mokymo ar spėjimo metu. Kita kryptis yra plastiškumo modeliavimas – dinaminių sinapsių esmė yra jų gebėjimas keistis, atsižvelgiant į perduodamą informaciją, procesas, kuris yra žinomas kaip sinaptinis plastiškumas. Tai gali būti geras laukas tolesniems tyrimams, siekiant geriau modeliuoti ir suprasti šį plastiškumo procesą. Taip pat dinaminės sinapsės gali būti integruotos su kitomis neuronų tinklų technologijomis, tokiomis kaip atminties vienetai arba uždarojo ciklo neuronai, siekiant sukurti dar efektyvesnius ir lankstesnius tinklus.

Literatūra

- Back, A. D., & Tsoi, A. C. (1991). FIR and IIR synapses, a new neural network architecture for time series modeling. *Neural Computation*, 3(3), 375–385. <https://doi.org/10.1162/neco.1991.3.3.375>
- Back, A. D., & Tsoi, A. C. (1992). An adaptive lattice architecture for dynamic multilayer perceptrons. *Neural Computation*, 4(6), 922–931. <https://doi.org/10.1162/neco.1992.4.6.922>
- Biswas, T., & Fitzgerald, J. E. (2022). Geometric framework to predict structure from function in neural networks. *Physical Review Research*, 4(2), 023255. <https://doi.org/10.1103/PhysRevResearch.4.023255>
- Cho, K., Merriënboer, B., Bahdanau, D., & Bengio, Y. (2014). On the properties of neural machine translation: Encoder-decoder approaches. In *Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation* (pp. 103–111), Doha, Qatar. Association for Computational Linguistics. <https://doi.org/10.3115/v1/W14-4012>
- De Vries, B., Principe, J. C., & Guedes de Oliveira, P. (1991). Adaline with adaptive recursive memory. In *Neural Networks for Signal Processing Proceedings of the 1991 IEEE Workshop* (pp. 101–110), Princeton, NJ, USA. IEEE. <https://doi.org/10.1109/NNSP.1991.239531>
- Diepenhorst, M., Nijhuis, J. A. G., Venema, R. S., & Spaanenburg, L. (1995). Growing filters for finite impulse response networks. In *Proceedings of ICNN'95 – International Conference on Neural Networks* (Vol. 2, pp. 854–859), Perth, WA, Australia. IEEE. <https://doi.org/10.1109/ICNN.1995.487530>
- Han, Y., Huang, G., Song, S., Yang, L., Wang, H., & Wang, Y. (2022). Dynamic neural networks: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44, 7436–7456. <https://doi.org/10.1109/TPAMI.2021.3117837>
- Hashemi, A., Orzechowski, G., Mikkola, A., & McPhee, J. (2023). Multibody dynamics and control using machine learning. *Multibody System Dynamics*, 58, 397–431. <https://doi.org/10.1007/s11044-023-09884-x>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9, 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Huang, H. M., Wang, Z., Wang, T., Xiao, Y., & Guo, X. (2020). Artificial neural networks based on memristive devices: From device to system. *Advanced Intelligent Systems*, 2(12), 2000149. <https://doi.org/10.1002/aisy.202000149>

- Lawrence, S., Tsoi, A., & Back, A. (1995). The Gamma MLP for speech phoneme recognition. In *Advances in neural information processing systems*. MIT Press.
- Lin, H., Wang, C., Deng, Q., Xu, C., Deng, Z., & Zhou, C. (2021). Review on chaotic dynamics of memristive neuron and neural network. *Nonlinear Dynamics*, 106(1), 959–973. <https://doi.org/10.1007/s11071-021-06853-x>
- Lu, Q., Zhao, Y., Huang, L., An, J., Zheng, Y., & Yap, E. H. (2023). Low-dimensional-materials-based flexible artificial synapse: Materials, devices, and systems. *Nanomaterials*, 13(3), 373. <https://doi.org/10.3390/nano13030373>
- McClelland, J. L., & Rumelhart, D. E. (1987). Schemata and sequential thought processes in PDP models. In *Parallel distributed processing: Explorations in the microstructure of cognition: Psychological and biological models* (pp. 7–57). MIT Press. <https://doi.org/10.7551/mitpress/5236.003.0004>
- Mei, J., Muller, E., & Ramaswamy, S. (2022). Informing deep neural networks by multiscale principles of neuromodulatory systems. *Trends in Neurosciences*, 45, 237–250. <https://doi.org/10.1016/j.tins.2021.12.008>
- Navakauskas, D., Serackis, A., Matuzevičius, D. ir Laptik, R. (2014). *Specializuotos elektroninės intelektualesios sistemas garsams ir vaizdams apdoroti. Teorija ir taikymai*. Technika. <https://doi.org/10.3846/2310-M>
- Navakauskas, D. (1999). *Artificial neural networks for the restoration of noise distorted songs audio records* [Doctoral dissertation, Sciences of Technology, Electrical and Electronic Engineering (01T)]. Technika.
- Paliwal, K. K. (1991). A time-derivative neural net architecture – an alternative to the time-delay neural net architecture. In *Neural Networks for Signal Processing Proceedings of the 1991 IEEE Workshop* (pp. 367–375), Princeton, NJ, USA. IEEE. <https://doi.org/10.1109/NNSP.1991.239505>
- Prisciandaro, E., Sedda, G., Cara, A., Diotti, C., Spaggiari, L., & Bertolaccini, L. (2023). Artificial neural networks in lung cancer research: A narrative review. *Journal of Clinical Medicine*, 12(3), 880. <https://doi.org/10.3390/jcm12030880>
- Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45, 2673–2681. <https://doi.org/10.1109/78.650093>
- Tsoi, A. C., & Back, A. (1997). Discrete time recurrent neural network architectures: A unifying review. *Neurocomputing*, 15, 183–223. [https://doi.org/10.1016/S0925-2312\(97\)00161-6](https://doi.org/10.1016/S0925-2312(97)00161-6)
- Waibel, A. (1989). Modular construction of time-delay neural networks for speech recognition. *Neural Computation*, 1, 39–46. <https://doi.org/10.1162/neco.1989.1.1.39>
- Wan, E. A. (1990). Temporal backpropagation for FIR neural networks. In *1990 IJCNN International Joint Conference on Neural Networks* (Vol. 1, pp. 575–580), San Diego, CA, USA. IEEE. <https://doi.org/10.1109/IJCNN.1990.137629>
- Wan, E. A. (1991). Temporal backpropagation: An efficient algorithm for finite impulse response neural networks. In *Connectionist models* (pp. 131–137). Morgan Kaufmann. <https://doi.org/10.1016/B978-1-4832-1448-1.50019-6>
- Zhang, T., Yang, K., Xu, X., Cai, Y., Yang, Y., & Huang, R. (2019). Memristive devices and networks for brain-inspired computing. *Physica Status Solidi (RRL)–Rapid Research Letters*, 13(8), 1900029. <https://doi.org/10.1002/pssr.201900029>
- Zhao, S., Ran, W., Lou, Z., Li, L., Poddar, S., Wang, L., Fan, Z., & Shen, G. (2022). Neuromorphic-computing-based adaptive learning using ion dynamics in flexible energy storage devices. *National Science Review*, 9(11). <https://doi.org/10.1093/nsr/nwac158>

ARTIFICIAL NEURAL NETWORKS WITH DYNAMIC SYNAPSES: A REVIEW

M. Dumpis

Abstract

Artificial neural networks (ANNs) are widely applied to solve real-world problems. Most of the actions we take and the processes around us are time-varying. ANNs with dynamic properties allow processing time-dependent data and solving tasks such as speech and text processing, prediction models, face and emotion recognition, game strategy development. Dynamics in neural networks can appear in the input data, the architecture of the neural network, and the individual elements of the neural network – synapses and neurons. Unlike static synapses, dynamic synapses can change their connection strength based on incoming information. This is a fundamental principle allows neural networks to perform complex tasks like word processing or face recognition more efficiently. Dynamic synapses play a key role in the ability of artificial neural networks to learn from experience and change over time, which is one of the key aspects of artificial intelligence. The scientific works examined in this article show that there are no literature sources that review and compare dynamic DNTs according to their synapses. To fill this gap, the article reviews and groups DNTs with dynamic synapses. Dynamic neural networks are defined by providing a general mathematical expression. A dynamic synapse is described by specifying its main properties and presenting a general mathematical expression. Also an explanation, how these synapses can be modelled and integrated into 11 different dynamic ANNs is shown. Moreover, structures of dynamic ANNs are compared according to the properties of dynamic synapses.

Keywords: artificial neural networks, dynamic synapses, dynamic connections, time-varying signals.