

U. Neironu tīklu pielietošana

U1. Ar neironu tīkliem risināmu problēmu klases

Dažādi neironu tīklu modeļi nodrošina dažādu problēmu klašu risināšanas iespēju. Skatoties un praktiskā pielietojuma viedokļa, neironu tīkli parasti nerisina problēmu kopumā, bet veic tikai daļu (un parasti nelielu) no problēmas kopējā risinājuma. Pārējā daļa, t.sk. procesa vadība, tiek atstāta tradicionāli veidotas sistēmas ziņā.

Tādējādi ir ļoti svarīgi saprast par doto problēmu, vai neironu tīkli vispār ir pielietojami tās risināšanā, ja ir, tad kādu daļu no problēmas tie varētu veikt, un vai ir praktiski iegūstami dati neironu tīkla apmācībai.


Tālāk aprakstītas dažas svarīgākās ar neironu tīkliem risināmu problēmu klases

U1.1. Klasifikācija

Klasifikācija (*classification*) ir ieejas paraugu grupēšana iepriekš noteiktās grupās.

Klasifikācija būtu uzskatāma par funkciju aproksimācijas speciālgadījumu.

Klasifikāciju var veikt neironu tīkli, kas pieder pie modeļiem ar apmācību “ar skolotāju” (*supervised*, “with a teacher”), piemēram, perceptrons, RBF tīkls.




Attēls U1. Paraugu klasifikācija

U1.2. Klāsterizācija

Klāsterizācija (*clustering*) jeb kategorizācija (*categorization*), līdzīgi kā klasifikācija, nodrošina ieejas paraugu grupēšanu. Vienīgā starpība ir tā, ka kategorijām nav iepriekš noteikti kritēriji, kas tiek definēti apmācības laikā neironu tīkla ietvaros. Iepriekš noteikts ir tikai kategoriju skaits. Atkarībā no svaru inicializācijas vērtībām, kā arī neironu tīkla konfigurācijas parametriem, neironu tīkls katrā no darbināšanas reizēm var atgriezt citu dalījumu kategorijās.


Klasifikāciju var veikt neironu tīkli, kas pieder pie modeļiem ar apmācību “bez skolotāja” (*unsupervised*, “without a teacher”), piemēram, Kohonena tīkls.



Attēls U2. Paraugu klāsterizācija

U1.3. Kontrole

Kontrole (*control*) nodrošina pastāvīgu sistēmas darbības uzraudzību, balstoties uz noteiktu parametru kopuma analīzi.




Attēls U3. Sistēmas kontrole

U1.4. Funkcijas aproksimācija

Funkcijas aproksimācija (*function approximation*) ir funkcijas tuvinājuma iegūšana, balstoties uz zināmiem funkcijas punktiem.

Aproksimāciju var veikt neironu tīkli, kas pieder pie modeļiem ar apmācību “ar skolotāju” (*supervised, “with a teacher”*), piemēram, perceptrons, RBF tīkls.




Attēls U4. Funkcijas aproksimācija

U1.5. Prognoze

Prognoze (*forecast*) noteikta parametru kopuma noteikšana laika posmā $t+1$, balstoties uz noteiktu informāciju laika posmos $1..t$.

Prognoze ir faktiski neironu tīkla aproksimēšanas spējas specifisks pielietojums, uzskatot, ka paraugi, kas tikuši izmantoti apmācībā un tiek izmantoti darbināšanai, ir izvērsti laikā.


Prognozi parasti veic ar tīkliem ar apmācību ar skolotāju, un prognozes problēmas risināšanā ietvertā laika dimensija tiešā veidā neironu tīkla konstrukcijā neparādās.



Attēls U5. Prognoze

U1.6. Optimizācija

Optimizācija (*optimization*) ir informācijas vai darbību apjoma samazināšana tādā veidā, lai sistēma turpinātu darboties līdzīgi kā pirms izmaiņas.



Attēls U6. Optimizācija


U1.7. Atmiņa ar adresāciju pēc satura

Atmiņa ar adresāciju pēc satura (*content-addressable memory*) kaut kādā nozīmē darbojas līdzīgi klasifikācijai, bet ar šādām atšķirībām:

- Neironu tīkls tiek apmācīts tikai ar “pareiziem paraugiem”, t.i. tiek apmācīts atcerēties paraugus, nevis tos kaut kādā veidā novērtēt.
- Parasti ievades un izvades apjoms ir līdzvērtīgi (klasifikācijas gadījumā iegūtā informācija par klasi (piemēram, numurs) parasti pēc apjoma ir daudz mazāka nekā pats ievadītais paraugs.

Piemēram, ja klasifikācija pēc parauga nosaka, kurai klasei pieder paraugs, tad atmiņas ar adresāciju pēc satura gadījumā, padodot neironu tīklam sabojātu paraugu, tiek atgriezts pareizs paraugs.

Atmiņu ar adresāciju pēc satura nodrošina, piemēram, Hopfilda tīkls un BAM tīkls.



Attēls U7. Atmiņa ar adresāciju pēc satura

U2. Neironu tīklu praktiskais pielietojums

Neironu tīklu praktiskais pielietojums izriet no neironu tīklu spējas risināt konkrētas problēmu klases.

Neironu tīkliem ir plašs pielietojums reālās pasaules problēmu risināšanā, un tie ir veiksmīgi sevi pierādījuši daudzās nozarēs.

Tā kā neironu tīkli ir viena no labākajām izvēlēm paraugu un citu struktūru identifikācijā datos, tie ir labi izmantojami prognozēšanas un paredzēšanas vajadzībām. Lūk, vairākas sfēras neironu tīklu pielietošanai:

- tirgus attīstības prognozes ,
- ražošanas procesu kontrole,
- klientu analīze,
- datu validācija,
- riska vadība,
- runātāja atpazīšana,
- sejas atpazīšana,
- slimību diagnostika,
- virsmu struktūras analīze,
- rokrakstu atpazīšana,

- 3D objektu atpazīšana,
- mīnu meklēšana.

U2.1. Neironu tīkli medicīnā

Medicīnā neironu tīkli tiek pielietoti gan slimību diagnosticēšanā (piemēram, no kardiogrammām un ultrasonogrāfiskiem izmeklējumiem), gan cilvēka ķermeņa daļu darbības modelēšanai.

Neironu tīkli ir īpaši piemēroti slimību diagnosticēšanai pēc skenētas informācijas, jo nav nepieciešams definēt speciālu algoritmu, kas identificētu slimību. Nepieciešams paraugu kopums, kas reprezentētu dažādus slimības stāvokļus. Piemēri, kas raksturo slimību, ir jāizvēlas ļoti rūpīgi, lai nodrošinātu uzticamu sistēmas darbību.

U2.1.1. Sirds un asinsvadu sistēmas modelēšana un diagnosticēšana

Neironu tīkli ir tikuši eksperimentāli lietoti, lai modelētu sirds un asinsvadu sistēmu. Diagnoze var tikt noteikta, ja tiek izveidots indivīda sirds un asinsvadu sistēmas modelis un tas tiek salīdzināts ar konkrētam pacientam veiktajiem mērījumiem reālā laikā. Ja šādas pārbaudes tiek veiktas regulāri, potenciāli bīstami apstākļi var tikt noteikti ļoti agrīnā stadijā, tādējādi atvieglojot cīņu ar slimību.

Konkrēta indivīda sirds un asinsvadu sistēmas modelim ir jāimitē saistība starp dažādiem fizioloģiskajiem mainīgajiem, piemēram, pulsu, asinsspiedienu un elpošanas biežumu, pie dažādas fiziskās noslodzes. Ja modelis tiek pielāgots noteiktam indivīdam, tad tas kļūst par šī indivīda fiziskā stāvokļa modeli. Simulējošajai programmai jāspēj pielāgoties katra indivīda specifiskajam īpašībām bez eksperta iejaukšanās, un šeit jau parādās vajadzība pēc neironu tīkla.

Vēl viens iemesls, kas attaisno neironu tīklu pielietošanu, ir to spēja nodrošināt sensoru “sapludināšana” (*fusion*), kombinējot vairāku sensoru dotās vērtības. Sensoru sapludināšana dod iespēju neironu tīkliem iemācīties kompleksas sakarības starp atsevišķo sensoru vērtībām, kas tiktu pazaudētas, ja šīs vērtības tiktu analizētas atsevišķi. Tādējādi medicīniskajā modelēšanā un diagnosticēšanā neironu tīkli spēj konstatēt kompleksus medicīniskus stāvokļus, kaut arī katrs sensors atsevišķi spēj uztvert tikai kāda specifiska fizioloģiskā mainīgā vērtības.

U2.1.2. Elektroniskais deguns

Neironu tīkli ir eksperimentāli lietoti, lai izveidotu elektronisko degunu. Elektroniskajam degunam ir potenciāls pielietojums telemedicīnā. Telemedicīna ir medicīnas prakse, kas tiek

nodrošināta no liela attālumu, izmantojot komunikācijas līdzekļus. Elektroniskajam degunam būtu jāidentificē smaržas attālinātajā ķirurģiskajā vidē. Identificētās smaržas tālāk tiktu pārsūtītas uz citu vietu, kur speciāla sistēma tās atkal uzģenerētu. Oža ir svarīga maņa, kas nepieciešama ķirurga darbā, tādējādi “tele-oža” varētu atbalstīt “tele-ķirurģiju”.

U2.1.3. Mājas dakteris

Datorprogramma “Instant physician”, kas tika izveidota 80. gadu vidū, autoasociatīvās atmiņas neironu tīkls tika apmācīts, lai saglabātu lielu daudzumu medicīniskas informācijas par simptomiem, diagnozēm un atbilstošo ārstēšanu. Pēc apmācības neironu tīklam ieejā bija paredzēts padot simptomu kopumu. Tad tam bija jāatrod saglabātais paraugs, kas reprezentēja “labāko” diagnozi un ārstēšanu.

U2.2. Neironu tīkli biznesā

Bizness ir plaša nozare ar vairākiem specializācijas apgabaliem, piemēram, grāmatvedība vai finanšu analīze. Neironu tīkliem ir liels potenciāls lietošanai biznesa vajadzībām, ieskaitot resursu un laika dalīšanu.

U2.2.1. Mārketings

Tika izveidota mārketinga programma, kas ir integrēta ar neironu tīklu sistēmu. Tajā neironu tīkls tika apmācīts, lai palīdzētu nodrošināt mārketinga kontroli pār sēdvietu piešķiršanu lidmašīnās.

Kaut arī ir nozīmīgi, ka neironu tīkli ir tikuši pielietoti šīs problēmas risināšanai, tomēr ir ne mazāk nodrošināt dažādu inteliģentu tehnoloģiju integrēšanu kopējā sistēmā. Šajā gadījumā neironu tīkli tika sapludināti ar ekspertu sistēmu.

U2.2.2. Kredītu analīze

Neironu tīklu klasiķa Roberta Hehta-Nīlsena (*Robert Hecht-Nielsen*) dininātā kompānija HNC izstrādāja vairākas neironu tīklu programmas. Viena no tām bija kredītu novērtēšanas sistēma, kas palielināja esoša modeļa ienesīgumu par 27%.

U2.3. Citas sfēras


U2.3.1. Notikumu atpazīšana, apmācot tīklu uz objektu trajektorijām

John Neilson & David Hogg, University of Leeds

Šajā pētījumā ir par objektu uzvedības modelēšanu, izmantojot detalizētus, apmācītus statistiskus modeļus. Šī tehnoloģija ir paredzēta, lai nodrošinātu to, ka specifisku objektu raksturīgās uzvedības modelis varētu tikt iegūts no garas attēlu virknes nepārtrauktas aplūkošanas. Tiek cerēts, ka šādiem raksturīgās uzvedības modeļiem būtu vairāki pielietojumi, piemēram, automātiska izdzīvošana vai notikumu atpazīšana, ļaujot izdzīvošanas problēmu risināt no zemāka līmeņa pozīcijām bez nepieciešamības pēc augsta līmeņa zināšanām par notikuma vietu un uzvedību. Citi pielietojumi varētu būt – pēc nejaušības principa ģenerēta reālistiska objekta uzvedība lietošanai virtuālās realitātes sistēmās, vai objektu uzvedības paredzēšanai ilgā laika periodā lai nodrošinātu atbalstu objektu izsekošanā (*tracking*).



(a) Apmācības režīms



(b) Prognozes režīms

Modelis tiek apmācīts “bez skolotāja” (*in an unsupervised manner*), izsekojot objektus garās attēlu virknēs. Risinājums ir balstīts uz neironu tīklu, kas realizē t.s. vektoru kvantizāciju (*vector quantisation*) un neironu tipu, kas ietver īslaicīgās atmiņas (*short-term memory*) iespējas.

Izmantošanas režīmā gājēju trajektoriju modeļi tika ģenerēti un lietoti, lai novērtētu, cik tipiskas ir jaunās trajektorijas, kā arī lai prognozētu nākotnes trajektorijas vai pēc nejaušības principa ģenerētu jaunas trajektorijas.

Attēls U8. Notikumu atpazīšana, apmācot tīklu uz objektu trajektorijām

U2.3.2. Futbola spēles simulācija, izmantojot neironu tīklus

Neo Say Poh & Tralvex Yeap, Japan-Singapore AI Centre / Kent Ridge Digital Labs


Aplikācija: RoboCup (Robot World Cup)

RoboCup sacensībā roboti (gan reāli, gan virtuāli) tiek izaicināti savstarpēji cīnīties simulētā futbola turnīrā. Šīs programmas mērķis ir veicināt starpdisciplīnu pieeju robotikai un aģentu bāzētajam mākslīgajam intelektam, demonstrējot problēmu apgabalu, kas prasa plaša mēroga kooperāciju un koordināciju dinamiskā, trokšņainā un kompleksā vidē.

Automatizētā *RoboCup* apmācība ietver šādus soļus:

Spēlētāji spēles procesā tiek apmācīti izdarīt izvēli par to, vai (a) turpināt driblēt bumbu, (b) piespēlēt to citam spēlētājam, vai (c) sist to pa vārtiem.

- Vārtsargi spēles procesā tiek apmācīti uzminēt, kā pretinieki izspēlēs bumbu. Sarežģītība rodas tad, kad pretinieku spēlētājs izvēlas piespēlēt bumbu citam, tā vietā, lai mēģinātu sist pa vārtiem.
- Komandas novērtēšana, kas ir ļoti komplicēts uzdevums, jo komanda ir sadarbojošos objektu kopums, un tās darbība ir neparedzama.
- Galvenās lietotās mākslīgā intelekta metodes šeit ir dažādi neironu tīklu paveidi un ģenētiskie algoritmi.



Attēls U9. Futbola spēles simulācija, izmantojot neironu tīklus

U2.3.3. Sejas animācija, balstoties uz runāto tekstu

Ram Rao, Russell Mersereau & Chen Tsuhan, Georgia Institute of Technology / AT&T Research

Vēl viens programmas piemērs, kas balstās uz korelāciju starp skaņu un attēlu, ir sejas animācija, balstoties uz runāto tekstu. Tās uzdevums ir sintezēt reālistisku video no akustiskas runas. Vairums esošo pētījumu audio-video konversijai izmanto tādas labi zināmas metodes, kā vektoru kvantizācija vai neironu tīkli. Šeit autori pēta, kā konversijas process būtu veicams, izmantojot slēptos Markova modeļus (*hidden Markov models, HMM*).



(a) Kustību izsekošana



(b) Kustību ģenerēšana

Attēls U10. Sejas animācija, balstoties uz runāto tekstu

Kustību izsekošana. Katram video freimam, izmantojot specifisku deformējamo šablonu algoritmu (*modified deformable template algorithm*) tiek piekārtots paraboliskais kontūrs. No šabloniem iespējams izgūt vertikālo attālumu starp diviem kontūriem un horizontālo attālumu starp mutes kaktiņiem, un tas kopā veido vizuālo parametru kopumu.

Sejas kustību ģenerēšana ir otrs nozīmīgākais šīs programmas modulis.


A2.3.4. Lasīšana no lūpām

Günter Mamier, Marco Sommerau & Michael Vogt, Universität Stuttgart

Uz neironu tīkliem balstīta runas (lūpu) nolasīšanas sistēma tika būvēta kā lietotāja saskarnes daļa darbstacijām. Trīs galvenās sistēmas sastāvdaļas ir (1) sejas nolasītājs, (2) lūpu modelēšana un runas apstrāde, (3) neironu tīklu komponente.

Automātiskā runas lasīšana no lūpām balstās uz efektīvas lūpu attēlu analīzes. Šis risinājums neprasa lietot speciālu apgaismojumu vai kosmētiku, bet tiek balstīts uz parastiem krāsainajiem video attēliem, un tā pamatā ir kubiskās kontūru līknes. Neironu tīkla klasifikators uztver zobu malas redzamību un citus atribūtus. Neironu tīkli, nodrošina arī līnijas modelēšanu starp aizvērtām lūpām.

Lai nodrošinātu augstu efektivitāti lūpu modelēšanā, tika izveidota un realizēta speciāla modeļu apraksta valoda. Vispārīgi ņemot, valoda ļauj definēt malu (līniju) modeļus, balstoties uz mezgliem un līniju malu (līniju) funkcijām. Modeļu adaptācija tika veikta, izmantojot algoritmus, kas izmanto līdzīgus principus kā gradienta nolaišanās (*gradient descent*) un simulētā atkvēlināšana (*simulated annealing*).




Attēls U11. Lasīšana no lūpām

Modeļa interpretators nodrošina nepārtrauktu modeļa mezglu pozīciju un gar līnijām esošo krāsu sajaukumu mērīšanu adaptācijas laikā. Iegūtie parametri ir izmantojami runas atpazīšanai tālākajos algoritma soļos.

U2.3.5. Kustīgu mērķu noteikšana un izsekošana

Defense Group Incorporated

Kustīgu mērķu noteikšana un izsekošana šeit tiek saprasta ar metodēm ar izsekošanu pirms noteikšanas (*“track before detect”*). Tās sasaista sensoru datus ar laiku un vietu, balstoties uz izsekojumu principiem. Izsekojumu statistika tiek apgūta, apmācot neironu tīklus uz reāliem vai simulētiem datiem. Šīs metodes pielietojums, salīdzinot ar parastajām tiešās sakritības metodēm, dod būtisku (līdz pat 1000 reižu) uzlabojumu, samazinot viltus trauksmes (*false alarm*) līmeni.



Attēls U12. Kustīgu mērķu noteikšana un izsekošana

Attēls U12.A parāda aptuveno ieejas datu formu, kādā tiek meklēti kustīgi objekti, bet A12.B parāda neironu tīklu izeju, uzrādot noteiktos kustīgos mērķus.

U2.3.6. Mērķu identifikācija reālā laikā drošības (security) nodrošināšanai

Stephen McKenna, Queen Mary & Westfield College


Sistēma lokalizē un izseko cilvēku sejas, kolīdz tie virzās cauri scēnai. Tā ietver šādas metodes:

- Kustības uztveršana (*motion detection*),
- Cilvēku izsekošana, balstoties uz kustību,
- Seju izsekošana, izmantojot izskata (*appearance*) modeli.

Sejas tiek efektīvi izsekotas, integrējot kustības uztveršanu un uz modeli balstītu izsekošanu.



(a) Izsekošana mazas izšķirtspējas un sliktas redzamības apstākļos



(b) Divu objektu vienlaicīga izsekošana

Attēls U13. Mērķu identifikācija reālā laikā

U2.3.7. Sejas animācija

David Forsey, University of British Columbia


Sejas animācijas ir veidotas, izmantojot hierarhisko B-splainu. Šeit neironu tīkli ir izmantoti, lai iemācītos sejas izteiksmju variācijas.



Attēls U14. Sejas animācija

U2.3.8. Mākslīgā dzīve (Artificial life)

Mākslīgā dzīve ir dzīvu sistēmu modelēšana un simulēšana. Šādi objekti raksturojas ar ļoti lielu sarežģītību, un parasti tiek modelēti fiziski. Konceptuāli ņemot, mākslīgā dzīve pārkāpj datorzinātnes un bioloģijas tradicionālās robežas.



Attēls U15. Mākslīgā dzīve. Dažādu programmu piemēri

U3. Rīki neironu tīklu izstrādei

Neironu tīkli nebūt vienmēr nav jāprogrammē no jauna, jo eksistē daudz rīku – no brīviem līdz komerciāliem – to izstrādei un validācijai.

U3.1. BrainMaker

www.calsci.com


Viena no savulaik populārākajām neironu tīklu izstrādes sistēmām. Izmantojama ļoti plašā problēmu apgabalā, un ir ļoti daudz izmantošanas piemēru.

U3.2. STATISTICA Neural Networks


www.statsoft.com

Pazīstamās programmu paketes STATISTICA neironu tīklu komponente. Ļoti spēcīgs profesionāls rīks neironu tīkli izstrādei.

Nodrošina neskaitāmas iespējas neironu tīklu izstrādei, vizualizācijai un problēmu risināšanai.



Attēls U16. STATISTICA Neural Networks



Attēls U17. STATISTICA Neural Networks. Datu vizualizācijas piemērs




Attēls U18. STATISTICA Neural Networks. The Intelligent Problem Solver. Nodrošina automātisku daudzu tīklu arhitektūru izvēli un novērtēšanu

U3.3. Neural Network Toolbox

www.mathworks.com

Neural Network Toolbox ir paketes MATLAB neironu tīklu paplašinājums, kas nodrošina plašu rīku kopumu neironu tīklu izstrādei un to darbības vizualizācijai.



Attēls U19. Neural Network Toolbox

U3.4. Cortex

cortex.snowseed.com

Neironu tīklu pakete tīklu veidošanai ar backpropagation apmācības algoritmu (*Backpropagation Neural Networks Application*).

Ir iebūvēta skriptu valoda darbību automatizēšanai, piemēram, lai veiktu datu konvertāciju.

Import | **Network** | **Processing** | **Learning** | **Apply** | **Output**

Data file: ...

Skip before start line: Skip after start line:

Start line:

End line:

Inputs:

- Adj. Close*-1
- Adj. Close*-2
- Adj. Close*-3
- Adj. Close*-4
- Adj. Close*-5
- Adj. Close*-6
- Adj. Close*-7
- Adj. Close*-8
- Adj. Close*-9
- Adj. Close*

Outputs:

- Adj. Close*-1
- Adj. Close*-2
- Adj. Close*-3
- Adj. Close*-4
- Adj. Close*-5
- Adj. Close*-6
- Adj. Close*-7
- Adj. Close*-8
- Adj. Close*-9
- Adj. Close*

☐ Reverse

Preview:

No	Adj. Close*	Adj. Close*-1	Adj. Close*-2	Adj. Close*-3	Adj. Close*-4	Adj. Close*-5	Adj. Close*-6	Adj. Close*-7	Adj. Close*-8	Adj. Close*-9	Adj. Close*
10	48.400000	48.150000	47.250000	47.330000	46.990000	46.050000	45.500000	45.200000	45.510000	46.650000	47.530000
11	48.150000	47.250000	47.330000	46.990000	46.050000	45.500000	45.200000	45.510000	46.650000	47.530000	48.300000
12	47.250000	47.330000	46.990000	46.050000	45.500000	45.200000	45.510000	46.650000	47.530000	48.300000	48.650000
13	47.330000	46.990000	46.050000	45.500000	45.200000	45.510000	46.650000	47.530000	48.300000	48.650000	49.000000
14	46.990000	46.050000	45.500000	45.200000	45.510000	46.650000	47.530000	48.300000	48.650000	49.000000	49.350000
15	46.050000	45.500000	45.200000	45.510000	46.650000	47.530000	48.300000	48.650000	49.000000	49.350000	49.700000
16	45.500000	45.200000	45.510000	46.650000	47.530000	48.300000	48.650000	49.000000	49.350000	49.700000	50.050000
17	45.200000	45.510000	46.650000	47.530000	48.300000	48.650000	49.000000	49.350000	49.700000	50.050000	50.400000
18	45.510000	46.650000	47.530000	48.300000	48.650000	49.000000	49.350000	49.700000	50.050000	50.400000	50.750000
19	46.650000	47.530000	48.300000	48.650000	49.000000	49.350000	49.700000	50.050000	50.400000	50.750000	51.100000


Browse file... Generate lag file Select fields... Apply Chart

Attēls U20. Cortex

U3.4. MemBrain

www.membrain-nn.de

Brīvā programmatūra (*freeware*) neironu tīklu veidošanai, darbināšanai un analīzei.




Attēls U21. MemBrain. Neironu tīkla analīze


U3.5. BioComp iModel

www.biocompsystems.com

Efektīvs datu modelēšanas rīks. Nodrošina augstvērtīgu prognozes modeļu izveidi.



Attēls U22. BioComp iModel. Programmas darbības piemērs




Attēls U23. BioComp iModel. Datu klāsterizācija

U3.5. THINKS

www.sigma-research.com

Neironu tīklu izstrādes vide.



Attēls U24. THINKS. Neironu tīkla piemērs