



**KAUNO TECHNOLOGIJOS UNIVERSITETAS**  
**ELEKTROS IR ELEKTRONIKOS FAKULTETAS**

**Tomas Zimnickas**

**VANDENS TINKLO STEBĖSENA IR DIAGNOSTIKA**

Baigiamasis magistro projektas

**Vadovas**

Lekt. dr. Jonas Vanagas

**KAUNAS, 2017**

**KAUNO TECHNOLOGIJOS UNIVERSITETAS**  
**ELEKTROS IR ELEKTRONIKOS FAKULTETAS**  
**ELEKTROS ENERGETIKOS SISTEMŲ KATEDRA**

**VANDENS TINKLO STEBĖSENA IR DIAGNOSTIKA**

Baigiamasis magistro projektas

**Elektros energetikos sistemos (621H63005)**

**Vadovas**

Lekt. dr. Jonas Vanagas

2017.05.26

**Recenzentas**

prof. Adas Gelžinis

2017.05.26

**Projektą atliko**

Tomas Zimnickas

2017.05.26

**KAUNAS, 2017**



KAUNO TECHNOLOGIJOS UNIVERSITETAS

Elektros ir elektronikos fakultetas

(Fakultetas)

Tomas Zimnickas

(Studento vardas, pavardė)

Elektros energetikos sistemos (621H63005)

(Studijų programos pavadinimas, kodas)

Baigiamojo projekto „Vandens tinklo stebėseną ir diagnostiką“

### AKADEMINIO SAŽININGUMO DEKLARACIJA

20 17 m.            gegužės 26 d.  
Kaunas

Patvirtinu, kad mano **Tomo Zimnicko** baigiamasis projektas tema „Vandens tinklo stebėseną ir diagnostiką“ yra parašytas visiškai savarankiškai, o visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

\_\_\_\_\_  
(vardą ir pavardę įrašyti ranka)

\_\_\_\_\_  
(parašas)

Tomas Zimnickas. Vandens tinklo stebėseną ir diagnostiką. Magistro baigiamasis projektas / vadovas dr. Jonas Vanagas; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas, Elektros energetikos sistemų katedra.

Mokslų kryptis ir sritis: Elektros ir elektronikos inžinerija, Technologiniai mokslai

Reikšminiai žodžiai: neuroninis tinklas, nuotėkis, guoliai, vibracijos

Kaunas, 2017. 73 p.

## SANTRAUKA

**Darbo tikslas** – sukurti autonominę sistemą, galinčią stebėti vandens tinklą ir siurblių su varikliais darbą, aptikti nuotėkius linijose bei variklių guolių gedimus, naudojant dirbtinius neuroninius tinklus.

Darbe apžvelgiami vandens tinklai, jų tipai, kaip išgaunamas vanduo. Aptariama nuotėkių tinkluose problematika, priežastys. Be vandens tinklų, apžvelgiami elektros variklių guoliai, jų gedimų priežastys, tipai ir požymiai. Tyrimo metu, kuriamas modelis, galintis aptikti nuotėkį vandens linijoje, naudojant sukurtus duomenis, imituojančius sistemos darbą normaliu ir avariniu režimais. Sukurtas modelis, aptinkantis nuotėkį tinkle, kurio vidutinė kvadratinė klaida siekia  $5,4 \times 10^{-12}$ . Tyrimo su guoliais metu, dirbtinai sukėlus specifinius gedimus guoliuose, matuojamos jų vibracijos ir naudojant šiuos gautus duomenis, kuriami neuroniniai tinklai, geram nuo blogo guoliui atskirti, gauto modelio tinklo vidutinė kvadratinė klaida siekia  $2,41 \times 10^{-10}$ . Pasitelkiant struktūrų atpažinimo neuroninius tinklus ir naudojant anksčiau gautus vibracijų duomenis, sukurtas modelis, gebantis 78,5 % tikslumu atskirti guolio gedimo pobūdį, gauto tinklo vidutinė kvadratinė klaida siekia 0,0935.

Zimnickas, Tomas. Monitoring and Diagnostics of Water Networks: Master's thesis in Electrical Power Systems / supervisor dr. Jonas Vanagas. Kaunas University of Technology, Faculty of Electrical and Electronics Engineering, Department of Electric Power Systems.

Research area and field: Electrical and Electronics Engineering, Technological Sciences

Key words: neural networks, leakage, bearings, vibrations.

Kaunas, 2017. 73 p.

## SUMMARY

**Aim of this research** – to create an autonomous water network and motor monitoring system, which can identify leaks in water lines and broken motor bearings, using artificial neural networks.

In this work, water networks, water extraction and their types are reviewed. Also, a review of electric motor bearings, their causes of failure, types and features is done. During the experiment, a model that can detect water leaks in the network, using the data, imitating normal and emergency modes was made. This model, can detect the leak in the system with  $5,4 \times 10^{-12}$  mean squared error. After creating specific failures in bearing construction, vibration patterns were measured. Using this data and artificial neural networks, a model that can separate bearings in good condition from broken ones with  $2,41 \times 10^{-10}$  mean squared error was made. Using pattern recognition neural networks and data, obtained from previous experiment a model which can identify the broken part of bearing with 78,5 % accuracy was created. This model had a mean squared error of 0,0935.

# TURINYS

ILIUSTRACIJŲ SĄRAŠAS .....	7
ĮVADAS .....	9
1. VANDENS TINKLŲ STEBĖSENOS IR DIAGNOSTIKOS APŽVALGINĖ DALIS .....	10
1.1 Vandens ištekliai .....	10
1.2 Vandens pakėlimas ir slėgio palaikymas .....	13
1.3 Nuotėkiai vandens tinkluose .....	15
1.4 Neuroniniai tinklai .....	18
1.4.1 Neuroninio tinklo sąvoka .....	18
1.4.2 Taikymas .....	22
1.4.3 Neuroninių tinklų mokymas .....	22
1.4.4 Klasifikavimas .....	24
1.4.5 Vaizdų ir struktūrų atpažinimo neuroninis tinklas .....	26
1.4.6 Neuroninio tinklo mokymo funkcijos .....	27
1.5 Elektros varikliai ir mechaniniai gedimai .....	29
1.5.1 Asinchroninės mašinos .....	29
1.5.2 Asinchroninių mašinų konstrukcija .....	30
1.5.3 Asinchroninių mašinų guoliai ir jų gedimai .....	31
1.5.4 Neuroninio tinklo mokymas guolių gedimams aptikti .....	39
1.6 Sensoriai .....	42
2. TYRIMO METODINĖ DALIS .....	45
2.1 Nuotėkio linijoje aptikimas .....	45
2.2 Guolių gedimų aptikimas .....	48
3. TYRIMO REZULTATAI .....	53
3.1 Vandens nuotėkių tinkle tyrimas .....	53
3.2 Guolių gedimų aptikimo tyrimas .....	58
IŠVADOS .....	64
REKOMENDACIJOS .....	66
LITERATŪROS SĄRAŠAS .....	67
PRIEDAI .....	70
1 priedas .....	70
2 priedas .....	72

## ILIUSTRACIJŲ SĄRAŠAS

- 1.1 pav. Požeminio vandens išgavimas, šaltinis – fao.org
- 1.2 pav. Vieno kėlimo ir dviejų kėlimų sistemos pavyzdys, šaltinis – nzdl.org
- 1.3 pav. Neseniai įvykusi nuotekų vamzdyno avarija Vilniuje, šaltinis – 15min.lt
- 1.4 pav. 2017 metų pradžioje dėl šalčių trūkusios geriamo vandens linijos, padariniai, šaltinis – 15min.lt
- 1.5 pav. Realizuotas ir prarastas vanduo Kaune, sudarė UAB „Kauno vandenys“
- 1.6 pav. Išgauto vandens pasiskirstymas 2016 metais, sudarė UAB „Kauno vandenys“
- 1.7 pav. Dirbtinio neuroninio tinklo neuronas, šaltinis – 2centsapiece.blogspot.lt
- 1.8 pav. Daugiasluoksnis vieno paslėptojo sluoksnio neuroninis tinklas, šaltinis – neuralnetworksanddeeplearning.com
- 1.9 pav. Viensluoksnis neuroninis tinklas galintis skirti duomenis į keletą klasių, šaltinis – abhishek4273.com/2015/11/
- 1.10 pav. Asinchroninio variklio sandara, šaltinis – 3dprint.com
- 1.11 pav. Sugedęs guolio ratukų narvelis, sudeginęs variklį, šaltinis – machinerylubrication.com
- 1.12 pav. Guolio sandara [6]
- 1.13 pav. Variklio su užkaitusiu guoliu termografinė analizė, šaltinis – iactthermography.org/
- 1.14 pav. Normalaus ir sugedusių guolių darbo režimai [6]
- 1.15 pav. Duomenų masyvai MatLab programai, neuroniniam tinklui apmokyti, su įvairiais guolių gedimais [18]
- 1.16 pav. Temperatūrą ir vibracijas stebintis prietaisas, šaltinis – analog.com
- 2.1 pav. Principinė stendo schema, sudaryta autoriaus
- 2.2 pav. Debito matuoklių rodmenys, sudaryta autoriaus
- 2.3 pav. Apmokymo neuroninio tinklo bandymo duomenys, sudaryta autoriaus
- 2.4 pav. Stendas guolių gedimams aptikti, sudaryta autoriaus
- 2.5 pav. Variklio su geru guoliu vibracijų grafikas, sudaryta autoriaus
- 2.6 pav. Guolis su sugadintu išoriniu žiedu, sudaryta autoriaus
- 2.7 pav. Guolis su sugadintu separatoriumi ir rutuliuku, sudaryta autoriaus

- 2.8 pav. Gautų vibracijų grafikas, sudaryta autoriaus
- 2.9 pav. Vibracijų grafikas su pažymėtomis ribomis
- 3.1 pav. Apmokytas neuroninis tinklas (10 neuronų, trainlm funkcija), sudaryta autoriaus
- 3.2 pav. Rezultatai po apmokyto tinklo bandymo su naujais duomenimis, sudaryta autoriaus
- 3.3 pav. Panaikintas triukšmas po neuroninio tinklo mokymo, sudaryta autoriaus
- 3.4 pav. Mokymo rezultatai naudojant traincgb funkciją ir 10 neuronų tinklą, sudaryta autoriaus
- 3.5 pav. Galutiniai mokymo rezultatai su 5 neuronų tinklu ir trainlm funkcija, sudaryta autoriaus
- 3.7 pav. NT mokymo procesas, sudaryta autoriaus
- 3.8 pav. Gautas mokymo rezultatas, sudaryta autoriaus
- 3.9 pav. Gerai apmokyto tinklo rezultatas, sudaryta autoriaus
- 3.10 pav. Neuroninio tinklo mokymo eiga, sudaryta autoriaus
- 3.11 pav. Guolio gedimo pobūdį nustatančio tinklo mokymo rezultatai, sudaryta autoriaus
- 3.12 pav. Gedimo guolyje pobūdžio nustatymo, neuroninio tinklo mokymo rezultatas, sudaryta autoriaus
- 3.13 pav. Mokymo proceso eiga naudojant vaizdų ir struktūrų atpažinimo neuroninį tinklą, sudaryta autoriaus



## IVADAS

Vandens tinklų diagnostika ir stebėseną yra labai aktuali problema šiais, technologijų laikais, vykstant modernizacijoms ir diegiant naujoves, automatizuojant procesus. Įmonės, mažindamos kaštus, po truputį naikina dispečerines bei operatorius jose, pritaikant automatines valdymo sistemas, kurioms retai prireikia žmogaus įsikišimo. Tačiau, net ir visiškai automatizuota sistema, kartais negali pralenkti žmogiškojo faktoriaus. Pavyzdžiui sistema negali išgirsti kad mašinos guolyje bilda guolis ar dirbantis siurblys ir nepatikrins ar sistema nekaista, bei neatliks vizualios inspekcijos. Taip pat po žeme negalima pamatyti trūkusio vandentiekio vamzdžio, kuris gali pridaryti daug žalos įmonei ar aplinkiniams.

Čia pasitarnauja modernios priemonės – pažangūs daiktų interneto (IoT) bevieliai davikliai, galintys stebėti sistemą, kartu su dirbtiniais neuroniniais tinklais, imituojančiais žmogaus smegenų veiklą ir gebantys prognozuoti žmogui nepastebimus artėjančius gedimus realiu laiku, bei stabdyti sistemą, ar išpėti objektą prižiūrintį asmenį. Neuroniniai tinklai, rinkdami debito matuoklių ir slėgio daviklių duomenis abiejuose linijos pusėse gali pastebėti menkiausią nuotėkį ir žaibiškai reaguoti vos tik jam prasidėjus. Šiame darbe, taip pat, siekiama supaprastinti guolių vibracijų matavimą aptinkant guolių gedimus, naudojant „žalius“ vibracijų duomenis neuroniams tinklams mokytis. Norint pasiekti norimų rezultatų su sunkiai apdorojamais duomenimis reikia gana sudėtingų neuroninių tinklų modelių.

**Darbo tikslas** – sukurti autonominę sistemą, galinčią stebėti vandens tinklų ir siurblių su varikliais darbą, aptikti nuotėkius linijose bei variklių guolių gedimus, naudojant dirbtinius neuroninius tinklus.

### **Uždaviniai:**

1. Sukurti neuroninį tinklą, galinti aptikti nuotėkį vandens tinkle;
2. Susikurti stendą vibracijoms matuoti;
3. Sugadinant guolius ir išmatuojant jų keliamas vibracijas susikurti duomenų masyvus neuroninio tinklo mokymui;
4. Sukurti neuroninį tinklą, įvertinantį guolių būklę;
5. Sukurti neuroninį tinklą, galintį nustatyti guolio gedimo pobūdį;

# 1. VANDENS TINKLŲ STEBĖSENOS IR DIAGNOSTIKOS APŽVALGINĖ DALIS

## 1.1 Vandens ištekliai

Pagrindiniai išgaunamo geriamo vandens ištekliai yra:

- Lietaus arba sniego
- Paviršiniai (upės, ežerai, ledynai ar jūros vanduo)
- Požeminiai

Lietaus vanduo gali būti naudojamas kaip pagrindinis arba papildomas vandens šaltinis ūkyje. Kadangi, vartojimui jį reikia apdoroti, jis gali būti naudojamas kaip pagrindinis tik ten kur nėra jokio kito vandens šaltinio (upių, ežerų ar giluminio vandens). Tačiau ši vandens rūšis darosi vis populiarsnė namų ūkyje kaip papildomas gėlo vandens šaltinis, skirtas sutaupyti geriamo vandens naudojimą, taip taupant pinigus bei tausojant gamtą.

Šis vanduo, kuris nėra apdorotas nuo mikroorganizmų, puikiai tinka laistyti augalams, skalbti skalbinius, naudoti tualete (bakelyje), plauti automobilį, ar kitokiems dalykams, kurie nesusiję su maisto gaminiu ir vartojimu virtuvėje, bei asmenine higiena. Pasak tokių sistemų montuotojų, naudojant lietaus vandenį kaip papildomą, galima sutaupyti apie 70 % vandens suvartojimo iš tinklo.

Paviršinį vandenį vartojimui galima išgauti iš jūrų, vandenynų, ežerų ar upių. Šis vanduo naudojamas, kai yra požeminio vandens deficitas vietovėje, arba jį išgauti per brangu. Be to, šį vandenį reikia paruošti prieš naudojant. Vandenį reikia dezinfekuoti nuo mikroorganizmų, ir išnaikinti jame esančius kenksmingus junginius ar medžiagas. Jūros vandenį reikia papildomai valyti nuo druskų.

Paviršinio vandens valymo įrenginiuose vanduo perpumpuojamas iš ežero rezervuaro į valymo įrenginius, kuriuose pirmiausia vanduo chloruojamas, tada vanduo koaguluojamas ir flokuluojamas (visos kietos dalelės ištirpusios vandenyje sukibamos į didesnes, kol susidaro dideli gniužulai, dispersinėje sistemoje). Tada naudojant nusėdintuvus dalelės, sukibusios į gniužulus, nusodinamos ir pašalinamos (panašiai kaip ir nuotekų valyme). Išvalytas vanduo yra filtruojamas per kompozitinį filtrą, kurį sudaro antracitas, smėlis ir žvyras. Po filtracijos vanduo

yra chloruojamas dar kartą ir prieš paduodant į rezervuarą su didelio slėgio siurbliais, daromas fluoravimo procesas. Galiausiai vanduo pumpuojamas į lokalius rezervuarus iš kurių II ir III kėlimo siurblinės vandenį perpumpuoja vartotojams. [1]

Giluminis vanduo – tai geriausias geriamo vandens šaltinis pasaulyje. Jo požeminiai telkiniai plačiai paplitę ir nuolat atsinaujina. Žemė yra natūralus filtras, kuris filtruoja paviršinių telkinių ir lietaus vandenį. 1 lentelėje pateikiami Lietuvos statistikos departamento surinkti duomenys apie išgaunamą ir suvartojamą vandens kiekius Lietuvos Respublikoje 2006 – 2012 metais.

1 lentelė. Vandens gavyba ir suvartojimas Lietuvos Respublikoje, šaltinis – <http://db1.stat.gov.lt>

Lietuvos Respublika	2006	2007	2008	2009	2010	2011	2012
Snaudota vandens ūkio ir buities reikmėms	101 851,90	96 266,90	94 182,90	89 443,40	89 769,20	90 038,30	89 257,40
Snaudota vandens energetikos reikmėms	3 507 530,60	4 265 361,80	4 444 907,40	5 125 443,70	3 639 144,80	2 780 828,80	2 710 012,10
Snaudota vandens kitoms reikmėms	3 347,80	4 065,50	4 438,60	4 176,10	4 619,30	4 520,70	2 611,40
Paimta vandens, iš viso	3 775 687,60	4 528 289,90	4 698 043,50	5 360 202,80	3 860 239,50	2 999 593,10	2 925 581,90
Paimta požeminio vandens	163 802,70	154 602,70	149 874,90	140 320,40	138 403,40	135 827,80	132 167,10
Snaudota vandens pramonės reikmėms	52 182,70	52 333,50	45 668,20	35 939,40	34 975,50	38 599,10	42 616,80
Snaudota vandens, iš viso	3 741 667,80	4 494 461,40	4 665 799,90	5 329 713,20	3 831 716,70	2 973 470,40	2 901 379,90
Snaudota požeminio vandens	138 116,40	122 399,90	119 258,40	111 444,20	111 426,80	110 884,70	109 155,70
Snaudota vandens žemės ūkio reikmėms	2 297,00	2 075,10	1 746,30	1 381,30	1 299,40	1 322,60	1 265,10
Snaudota vandens žuvininkystės reikmėms	74 457,80	74 358,60	74 856,50	73 329,30	61 908,50	58 160,90	55 617,10


Čia duomenys pateikiami tūkstančiais kubinių metrų.

Iš pirmoje lentelėje pateiktų duomenų, galima daryti išvadą, jog požeminis vanduo siekia tik 0,045 viso paimto vandens kiekio. Šis skaičius yra 22 kartus mažesnis, nei visas išgaunamas vanduo todėl, kad didžioji dalis paimto vandens yra suvartojama energetikos ūkyje. Kadangi energetikoje neapsimoka naudoti požeminio vandens, dėl ekologinių ir ekonominių priežasčių, dažniausiai yra naudojamas vanduo iš netoliese esančių telkinių, pavyzdžiui – ežerų. Šis vanduo dažniausiai naudojamas aušinimui ir garinimui. Be to, nemažai paviršinio vandens, be energetikos ūkio, sunaudojama žemės ūkyje ir pramonės reikmėms. Nors šiose srityse naudojamas ir požeminis vanduo. Pagrindiniai giluminio vandens vartotojai yra gyventojai, suvartojantys vandenį savo namų ūkiuose. Jie iš 132 mln. išgaunamo vandens suvartoja 89 mln. kubinių metrų. [28]

Lietuvoje yra viena geriausių žaliava vandens gamybai. Yra įvairių pavyzdžių, kaip geriamą vandenį ruošia kituose Europos didmiesčiuose. Lietuvoje, vanduo visiškai apsaugotas nuo taršos, į jį negali patekti ir paviršinė tarša – pesticidai, technogeninės medžiagos. Kitose šalyse geriamajam vandeniui, kaip žaliava, naudojamas gruntinis vanduo, kartais net paviršinis.

Pavyzdžiui, Stokholme ar Helsinkyje geriamas ežerų vanduo, Londono gyventojai geria Temzės vandenį. Geriamą vandenį pagaminti galima iš bet ko. [16]

Lietuvoje didžioji dalis išgaunamo vandens yra iš požeminių rezervuarų. Požeminio vandens rezervuarai čia dideli ir geros kokybės, todėl tiekiamas vanduo ne visada yra valomas ir apdorojamas prieš tiekimą. Jis dažnai atitinka standartus, tiesiai išgautas iš giluminio gręžinio. Kaune, vandenvietėse vanduo išgaunamas iš požeminių rezervuarų prie Nemuno ir Neries upių. Kadangi požeminis vanduo prie šių upių yra negiliai ir spėja išsifiltruoti, nereikia gilių gręžinių, taip pat jo kokybė atitinka standartus naudojimui ir jis greitai atsinaujina. Tokio vandens išgavimo dviem būdais (varikliui po vandeniu gręžinyje ir varikliui esant virš gręžinio) pavyzdys pateiktas 1.1 paveiksle. Kauno vandenvietėse vyrauja pirmasis išgavimo variantas. [1]



1.1 pav. Požeminio vandens išgavimas, šaltinis – fao.org

Kaune yra 4 pagrindinės vandenvietės. Petrašiūnų prie Kauno marių, Vičiūnų, prie Nemuno upės, Eigulių bei Kleboniškių prie Neries upės. Dėl skirtingų reljefų, šiose vandenvietėse vyrauja skirtingų gylių gręžiniai, nuo 10 – 15 metrų Kleboniškyje ir Vičiūnuose, iki 45 metrų Petrašiūnų vandenvietėje.

Taip pat giluminiam vandeniui neatitinkant reikalavimų, ar norint pagerinti vandens kokybę, įrengiami vandens gerinimo įrenginiai. Londone valant vandens žaliavą reikia atlikti apie 15 – 20 valymo operacijų, viena jų – vandens chloravimas ir dezinfekavimas. Vilniuje valant vandens

žaliavą reikia viso labo pašalinti geležį. Vandenyje tvyro redukcinės sąlygos, kuriomis geležis ištirpsta. Geležis yra biogeninis elementas, kuris reikalingas žmogaus organizmui, tačiau iš vandens jo neįsisaviname. Nei naudos, nei žalos žmogaus organizmui šis elementas neturi, tačiau žinoma, kad bet kokia medžiaga dideliais kiekiais gali būti kenksminga. Vis dėlto, Lietuvoje, gręžiniais išgaunamame vandenyje, geležies kiekis nėra pavojingas – jis gali viso labo lemti blogą vandens kvapą ar rūdis santechnikoje. Tiesa, kitose Lietuvos vietovėse, švarinant vandenį, reikia kur kas labiau pasistengti. Yra vietų, kur yra kitų problemų – štai Šiaurės Vakaruose reikia sumažinti fluoro perteklių. Viskas reglamentuojama higienos normomis, todėl vanduo yra išvalomas taip, kad jas atitiktų. Šie valymai – kur kas sudėtingesni. Kituose gerinimo įrenginiuose, jeigu yra poreikis vanduo taip pat gali būti dezinfekuojamas. [16]

Giluminio vandens valymo įrenginiuose koreguojamas vandens pH lygis, pilamas koaguliantas, sukabinantis kietąsias daleles, esančias vandenyje, jos atskiriamos nuo vandens, taip pat atliekamas filtravimas ir vanduo dezinfekuojamas, dažniausiai chloru. Pilna valymo sistema mažai skiriasi nuo paviršinio vandens valymo. Esant didelei įvairovei giluminio vandens sudėties, kiekvienoje vietovėje iš esmės reikia pritaikyti skirtingus valymo metodus, kurie pašalina tam tikras daleles ar ištirpusius metalus bei medžiagas.


Kaune, Chemijos gatvėje esančioje vandens gerinimo stotyje, iš vandens yra tik pašalinama geležis bei kitos kietosios dalelės. Dėl to ji vadinama nugeležinimo stotimi. [1]

## **1.2 Vandens pakėlimas ir slėgio palaikymas**

Norint, kad išgautas ir/ar apdorotas vanduo patektų pas vartotoją, reikia jį pakelti iki tam tikros vietos ir tiekti, atitinkantį slėgio reikalavimus. Kauno miesto vandens tiekimo sistemą sudaro 3 kėlimų siurblinės, jos reikalingos, dėl netolygaus miesto reljefo. I kėlimo siurblinės išgauna vandenį iš vandens telkinių, Kauno atveju – giluminių. II kėlimo siurblinės perpumpuoja vandenį iš vandenviečių, palaikant didelį slėgį linijoje, tam kad būtų praleidžiamas didelis kiekis vandens į aukštesnes vietas magistraliniais vamzdžiais. Taip daroma dėl to, kad vandenvietės yra upių lygyje – slėniuose, kur lengviau pasiekti giluminius vandenius. Taip pat antro pakėlimo siurblinė laikoma ir nugeležinimo stotis. Tokios, vandentiekių sistemų su vieno ir dviejų kėlimų siurblinių, struktūros pateikiamos 1.2 paveiksle. Galiausiai vanduo, pasiekia vartotojus arba kur dar trūksta slėgio magistraliniais vamzdžiais paskirstomas į 3 kėlimo siurblines, kurios yra gana nedidelės ir pakelia vandenį iš antro kėlimo siurblinių, vartotojams.

Kad užtikrinti nenutrūkstamą vandens tiekimą gyvenamųjų namų ir įmonių vartotojams, vandentiekio tinkluose būtina sukelti atitinkamą slėgį. Pavyzdžiui, penkiaaukščiam namui reikia sukelti ir išlaikyti būtinas apie 25 metrų vidutinis vandens tiekimo slėgis.

Kad pakelti vandenį į 9 aukštų ar dar aukštesnius pastatus, reikia didesnio – iki 60 metrų – vandens slėgio. Padidinto aukštingumo gyvenamųjų namų grupių aprūpinimui geriamuoju vandeniu įrengiamos trečio kėlimo siurblinės su nedidelio galingumo siurbliais. Jos aptarnauja daugiaaukštį namą arba jų grupę. Dažniausiai jos įrengiamos daugiabučių rūsiuose. Šio tipo siurblinėse stovi maži siurbliai su dažnio keitikliais, kurie automatiškai palaiko tam tikrą slėgio vertę, tinkamą vartotojams, kitoje linijos pusėje.



SANDEC 26.8.96

1.2 pav. Vieno kėlimo ir dviejų kėlimų sistemos pavyzdys, šaltinis – nzdl.org

Norint palaikyti kokybišką vandens tiekimą, svarbiausia yra palaikyti tinkamą slėgį linijose. Slėgį vandens linijoje, galima prilyginti dažniui elektros tinkluose. Slėgio palaikymas vandentiekyje yra vandens pasiūlos reguliavimas, kad atitiktų paklausą. Tačiau energetikoje sudėtingiau palaikyti dažnį nei vandentiekyje slėgį, nes vandenvietėse yra rezervuarai – kaupikliai, iš kurių esant poreikiui nesunku paimti vandenį perpumpavimui, bei galima sutaupyti energijos, pripildant rezervuarus naktį – kai elektros energija pigesnė. Esant per mažam slėgiui linijoje,

aukščiau esančių vartotojų vanduo gali ir nepasiekti. Pavojaingas ir staigus slėgio kritimas, dėl kurio gali atsirasti vakuumas vandens linijoje ir taip ją sugadinti. O slėgiui viršijant normines vertes, kyla trasos trūkimo ar sprogo rizika, ypač esant senesniems vamzdynams. Taip pat didelis slėgis gali sugadinti vamzdynus pas vartotojus, taip pridarant daug žalos. Padidėjus slėgiui linijoje, gali suprastėti ir vandens kokybė, nes nuo trasos sienelių atsoka prikibusios nuosėdos ir patenka į liniją.

Anksčiau, kai sistemos nebuvo automatizuotos, ši slėgio palaikymo problema buvo sprendžiama rankiniu būdu, siurbliū su varikliu prijungiant tiesiai prie tinklo per kirtiklį, bei vandenvietės operatoriams reguliuojant slėgį linijoje ranka atidarant ar uždarant sklendę už siurblio. Tada trasos buvo patvaresnės ir mažiau reaguodavo į slėgio šuolius, bei nebuvo kokybinių slėgio palaikymo reikalavimų. Dėl šių priežasčių slėgis nebūdavo pastovus.

Dabar, automatizavus sistemas, slėgis palaikomas automatiškai, kompiuterio su SCADA sistema, arba siurblio dažnio keitikliu. Dispečeris užduoda tam tikrą slėgio vertę, pagal kurią dirbs vandenvietė, ir ji automatiškai palaiko šį paklausos ir pasiūlos santykį, keisdama siurblių dažnį, bei į pagalbą įjungiant, ar atjungiant siurblius. Šiuo būdu slėgis nekinta per šimtąsias vertės dalis.

[1]

### **1.3 Nuotėkiai vandens tinkluose**

Nuotėkiai vandens tinkluose – tai dažna kiekvienos vandenį tiekiančios ir nuotekas surenkančios įmonės problema. Jie daro žalą turtui ir gamtai, bei sukelia nuostolių vandenį tiekiančioms įmonėms. 1.3 ir 1.4 paveiksluose pateikti vaizdai, po avarijų, kurių metu įvyko nuotėkis.



1.3 pav. Neseniai įvykusi nuotekų vamzdyno avarija Vilniuje, šaltinis – 15min.lt




1.4 pav. 2017 metų pradžioje dėl šalčių trūkusios geriamo vandens linijos, padariniai, šaltinis – 15min.lt



Kai kurie nuotėkiai pastebimi iš karto, kaip ir įvyko pirmuoju atveju, bet kai kurie vyksta nepastebėti, kaip pastebima antroje nuotraukoje. Būtent ši avarija, išplovė gruntą po automobiliu. Šios avarijos pastebimos tik pamačius žmonėms. Tokie atvejai parodo kaip reikalinga autonominė sistema, galinti pastebėti įvykusį nuotėki ir pati imtis sprendimų, izoliuojant šią liniją ir perspėjant avarines tarnybas. Būtent čia praverčia dirbtiniai neuroniniai tinklai.

1.5 paveiksle pateiktas realizuoto vandens ir prarasto vandens grafikas Kaune 1998 – 2016 metų laikotarpiui.

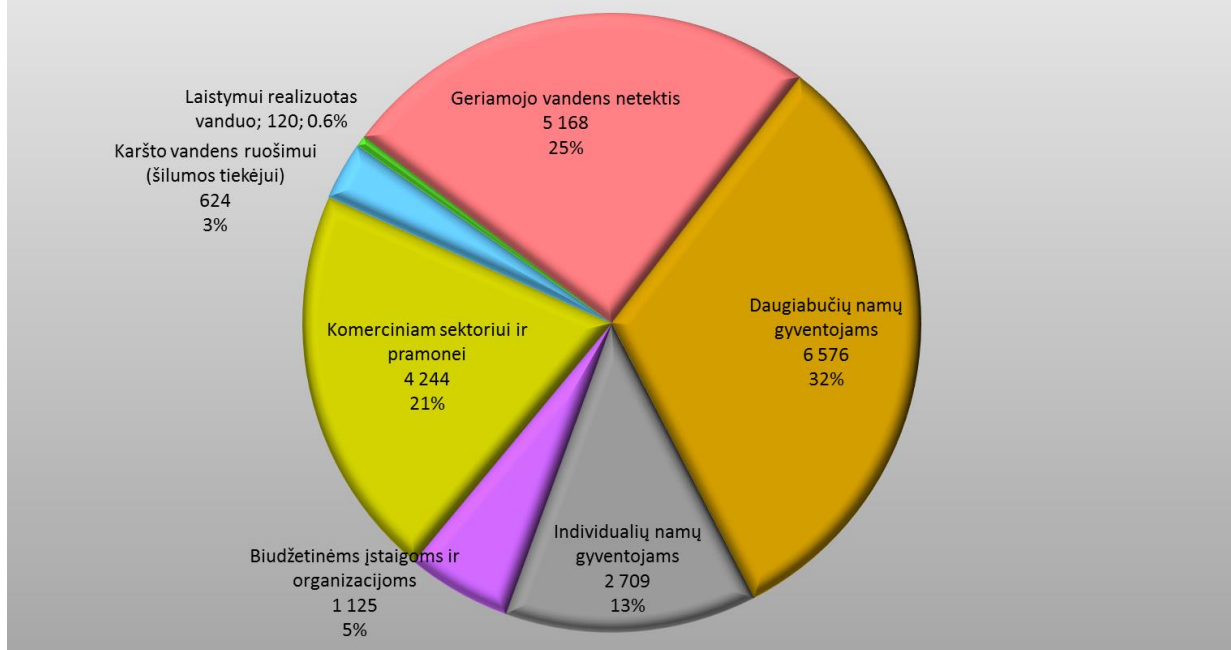


1.5 pav. Realizuotas ir prarastas vanduo Kaune, sudarė UAB „Kauno vandenys“

Šie nuotėkiai atsiranda dėl įvairių priežasčių, kurių pagrindinės: gedimai linijose (supuvę vamzdžiai, hidrosmūgiai, išoriniai mechaniniai poveikiai ir pan.), technologiniai nuostoliai (nugeležinimo atliekos ir pan.), bei viena iš daugiausiai nuotėkių sukeliančių priežasčių – vandens vogimas. Tačiau ši problema mažėja statistškai, dėl to, kad daugėjant pramonės įmonių, su apskaita, kurie suvartoja daugiau vandens, užgožia šias vagystes. 1.6 paveiksle pateikiamas viso išgauto geriamo vandens panaudojimas 2016 metais.



### Viso 2016 m. išgauto vandens pasiskirstymas, tūkst m<sup>3</sup>/metus



1.6 pav. Išgauto vandens pasiskirstymas 2016 metais, sudarė UAB „Kauno vandenys“


Kaip matyti paveiksle, netektis sudaro net ketvirtadalį, viso išgauto vandens. Tai yra didžiulė problema įmonei. Taip pat dėl prarasto vandens yra švaistoma elektros energija, nes siurbLIAI pumpuoja vandenį bandydami palaikyti spaudimą linijoje ir esant trūkusiai trasai, bei nukritus spaudimui sistema automatiškai pumpuoja vandenį pilnu pajėgumu, nesugebėdama pakelti slėgio linijoje.

## 1.4 Neuroniniai tinklai

### 1.4.1 Neuroninio tinklo sąvoka

Dirbtiniai neuroniniai tinklai – tai informacijos apdorojimo struktūros, netiksliai imituojančios kai kurių gyvųjų organizmų smegenyse vykstančius informacijos apdorojimo procesus. Dirbtiniai neuroniniai tinklai sudaromi iš daugelio tarpusavyje sujungtų labai paprastų skaičiavimo elementų. Šie elementai, jungiami vieni su kitais įvairaus stiprumo jungtimis, yra apytikris biologinių neuronų modelis. Skaičiavimo elementus siejančios jungtys yra analogiškos biologinių neuronų sinapsėms. Dirbtiniu neuroniniu tinklu siekiama atkartoti kai kurias biologinių sistemų savybes. Labiausiai dominantis yra biologinių sistemų gebėjimas, mokytis, prisitaikyti ir adaptuotis. [2]

Mokymosi metu smegenyse keičiasi jungčių, siejančių neuronus, stiprumas. Toks jungčių stiprumo kitimas būdingas ir dirbtiniams neuroniniams tinklams. Dirbtiniams neuroniniams tinklams mokytį naudojami duomenų pavyzdžiai. Mokymo metu, duomenimis veikiant dirbtinį neuroninį tinklą, specialiais algoritmais iteratyviai keičiami jungčių stiprumo koeficientai – svoriai. Informacija uždaviniui spręsti kaupiama svorių vertėse. [2]




1.7 pav. Dirbtinio neuroninio tinklo neuronas, šaltinis – 2centsapiece.blogspot.lt

1.7 paveiksle pateiktas dirbtinis neuroninio tinklo neuronas. Jį sudaro įėjimo signalai (X1, X2 ir X3), atitinkami jų svoriai (W1, W2 ir W3), taip pat perdavimo funkcija bei išėjimo signalas Y.

Neuroninis tinklas yra sudaromas iš atskirų neuronų. Šį tinklą sudaro įėjimai ir išėjimai. Išėjimai, tai tinklo reakcija į jam pateiktus įėjimus – duomenis mokymui. Kartais neuroniniai tinklai būna kelių paslėptųjų sluoksnių, jie įterpiami tarp įėjimo ir išėjimo sluoksnių. Sluoksnių skaičius priklauso nuo uždavinio sudėtingumo. [2]

Tiesioginio sklaidimo neuroninio tinklas, kuriame neuronai išdėstyti sluoksniais schema pateikiama 1.8 paveiksle.



1.8 pav. Daugiasluoksnis vieno paslėptąjį sluoksnį neuroninis tinklas, šaltinis – [neuralnetworksanddeeplearning.com](http://neuralnetworksanddeeplearning.com)

Kaip anksčiau minėta, daugiasluoksniai tinklai taikomi esant sudėtingesniai tinklui, kai reikia aptikti sunkiau randamas priklausomybes tarp duomenų. Dažniausiai, nesudėtingiems uždaviniams spręsti užtenka ir paprasto – vieno sluoksnio neuroninio tinklo. Sudėtingėjant uždaviniui didėja ir neuronų, bei jų sluoksnių skaičius. [2]

Naudojant daugiasluoksnius neuroninius tinklus, sudėtingiems uždaviniams spręsti, sunku nustatyti tinkamą paslėptųjų sluoksnių ir neuronų skaičių juose. Uždavinio sudėtingumas ir nulemia reikalingą neuronų skaičių sluoksnyje, bet didinant šį skaičių tinklas darosi sudėtingesnis ir reikalaujantis daugiau laiko ir resursų mokymui. Didėjant sluoksnių skaičiui, reikalingų neuronų skaičius juose, paprastai, mažėja. Dažniausiai atlikti nesudėtingiems mokymams užtenka ir vieno sluoksnio neuroninio tinklo, tačiau dviejų sluoksnių tinklas gali aproksimuoti bet kokią tolydinę funkciją. Geriausia, kuriant tinklus, išlaikyti sąlygą, kad tinklai būtų tik tiesioginio sklaidimo. Tuo atveju neuroninio tinklo išėjimai gali būti skaičiuojami, kaip apibrėžtos įėjimų ir svorių funkcijos. [2]

Daugiasluoksniai neuroniniai tinklai, dažniausiai, turi kur kas daugiau adaptuojamų svorių nei viensluoksniai, todėl naudojant sudėtingesnius tinklus, svarbu, kad mokymo algoritmas darbą atliktų greitai. Šiuo atveju labai tinka gradientiniai mokymo metodai, tačiau norint juos panaudoti tinklo neuronų perdavimo funkcijos turi būti diferencijuojamos. [2]

Neuroninio tinklo elementas naudojant perdavimo funkciją, transformuoja savo įėjimo kintamųjų svorinę sumą. Šio tinklo dydis priklauso nuo uždavinio sudėtingumo. Dažniausiai

daugiasluoksniame neuroniniame tinkle, kiekvieno, vienas po kito einančio, sluoksnio neuronai yra sujungti su visais neuronais kitame sluoksnyje ir neturi jokių kitų jungčių. Šie tinklai lengviau modeliuojami ir analizuojami, nei bendri tiesioginio sklidimo tinklai. [2]

Analitinė NT realizuojama funkcija užrašoma taip:  $j$ -tojo paslėptojo neurono svorinė suma gaunama formuojant svorinę visų  $d$  įėjimo kintamųjų kombinaciją ir pridendant laisvąjį narį:

$$a_j = \sum_{i=1}^d w_{ji}^{(1)} x_i + w_{j0}^{(1)} \quad (1.4.1)$$

čia  $w_{ji}^{(1)}$  reiškia pirmojo sluoksnio svorį iš  $i$ -tojo paslėptojo neurono į  $j$ -tąjį kito sluoksnio neuroną,  $w_{j0}^{(1)}$  žymi  $j$ -tojo paslėptojo neurono laisvojo nario svorį. Paslėptojo neurono išėjimo vertė gaunama transformuojant tiesinę sumą perdavimo funkcija  $g()$ . Neurono išėjimo vertė:

$$z_j = g(a_j) \quad (1.4.2)$$

Kiekvienam neuroninio tinklo išėjimui skaičiuojamos tiesinės paslėptojo sluoksnio neuronų išėjimų kombinacijos:

$$a_k = \sum_{j=1}^M w_{kj}^{(2)} z_j + w_{k0}^{(2)} \quad (1.4.3)$$

Tada neuroninio tinklo išėjimas:

$$y_k(x) = \tilde{g}(a_k) \quad (1.4.4)$$

Išėjimo ir paslėptųjų sluoksnių neuronų perdavimo funkcijos  $g()$  ir  $\tilde{g}()$  nebūtinai turi būti tos pačios. [2]

Sujungus visas šias formules bei laisvus svorius į bendrą svorių vektorių, gaunama:

$$y_k(x) = \tilde{g} \left( \sum_{j=0}^M w_{kj}^{(2)} g \left\{ \sum_{i=0}^d w_{ji}^{(1)} x_i \right\} \right) \quad (1.4.5)$$

Jeigu, kurio nors paslėptojo sluoksnio elementų skaičius mažesnis nei įėjimo ar išėjimo sluoksnio elementų skaičius, tokiam sluoksnyje prarandama dalis informacijos. Be to, neuroninio tinklo perdavimo funkcija gali būti suformuota viensluoksniu tinklu, jei visų šio tinklo neuronų paslėptajame sluoksnyje perdavimo funkcijos yra tiesinės. Tai galima daryti, nes tiesinių, viena po kitos einančių transformacijų kompozicija yra tiesinė transformacija. [2]

#### 1.4.2 Taikymas

Neuroniniai tinklai, turi daug pritaikymo sričių:

1. Prognozavimas: turint duomenis, pavyzdžiui orų prognozes galima panaudoti šiuos duomenis prognozuoti saulės ar vėjo elektrinių gamybą, arba turint elektros energijos vartojimo duomenis, prognozuoti elektros energijos poreikius ateityje.
2. Kontrolė: naudojant vaizdų atpažinimą, galima nurodyti kur judėti robotui.
3. Stebėjimas: apdorojant vibracijos, temperatūrų ir triukšmų lygio daviklių duomenis, galima anksti diagnozuoti artėjančius mechaninių sistemų gedimus.
4. Vaizdų analizė: tikrinamas piršto antspaudas, duomenų bazėje.

Dažniausiai neuroniniai tinklai pasitarnauja, kai nežinomas santykis tarp įėjimo ir išėjimo duomenų. Pagrindinė šių tinklų savybė – gebėjimas išmokti priklausomybes tarp duomenų, kurių neaptinka jokie kiti metodai. Žinant priklausomybes, neuroniniai tinklai nėra būtini, tada duomenys gali būti modeliuojami tiesiogiai. [2]

#### 1.4.3 Neuroninių tinklų mokymas

Neuroninio tinklo mokymo metu modelio parametrai keičiami naudojant sistemos daromą klaidą. Iš šios klaidos galima spręsti, kaip gerai buvo apmokytas tinklas ir ką reikia keisti, kad šią klaidą sumažinti. Kuo sistema daro mažesnę klaidą, tuo ji geriau apmokyta ir geriau aptinka priklausomybes tarp įėjimo ir išėjimo duomenų. Todėl neuroninio tinklo mokymas yra grindžiamas mokymu ir adaptacija. Sistemai apdorojant duomenis, ji randa geriausią parametru rinkinį. [2]

Kiekvienas iš neuroninių tinklų tipų, naudoja skirtingus mokymo metodus. Dažniausiai taikomi du metodai, tai mokymas su mokytoju ir be mokytojo. Egzistuoja ir trečias tipas – skatinantis mokymas. Neuroniniams tinklams mokyti naudojami tam paruošti duomenys – masyvai. Mokant tinklą su mokytoju, masyvas sudaromas iš tam tikrų požymių verčių ir tikslų (norimų gauti išėjimų verčių). Šiuo atveju tinklas mokomas atkartoti norimas išėjimo vertes, taip ieškodamas priklausomybių tarp įėjimo ir išėjimo duomenų. Jei tinklas tinkamai apmokytas, jis gali modeliuoti funkciją, siejančią įėjimo bei išėjimo kintamuosius. [2]

Mokymo rezultatai įvertinami skaičiuojant apmokyto tinklo daromą klaidą. Ji gali būti skaičiuojama vidutine kvadratine klaida visiems duomenims, sumine kvadratine klaida, kryžmine entropija (šių klaidų formulės pateikiamos žemiau) arba kitokiais neuroninio tinklo darba įvertinančiais kriterijais. Mokymo rezultatai gerinami, mažinant klaidą – koreguojant tinklo svorius ir slenksčių vertes. [2]

NT mokymas dažniausiai grindžiamas klaidos minimizavimo metodais. Klaida, kurią minimizuojant mokomas tinklas, gali būti parenkama pagal sprendžiamą uždavinį ir neuroninio tinklo tipą. Viena iš klaidos funkcijų, plačiai naudojama neuroniniams tinklams apmokyti, yra suminė kvadratinė klaida – SSE. Ši funkcija tinka regresijos uždaviniams spręsti. Funkcija gali būti naudojama ir klasifikavimo problemoms, tačiau tam yra tinkamesnių funkcijų. Suminė kvadratinė klaida gaunama sumuojant klaidas visuose tinklo išėjimuose, visai duomenų imčiai:

$$E(W) = \frac{1}{2} \sum_{n=1}^N \sum_{k=1}^c \{y_k(x^n, w) - t_k^n\}^2 \quad (1.4.6)$$

čia  $y_k(\mathbf{x}^n, \mathbf{w})$  yra k-tasis tinklo išėjimas, apskaičiuojamas kaip n-tojo įėjimo vektoriaus  $\mathbf{x}^n$  ir svorių vektoriaus  $\mathbf{w}$  funkcija, N yra įėjimo vektorių skaičius, o c žymi tinklo išėjimų skaičių. [2]

Be suminės kvadratinės klaidos yra ir kitų klaidos įvertinimo kriterijų, tokių kaip vidutinė kvadratinė klaida (MSE). Statistikoje vidutinė kvadratinė įvertinimo klaida (procedūros, įvertinant nepastebėtą kiekį) matuoja klaidų kvadratų vidurkį, arba nuokrypius – tai yra skirtumą

tarp įvertintojo ir tai kas yra įvertinama. Vidutinė kvadratinė klaida yra įvertintojo kokybės rodiklis, jis visada teigiamas ir kuo arčiau nulio, tuo geresnis. [25]

Vidutinė kvadratinė klaida nusako kaip arti regresijos linijos yra taškų grupė. Tai pasiekama, paimant atstumus nuo taškų iki regresijos linijos (šie atstumai ir yra klaidos) ir juos kelia kvadratu. Kėlimas kvadratu yra reikalingas, pašalinti neigiamiems ženklams. Be ženklų pašalinimo, taip pat, pridama daugiau svorio didesniems skirtumams. Vidutinė kvadratinė klaida apskaičiuojama:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{X}_i - X_i)^2 \quad (1.4.7)$$

čia,  $X_i$  – nežinomas parametras, o  $\hat{X}_i$  – jį atitinkantis ieškomasis

Dar viena iš mokymo klaidos funkcijų yra kryžminė entropija, jos funkcija pateikiama žemiau:

$$- \sum_{i=0}^n \ln(o_i) \times t_i \quad (1.4.8)$$

čia,  $o_i$  – apskaičiuota vertė, o  $t_i$  – atitinkama užduota vertė

Realiai kryžminė entropija ignoroja visus apskaičiuotus išėjimus, kurie neatitinka išėjimo tikslo, lygaus 1. Šios klaidos idėja yra tokia, kad nesvarbu kiek išėjimai, nelygus 1, yra nutolę nuo šios vertės, svarbiausia yra, kiek viena apskaičiuota vertė, atitinkanti norimą 1 tikslo vertę yra arti šios vertės. [25]

#### 1.4.4 Klasifikavimas

Optimalus klasifikatorius geba minimizuoti klasifikavimo klaidą visam duomenų masyvui. Klaidingo klasifikavimo tikimybė mažiausia, kai  $x$  priskiriamas klasei, turinčiai didžiausią sąlyginę tikimybę, t.y. taškas  $x$  priskiriamas klasei  $C_k$ , jei

$$P(C_k|x) > P(C_j|x) \text{ visiems } j \neq k \quad (1.4.9)$$



Taigi optimalus klasifikatorius duomenų tašką  $x$  turi priskirti tai klasei  $C_k$ , kuriai sąlyginė tikimybė  $P(C_k|x)$ , kad duomenų taškas  $x$  priklauso klasei  $C_k$ , yra maksimali, tai yra:

$$x \in C_k, \text{ jei } P(C_k|x) > P(C_j|x), \forall j \neq k \quad (1.4.10)$$

Įvykio tikimybė, po atliktų matavimų (kai turima  $x$  vertė), vadinama sąlygine tikimybe. Naudojant anksčiau pateiktą taisyklę klasifikuojant, pasiekiami mažiausia klaidingo klasifikavimo tikimybė. Ši tikimybė nėra matuojama tiesiogiai, ji apskaičiuojama pagal Bayeso teoremą:

$$P(C_k|x) = \frac{P(x|C_k)P(C_k)}{p(x)} \quad (1.4.11)$$


Tikimybė  $P(C_k)$  ir sąlyginis duomenų tankis  $p(x|C_k)$  gali būti įvertinti iš turimų duomenų. Iš (1.2.9) ir (1.2.11) galima teigti, kad taškas  $x$  turėtų būti priskiriamas klasei  $C_k$ , jei galioja sąlyga:

$$P(x|C_k)P(C_k) > P(x|C_j)P(C_j), \forall j \neq k \quad (1.4.12)$$

Klasifikatorius nusako taisyklę, pagal kurią kiekvienas įėjimo erdvės taškas priskiriamas vienai iš  $c$  galimų klasių. Galima sakyti, jog įėjimo erdvė padalijama į  $c$  regionų  $R_1, \dots, R_c$  taip, kad taškas, patenkantis į regioną  $R_k$ , yra priskiriamas klasei  $C_k$ . Sprendimo paviršiais arba ribomis vadinamos ribos tarp šių regionų. [2]

Kai klaidingo klasifikavimo tikimybė mažiausia, tada skiriamasis paviršius yra laikomas optimaliu. Klasifikatorius dirba klaidingai, kai naujas narys priklausantis klasei  $C_2$  priskiriamas klasei  $C_1$  arba atvirkščiai. [2]

1.9 paveiksle pateiktas viensluoksnis neuroninis tinklas, galintis spręsti kelių klasių klasifikavimo problemą.



1.9 pav. Viensluoksnis neuroninis tinklas galintis skirti duomenis į keletą klasių, šaltinis – [abhishek4273.com/2015/11/](http://abhishek4273.com/2015/11/)

#### 1.4.5 Vaizdų ir struktūrų atpažinimo neuroninis tinklas

Struktūrų atpažinimas tai, mašinių mokymo atšaka, kuri fokusuojama į struktūrų ar modelių ir dėsningumų atpažinimą, tačiau dažnai laikomas sinonimišku mašinių mokymui. Struktūrų atpažinimo sistemos dažniausiai apmokomos iš paženklintų mokymo duomenų, (mokymas su priežiūra), bet gali būti naudojami ir kiti mokymo algoritmai aptikti anksčiau neatpažintas struktūras, kai duomenys yra nepaženklinti (mokymas be priežiūros). [21]

Klasifikavimas dažnai paprasčiausiai vadinamas diskriminantine analize. Inžinerijoje ir informatikoje klasifikavimas dažnai vadinamas vaizdų ir struktūrų atpažinimu (angl. pattern recognition). Kai kurie rašytojai naudoja terminą klasifikavimo analizė, apibūdinant grupavimo analizę, kurioje stebimi duomenys yra susigrupavę pagal kintamąsias vertes, o ne iš anksto nustatytas klases. Klasifikavime mėginio vienetas (subjektas ar objektas), kurio klasė nežinoma yra priskiriamas prie klasės, remiantis vektoriaus  $p$  išmatuota verte  $y$ , susijusia su tuo vienetu. Norint klasifikuoti šį vieneta, privaloma turėti anksčiau gautus, kiekvienos klasės, stebėjimo vektorių mėginius. [22]

Šios automatinės (mašinių) struktūrų atpažinimo, apibūdinimo, aprašymo, klasifikavimo ir grupavimo problemos yra labai svarbios įvairiose inžinerijos ir mokslo srityse, tokiose kaip: biologija, psichologija, medicina, marketingas, kompiuterinė rega, dirbtinis intelektas, ir nuotolinis jutimas. Šiais atvejais struktūra gali būti piršto antspaudas, rašytinė kalba, žmogaus veidas, kalbos ar banginis signalas. Struktūros atpažinimas ar klasifikavimas, gali susidėti iš vieno iš užduočių: mokymo su priežiūra (pvz. diskriminantinė analizė), kurioje įėjimo modelis yra

pripažįstamas, kaip iš anksto nustatytos klasės narys, bei klasifikavimas be priežiūros (pvz. Grupavimas), kuriame modelis priskiriamas iki šiol nežinomai klasei. Čia atpažinimo keliama problema yra klasifikavimo ar kategorizavimo užduotis, kur klasės yra nustatomos sistemos kūrėjo (mokant su priežiūra), arba yra išmokstamos atsižvelgiant į modelių panašumus (mokant be priežiūros). Šias pritaikymo sritis sudaro duomenų išgavimas (modelio ar struktūros aptikimas, pavyzdžiui koreliacija), dokumentų klasifikavimas, finansinės prognozės, multimedijos duomenų bazių organizavimas ar išgavimas ir darbas su biometriniais duomenimis. Vis auganti ir prieinama kompiuterinio apdorojimo galia, padedant greitinti didelių duomenų masyvų apdorojimą, taip pat palengvino detalizuotų ir įvairių duomenų analizės metodų panaudojimą. Tuo pačiu metu nežmoniškai auga automatinių struktūrų atpažinimo sistemų paklausa, dėl prieinamumo prie didelių duomenų bazių bei griežtų didelių pajėgumų (greičio, tikslumo, ir kainos) reikalavimo. [21]

Struktūrų atpažinimo sistemą iš esmės sudaro trys aspektai: duomenų surinkimas ir pirminis apdorojimas, duomenų pateikimas ir sprendimo priėmimas. Problemos sritis diktuoja sensorių pasirinkimą, pirminio apdorojimo techniką, pateikimo schemą ir sprendimo priėmimo modelį. Paprastai sutariama, gerai apibrėžta ir pakankamai suvaržyta atpažinimo problema (maži pokyčiai tarp klasių ir dideli pokyčiai tarp klasių) gali nuvesti prie glausto struktūros atvaizdavimo ir paprastos sprendimo priėmimo strategijos. Mokant iš pavyzdžių masyvo (mokymo imties) yra svarbi ir geidžiama daugumos struktūrų atpažinimo sistemų savybė. Keturi geriausi būdai atpažinti struktūrai yra: prilyginimas šablonui, statistinis klasifikavimas, sintaksinis ar struktūrinis prilyginimas ir neuroniniai tinklai. [21]

#### **1.4.6 Neuroninio tinklo mokymo funkcijos**

Pagrindinės MatLab aplinkoje naudojamos mokymo funkcijos yra:

Levenberg–Marquardt algoritmas – dažniausiai naudojamas spręsti netiesinių mažiausių kvadratų problemas. Šios minimizavimo problemos dažniausiai iškyla mažiausių kvadratų kreivėse. Šis metodas randa vietinį minimumą, kas nebūtinai yra globalusis minimumas. Jis interpoliuoja tarp Gauso–Niutono algoritmo ir gradientinio nusileidimo metodo. Šis metodas stipresnis už Gauso–Niutono, nes daugelyje atveju jis randa sprendimą, net jeigu ir pradeda labai toli nuo galutinio minimumo. Tačiau šis metodas yra ir šiek tiek lėtesnis. [3]

Kaip ir kiti skaitinio minimizavimo algoritmai, šis atliekamas kartojant iteracijomis. Tam, kad pradėti minimizavimą, vartotojas privalo spėti vektorių  $\beta$ . Vieno minimumo atvejais užtenka spėjimo –  $\beta^T = (1, 1, \dots, 1)$ . Kelių minimumų atveju algoritmas konverguoja su globaliuoju

minimumu tik jeigu pradinis spėjimas yra arti galutinio sprendinio. Kiekviename iteracijos žingsnyje, vektorius  $\beta$  yra pakeičiamas nauju spėjimu  $\beta + \delta$ . [3]

Kvasi–Niutono metodai – tai metodai, kurie naudojami rasti nuliams ar vietiniams maksimumams ar minimumams. Šie metodai yra Niutono metodo alternatyva. Jie naudojami jeigu neįmanoma naudoti Jakobiano ar Hesiano, arba šie metodai reikalauja per daug resursų kiekvienai iteracijai. [3]

Lankstaus atgalinio dauginimo ( angl. resilient backpropagation) (Rprop) yra tiesioginio sklidimo neuroninių tinklų mokymosi funkcija. Šis metodas paima tik dalinės išvestinės ženklą per visą modelį ir elgiasi nepriklausomai su kiekvienu svoriu. Kiekvienam svoriui atsiradus visos klaidos funkcijos dalinės išvestinės ženklo pokyčiui, lyginant su praeita iteracija, tam svoriui atnaujinta vertė dauginama iš  $\eta^-$ , kur  $\eta^- < 1$ . Jei paskutinės iteracijos metu gautas tas pats ženklas, atnaujinta vertė dauginama iš  $\eta^+$ , kur  $\eta^+ > 1$ . Atnaujintos vertės perskaičiuojamos kiekvienam svoriui, prieš tai nurodyta tvarka ir galiausiai kiekvienas svoris yra pakeičiamas jo atnaujinta verte, priešinga dalinės išvestinės verte, tam kad minimizuoti visą klaidos funkciją.  $\eta^+$  empiriškai nustatomas 1,2 ir  $\eta^-$  į 0,5. [3]

Jungtinis gradientas – algoritmas apskaičiuoja kiekvieno išėjimo mazgo ir paslėptojo mazgo gradientą. Šie gradientai rodo, kaip toli ir kuria kryptimi (teigiama ar neigiama) šiuo metu apskaičiuotos vertės yra, išėjimo tikslų atžvilgiu. Šie gradientai tada yra naudojami reguliuoti neuroninio tinklo svorius ir nuolydžius, tam kad apskaičiuotos vertės būtų arčiau tikslų verčių. Šis metodas taip pat tinka spręsti nesuvaržytas optimizavimo problemas, tokias kaip energijos minimizavimas. [3]

Jungtinis gradientas su Powell-Beale perkrovimais. Jungtinio gradiento metodo paieškos kryptis yra pastoviai perkraunama į gradiento neigiamą pusę. Šis perkrovimas dažniausiai įvyksta, kai iteracijų skaičius tampa lygus tinklo parametrų (svorių, poslinkio) skaičiui. Šis metodas pagerina jungtinio gradiento mokymo efektyvumą. Powell (Powe77) metodas pagerina anksčiau siūlytą Beale (Beal72) metodą. Ši technika perkrauna tik tada, kai tarp esamo ir praeito gradientų lieka labai mažai ortogonalumo. Ši mokymo funkcija yra šiek tiek geresnė nei netiesinio jungtinio gradiento metodas, nors gerumą sunku nuspėti kiekvienai problemai. [3]

Fletcher–Powell jungtinis gradientas – randa kertinio skaičiavimo lygtį, kuri yra arčiausiai manomo ir patenkina išlinkimą. Tai buvo pirmasis Kvasi–Niutono metodas, kuris apibendrina kertinį metodą daugiamatei problemai. Šis pagerinimas išlaiko Hesiano matricos simetriją ir teigiamą griežtumą. [3]

Netiesinio jungtinio gradiento metodas – šis metodas iš esmės yra jungtinio gradiento metodas apibendrintas netiesinei optimizacijai. Kur tiesinis jungtinis gradientas ieško tiesinės lygties sprendinio, šis metodas ieško netiesinės funkcijos vietinio minimumo, naudojant savo gradientą. Tai veikia, kai funkcija yra apytiksliai kvadratinė prie minimumo. [3]

Vieno žingsnio kertantysis – skaitinėje analizėje, šis metodas yra šaknų radimo algoritmas, kuris naudoja kertinių linijų šaknų perėmimus, tam, kad geriau aproksimuoti funkcijos  $f$  šaknį. Apie šį metodą galima galvoti, kaip Niutono metodo baigtinių skirtumų aproksimaciją. [3]

Yra dar daug kitų mokymo funkcijų, tačiau jos šiame darbe nebus naudojamos ir todėl nėra aptariamoms. Dažniausiai mokymo sąlygas, ypač nesudėtingais atvejais patenkina standartinės mokymo funkcijos.

## 1.5 Elektros varikliai ir mechaniniai gedimai

### 1.5.1 Asinchroninės mašinos

Kaip ir visi elektromechaniniai keitikliai asinchroninės mašinos susideda iš dviejų mazgų: statoriaus ir rotoriaus. Statorius sudarytas iš feromagnetinio magnetolaidžio, kuris sutelkia magnetinį lauką, ir apvijos, kuria teka kintamoji srovė. Rotorius taip pat dažniausiai sudarytas iš feromagnetinio magnetolaidžio, kuriame sukota apvija. Kaip ir sinchroninėje elektros mašinoje, daugiafazė statoriaus apvija sukuria asinchroninės mašinos oro tarpe sukamąjį magnetinį lauką, kurio kampinis greitis [4]:

$$\Omega_1 = \frac{f_1}{p} 2\pi \text{ rad/s} \tag{1.5.1}$$


čia  $f_1$  – tinklo dažnis,  $p$  – polių porų skaičius.

Dažnai vietoje kampinio greičio naudojamas sukimosi greitis:

$$n_1 = \frac{60f_1}{p} \text{ min}^{-1} \tag{1.5.2}$$

## 1.5.2 Asinchroninių mašinų konstrukcija

Vienfazio asinchroninio variklio pjūvis su viduje esančiomis dalimis pateiktas 1.10 paveiksle.



1.10 pav. Asinchroninio variklio sandara, šaltinis – 3dprint.com

Čia 1 – paleidimo kondensatorius, 2 – išpjova, 3 – velenas, 4 – rutulinis guolis, 5 – vidinis ventiliatorius, 6 – tvirtinimo padas, 7 – sujungimo dėžutė, 8 – rotorius, 9 – statorius, 10 – apvijos, 11 – išcentrinis jungiklis, 12 – užsandarintas vidinis korpusas, 13 – išorinis ventiliatorius, 14 – ventiliatoriaus sparnuotė. [4]

Asinchroninės mašinos taip pat būna ir skirtingų konstrukcijų. Pavyzdžiui asinchroninė mašina su faziniu rotoriumi ar narveliniu rotoriumi. Dažniausiai asinchroniniai varikliai būna uždarojo ir apsaugotojo tipo. Uždarojo tipo asinchroninių variklių guolių dangčiai yra be ventiliacijos angų. Į mašinos vidų oras nepatenka. Ventiliatorius tvirtinamas išorėje, po gaubtu, ant variklio veleno. Šis ventiliatorius padeda aušinti variklį, sukeldamas kryptingą oro srautą apie variklį. Norint pagerinti aušinimo savybes, variklio korpusas daromas su išilgomis briaunomis, einančiomis per visa korpuso ilgį. [10]

Apsaugotojo tipo guolių dangčiai gaminami su ventiliacijos angomis. Jos uždengiamos metaliniu tinkleliu. Taip pat ant variklio korpuso gali būti įrengiamos šoninės ventiliacijos angos. Ant variklio veleno po dangčiu gali būti įrengtas ventiliatorius. [10]

Pagrindinė judanti dalis yra velenas, ant kurio sumontuotas rotorius su ventiliatoriais ir guoliais iš abiejų dangčių pusių.

### **1.5.3 Asinchroninių mašinų guoliai ir jų gedimai**

Paprastai, guolis susideda iš dviejų žiedų su ratukais arba rutuliais tarp vidinio ir išorinio žiedo, šie rutuliai yra prilaikomi separatoriaus. Guolio gedimai gali būti klasifikuojami į paskirstytuosius ir vietinius. Paskirstyti gedimai apima guolio banguotumą, nelygų paviršių, netinkamo dydžio rutulius ar ratukus, arba nesuderintą guolio apkabą. Vietinius gedimus apima duobutės, įtrūkimai ar įskilimai ant paviršiaus. Kai besisukantis rutulys ar ratukas praeina pro sugadintą paviršiaus vietą, jis sukelia vibracijų rezonansą, neįprastą įprastam variklio darbui. Smūgio periodas ir amplitudė apskaičiuojami iš anomalijos pozicijos, greičio ir guolio dimensijų. [5] Dažniausius guolių gedimus sukelia, vidinio ar išorinio žiedų, arba rutulių susidėvėjimas. Dažniausiai pasitaiko žiedų sutrupėjimas nuo sudilimo. [6]


Guolių būsenai nustatyti darbo metu, yra daug būdų ir instrumentų. Sudilę guoliai, dažniausiai skleidžia pastebimus simptomus. Praktikoje, ne visas mašinas ir jų funkcijas galima stebėti pažangiais įrenginiais. Šiais atvejais, gedimo skleidžiami požymiai gali būti pastebėti tiesiogiai apžiūrint ar klausantis dirbančios mašinos. Tačiau, naudojant žmogaus pojūčius, yra apribojimų. Tuo metu, kai žmogus, savo pojūčiais gali aptikti guolio gedimą mašinoje, dažniausiai jau būna per vėlu ir ši bėda jau gali būti pridariusi žalos. Naudojant tokius matavimus, kaip vibracijų analizė, galima artėjančius gedimus aptikti ankstyvoje stadijoje, jiems dar nepadarus daug žalos. [20]

Vienas iš dažnai pritaikomų būdų tikrinti guoliams yra garso analizė. Geri guoliai skleidžia tolygų, švelnų, be pašalinių garsų, triukšmą. Blogas guolis skleidžia metalo šveitimosi, traškėjimo, pasikartojančius metalo skleidžiamus garsus. Platus, mašinų skleidžiamo garso spektras, susideda ir iš ultragarsinių, trumpųjų bangų. Ultragarsiniai davikliai padeda išskirti šiuos ultragarsus iš aplinkinio ir mašinų skleidžiamų triukšmų, taip nustatydami tikslų gedimo tašką. [20]

Guoliai gali dirbti pilnu pajėgumu, tik tada, kai yra pakankamai sutepami. Guolių tepimo sąlygos turi būti atidžiai stebimos. Taip pat, privalu periodiškai tikrinti ir lubrikanto būklę. Šis procesas atliekamas imant kelis mėginius iš skirtingų guolio vietų ir su specialia įranga atliekama jo analizė, panašiai kaip alyvos analizė transformatoriams. Šis tyrimas atliekamas dėl dviejų

priežasčių, įvertinti guolio bei mašinos būklės. Atliekant guolių alyvos inspekciją, galima prailginti laikotarpį tarp alyvos keitimo, taip mašinos nebūtina atjunginėti tepimams ir sutaupoma guolio alyvos atžvilgiu. [20]

Šių gedimų padariniai pateikti 1.11 paveiksle.



1.11 pav. Sugedęs guolio ratukų narvelis, sudeginęs variklį, šaltinis –  
machinerylubrication.com

Egzistuoja įvairūs būdai aptikti variklio gedimams. Jie skirstomi į dvi grupes – atliekami išardžius nedarbantį variklį ir veikiančiam varikliui.

Pagrindiniai būdai skirti stebėjimui ir testavimui:

- Vizualus. Šiuo metodu apžiūra atliekama plika akimi, naudojant mikroskopus, kameras ar kitus pagalbinius prietaisus;
- Vibracijų stebėjimas. Tai seniausia ir jau tradicinė matavimo technika, plačiai naudojama aptikti gedimams, tokiems kaip mechaninis disbalansas ar blogi guoliai. Pjezoelektrinis prietaisas, pridedamas prie matavimo taško, aptinka judančios dalies pagreitejimus visomis ašimis. Šis signalas tada gali būti paverstas į pagreitį ar poziciją;
- Srovių stebėjimas. Kai kurie gedimai gali būti pastebimi, stebint apvijų sroves ir įtampas. Kai vyksta gedimai, atitinkamai kinta magnetinis laukas. Todėl gali būti naudojamos papildomos apvijos variklio būsenos stebėjimui. Statoriaus srovė dažnai matuojama, naudojant Holo efekto relę. Naudojant reles, dažnio komponentės gali būti koreliuojamos su įvairiais gedimais;



- Įtampos stebėseną. Statoriaus įtampa gali būti matuojama naudojant didelio dažnio diferencinės įtampos zondą arba izoliacijos stiprintuvą, kurie gali būti panaudoti nustatyti momentinę galią, sukimo momentą ir neigiamos sekos varžą;
  - Svyravimų stebėseną. Yra metodas aptikti gedimams, analizuojant mašinos ašies svyravimų komponentę, naudojant didelę ritę, apvyniotą koncentriškai aplink mašinos veleną. Įstatant 4 rites simetriškai visuose motoro ketvirčiuose, pusės atstumo nuo veleno iki galutinės statoriaus apvijos, spinduliu, net galima nustatyti gedimo vietą. Tačiau šis metodas neveikia pramonėje, nes į kiekvieną variklį reikėtų sudėti anksčiau minėtas apvijas. Taip pat šis siūlomas metodas yra labai priklausomas nuo variklio apkrovos sukimo momento, dėl šios priežasties yra sunku nustatyti avarines ribas;
  - Oro tarpo sukimo momentas. Oro tarpo sukimo momentas yra jautrus bet kokiam defektui ar gedimui. Pavyzdžiui: įtampų disbalansas, suskilęs rotorius narvelis ar nesimetrinė statoriaus apvija;
  - Sekos komponentė. Variklio fazių srovių neigiamos sekos srovės komponentė yra pirmas indikatorius gedimų diagnozavime. Įrodytas šio parametro pokytis statoriaus apvijų asimetrijoje. Kadangi neigiamos sekos srovė paprastai priklauso nuo šaltinio įtampos disbalanso, yra ir tikrosios neigiamos sekos varžos indikatorius, skirtas aptikti gedimams.
  - Temperatūrų stebėjimas. Kaip žinoma aukšta temperatūra kenkia variklio izoliacijai. Kiekvienas  $10^{\circ}\text{C}$  temperatūros pakilimas sumažina izoliacijos gyvenimą 50 %. Dėl šios priežasties statoriaus terminė inspekcija yra labai svarbi technika, prailginant variklio gyvenimą ir gali būti naudojama kaip variklio gedimų stebėsenos technika.
- [17]

Šiame darbe bus naudojamas tik vienas iš pateiktų metodų, tai vibracijų stebėjimai. Kadangi sensoriai jiems matuoti plačiai paplitę ir variklius nesunku paruošti šiems matavimams, yra sutaupoma daug laiko ir pinigų. Toliau nagrinėjami guoliai. Guolio sandara pateikiama 1.12 paveiksle.

Matuoti vibracijas yra svarbu dėl šių priežasčių: visos mašinos vibruoja, atsirandantis gedimas yra tiesiogiai susijęs su vibracijų padidėjimu ir gedimo pobūdis gali būti nustatomas iš vibracijos charakteristikų. Kiekviena mechaninė problema generuoja unikalų vibracijų dažnį, todėl šis dažnis turi būti analizuojamas, ieškant gedimo priežasties. Matuoti vibracijas dažniausiai naudojamas pjezoelektrinis vibracijų daviklis, kuris pritvirtinamas ant analizuojamos mašinos. Įvairios problemos generuoja triukšmus plačiame dažnių spektre: žemame (0 – 2 kHz), aukštame


(2 –50 kHz) ir labai aukštame (virš 50 kHz). Žemo dažnio vibracijos sukeltos korpuso ir tvirtinimo elementų rezonansų, mechaninio laisvumo arba kreivumo. Didelio ir labai didelio dažnio vibracijas kelia sugadinti rutulinių guolių elementai. Todėl matuojant akceleracijos amplitudes, galima anksti aptikti besivystančius gedimus. [20]

Geriausia vibracijas matuoti keliuose taškuose, tačiau šis atvejis taikomas kai vibracijos matuojamos periodiškai specialisto. Stipresnės vibracijos matomos horizontaliaja ašimi, nes mašina yra labiau linkusi judėti šia ašimi. Disbalansas (veleno) sukelia radialines vibracijas, kurios susideda iš horizontalių ir vertikalinių vibracijų. Padidėjusios horizontalios vibracijos dažnai yra veleno disbalanso požymis. Ašinės vibracijos dažniausiai būna labai mažos, bet joms atsiradus, gali būti įtariamas blogas veleno tvirtinimas arba sulenktas velenas. [20]

Geriausia guolių vibracijas matuoti normaliomis variklio darbo sąlygomis, kai guoliai pasiekia darbinę temperatūrą, ir mašina sukasi nominaliu greičiu, apkrova šiuo atveju nėra būtina, nebent matuojamas veleno sujungimas. Kintamo greičio mašinose matavimai turi visada būti atliekami esant tam pačiam greičiui. [20]

Kai mašina nedirba, atsiranda galimybė įvertinti guolių būklę vizualiai, patikrinti dangtelius, separatorių ir alyvą. Bendras patikrinimas gali būti atliekamas atidarius dangtelį. Nuodugniau patikrinimui, pirmiausia turi būti išplaunama sena alyva. Jei pastebimi pažeidimai, jis privalo būti išardomas ir nuodugniau patikrinamas. Išjungus mašiną taip pat galima atlikti veleno ir diržo suvedimo, mašinos tvirtinimo bei bendros būklės patikrinimus. Guoliai yra gana sunkiai pasiekiami, todėl juos apžiūrėti geriausia yra per planinius remontus ir patikrinimus, jei prie guolio prieiti gana sudėtinga, galima naudoti specialius echoskopus. [20]

Dažniausiai maža dalis guolių sugenda. Pagal firmos SKF statistiką 90 % guolių pragyvena savo mašinas, 9,5 % guolių pakeičiami jiems prieš sugendant, kai aptinkami artėjantys gedimai ir tik 0,5 % guolių pakeičiami nes sugenda darbo metu. Šią mažą gedimų dalį sudaro tokios priežastys, kaip bendras guolių susidėvėjimas (laisvumas guolyje), neefektyvus guolio dangteliai, nepakankamas guolių tepimas, didesnė nei planuota apkrova, netinkamas montavimas. Trečdalis visų guolių sugenda dėl bendro susidėvėjimo, kitas trečdalis dėl blogos lubrikacijos ir tik šeštadalis dėl užterštumo ar svetimkūnių tepale. [20]



1.12 pav. Guolio sandara [6]

Guolį sudaro vidinis ir išorinis žiedai, tarp kurių išsidėstę rutuliukai, prilaikomi separatoriaus. Rutuliukų kamera uždengiama dangčiais, ir viduje pridedama tepalo.

Iš vibracijų galima pastebėti ir kitus gedimus mašinoje, pavyzdžiui rotoriuje. Esant anomalijoms vibracijos padidėja, taip veikdamos guolius. Be to blogai pritvirtinus variklį galima pastebėti vibracijų anomalijų. [5]

Šokų dažnis gali būti apskaičiuojamas pagal šias formules:

$$F_{CF} = \frac{1}{2} F_R \left( 1 - \frac{D_B \cos \theta}{D_P} \right) \quad (1.5.3)$$

$$F_{ORF} = \frac{N_B}{2} F_R \left( 1 - \frac{D_B \cos \theta}{D_P} \right) \quad (1.5.4)$$

$$F_{IRF} = \frac{N_B}{2} F_R \left( 1 + \frac{D_B \cos \theta}{D_P} \right) \quad (1.5.5)$$

$$F_{BF} = \frac{D_P}{2D_B} F_R \left( 1 - \frac{D_B^2 \cos^2 \theta}{D_P^2} \right) \quad (1.5.6)$$


čia,  $F_{CF}$ , narvelio gedimų dažnis,  $F_{ORF}$  ir  $F_{IRF}$  rutulių praėjimo vidiniam ir išoriniam takeliui, dažnis,  $F_{BF}$  rutulių gedimų dažnis. Šių gedimų dažniai priklauso nuo:  $N_B$  – rutulių skaičiaus,  $F_R$  – veleno sukimosi greičio,  $\theta$  – kontakto kampo bei rutulių ir žingsio diametrų –  $D_B$  ir  $D_P$ . [6]

Be pagrindinės, guolių diagnostikos – vibracijų stebėjimo, yra ir dar kiti metodai. Tai temperatūros, triukšmo stebėseną ir statoriaus srovės analizę. Temperatūros stebėseną praverčia, ypač kai guolis nebesitapa arba nebuvo profilaktiškai suteptas, ties juo pradeda staigiai didėti temperatūra, kuri gali pažeisti ar sudeginti visą variklį. Termografinės su perkaitusiu guoliu variklių analizę pateikta 1.13 paveiksle. Be to stebint temperatūrą, galima pastebėti ir kitus gedimus, tai vijų perkaitimus ar sulūžusią ventiliatoriaus sparnuotę. [7]

Svarbu mašinos guolių temperatūrą stebėti visuose taškuose. Jei nekeičiamos mašinos darbo sąlygos, pakilusi temperatūra gali reikšti artėjantį guolių gedimą. Tačiau reikia pridurti, kad porą dienų trunkantis temperatūros pakilimas yra normalu, iškart po alyvos guolyje keitimo ir pertepimo. Infraraudonųjų spindulių kameros, gali aptikti šiluminės anomalijas ar karštuosius taškus, kurių nepastebi žmogaus akis. Naudojant šiluminę analizę, galima aptikti potencialias problemas ar nustatyti problematiškų taškų vietas, nesustabdant darbo proceso. [20]

Sprendžiant iš gedimo signalo pobūdžio, guolių gedimai gali būti kategorizuojami kaip vieno taško defektai arba bendras susidėvėjimas. Yra du šio kategorizavimo į dvi klases privalumai. Pirmiausia, apėinama bendro susidėvėjimo klaida. Daugiausia literatūros apie guolių būklės stebėseną susitelkia ties vieno taško defektais. Tuo tarpu norima aptikti abiejų pobūdžių gedimus, tai yra bendrą variklio guolių susidėvėjimą ir vieno taško defektus. Antra, esant gedimų grupei, galima aiškiai suprasti kiekvieną iš šių gedimų grupėje. Šio būdu galima aiškiau suprasti kaip turi būti kuriamos ir pritaikomos guolių būklės stebėsenos sistemos. [7]





Taip pat galima naudoti ir statoriaus srovės stebėseną, aptinkant guolių gedimus. Oro tarpo ilgio variacijos ir apkrovos sukimo momento pokyčių stebėseną, yra vienas iš naujų siūlomų metodų aptinkant gedimus. Neseniai pradėta guolių stebėsenos sistema naudojant dažnio analizę. Šiai technikai reikia tik vibracijų iš vieno sensoriaus ir žinių apie guolių gedimų charakteristikų dažnius. [7]



1.13 pav. Variklio su užkaitusiu guoliu termografinė analizė, šaltinis – [iactthermography.org/](http://iactthermography.org/)

1.14 paveiksle pateikiami vibracijų grafikai, esant įprastam režimui (pirmas grafikas), sulūžusiems ratukams guolyje (antras grafikas), sugedusiam vidiniam žiedui (trečias grafikas) ir sugedusiam išoriniam žiedui (ketvirtas grafikas), esant 1200 apsisukimams per minutę. [6]

Iš 1.14 paveiksle pateiktų teorinio guolių modeliavimo grafikų galima teigti, jog atsiradus guolių gedimams, vibracijų grafikuose labai akivaizdžiai galima juos pastebėti ir netgi atskirti nustatyti sugedusią guolio komponentę. Iš šios medžiagos neuroninis tinklas nesunkiai gali būti apmokomas atpažinti guolių savybes ir aptikti gedimus.



1.14 pav. Normalaus ir sugedusių guolių darbo režimai [6]

### 1.5.4 Neuroninio tinklo mokymas guolių gedimams aptikti


Dirbtiniai neuroniniai tinklai yra kompiuterinės sistemos, skirtos simuliuoti biologines nervines sistemas. Šie tinklai pasižymi dideliu prisitaikymo lygiu, kuriuo negali pasigirti jokios kitos skaitinės ar analitinės procedūros. Be to jie duomenų pagrindu, būklės stebėseną gali atlikti euristiniu požiūriu. [18]

Tinklo tipo pasirinkimas priklauso nuo sprendžiamos problemos. Šiuo metu yra du populiariausiai taikomi neuroniniai tinklai. Tai daugiasluoksnis tiesioginio sklidimo tinklas, mokomas atgalinio dauginimo algoritmu ir Kohoneno savaime susiorganizuojantis žemėlapis. [19]

Egzistuoja trys pagrindiniai faktoriai, kurie nulemia tinklo apibendrinimą yra: mokymo duomenų dydžio efektyvumas, fizinis problemos sudėtingumas ir naudojamo tinklo architektūra. Visi šie faktoriai yra vienodai svarbūs tinklo klasifikavimo darbui. Dažnai pasitaikantis atvejis praktikoje yra klasifikavimo sudėtingumas ir/arba nelygus mokymo duomenų skaičius iš skirtingų klasių mokant tinklą atpažinti įvairias skirtingas klases. Idealiu atveju mokymo duomenų skaičius turėtų būti lygus, su plačiu ir pakankamu duomenų kiekiu kiekvienai klasei. Daugiasluoksnio perceptrono tinklai gali būti apmokomi įvairiais metodais, iš kurių populiariausias yra klaidų atgalinio dauginimo algoritmas. Šis algoritmas naudoja gradientinį nusileidimą, tam kad atnaujinti tinklo svorius. [6]

Tiriant vibracijų dydį, dirbančiam varikliui sunku atskirti normalius darbo režimo duomenis, nuo įvairių gedimo duomenų prasidedantiems guolių gedimams. Tai yra ir ne visada pritaikoma, nes signalo morfologija, sklindanti iš sugedusio guolio, keičiasi jam toliau dirbant, nuo gedimo pradžios iki visiško sugedimo. Todėl, kai kurie gedimai gali būti neaptinkami, kol sistema nesugedo visiškai. Kadangi ankstyvas diagnozavimas ir gedimo izoliavimas yra labai svarbus variklio būklės priežiūroje, vienas iš variantų yra įmanrus signalo apdorojimas. Tai yra signalo apdorojimas naudojant bangelių analizę. [18]

1.15 paveiksle pateikiamas neuroniniams tinklams tinkamas duomenų masyvas. Čia pateikiami realiai gauti duomenys, tinkami neuroninio tinklo mokymui, kur pirmasis mėginys yra normalaus režimo darbo duomenys, antras – vidinio guolio žiedo gedimas, trečias – išorinio žiedo gedimas ir ketvirtas – rutulio gedimas. Čia kiekvienas duomenų masyvas priskiriamas tam tikrai klasei, pavyzdžiui: 0 – nėra gedimo, sistema veikia be gedimų, 1 – vidinio žiedo gedimas, 2 – išorinio žiedo gedimas, 3- rutuliuko gedimas, 4 – bendras guolio susidėvėjimas. Jeigu tinklas nesugebės atskirti kai kurių klasių, arba jas atskirs su didele klaida, galima naudoti anksčiau minėtą bangelių analizę. Be to, šiame paveiksle nėra bendro guolių susidėvėjimo vibracijų charakteristikos.



1.15 pav. Duomenų masyvai MatLab programai, neuroniniam tinklui apmokyti, su įvairiais guolių gedimais [18]

Pagrindiniai neuroninio tinklo topologijos pasirinkimą lemiantys punktai yra: tinklo planas, mokymas ir praktiniai sprendimai. Tinklo planas apima tokius punktus, kaip įėjimo ir išėjimo duomenų kintamųjų apibrėžimas, naudojamų įėjimo ir išėjimo mazgų skaičius, paslėptųjų sluoksnių neuroniniame tinkle skaičius, paslėptųjų mazgų skaičius kiekviename paslėptajame sluoksnyje ir mokymo duomenų, bei bandymo duomenų rinkinių dydžiai. Tinklo mokymas susideda iš tinklo svorių parinkimo, tinkamų mokymo parametrų parinkimo (tokių kaip mokymo ir impulso greitis) ir mokymo stabdymo kriterijaus parinkimo. O praktiniai sprendimai susideda iš tinklo tikslumo, tinklo atsparumo ir vykdymo tinkamumo. [18]

Paslėptųjų sluoksnių ir paslėptųjų mazgų skaičiai lema ir tinklo tikslumą ir neuroninio tinklo mokymo laiką. Geriausia, nesudėtingiems uždaviniams, naudoti paprastą – trijų sluoksnių neuroninį tinklą. Jis tinkamas, nes ši struktūra yra populiariausia ir yra įrodyta, kad šios struktūros tinklas gali savarankiškai išmokti sudėtingas nepertraukiamas funkcijas. Norint patikrinti, kaip įvairūs neuroniniai tinklai atlieka savo tikslą, yra svarbu, skirtingiems testams, nustatyti paslėptųjų mazgų skaičių į 10, 20 arba 30. Dažnai praktikoje priimta pasirinkti statistiškai svarbius, reikalingus tinkamai atvaizduoti tariamą sistemą, mokymo ir bandymo duomenų kiekius. Mokymo duomenų rinkinys naudojamas apmokyti neuroninį tinklą ir į jų sudėtį įeina ir patvirtinimo duomenys, tuo tarpu, bandymo duomenų rinkinys yra naudojamas patikrinti neuroninio tinklo tikslumą po sėkmingo mokymo. [18]



Geresniems rezultatams pasiekti naudojamus duomenis galima apdoroti. Įėjimo verčių normalizavimas gali pakelti neuroninio tinklo darbo stabilumą, tuo tarpu išėjimo verčių normalizavimas yra reikalingas, dėl neuroninio tinklo apdorojimo blokų naudojamos aktyvavimo funkcijos charakteristikų. Pavyzdžiui galima normalizuoti įėjimo vertes tarp  $[0, 1]$  ir išėjimo  $[0, 1]$ . Po tinklo konfigūravimo ir įėjimo – tikslų mokymo duomenų apibūdinimo, reikia parinkti mokymo parametrus, kurie susideda iš pradinių tinklo svorių, mokymo greičio, impulso greičio ir mokymo stabdymo kriterijų. Šių parametrų pasirinkimas dažniausiai yra kritiškai svarbus neuroninio tinklo mokymui. Deja, šių parametrų dydžių pasirinkimas priklauso nuo problemos. Nėra jokios formulės, skirtos anksčiau minėtų parametrų parinkimui. Tačiau, yra tam tikros gairės, kurių galima laikytis, pradedant mokymą, jos apibūdinamos toliau. Po kelių pirmų bandymų, neuroninį tinklą kuriantis asmuo, turėtų turėti pakankamai patirties, kad bet kokiai problemai nustatyti reikalingus atitinkamus tinklo parametrus. Vienas iš kritinių parametrų yra konvergencijos greitis, jį nustato mokymo koeficientas. Dažniausiai, norima mokymą atlikti greitai, tačiau ne per greitai, kad nesukelti mokymo iteracijų nestabilumą. Galima pasiekti stabilias iteracijas ir greitą mokymą, pradedant su dideliu koeficientu ir mažinant jį mokymo proceso metu. Neuroninio tinklo apmokymui ir stebėjimui galima naudoti įvairias priemones. [18]

Daugiasluoksniu, tiesioginiu sklidimo, atgalinio dauginimo, neuroninis tinklas yra pagrįstas prižiūrima procedūra. Tinklas konstruoja modelį naudodamas duomenų su žinomais išėjimais pavyzdžius. Tinklas konstruoja modelį, naudodamas tik pateiktus pavyzdžius, priimdamas prielaidą, kad šie duomenys netiesiogiai turi informacijos reikalingos aptikti ieškomų sąryšių. Tinkamo paslėptųjų neuronų sluoksnių skaičiaus ir mazgų kiekviename sluoksnyje skaičiaus nustatymas yra vienas svarbiausių čia aptariamų neuroninių tinklų dizaino aspektų. Mokymas pradedamas be pradinių, mokomų paslėptųjų sluoksnių skaičiaus ir dydžio, žinių, skirtingai nuo įėjimo ir išėjimo sluoksnių skaičiaus, kurie žinomi pradedant mokymą. Per mažas paslėptųjų mazgų skaičius gali sunkiai diferencijuoti tarp sudėtingų struktūrų. Arba esant dideliame paslėptųjų mazgų skaičiui tinkle, jis gali pradėti sekti triukšmą ir prastai apibūdinti modelį, dėl per didelio parametrų skaičiaus, kitaip tariant tinklas tampa per daug protingas ir ieško priklausomybių, kurių gali net nebūti. Be šių problemų, esant dideliame paslėptųjų mazgų skaičiui, tinklo mokymas tampa daug laiko reikalaujančiu procesu. Kiekviena funkcija gali būti įvykdoma norimu tikslumo laipsniu su pakankamai paslėptųjų neuronų, naudojant universalų trijų sluoksnių neuroninį tinklą. Šis tinklas susideda iš įėjimo, išėjimo ir tarp jų esančio paslėptojo, sluoksnių. Paslėptasis sluoksnis skirtas apdoroti ir sujungti duomenis iš įėjimo sluoksniu į išėjimo sluoksni, tik viena kryptimi (tiesiai). Paslėptasis sluoksnis atlieka ypatingą išgavimą iš įėjimo duomenų. [18]

Naudojant struktūrų atpažinimą dirbant su vibracijomis, kategorizavimo procedūra yra skirta atskirti vieną ar dvi galimas objektų kategorijas. Šio struktūrų atpažinimo procedūros yra sukurtos išspręsti kategorizavimo problemas. Pagrindinės tokios problemos sprendimo sudedamosios dalys yra:

- Vienas ar daugiau objektų kategorijų atpažinimui.
- Išmatuota, objektų iš apibrėžtų kategorijų, informacija.

Naudojant šiuos duomenis, klasės (kategorijos)  $C_1, C_2, \dots, C_n$ , apibrėžiamos struktūros atpažinimo problemai. Taip, kiekvienam kategorizuojamam objektui gaunamas požymių vektorius  $y$ . Toliau vystant struktūrų atpažinimo procedūrą, reikia gauti diskriminantines funkcijas. Šios funkcijos yra naudojamos išskirti duomenis tarp apibrėžtų klasių. Yra įvairūs metodai gauti diskriminantines funkcijas struktūrų atpažinimo problemai. Kiekvieno metodo pasirinkimas ir pritaikymas priklauso nuo sprendžiamos problemos. Stochastinės ir deterministinės procedūros gali būti naudojamos gauti diskriminantines funkcijas ir galiausiai išspręsti struktūrų atpažinimo problemą. [23]

Dirbant su vibracijomis ir naudojant struktūrų atpažinimo neuroninius tinklus, patartina surinkti duomenų masyvą ir jį sudalinti į kelias dalis. Pavyzdžiui vienai masyvo imčiai priskirti vibracijas normaliu darbo režimu, tai yra pirmoji klasė. Likusiam duomenų masyvui priskirti klases esant tam tikriems gedimams. Pavyzdžiui lėktuvo sparno vibracijoms esant skirtingiems įtrūkimų ilgiams, kurių kiekvienam ilgiui priskiriama skirtinga klasė. Be to gerai turėti kelis duomenų masyvus, mokymui ir testavimui. Arba galima suskaidyti vieną masyvą į kelias dalis, naudojant programos kodus. Modelio patikrinimas atliekamas naudojant testavimui skirtą masyvą ir tikrinant gautas vertes su realiomis. Sparno vibracijų atveju, gaunamos dvi klasės, tai arba sparnas geras, arba yra įtrūkimas ir sparnas blogas. Struktūrų atpažinimo tinklas po tinkamo apmokymo turi atpažinti kokio dydžio įtrūkimas atsirado ant sparno pagal jam pateikta vibracijos grafiką. [24]

Iš [24] straipsnyje gautų rezultatų, prie šio struktūrų atpažinimo metodo galima prijungti ir principinių komponenčių analizės transformaciją, aptikti gedimams, naudojant vibracijos analizę, norint pagerinti gautus rezultatus.

## 1.6 Sensoriai

Pažangūs judesio ir temperatūros davikliai, anksčiau laikomi prabanga, dabar kainuoja vos kelis eurus. Paprastai sensoriai skirstomi į bevielius ir ne. Bevieliai gali komunikuoti per WiFi,

Bluetooth, ar kitokias ryšio priemones. Veikimo principas pagrįstas paimto analoginio signalo vertimu į skaitmeninį ir jį diskretizuojant atvaizdavimas ekrane.

Pasitelkus juos galima sukurti visiškai autonomines sistemas, siurblinėse, galinčias stebėti įrenginius, jų darbą, iš anksto numatyti artėjančius gedimus naudojant sensorius. Tai yra labai aktuali problema modernizuojant siurbines ir atsisakant dispečerinių bei operatorių. Vieno iš sensorių, galinčių matuoti vibracijas ir temperatūrą pavyzdys pateikiamas 1.16 paveiksle.



1.16 pav. Temperatūrą ir vibracijas stebintis prietaisas, šaltinis – analog.com

Šio prietaiso privalumas – vibracijų stebėjimas visomis ašimis, mažos energijos sąnaudos ir didelis atliekamų stebėjimų dažnis ( $1.8 \mu\text{A}$  prie 100 Hz, 2.0 V ir  $3.0 \mu\text{A}$  prie 400 Hz, 2.0 V). Taip pat šiuos prietaisus galima panaudoti LoRaWAN sistemoje.

LoRaWAN – mažos galios platus bevielis tinklas (angl. Low Power Wide Area Network). Tinklas gali būti naudojamas regioniniu, valstybiniu arba pasauliniu mastu. Šio tinklo tikslas yra padėti išsivystyti daiktų internetui, kuriam yra būdinga saugi dvipusė komunikacija. Komunikacija tarp įvairių daviklių ir duomenų koncentratoriaus vyksta belaidžiu būdu skirtingais dažnių kanalais. Dėl skirtingų dažnių kanalų (dažnių kanalai vieni kitiems neskleidžia trikdžių) pagerinamas duomenų perdavimas į koncentratorių.

Pagrindiniai privalumai, lyginant su mobiliaisiais tinklais, tie kad jis yra pigesnis ir mažiau energijos vartojantis tinklas. Taip pat duomenis galima perduoti didesniu atstumu, o tai reiškia kad įdiegus daiktų internetą, gali būti surenkama daugiau duomenų.[8]

Daiktų internetas (angl. The Internet of things – IoT) yra fizinių prietaisų, transporto priemonių, pastatų ir kitų daiktų, kuriuose yra elektronika, programinė įranga, sensoriai, pavaros ir prieiga į tinklą, kuri leidžia šiems objektams rinkti ir dalintis informacija, tarptinklinis ryšys. 2013 metais, pasaulinių standartų iniciatyva daiktų internetui (IoT–GSI) apibūdino daiktų internetą, kaip „informacinės visuomenės infrastruktūrą“. Naudojantis daiktų internetu, objektai gali būti stebimi ir valdomi nuotoliniu būdu, per jau egzistuojančią tinklo infrastruktūrą, taip sudarant galimybes tiesioginiam fizinio pasaulio integravimui į kompiuterines sistemas, kuriomis didinamas efektyvumas, tikslumas, ekonominė nauda ir mažinamas žmogaus įsikišimas. Kai daiktų internetas papildomas sensoriais ir pavaromis, jis tampa kibernetinių – fizinių sistemų pavyzdys, taip pat apimantis technologijas, tokias kaip: išmanieji tinklai, išmanieji pastatai, išmanusis transportas ir išmanieji miestai. Kiekvienas iš jų identifikuojamas juose integruotos kompiuterinės sistemos, tačiau gali sąveikauti ir interneto infrastruktūroje. Ekspertų nuomone, 2020 metais, daiktų internetą sudarys 50 milijardų objektų. [9]

Įprastai, daiktų internetas siūlo labiau pažengusį, už standartinį mašinos – mašinos, prietaisų sistemų ir paslaugų tarpusavio sąryšį, kurį sudaro įvairūs protokolai, domenai ir programos. Tikimasi, jog toks prietaisų (taip pat ir išmanių objektų) tarpusavio susijungimas, paskatins visų sričių automatizavimą, taip pat padedant vystyti pažangioms programoms, tokioms kaip išmanieji tinklai, bei išsiplečiant į išmaniuosius miestus.

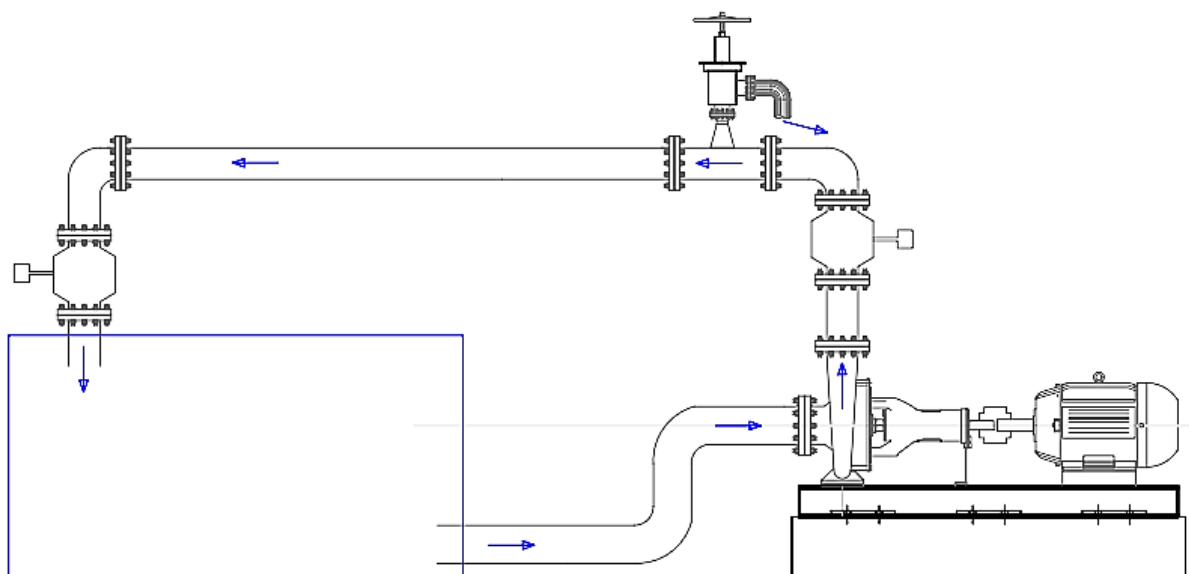
Daiktų interneto sensoriai gali būti: akustiniai, garso ir vibracijų, cheminiai ar dujų, tekėjimo, apkrovos (jėgos, sukimo momento, spaudimo), nuotėkių (lygio), elektros ir magnetinių laukų, akceleracijos ir pasvirimo, optiniai (šviesos, vaizdo atpažinimo ir stebėsenos), pozicijos (buvimo, artumo), judesio (pagreičio, poslinkio), temperatūros ir drėgmės.

Integravimas į internetą reiškia, jog prietaisai naudos IP adresą kaip identifikatorių. Tačiau dėl riboto Ipv4 adresų skaičiaus (kur gali egzistuoti 4,3 milijardai adresų), daiktų interneto įrenginiai, norint sutilpti į didžiulį reikalingų adresų skaičių, turės naudoti IPv6. Šie daiktų interneto objektai, ne tik bus prietaisai su sensoriais, bet ir turės įjungimo ar perjungimo galimybes (pavyzdžiui, lemputės, užraktai, valdomi per internetą). Didžiąja dalimi, daiktų interneto ateitis, nebus įmanoma be Ipv6 palaikymo ir todėl visuotinis IPv6 pritaikymas ateityje yra labai svarbus tolesniam daiktų interneto vystymuisi.

## 2. TYRIMO METODINĖ DALIS

### 2.1 Nuotėkio linijoje aptikimas


Nuotėkio linijoje aptikimo tyrimas bus atliekamas MatLab programos aplinkoje. Stendo principinė schema pateikta 2.1 paveiksle. Paveiksle nurodytos, visos stendą sudarančios dalys: variklis su siurbliu, sklendė imituoti nuotėkiui linijoje ir du ultragarsiniai debito matuokliai, bei slėgio daviklis jiems aptikti. Vanduo cirkuliuoja rezervuaru, čia jis grįžta iš linijos ir iš jo yra vėl pumpuojamas atgal. Nuotėkis imituojamas atidarant sklendę, sklendės atidarymas sistemoje sukelia nuotėkį, dėl kurio debito matuokliai rodo skirtingas srauto reikšmes. Taip pat atidarius sklendę, linijoje krenta slėgis. Šie pagrindiniai parametrai ir bus naudojami neuroninio tinklo modelyje.



2.1 pav. Principinė stendo schema, sudaryta autoriaus

Kuriant neuroninį tinklą nuotėkiams atrasti, pirmiausia reikia debito matuoklių duomenų ir slėgio parodymų, apmokyti ir testuoti sukurtam dirbtiniam tinklui. Nėra būtinybės gauti realius duomenis, todėl jie bus sukuriami, kad atspindėtų du režimus 0 – nėra nuotėkio ir sistema veikia normaliu režimu ir 1 – pradžios ir galo debito matuoklių duomenys nesutampa ir krenta slėgis, todėl įtariama avarija ar gedimas. Tai reiškia, kad duomenys bus klasifikuojami į dvi klases. Tokiam modeliui iš esmės užtenka viensluksnio neuroninio tinklo, galinčio skirstyti duomenis į dvi klases, ypač, kai priklausomybės tarp duomenų gana lengvai nustatomos, tačiau, jeigu nebus pasiektas norimas tikslumas, bus naudojami sudėtingesni neuroniniai modeliai.

Sukuriamas naudojamų duomenų masyvas. Pasirenkamas duomenų surinkimas iš debito matuoklių ir slėgio daviklio kas 1s. Šis periodas nebūtinai turi būti lygus 1 sekundei. Gauti duomenys atvaizduojami 2.2 paveiksle.



2.2 pav. Debito matuoklių rodmenys, sudaryta autoriaus

Iš 2.2 paveikslo matyti, kad linija veikia normaliu darbo režimu, kol praėjus 820 sekundžių atsiranda skirtumas tarp galinio ir pradinio debito matuoklių ir pradeda kristi slėgis linijoje. Sukuriami dar du tokie dirbtiniai nuotėkiai 1300 sekundę ir apie 1700 sekundę. Kadangi ryšio perdavimas nėra absoliučiai patikimas, į modelį įtraukiami ir trumpi debito matuoklių ir slėgio daviklių parodymų dingimai, kad sistema būtų atsparesnė trikdžiams. Sistema modeliuojama taip, kad nuotėkis fiksuojamas tik tada, kai atsiranda skirtumas tarp debito matuoklių ir kartu krenta slėgis.

Iš pradžių, pasirenkamas 1 sluoksnio neuroninis tinklas su 10 neuronų, naudojant MatLab funkciją `net = feedforwardnet(10)`; kur 10 – neuronų skaičius tinkle. Tada sudaromi duomenų masyvai, vienas masyvas – debito matuoklių ir slėgio daviklių rodmenys ir antras masyvas – jiems priskirti 1 arba 0 (avarija arba normalus režimas).

Mokymo funkcija naudojama – `[net,tr] = train`.

Tiesa, bus išbandomi keli mokymo būdai, norint pasiekti geriausią tikslumą. Jeigu standartinis Levenberg–Marquardt algoritmas (`trainlm` MatLab kodas) nepasieks tenkinamų rezultatų, bus naudojami kiti, literatūros analizėje apžvelgti mokymo būdai, kurių programos kodai:

trainbfg – Kvasi–Niutono metodai;

trainrp – Lankstaus atgalinio dauginimo ( angl. resilient backpropagation);

trainscg – Jungtinis gradientas;

traincgf – Fletcher–Powell jungtinis gradientas;

traincgp – Netiesinio jungtinio gradiento metodas;

trainoss – Vieno žingsnio kertantysis

traincgb – Jungtinis gradientas su Powell/Beale perkrovimais.

Perdavimo funkcija paliekama standartinė, ir tikslumui įvertinti naudojama vidutinė kvadratinė klaida (MSE). Apmokius neuroninį tinklą, jis tikrinamas pagal vidutinę kvadratinę klaidą, bei pateikiamos vizualizacijos, kaip apmokytas tinklas reaguoja į mokymo duomenis.

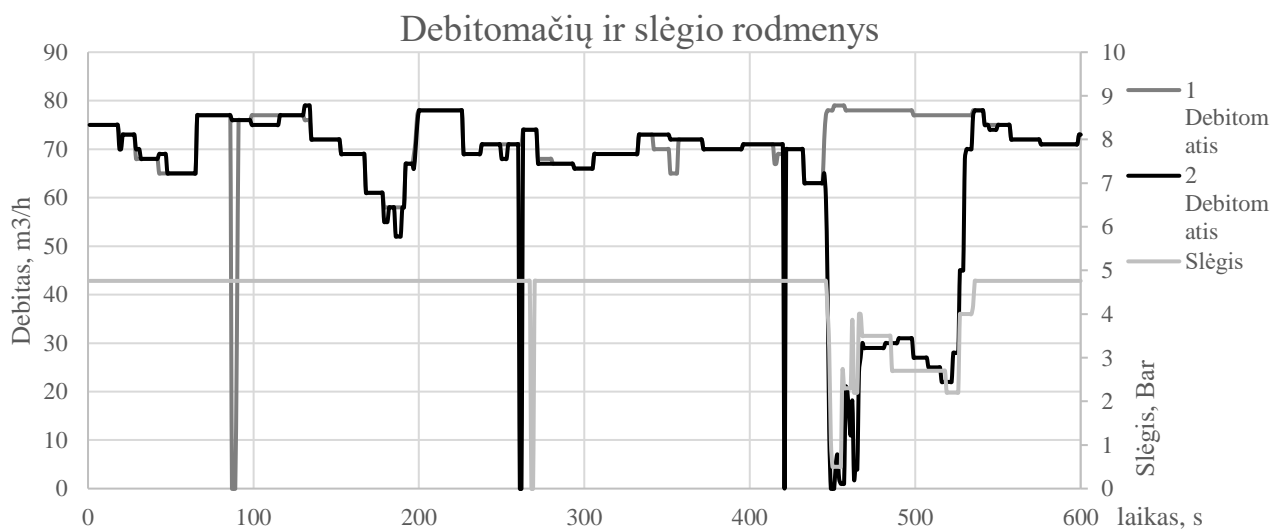
Kiti mokymo metu naudojami parametrai:

net.trainParam.epochs=2000 – parenkamas mokymo epochų skaičius

net.trainParam.max\_fail=10 – patvirtinimo kartai, pasiekus šią vertę baigiamas mokymas


net.trainParam.goal=0 – pasirenkamas mokymo klaidos tikslas, 0 reiškia, kad norima pasiekti nulinę klaidą, nors iš tiesų tai pasiekti beveik neįmanoma. Dažniausiai mokymas stabdomas pasiekus kitus nustatytus parametrus. Visas programos kodas pateikiamas 1 priede.

Tada norint patikrinti gautą tinklą, jam pateikiamas naujas duomenų masyvas (pateiktas 2.3 paveiksle) ir stebimi rezultatai. Tinkamai apmokytas tinklas, kurio klaida maža turėtų atpažinti nuotėkį, ties 440 sekunde pateiktuose duomenyse.



## 2.2 Guolių gedimų aptikimas

Guolių gedimo aptikimo tyrimas atliekamas iš dviejų dalių. Pirmoji dalis tai sugedusio guolio nuo sveiko atskyrimas, naudojant neuroninius tinklus, ir antroji – guolio gedimo pobūdžio nustatymas naudojant neuroninį tinklą. Abu šie tyrimai atliekami naudojant realiai gautus vibracijų duomenis. Šie duomenis gauti, naudojant stendą, pateiktą 2.4 paveiksle.




2.4 pav. Stendas guolių gedimams aptikti, sudaryta autoriaus

Stendą sudaro 7,5 kW tiriamas variklis, prijungtas prie sinchroninio generatoriaus. Šiame tyrime velenas buvo atjungtas, nes guolių gedimams aptikti užtenka variklio, dirbančio be apkrovos. Variklio viršuje įtvirtinama aikštelė, ant kurios pritvirtinamas pjezoelektrinis vibracijų daviklis. Daviklis tvirtinamas viename taške, iš kurio teoriškai imtų vibracijų duomenis visą laiką. Šis daviklis prijungiamas prie osciloskopo, kuriame iš įtampos svyravimų, keliamų daviklio, yra gaunami vibracijų grafikai.



Naudojamas osciloskopas, yra gana senas, todėl gali užfiksuoti tik 2500 taškų vienu duomenų išsaugojimu. Norint pasiekti geresnius neuroninio tinklo mokymo rezultatus, tikslingiau naudoti geresnį, daugiau taškų gebantį fiksuoti, osciloskopą.

Pirmiausia, išmatuojamos sveikam varikliui, su nepažeistais guoliais. Šio matavimo rezultatai, pateikiami 2.5 paveiksle.



2.5 pav. Variklio su geru guoliu vibracijų grafikas, sudaryta autoriaus

Visi matavimai atliekami naudojant tuos pačius parametrus, tai yra 5 mV jautrumą ir 10 ms dažnį. Taip pat, visų tyrimų metu vibracijų daviklio vieta nekeičiama. Toliau geram guoliui yra sugadinamas išorinis guolio žiedas. Šis, sugadintas guolis pateikimas 2.6 paveiksle.




2.6 pav. Guolis su sugadintu išoriniu žiedu, sudaryta autoriaus

Atlikus matavimus, kitam geram guoliui sugadinamas separatorius su rutuliuku, ir matavimai kartojami tomis pačiomis sąlygomis. Guolis su sugadintu rutuliuku ir separatoriumi pateikiamas 2.7 paveiksle.



2.7 pav. Guolis su sugadintu separatoriumi ir rutuliuku, sudaryta autoriaus


Tyrimas su sugadintu vidiniu žiedu neatliekamas, dėl įrangos sugadinimui trūkumo. Gavus visus tris vibracijų grafikus, jie sujungiami į vieną ir gautas rezultatas pateikiamas 2.8 paveiksle.



2.8 pav. Gautų vibracijų grafikas, sudaryta autoriaus

Grafike ryškiai matosi pirmą 2500 duomenų mėginį, gero guolio vibracijų grafikas. Sekantį 2500 mėginį sugadinto išorinio žiedo ir likusį duomenų mėginį – sugadinto separatoriaus ir ratuko grafikai.

Pirmiausia, su šiais duomenimis tyrimas atliekamas atskirti gerą guolį nuo blogo ir įspėti kad guolis tuoj suges. Tam naudojamas panašus tinklas kaip ir vandens nuotėkiams sistemoje aptikti. Pasirenkamos ribos nuo kada sistema įspėja, kad guolis tuoj suges – 0,0015 mV ir kada guolis sugedęs – 0,0024 mV. Šiam tyrimui naudojami vibracijų grafiko pikai. Gautas grafikas su pažymėtomis ribomis pateikiamas 2.9 paveiksle.



2.9 pav. Vibracijų grafikas su pažymėtomis ribomis

Kuriamas neuroninis tinklas kuris skaidys duomenis į 3 klases, 0 – nėra gedimo, guolis geras, 1 – įspėjimas artėja guolio gedimas ir 2 – guolis sugedęs, reikia remonto. Šie duomenys pritaikomi prie gautų rezultatų ir kiekvienam varikliui gali skirtis.

Neuroniniam tinklui naudojami tie patys parametrai, kaip ir anksčiau aprašytame, nuotėkio aptikimo tinkle. Tinklui sukurti naudojama funkcija `net = feedforwardnet(10)`, pirmiausia naudojamas 10 neuronų tinklas ir standartinė `trainlm` funkcija. Mokymo funkcija – `[net,tr]=trainlm`. Visas programos kodas pateikiamas 2 priede.

Gavus gerą neuroninį tinklą, toliau atliekamas tyrimas, atpažinti gedimo pobūdį guolyje. Šiam tyrimui naudojami tie patys duomenys, tačiau čia klasės suskaidomos kitaip. Kiekvienam signalui priskiriama tam tikra klasė: 1 – geras guolis, 2 – sugedęs išorinis žiedas ir 3 – sugedęs rutuliukas ir separatorius.

Šiam mokymui bandomi įvairūs mokymo metodai. Pasirinktas bus geriausias mokymo rezultatus pasiekęs tinklas. Jeigu gauti rezultatai netenkins norimo tikslumo, bus naudojamas vaizdų ir struktūrų atpažinimo neuroninis tinklas (angl. pattern recognition network). Jis geba pastebėti ir atskirti vaizdus. Šiuo atveju mokymas vyks su pagalba, tai reiškia klasės bus priskiriamos iš anksto. Šiam neuroniniam tinklui sukurti yra naudojama funkcija – `net=patternnet(20)`. Pradedant mokymą, pasirenkamas 20 neuronų tinklas.

Šiam mokymui atlikti duomenys suskaidomi taip:

```
net.trainParam.max_fail=50;
net.divideParam.trainRatio = 0.6;
net.divideParam.valRatio = 0.2;
net.divideParam.testRatio = 0.2;
```

Čia 50 yra minimalus patvirtinimo kartų skaičius, jis pasirenkamas didesnis, kad mokymas nesibaigtų per anksti. Tai reikalinga, norint pasiekti mažesnę klaidą. Toliau kode, mokymui naudojami duomenys yra suskaidomi, 60 % duomenų, mokymui ir po 20 % viso duomenų masyvo skiriama ir patvirtinimui, ir bandymui. Svarbu tinkamai nustatyti šių duomenų proporcijas geram tinklo mokymui. Tinklas automatiškai pasiima šiuos duomenis iš įvairių duomenų taškų. Tai yra ypač svarbu atliekant sudėtingus mokymus. Taip pat mokymo gale iš gautos kryžminės entropijos (angl. cross – entropy) klaidos, ji bus verčiama į vidutinę kvadratinę klaidą (MSE), naudojant funkciją `perf = mse()`. Šie duomenys tyrimo metu gali būti keičiami, derinant mokymą. Mokymui atlikti naudojama standartinė mokymo funkcija – pakeltas jungtinis gradientas (angl. scaled conjugate gradient).


Norint šiam tinklui gauti tinkamus rezultatus, klasių duomenis reikia pateikti matricos pavidalu. Tai yra 1 klasė priimama [1 0 0], antra klasė – [0 1 0] ir trečia klasė – [0 0 1]. Tada šios matricos yra transponuojamos, gaunant 7500 duomenų stulpelių su 3 klasių eilutėmis. Taip pat transponuojami ir mokymo duomenys, taip gaunant 7500 stulpelių duomenų su dviem požymių eilutėmis – vibracijų vertėmis ir laiku. Apmokius šiuos duomenis su klasėmis, gaunamas rezultatas pateikiamas sumišimo matricos pavidalu (angl. confusion matrix). Šis atvaizdavimo būdas yra

informatyvus ir tinkamas. Dėl skirtingų mokymų tyrimo metu, skirtingai pateikiami ir šių mokymų rezultatai.

### 3. TYRIMO REZULTATAI

#### 3.1 Vandens nuotėkių tinkle tyrimas

Tiriant nuotėkius, naudojami duomenys, pateikti 2.3 paveiksle. Sukuriamas 10 neuronų tinklas ir naudojama standartinė mokymo funkcija (trainlm). Gauti mokymo rezultatai pateikti 3.1 paveiksle.

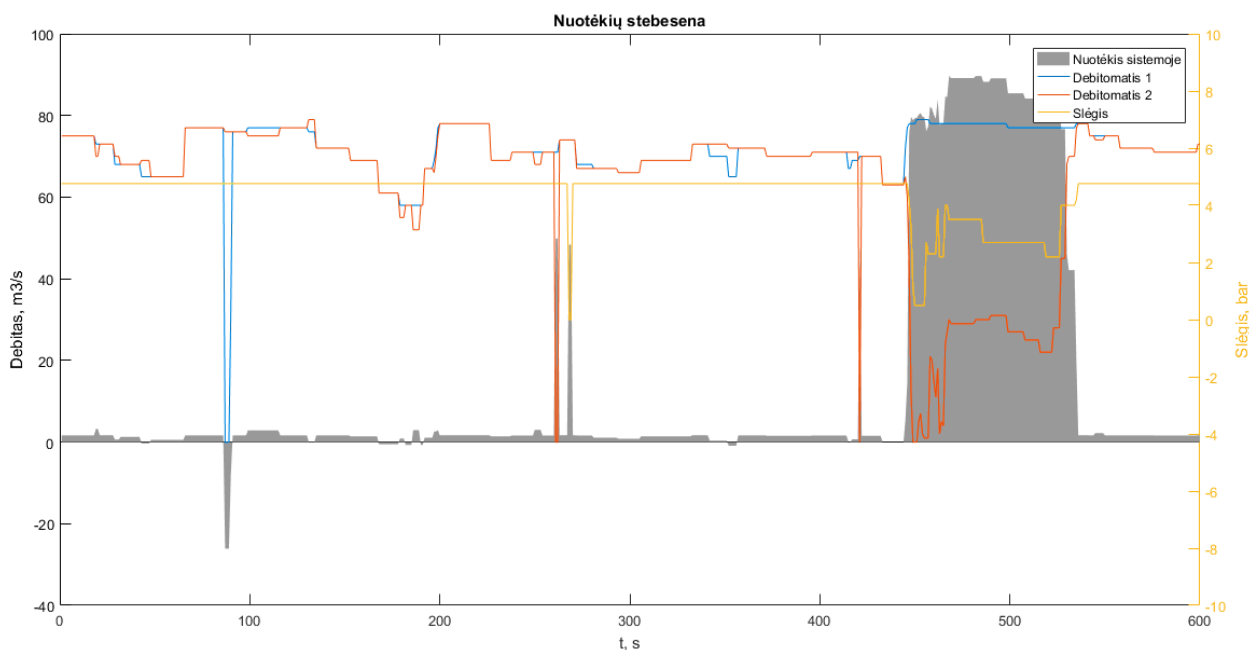


3.1 pav. Apmokytas neuroninis tinklas (10 neuronų, trainlm funkcija), sudaryta autoriaus

Paveiksle, raudonai pažymėti duomenys – duomenys su kuriais buvo mokomas tinklas, geras tinklas turėtų atkartoti raudonai pažymėtą kreivę, šis tinklas grafike pažymimas mėlyna spalva.

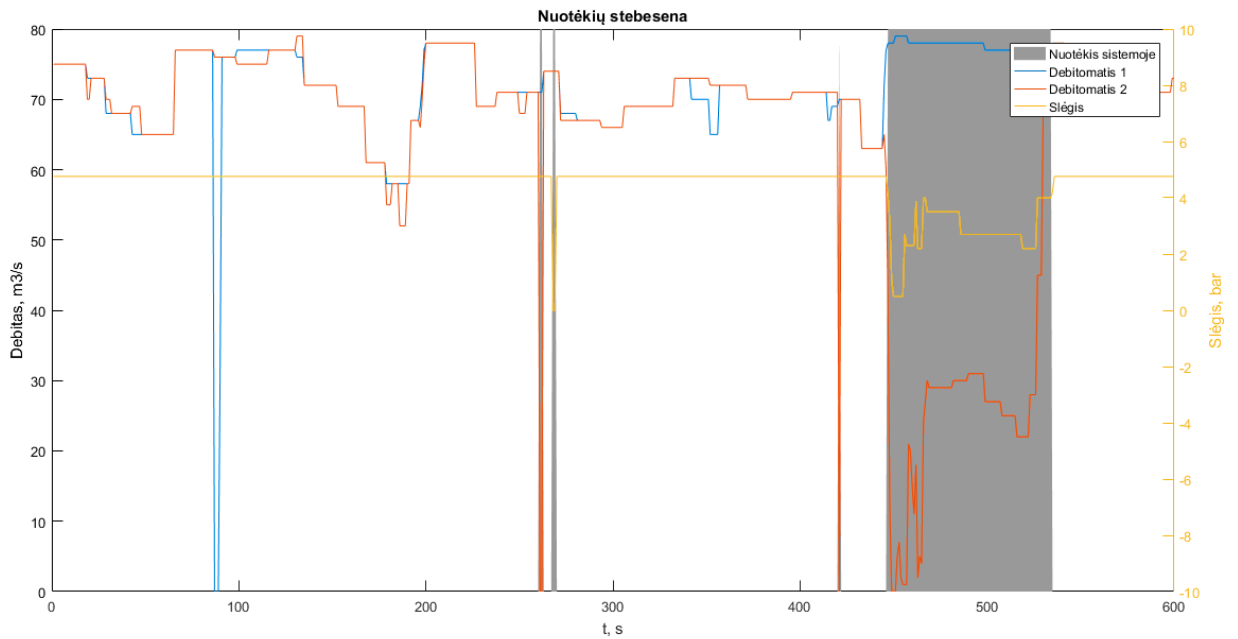
Paveiksle matyti, kad tinklas apmokytas gana blogai, nes yra matomi pikai ties 300, 1350 ir 1450 sekundes. Tokių pikų negali būti, nes tokia sistema gali neteisingai numatyti nuotėkį ir atjungti sistemą. Šio tinklo vidutinė kvadratinė klaida –  $0,699 \times 10^{-3}$ . Norint naudoti tokį tinklą, reiktų visas jo gautas vertes iki 0,5 prilyginti nuliui, o visas virš 0,5 prilyginti vienetui, taip padarant tik dvi kategorijas, 0 arba 1. Tačiau taip prarandamas neuroninio tinklo sistemos patikimumas.

Norint patikrinti kaip gerai pasirodė tinklas reikia apmokytam tinklui pateikti naujus duomenis ir žiūrėti kaip jis atvaizduoja rezultatus. Tam, paėmus naują duomenų masę, naudojamos komanda – `sim()`, ir naudojant `plot()` funkciją, duomenys atvaizduojami grafike, 3.2 paveiksle.




3.2 pav. Rezultatai po apmokyto tinklo bandymo su naujais duomenimis, sudaryta autoriaus

3.2 paveiksle pateikiama 2.4 paveikslo duomenys ir pilkas plotas – nuotėkis. Norint vizualiai perteikti duomenis, nuotėkis vaizduojamas kaip plotas ir yra padauginamas iš 80, tam kad būtų gerai matomas, tai reiškia, kad 80 – yra nuotėkis, o 0 – nėra nuotėkio. Matomi keli pikai 90 ir 260 sekundėmis, dėl tokių pikų sistema nėra patikima. Ši sistema priima ryšio perdavimo trikdžius kaip nuotėkį sistemoje. Tokiu atveju vienintelė išeitis tai prilyginti vertes, didesnes nei 0,5 vienetai, o mažesnes – 0. Tokiu atveju gaunamas rezultatas, kuriame išlieka 3 pikai pateiktas 3.3 paveiksle. Kadangi daugiau nei 0,5 prilyginti 1 nenaudinga, neuroninio tinklo modelis turi būti gerinamas.



3.3 pav. Panaikintas triukšmas po neuroninio tinklo mokymo, sudaryta autoriaus

Toliau bandomos įvairios kitos funkcijos, bandant atrasti geriausiai tinkamą šiems duomenims apdoroti. Antras geriausias rezultatas šiuo atveju buvo pasiektas su `traincgb` – Jungtinis gradientas su Powell/Beale perkrovimais. Šio mokymo rezultatas, naudojant 10 neuronų tinklą pateikiamas 3.4 paveiksle.




3.4 pav. Mokymo rezultatai naudojant `traincgb` funkciją ir 10 neuronų tinklą, sudaryta autoriaus

Paveiksle matyti, kad ši mokymo funkcija gauna blogesnius mokymo rezultatus, nei standartinė trainlm. Šį pastebėjimą patvirtina ir gauta mokymo vidutinė kvadratinė klaida, kuri siekia 0,00447.

Taip pat reikia paminėti, kad kiekvieną kartą apmokius tinklą gaunami šiek tiek skirtingi rezultatai ir gauti tuos pačius rezultatus beveik neįmanoma. Dėl to kiekvienas mokymas atliekamas po kelis kartus, kad pastebėti priklausomybes nuo tinklo parametrų.


Išbandžius įvairias funkcijas ir keičiant bei derinant įvairius tinklo parametrus, pasiekti norimi rezultatai. Tai 5 neuronų tinklas, naudojantis standartinę – trainlm funkciją. Šio mokymo rezultatas pateikiamas 3.5 paveiksle. Prieš tai naudoti tinklai turėjo per daug neuronų sluoksnyje, ir per daug giliai ieškojo neegzistuojančių priklausomybių, sumažinus neuronų skaičių, gautas tinklas atitinkantis mokymo reikalavimus.



3.5 pav. Galutiniai mokymo rezultatai su 5 neuronų tinklu ir trainlm funkcija, sudaryta autoriaus

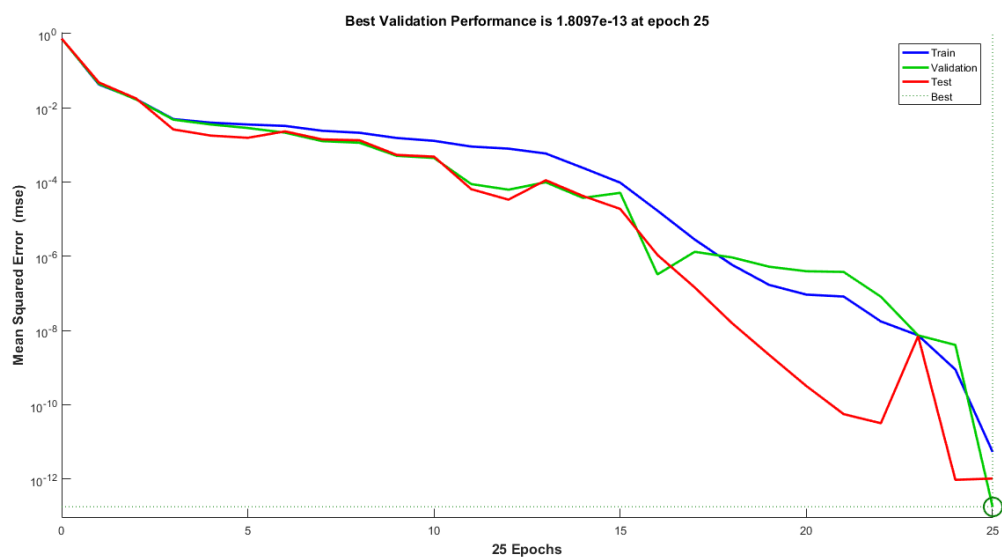
Paveiksle abi kreivės susilygina, tai reiškia kad tinklas geba visiškai atkartoti duomenis. Šis tinklas tikrinamas pateikiant naujus duomenis tinklui apdoroti. Rezultatai pateikiami 3.6 paveiksle.





3.6 pav. Patikrintas galutinis neuroninis tinklas su 5 neuronais sluoksnyje ir naudojant trainlm funkciją, sudaryta autoriaus

Šiam tinklui nebereikia daugiau jokių derinimų ar koregavimų, vos tik pradėjus kristi slėgiui ir esant skirtumui tarp debito matuoklių 440 sekundę, šis tinklas iškart aptiko nuotėkį linijoje ir nereagavo į laikinus prietaisų trikdžius. Tinklo vidutinė kvadratinė klaida siekia  $5,4 \times 10^{-12}$ . 3.7 paveiksle pateikiamas mokymo procesas.




3.7 pav. NT mokymo procesas, sudaryta autoriaus

Čia, mėlynai pateikta mokymo klaida, raudonai – bandymo ir žaliai – patvirtinimo, tuo tarpu pilka brūkšninė linija pažymi mažiausia pasiektą neuroninio tinklo klaidą. Grafike matyti, kaip klaida mažėjo, iki kol mokymas pasiekė vieną iš reikiamų parametru, šiuo atveju gradientą.

### 3.2 Guolių gedimų aptikimo tyrimas


Atliekamas metodinėje dalyje aptartas guolio skaidymas į sugedusį, baigiantį sugesti ir sugedusį, naudojant neuroninį tinklą, tyrimas. Panaudoto 10 neuronų tinklo rezultatas pateiktas 3.8 paveiksle.



3.8 pav. Gautas mokymo rezultatas, sudaryta autoriaus


Paveiksle raudonai pateiktos realios vertės ir mėlynai – apmokyto neuroninio tinklo pritaikytos vertės. Gautas tinklas nesugeba suskaidyti vibracijų grafiko į tris klases darant mažą klaidą. Matomos trys klasės ir rezultatai plačiai išsidėstę tarp jų. Nemaža dalis duomenų patenka tarp klasių. Vidutinė kvadratinė klaida siekia 0,00649. Todėl, reguliuojami neuroninio tinklo mokymo parametrai. Į programos kodą įvedamas minimalus 100 patvirtinimų skaičius, nes programa per anksti baigia mokymą ir nespėja sumažinti klaidos. Taip pat kartojant bandymus randamas tinkamas neuronų sluoksnyje skaičius. Geriausiai mokymą atlieka tinklas, kuriame yra

15 neuronų. Geriausias rezultatas pasiektas naudojant tik vibracijų vertes, laiko duomenys mokyme tik didina klaidą. Gautas rezultatas pateikiamas 3.9 paveiksle. Mokymas atliktas nekeičiant standartinės mokymo funkcijos.



3.9 pav. Gerai apmokyto tinklo rezultatas, sudaryta autoriaus

Šiuo atveju tinklo pasiekta vidutinė kvadratinė klaida –  $2,41 \times 10^{-10}$ . Tinklas apmokytas teisingai ir geba skaidyti pateiktus vibracijų duomenis į variklį su geru, blogu guoliais ir įspėjimą dėl artėjančio guolio gedimo. Visas panaudotas kodas mokymui atlikti ir rezultatams gauti, pateikiamas 2 priede. 3.10 paveiksle patiekama mokymo proceso eiga.



3.10 pav. Neuroninio tinklo mokymo eiga, sudaryta autoriaus

Paveiksle pateiktas mokymo procesas, kurio metu ties 60 mokymo epocha, mokymo klaida pradėjo staigiai kristi ir pasiekė labai mažą vertę.

Antro, guolių tyrimo metu, siekiant sukurti tinklą, gebantį atskirti guolio gedimo pobūdį ir išbandžius įvairius mokymo metodus, geriausių rezultatų pasiekė klasifikatorius, naudojantis atraminių vektorių mašinas (angl. support vector machines) bei vaizdų ir struktūrų atpažinimo neuroninis tinklas. Naudojamas geriausių rezultatų pasiekęs vaizdų ir struktūrų atpažinimo neuroninis tinklas. Tokio tinklo rezultatas su 20 neuronų sluoksnyje pateikiamas 3.11 paveiksle.



3.11 pav. Guolio gedimo pobūdį nustatančio tinklo mokymo rezultatai, sudaryta autoriaus

Šioje sumišimo matricoje, pateikiami mokymo rezultatai. X ašyje pateikiamos 3 tikslų klasės, o y ašyje mokymo metu gauti rezultatai. Žaliai pažymimos teisingos vertės, kur tikslas pasiektas. Į raudonas vertes patenka klasės kurios realiai buvo kitos, nei manė apmokytas tinklas. Apatinėje eilutėje ir paskutiniame stulpelyje yra duomenų suvestinės. Apatinės eilutės dešiniajame krašte, mėlynajame langelyje, pateikiamas galutinis rezultatas, šiuo atveju pasiektas 77,8 % tikslumas. Tai reiškia kad apmokytas tinklas sugebėjo tinkamai atspėti 77,8 procentus viso mokymo imties duomenų. Likę duomenys nepateko į tinkamas klases. Toliau pateikiami rezultatai su patvirtinimo, testavimo ir visų apibendrintų duomenų rezultatais. Šio mokymo metu pasiekta 0,152 kryžminės entropijos klaida. Vidutinė kvadratinė klaida siekia 0,094.

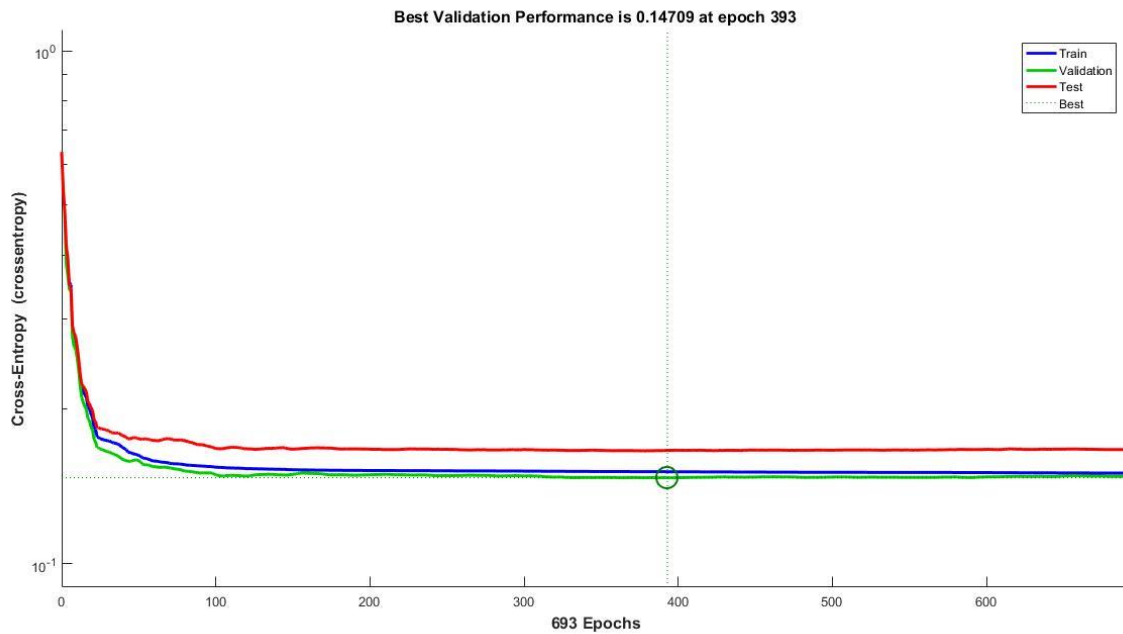
Toliau gerinamas neuroninio tinklo mokymas. Po eksperimentų su įvairiais parametrais, geriausias rezultatas pasiektas, paslėptajame sluoksnyje, naudojant 40 neuronų. Taip pat, suskaidant duomenis: 70 % visu duomenų – mokymui ir po 15 % duomenų bandymui bei patvirtinimui. Be to, geresniam rezultatui pasiekti į kodą įvedamas minimalus – 200 patvirtinimų skaičius. Taip sumažinama neuroninio tinklo daroma klaida. Gautas geriausias rezultatas pateiktas 3.12 paveiksle.



3.12 pav. Gedimo guolyje pobūdžio nustatymo, neuroninio tinklo mokymo rezultatas, sudaryta autoriaus

Šiame paveiksle matomas, pasiektas 78,5 % mokymo rezultatas. Bendras rezultatas siekia 78,1 %. Mokymo metu pastebėta, kad tinklas sunkokai atskiria 3 klasę nuo 1 ir atvirkščiai. Ši dalis

ir sudaro pagrindinę klaidą. Šio mokymo kryžminės entropijos klaida siekia 0,150, o vidutinė kvadratinė klaida – 0,0935. Mokymo proceso eiga pateikiama 3.13 paveiksle.



3.13 pav. Mokymo proceso eiga naudojant vaizdų ir struktūrų atpažinimo neuroninį tinklą, sudaryta autoriaus

Paveiksle matyti, kad ties 100 mokymo epocha, tinklo klaida normalizavosi ir kito labai mažai. Visas šio mokymo programos kodas pateikiamas 2 priede.

## IŠVADOS

1. Sukūrus duomenų masyvus, imituojančius procesus, vykstančius vandens linijoje, tokius, kaip laike kintantys debito matuoklių ir slėgio linijoje matavimai, sukurtas neuroninis tinklas galintis aptikti atsiradusį vandens nuotėkį linijoje, kai atsiranda skirtumas tarp debito matuoklių ir krenta slėgis. Neuroninio tinklo mokymo vidutinė kvadratinė klaida siekia  $5,4 \times 10^{-12}$ . Šis tinklas sugeba tiksliai aptikti vandens nuotėkį linijoje. Be to neuroninis tinklas mokytas taip, kad nereaguotų į trumpalaikius, ryšio su matavimo prietaisais, trikdžius. Tai pasiekta į duomenų masyvą įvedant nulines prietaisų vertes kelioms matavimų sekundėms. Naudotas neuroninis tinklas turėjo 5 neuronus paslėptajame sluoksnyje ir mokymas, atliktas naudojant standartinę mokymo funkciją. Apmokius iš naujo su kitais duomenimis, šis tinklas gali būti naudojamas stebėti daug linijų vienu metu.
2. Kitam bandymui, su variklio guoliais, sukurtas stendas, kurį sudaro 7,5 kW asinchroninis variklis su aikštele virš variklio guolio dangčio. Ant šios aikštelės tvirtinamas pjezoelektrinis vibracijų daviklis. Šis daviklis prijungiamas prie osciloskopo.
3. Išmatavus variklio su sveikais guoliais vibracijas, variklio guoliai buvo pakeisti į sugadintus. Vienam guoliui sugadintas išorinis žiedas, kitam supjaustytas separatorius su vienu rutuliuku. Uždėjus šiuos guolius variklio vibracijos pamatuotos iš naujo bei iš jų sudaryti duomenų masyvai, darbui su neuroniniais tinklais.
4. Naudojant gautus vibracijų duomenis ir atsižvelgiant į sveiko variklio vibracijas, nustatytos gero, blogo bei artėjančio guolio gedimo vibracijų ribos neuroninio tinklo mokymui. Tinklui mokyti pasirinkta 15 neuronų paslėptajame sluoksnyje bei naudojama standartinė mokymo funkcija. Gautas tinklas, gebantis atskirti gerą guolį nuo blogo bei įspėti apie artėjančią guolio gedimą. Tinklo vidutinė kvadratinė klaida siekia  $2,41 \times 10^{-10}$ . Kiekvienam varikliui šios vibracijų ribos gali skirtis, čia jos pasirinktos tik modeliui sukurti ir patikrinti.
5. Gavus tinklą, gebantį skaidyti vibracijų duomenis į tris klases, sukurtas dar vienas tinklas, 78,5 % tikslumu galintis nustatyti guolio gedimo pobūdį – sugedusį išorinį žiedą ir sugedusį separatorių su rutuliuku. Šiuo atveju panaudotas visai kitokios architektūros tinklas – vaizdų ir požymių atpažinimo (angl. pattern recognition). Modeliui kurti panaudotas 40 neuronų tinklas, naudojantis standartinę – jungtinio gradiento, mokymo funkciją. Šio tinklo vidutinė kvadratinė klaida siekia – 0,0935, o kryžminės entropijos klaida – 0,150. Mokant šį tinklą reikėjo reguliuoti mokymo ir



testavimo, bei patvirtinimo duomenų santykius (70 % ir po 15 % atitinkamai), kad tinklui pakaktu duomenų geram apmokymui. Be to, reikėjo padidinti ir patvirtinimų skaičių iki 200, kad klaida sumažėtų iki mažiausios vertės ir mokymas nebūtų stabdomas per anksti. Tinklas darė didelę klaidą atskirdamas 1 klasę nuo 3, čia mokymo metu net 547 taškai buvo priskirti 1 klasei, kai iš tikrųjų šie taškai priklausė 3 klasei. Taip pat tinklas beveik 200 taškų, priklausančių pirmai klasei, priskyrė 3 klasei. Toks rezultatas gautas, dėl panašumų, vibracijų tarp gero guolio ir guolio su blogu rutuliuku ir separatoriumi, atžvilgiu. Vidinio guolio žiedo gedimas nebuvo įtrauktas į tyrimą, dėl tinkamos įrangos, jam sugadinti trūkumo. Gautas modelis nesunkiai gali būti permokomas ir su kitais gedimais, žinant jų specifinius vibracinius grafikus.

## REKOMENDACIJOS

Pirmiausia geram tyrimui atlikti patartina naudoti geresnį osciloskopą, kuris vienu matavimu paimtu daugiau kaip 2500 taškų vienu metu, arba naudoti bevielį daviklį, kuris talpintų duomenis į kompiuterį, tai palengvintu neuroninio tinklo mokymą. Be to gerinant rezultatus, rekomenduojama vibracijų grafikui atlikti greitąją Furjė transformaciją (FFT) arba bangelių transformaciją, naudojant šias transformacijas, tam tikri gedimai būtų ryškiau matomi stebint pikus dažnių spektre. Taip pat stebint dažnių spektrą galima aptikti kelis gedimus vienu metu, pavyzdžiui sugedusi žiedą ir rutuliuką. Taip neuroninis tinklas darytų mažesnę klaidą. Guolių gamintojai pataria, norint dar labiau pagerinti rezultatus, daryti greitąją Furjė transformaciją, tada brėžti kreivę per visus gautus pikus dažnių spektre ir pakartoti Furjė transformaciją. Naudojant šį metodą, ryškiau matomi pikai spektre. Taip neuroninis tinklas pasiektų geresnius rezultatus, bei užtektų paprastesnės architektūros tinklo modelio.

Tikslesniam guolių gedimų išskyrimui reikia lokaliai sugadinti guolius. Žiede užtenka įskilimo, nes per didelis įpjovimas, gali kelti papildomų triukšmų, kurie trukdo atpažinti gedimą.

Temperatūrų stebėseną, naudojant daviklius prie guolių pagerintu guolių stebėseną bei papildytu stebimus gedimus. Atliekant temperatūrinę stebėseną galima aptikti tokius gedimus kaip bendras guolio susidėvėjimas ir tepimo guolio viduje trūkumą. Šios analizės taip pat padėtų neuroninio tinklo mokymui, įvedant papildomų kintamųjų. Dėl trinties, sukeltos defektų, be padidėjusios vibracijos, kyla ir temperatūra.

Norint pritaikyti nuotėkių aptikimo neuroninį tinklą, visai vandentiekio sistemai, reikia tinklą apmokyti iš naujo su daug debito matuoklių. Taip sistema gali stebėti didesnę kiekį linijų vienu metu.

## LITERATŪROS SĄRAŠAS

1. UAB „Kauno vandenys“ specialistų suteikti duomenys ir įžvalgos.
2. „Neuroniniai tinklai ir skaičiavimai“, Antanas Verikas, Adas Gelžinis, KTU, 2008
3. MatLab pagalba, neuroniniai tinklai. Nuoroda į tinklapį:  
<<https://se.mathworks.com/help/nnet/>>
4. „Asinchroninės elektros mašinos“, Povilas Kostrauskas, KTU, 2004
5. „Induction machine bearing faults detection based on artificial neural network“. Ciprian Harlisca\*, Ilhem Bouchareb\*\*, Lucia Frosini\*\*\*, Lorand Szabo\*. \* Technical university of Cluj–Napoca/Department of electrical machines and drives, Cluj–Napoca, Romania. \*\* University of Mentouri/Laboratory of Electrical Engineering of Constantine (LGEC), Constantine, Algeria. \*\*\* University of Pavia/Department of Electrical, Computer and Biomedical engineering, Pavia, Italy.
6. „Application of Fourier Descriptors & Artificial Neural Network to Bearing Vibration Signals for Fault Detection & Classification“, A. Oulmane, A.A.Lakis and N. Mureithi, Department of Mechanical Engineering, École Polytechnique de Montréal
7. „Condition Monitoring of Induction Motors: – A Review“, Rudra Narayan Dash, Sangeeta Sahu, Chinmoy Ku. Panigrahi, School of Electrical Engineering, KIIT University, Bhubaneswar, Odisha. Bidyadhar Subudhi, Department of Electrical Engineering, NIT Rourkela, Odisha.
8. <http://www.analog.com/en/products/mems/accelerometers/adxl362.html#product-overview>
9. „Non Invasive Sensors for Monitoring the Efficiency of AC Electrical Rotating Machines“, Farid Zidat 1,2, Jean–Philippe Lecoite 1,2,\*, Fabrice Morganti 1,2, Jean–François Brudny 1,2, Thierry Jacq 3 and Frédéric Streiff 4, 1 Univ Lille Nord de France, F–59000 Lille, France, 2 UArtois, LSEE, F–62400 Béthune, France, 3 EDF–R&D–Département THEMIS Groupe R25, F–92141 Clamart Cedex, France, 4 ADEME–SEET Département–20, Av. Du Grésillé BP 90406, F–49004 Angers Cedex 01, France.
10. „Elektros mašinos, I d. Transformatoriai. Asinchroninės mašinos“, Steponas Gečys, Artūras Kalvaitis, Pranas Smolskas, KTU leidykla "Technologija", 2009 m.
11. „Detection of Stator, Bearing and Rotor Faultsin Induction Motors“, Semih Ergin, Arzu Uzuntas, M. Bilginer Gulmezoglu, Eskisehir Osmangazi University, Department of Electrical and Electronics Engineering, Eskisehir, 26480, Turkey.

12. „Advances in Internet of Things and Cyber Physical Systems and its Adoption to Smart Ship“, Professor Elizabeth Chang The University of New South Wales Australian Defence Force Academy, International conference on Wireless Communication and Network, Sept 21–23, 2015 Baltimore, USA.
13. „A Review On Fault Diagnosis Of Induction Machines“, C. J. Verucchi, G. G. Acosta and F. A. Bengier, Grupo Intelymec – Facultad de Ingeniería – Universidad Nacional del Centro de la Provincia de Buenos Aires, Argentina, Consejo Nacional de Investigaciones Científicas y Técnicas – CONICET, Argentina.
14. „A Hybrid Intelligent Technique for Induction Motor Condition Monitoring“, Xin Wen, Institute of Industrial Research University of Portsmouth, A thesis submitted for the degree of Doctor of Philosophy, April 2011.
15. „Assessment of Faults Diagnosis Techniques of Induction Motors“, Amandeep Sharma, S Chatterji, Lini Mathew, Niranjana Gupta, Electrical Engineering Department, NITTTR Chandigarh, INDIA, Pro-VC, Desh Bhagat University, Punjab, INDIA.
16. UAB „Vilniaus vandenys“ duomenys. Prieiga internetu: <http://www.vilniausvandenys.lt/lt/>.
17. „An Experimental Study of Rotor Fault Detection Using Motor Current Signature Analysis Based on Neural Networks“, Rajul Misra, G. L. Pahuja, EED, NIT Kurukshetra, 2015.
18. Bearing Fault Diagnosis based on Neural Network Classification and Wavelet Transform, Omar José Lara Castro, Cristina Castejón Sisamón, Juan Carlos García Prada, Mechanical Engineering Department, Universidad Carlos III de Madrid, 2006.
19. Electric motor faults diagnosis using artificial neural networks, Lingxin Li, C K Mechefske and Weidong Li, Insight Vol 46, 2004.
20. SKF bearing maintenance handbook, SKF Group, 2011.
21. Pattern Recognition Using Artificial Neural Network: A Review, Tai-hoon Kim, Multimedia Engineering Department Hannam University Daejeon, Korea, 2010.
22. New Procedures of Pattern Classification for Vibration-Based Diagnostics via Neural Network, Nicholas Nechval, Konstantin Nechval, and Irina Bausova, University of Latvia, EVF Research Institute, Statistics Department, 2014.
23. Categorisation And Pattern Recognition Methods For Damage Localisation From Vibration Measurements, I. Trendafilova, Department of Mechanical Engineering, The University of Strathclyde, W. Heylen, Department of Mechanical Engineering, KULeuven, 2001.
24. Vibration-based damage detection in an aircraft wing scaled model using principal component analysis and pattern recognition, I. Trendafilova, Department of Mechanical

- Engineering, University of Strathclyde, M.P. Cartmell, Department of Mechanical Engineering, James Watt Building, University of Glasgow, W. Ostachowicz, Institute of Fluid-Flow Machinery of Polish Academy of Sciences, 2007.
25. The practically cheating statistics handbook, S. Deviant, 2010.
  26. A matlab toolbox for pattern recognition, Robert Duin, Delft University of Technology, 2000.
  27. Damage detection in bridges using neural networks for pattern recognition of vibration signatures, W.T. Yeung, J.W. Smith, 2004.
  28. Lietuvos statistikos departamento paskelbti duomenys. Prieiga internetu: <http://db1.stat.gov.lt/statbank/selectvarval/saveselections.asp?MainTable=M8010301&PLanguage=0&TableStyle=&Buttons=&PXSID=5956&IQY=&TC=&ST=ST&rvar0=&rvar1=&rvar2=&rvar3=&rvar4=&rvar5=&rvar6=&rvar7=&rvar8=&rvar9=&rvar10=&rvar11=&rvar12=&rvar13=&rvar14=>>

# PRIEDAI

## 1 priedas

```
%-----  
  
%Vandens nuotekiu aptikimas  
  
clc % Paruosiamas ekranas darbui  
close all  
clear all  
load debit_duom_NT.txt % Paimamas duomenų dokumentas  
  
net = feedforwardnet(5); % Sukuriamas 5 neuronų tinklas  
x=debit_duom_NT(14:end,1:3); % Paimami debitomacių rodmenys ir slėgis  
t=debit_duom_NT(14:end,end); % Paimamos priskirtos 0 arba 1 klasės  
  
net.trainParam.epochs=2000; % Perenkamas mokymo epochų skaičius  
net.trainParam.max_fail=50; % Patvirtinimo kartai, pasiekus šią vertę  
baigiamas mokymas  
net.trainParam.goal=0 % Pasirenkamas mokymo klaidos tikslas  
[net,tr]=train(net,x',t'); % Mokymas  
Dtr = sim(net,x'); % Sukuriamas masyvas duomenų atvaizdavimui  
figure(1); % Braizomas pirmas grafikas su realiomis  
vertėmis ir gautais rezultatais  
plot(t, 'red', 'LineWidth',3); % Braizomos realios vertės  
hold on; % Viskas brežiama į vieną grafiką  
plot(Dtr, 'blue', 'LineWidth', 2); % Braizomos gautos vertės apmokius tinklą  
xlabel('t, s'); % X ašies pavadinimas  
ylabel('Nuotėkis, 0 - nėra, 1 - yra'); % Y ašies pavadinimas  
legend({'Realūs duomenys','Apmokyto tinklo duomenys'}); % Lengendoje surasomi  
debitomaciai ir slėgio daviklis  
  
% Apmokytas tinklas naudojamas su kitais duomenimis, norint patikrinti gautą  
modelį  
  
load debit_band_NT.txt % Užkraunami vandens linijos duomenys  
z = debit_band_NT(:,1:3); % Paimami debitomacių ir manometro  
duomenys  
A = sim(net,z'); % Randamos galios kas pusvalandį,  
neuroniniam tinklui apskaiciavus su prognozės duomenimis  
A = A'; % Transponuojamas galių masyvas  
B = A*80; % 1 - yra nuotekis arba 0 - nėra nuotekio  
vertės dauginamos iš 10, kad būtų lengviau atskirti  
figure(2); % Rezultatai brežiami į antrą grafiką  
area(B, 'FaceColor', [0.6 0.6 0.6], 'EdgeColor', 'none'); % Braizomas plotas  
kuriame aptiktas nuotekis  
hold on; % Abu brežiniai brežiami į vieną  
plot(debit_band_NT(:,1:2)); % Braizomas tiekimo grafikas  
yyaxis right % Pasirenkama antra Y ašis  
plot(debit_band_NT(:,3)); % Braizomas slėgis naudojant antrą Y ašį  
ylim([-10 10]); % Nustatomos ašies ribos  
title('Nuotėkių stebėsena'); % Pasirenkamas grafiko pavadinimas  
legend({'Nuotėkis sistemoje','Debitomatis 1', 'Debitomatis 2', 'Slėgis'});  
% Lengendoje surasomi debitomaciai ir slėgio daviklis  
xlabel('t, s'); % X ašies pavadinimas  
yyaxis right; % Pasirenkama antra Y ašis  
ylabel('Slėgis, bar'); % Y antrosios ašies pavadinimas
```

```

yyaxis left; % Pasirenkama pirma Y asis
ylabel('Debitas, m3/s'); % Y asies pavadinimas

%Grafikas sutvarkomas taip kad liktu tik dvi klases, kai yra nuotekis ir jo
%nera

A(A>0.5)=1; % Vertes, nesiekiancios 0.5, prilyginamos
0
A(A<0.5)=0; % Vertes, virsijancios 0.5, prilyginamos 1
B = A*80; % 1 - yra nuotekis arba 0 - nera nuotekio
vertes dauginamos is 10, kad butu lengviau atskirti
figure(3); % Rezultatai breziami i antra grafika
area(B, 'FaceColor', [0.6 0.6 0.6], 'EdgeColor', 'none'); % Braizomas plotas
kuriame aptiktas nuotekis
hold on; % Abu breziniai breziami i viena
plot(debit_band_NT(:,1:2)); % Braizomas tiekimo grafikas
title('Nuotėkių stebesena') ; % Pasirenkamas grafiko pavadinimas
yyaxis right % Pasirenkama antra Y asis
plot(debit_band_NT(:,3)); % Braizomas slegis naudojant antra Y asi
ylim([-10 10]); % Nustatomos asies ribos
legend({'Nuotėkis sistemoje','Debitomatis 1', 'Debitomatis 2', 'Slėgis'}); %
Lengendoje surasomi debitomaciai ir slegio daviklis
xlabel('t, s'); % X asies pavadinimas
yyaxis right; % Pasirenkama antra Y asis
ylabel('Slėgis, bar'); % Y antrosios asies pavadinimas
yyaxis left; % Pasirenkama pirma Y asis
ylabel('Debitas, m3/s'); % Y asies pavadinimas

```

## 2 priedas

```
%-----  
%Sugedusio guolio aptikimas  
  
clc  
clear all % Paruosiamas langas darbui  
load duom_neuron.txt % Uzkraunamas duomenu masyvas  
  
figure(1); % Ijungiamas pirmas brezinys  
hold on; % Viskas breziama i pirma grafika  
E=duom_neuron(:,4); % Duomenims priskiriami kintamieji  
F=duom_neuron(:,5); % Duomenims priskiriami kintamieji  
Y=duom_neuron(:,4); % Duomenims priskiriami kintamieji  
Z=duom_neuron(:,5); % Duomenims priskiriami kintamieji  
Y=-Y; % Masyvui pakeiciamas zenklas i priesinga  
Z=-Z; % Masyvui pakeiciamas zenklas i priesinga  
plot(E, 'yellow', 'LineWidth', 2); % Breziamos vibraciju ribos  
plot(F, 'red', 'LineWidth', 2); % Breziamos vibraciju ribos  
plot(Y, 'yellow', 'LineWidth', 2); % Breziamos vibraciju ribos  
plot(Z, 'red', 'LineWidth', 2); % Breziamos vibraciju ribos  
plot(duom_neuron(:,2), 'black'); % Breziamas vibraciju grafikas  
set(gca, 'Color', [0.6 0.6 0.6]); % Parenkama brezinio aplinkos spalva -  
pilka  
xlabel('Mėginiai'); % X asiai priskiriamas pavadinimas  
ylabel('Vibracija, mV'); % Y asiai priskiriamas pavadinimas  
ylim([-0.008 0.008]); % Nustatomos Y asies ribos  
xlim([0 7500]); % Nustatomos X asies ribos  
  
net = feedforwardnet(15); % Sukuriamas 15 neuronu tinklas  
x=duom_neuron(:,2); % Paimamos vibraciju vertes  
t=duom_neuron(:,3); % Paimamas mokymo tikslu masyvas (klases)  
  
net.trainParam.epochs=1000; % Perenkamas mokymo epochu skaicius  
net.trainParam.max_fail=100; % Parenkamas minimalus patvirtinimo kartu  
skaicius  
net.trainParam.goal=0 % Pasirenkamas mokymo klaidos tikslas  
  
[net,tr]=trainlm(net,x',t'); % Mokymas  
Dtr = sim(net,x'); % Sukuriamas masyvas duomenu  
atvaizdavimui  
D = duom_neuron(:,1); % Is duomenu masyvo paimamos laiko vertes  
figure(2); % Braizomas pirmas grafikas su realiomis  
vertemis ir gautais rezultatais  
scatter(D, t, 'red'); % Braizomos realios vertes  
hold on; % Viskas breziama i viena grafika  
scatter(D, Dtr, 'blue'); % Braizomos gautos vertes apmokius tinkla  
xlabel('t, s'); % X asies pavadinimas  
ylabel('Guolio gedimas, 0 - nėra, 1 - išpėjimas, 2 - sugedęs'); % Y asies  
pavadinimas  
legend({'Realus duomenys', 'Apmokyto tinklo duomenys'}); % Lengendoje surasomi  
debitomaciai ir slegio daviklis  
  
%-----  
%Guoliu gedimo pobudzio nustatymas  
  
clc % Paruosiamas langas darbui  
clear all % Uzkraunamas klasiu masyvas  
load klases.txt % Uzkraunamas duomenu masyvas  
load guol_duom_be_klas.txt;  
  
figure(3); % Ijungiamas trecias brezinys
```



```

plot(guol_duom_be_klas(:,2), 'black'); % Braizomas vibracijų grafikas
hold on; % Brezinys laikomas įjungtas
xlabel('Mėginiai'); % X ašies pavadinimas
ylabel('Vibracija, mV'); % Y ašies pavadinimas
ylim([-0.01 0.01]); % Nustatomos Y ašies ribos
xlim([0 7500]); % Nustatomos X ašies ribos

ind = klases'; % Transponuojamas klasių masyvas
vec = ind2vec(ind); % Vertės keičiamos į vektorius
target_var = full(vec); % Vertės paverčiamos į pilną matricą

net=patternnet(40); % Kuriamas 40 neuronų tinklas
net.trainParam.max_fail=200; % Pasirenkamas minimalus patvirtinimų
skaicius
net.divideParam.trainRatio = 0.7; % Duomenų dalis mokymui
net.divideParam.valRatio = 0.15; % Duomenų dalis patvirtinimui
net.divideParam.testRatio = 0.15; % Duomenų dalis testavimui

x=guol_duom_be_klas(); % Mokymo duomenys priskiriami kintamajam
x
t=target_var; % Paimamas mokymo tikslų masyvas
[net,tr]=train(net,x',t); % Mokymo funkcija
Dtr = sim(net,x'); % Paimamas apmokytas masyvas
perf = mse(net,t,Dtr); % Skaiciuojama vidutinė kvadratinė klaida

```