

MESTERSÉGES INTELLIGENCIÁN ALAPULÓ MÓDSZER ELEKTROMECHANIKUS AKTUÁTOR HIBADIAGNOSZTIKÁJÁRA

Füvesi Viktor¹, Kovács Ernő²

¹Tudományos segédmunkatárs, fuvesi@afki.hu

²Egyetemi docens, PhD, elkke@uni-miskolc.hu

¹Miskolci Egyetem, Alkalmazott Földtudományi Kutatóintézet,
Műszerfejlesztési és Informatikai Osztály

²Elektrotechnika - Elektronikai Tanszék
3515 Miskolc, Miskolc-Egyetemváros

Összefoglalás

A cikk egy újszerű eljárást mutat be, amely alkalmas összetett mechatronikai rendszerek, például hajtásláncok és aktuátorok, különféle, esetlegesen felmerülő hibafajtáinak külön-külön való jelzésére, azok nagyságának meghatározására. A bemutatott módszer a mesterséges intelligencia egyik legnépszerűbb ágának módszerét, az előre csatolt mesterséges neurális hálózatot használja a probléma megoldására. A modell alapú megközelítést alkalmazó technika bemutatása során részletezésre kerül a felhasznált modellek kidolgozása, kiválasztása, az alkalmazott hálózatstruktúra és a felhasznált modellek befolyásoló szerepe is. Az eljárás mód hatékonyságának bemutatása során egy összetett kiértékelési stratégiát mutatunk be, a diagnosztikát végző neurális struktúra betanításához pedig egy aktív tanítási mód került alkalmazásra.

Kulcsszavak: hibadiagnosztika, neurális hálózatok, aktuátor

Abstract

This paper introduces a novel method to detect, identify and separate different faults may occur in complex mechatronic systems e.g. drive chains and actuators. The method is based on the feedforward artificial neural networks, which is known being one of the most popular family of artificial intelligence. In the course of introduction of the model-based method the development and selection of the used models, structure of applied networks, influence of used models on the results will be detailed. A complex evaluation strategy is introduced to assert the efficiency of the method and active training algorithm was used to train the separator neural network structure.

Keywords: fault diagnostics, neural network, actuator

1. Bevezetés

A biztonságos működés az ipari berendezések talán egyik legfontosabb követelménye a pontosság és megbízhatóság kritériumai mellett. A rendszer hibáinak minél korábban történő kimutatása, meghibásodásainak egyértelmű jelzése manapság már alapkövetelménynek tekinthető.

Számos modern matematikai metódus ismeretes a kemény és puha számítási módszerek családjába tartozó eljárások közül, amelyeket különféle dinamikai rendszerek [3] vagy éppen ipari folyamatok [2] hibáinak észlelési és diagnosztikai feladataira alkalmaznak [1]. A technikák tárháza igen széles: számos irodalom használ Kálmán szűrőt [4], paritás egyenleteket [5], főkomponens kiválasztást [6] a vizsgált rendszer hibáinak detektálására és diagnosztikájára. Más szerzők a mesterséges intelligencia széles spektrumának eszközeit alkalmazzák: Bayes hálózat [7], többrétegű perceptron (MLP) [8] vagy fuzzy logika [9].

Elektromechanikus aktuátorok hibadiagnosztikájára is találunk példákat az irodalomban. Egy módszer az egyenáramú motor másodrendű állapotváltozós modelljén alapult [10]. A felépített modellek négy párhuzamos Kálmán szűrő segítségével az áram jel szenzor négy különböző hibafajtáját detektálja. Indukciós gép hibadetektálásával és diagnózisával foglalkozik a [11] irodalom. A neuro-fuzzy alapú eljárás mód segítségével számos hibát lehet megkülönböztetni egymástól, amelyek a motor hajtásától illetve a vizsgált rendszer érzékelőtől eredhetnek. Másik példát találhatunk a [12] számú irodalomban, ahol MLP-féle struktúra került felhasználásra egy indukciós gép szimulációi alapján végzett hibadetektálás során.

Az irodalomban közölt cikkek nagy részében nem esik részletesen szó a hibadetektáló struktúra és hiba fajtákat megkülönböztető struktúra kiértékelési folyamatáról, általában csak az eredményt közlik.

Ebben a cikkben egy MLP alapokon nyugvó, rendszer hibáinak megkülönböztetésére alkalmas technika bemutatásáról lesz szó. A struktúra képes, a vizsgált aktuátor rendszer, négy különböző típusú, ofszetszerű hibájának a megkülönböztetésére, illetve a hibák nagyságának a meghatározására. A módszer használatához nélkülözhetetlen a rendszer modelljeinek a felépítése, ami szintén a cikk témája. A kidolgozott eljárás mód teljesítményének és az alkalmazott különféle szétválasztó struktúrák összehasonlításához egy összetett tesztelő folyamatot mutatunk be.

Számos neurális hálózat került betanításra a módszer kidolgozása során, a tanítási idő lerövidítésére egy aktív tanítási algoritmus került felhasználásra a Rprop hibavisszaterjesztésen alapuló algoritmus kiegészítéseként. Az így továbbfejlesztett tanítási stratégia előnyei kiemelésre kerülnek a továbbiakban.

2. Mérésadatgyűjtés a vizsgált rendszeren

A vizsgált rendszer egy soros gerjesztésű egyenáramú motor volt, amely megtalálható a közúti járművek egy jelentős részében. A belsőégésű motorokban lejátszódó kémiai folyamatok önfenntartásához, egy kezdeti fordulatszám értékre van szükség. Ennek eléréséhez indítómotor egységeket használnak.


A kutatás során egy olyan mérésadatgyűjtő és vezérlő rendszer kiépítése volt a cél, amely egyrészt képes a motor főbb paramétereinek mérésére, illetve alkalmas az indítási folyamat során fellépő terhelési állapot modellezésére is. A bemutatott tesztpad segítségével a motort annak, terhelési szempontból közel valós, üzemi körülményei között lehet tesztelni.

A mérőberendezés az 1. ábrán látható. Az aktuátor (1. ábra/1) terhelését és mechanikai paraméterek mérését egy Luckas-Nülle gyártmányú műteher (1. ábra/3) biztosította. A műteher képes volt egy vezérlőjellel arányos terhelést gyakorolni a motor tengelyére, a beépített mágnesporos fék segítségével. A terheléshez csatlakozó vezérlés a

tengelynyomatékkal és fordulatszámmal arányos feszültségjelet is szolgáltatott (1. ábra/4) a kimenetein. A mechanikai paraméterek mellett mérésre kerültek még a motor villamos paraméterei, mint a kapcsolófeszültség és a gerjesztő áram. A motor áramellátását egy 12 V-os akkumulátor biztosította. A műteher egy National Instruments gyártmányú mérőkártyához csatlakozott, amin keresztül a mérésadatgyűjtés és a vezérlés is megvalósult. Az alkalmazott mintavételi frekvencia 800Hz volt.

A mérések alapvetően két csoportba tartoztak:

- állandó terheléssel végzett mérések;
- változó terhelés alkalmazásával végzett mérések.



1. ábra. Kialakított mérőpad

3. Aktuátor modell alapú hibadiagnosztikája

A felépített hibadiagnosztikai rendszer kidolgozása több lépésből állt. A mérések felhasználásával olyan több bemenetű és egy kimenetű (MISO típusú) neurális hálózat alapú modellek kerültek kidolgozásra, amelyek széles paraméter tartományon megfelelő közelítést adnak az aktuátor viselkedésére. A modellek felépítése után diagnosztikai rendszer későbbi betanításához, kiértékeléséhez (validálásához) és teszteléséhez alkalmas, mérésekből mesterségesen előállított, adatkészletek kerültek kidolgozásra. A kialakított mintakészlet felhasználásával betanításra kerültek a hiba szétválasztására és identifikációjára alkalmas struktúrák. A betanított hálózatok hatékonyságának meghatározására egy összetett, automatizált kiértékelő algoritmus került kifejlesztésre.

3.1. Felépített modellek és a tanítási folyamat

Az aktuátorokat, mint dinamikai rendszereket kapcsolt differenciál-egyenletrendszerekkel vagy állapotter modellekkel lehet leírni [13]. Ezeknek a módszereknek az alkalmazása két alapvető részből kell, hogy álljanak: modellalkotás és validáció. A validációs folyamat gyakran nehézségekbe ütközhet, főleg egy tág tartományon érvényes modell felállítása esetén. A mérési zajok, egyszerűsített súrlódási modellek használata, hőmérséklet hatása és más elhanyagolt nemlinearitások rontani tudják a felállított modell érvényességét a működési tartományon. Egy másik megközelítés lehet, az előbbi nehézségek elkerülésére, a „puha” számítási modellek (softcomputing) használata. Ezek közé a módszerek közé sorolha-

tók a neurális hálózatok, mint fekete doboz alapú módszerek. Ennek a struktúrának használatával kidolgozhatók egy bemenetű és egy kimenetű (SISO) [14] vagy MISO modellek.

A SISO modellek nagy érzékenysége miatt ennek a cikknek a keretein belül a MISO modellek kidolgozását részesítjük előnyben. Két különböző modell került kidolgozásra, amelyeknek alapjául előrecsatolt többrétegű perceptron típusú hálózatot (MLP) alkalmaztunk. Az egyik modell a motor sebesség, a másik a tengelynyomaték közelítésére került kidolgozásra úgy, hogy széles tartományon belül szolgáltatassanak jó eredményt. A kidolgozott modellek az áram (i) és feszültség (v) értékek skálázott és transzformált értékeit használták bemenetként, ahogy (1) és (2) képletekben ez látható is.

$$y(t) = f[i(t-1), i(t-1-d), i(t-1-2d), \dots, i(t-1-nd), v(t-1), v(t-1-d), v(t-1-2d), \dots, v(t-1-nd)] \quad (1)$$

$$y(t) = f[i(t-1), i(t-1-d), i(t-1-2d), \dots, i(t-1-nd), v(t-1), v(t-1-d), v(t-1-2d), \dots, v(t-1-nd), o(t-1)] \quad (2)$$

A jó eredmények elérése érdekében, a használt neurális hálózat több paramétere is módosításra került pl. bemeneti konfiguráció vagyis NNFIR (1) és NNARX (2) hálózat konfigurációk [15], bemenetként felhasznált korábbi lépések száma (n), valamint a felhasznált korábbi időpillanatok között eltelt lépések száma (d). A felépített modellek megvalósított függvényeiből látszik, hogy egy lépéses predikciót valósítanak meg, hiszen $y(t)$ a modell kimenete a t . időpillanatban és ennek kiszámításához a $t-1$. és korábbi időpillanatok értékeit használják fel a modellek. Az NNARX modell annyiban különbözik az NNFIR modelltől, hogy a hálózattól megkívánt korábbi kimenet $o(t-1)$ értékét is a regresszorhoz kapcsolja. A modell valóságos implementációjánál ez a bemenet a modell valós futása közben, a rendszer korábbi kimenetével ($y(t-1)$) helyettesíthető.

A legjobb modell megtalálása érdekében a bemenetek száma változónként 1 és 4 között változott illetve a felhasznált korábbi bemenetek közti idő lépcsők nagysága is változtatásra került 10-es lépésekben 10-től 220-ig.

A használt hálózatok aktivációs függvényei, mind a rejtett, mind a kimeneti rétegben Elliott típusú aktivációs függvény volt, ami az esetek többségében összehasonlíthatóan jó vagy éppen jobb eredményt ad, mint az elterjedt szigmoid függvény használata és a függvény kiszámításához szükséges idő is kevesebb [14]. A rejtett réteg neuronjainak számát az aktuális bemenetszám kétszeresére állítottuk, a viszonylagosan kis méretű hálózat elérése érdekében.

A tanítási procedúra során a minden hálózatot 2000 cikluson keresztül tanítottuk. Az ilyen típusú hálózatoknál gyakori túltanulás elkerülése érdekében minden ciklusban kiszámításra került a kiértékelő mintakészlet átlagos négyzetes hibája (MSE) és az a hálózat került elmentésre, amelyik a tanítás során a legkisebb értéket adta [14]. Így elkerülhető volt a túltanulás, vagyis hálózat kellő mértékben képes az extra- és interpolációra. A hálózat kezdeti súlyainak beállításához a Widrow-Nguyen módszer használtuk, ami hálózat hibájának minimumhoz való jó konvergációját biztosítja a tanítás során [16]. A tanító algoritmusként a Rprop [17] módszerre esett a választás, ami a hibavisszeterjesztésen alapuló ellenőrzött tanítási módszerek közé tartozik.

A használt kiértékelő és tanító mintakészletek a mérésekből származó adatokból kerültek kialakításra, úgy hogy egymástól független adatkészleteket kapjunk. Ez úgy került

megvalósításra, hogy összesen kilenc különböző terhelési állapotot megvalósító mérés eredményét fűztük fel egymás után és alakítottuk ki a tanító mintakészletet illetve egy teljesen más terhelési állapotot megvalósító mérésből származott kiértékelő mintakészlet. A mintakészletek főbb paramétereit az 1. táblázat tartalmazza.

1. táblázat. A mintakészletek adatai

Paraméter	Tanító mintakészlet	Kiértékelő mintakészlet
Mintakészlet pontjainak száma [db]	55050	7300
Felhasznált mérések száma [db]	9	1

3.2. A felhasznált modellek kiválasztási folyamata

Számos modell született (összesen 88 darab) struktúra típusonként (NNFIR és NNARX), illetve megfigyelőnként (nyomatékot közelítő modell és sebességet közelítő modell). A modelltérből a leghatékonyabb modell kiválasztásához az irodalomban fellelhető kiválasztási kritériumokat (SC) használtuk. Ezek a következők voltak:

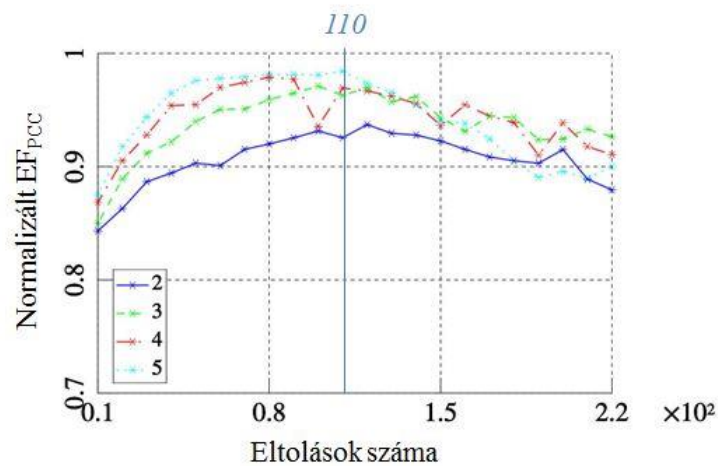
- Akaike információs kritérium (AIC) [18];
- Bayesian információs kritérium (BIC);
- Végső predikciós hiba (FPE) [19];
- Átlagos négyzetes hiba (MSE);
- Pearson-féle korrelációs együttható (PCC) [20];

AIC, BIC és FPE kritériumok az MSE értéken alapsznak, de kiegészülnek egy büntető taggal. Ezek a büntető tagok a hálózat és mintakészletek különféle paramétereinek a függvényei, mint hálózatban lévő súlyok száma, mintakészlet hossza, stb. Az említett kapcsolat miatt ezek a kiválasztási kritériumok nagyon hasonló eredményeket hoztak. PCC a hálózattól megkívánt kimenet és a hálózat közelítést adó kimenet kapcsolatának erősségét adja meg [20].

A kiválasztási folyamat során úgy választottuk ki a leghatékonyabb hálózat struktúráját, hogy figyelembe vettük az adott hálózat konfiguráció eredményét mind a nyomaték, mind a sebesség közelítésekor. Ennek érdekében bevezettük a következő (3) alakú kiértékelő függvényt (EF).

$$EF_{SC} = \sqrt{\text{norm}^2(SC_{\text{sebesség}}) + \text{norm}^2(SC_{\text{nyomaték}})} \quad (3)$$

A formula a fenti kiválasztási kritériumok közül bármelyik, normalizált változatával kiszámítható. A normalizált EF_{PCC} a modellek felhasznált eltolások függvényében, az NNARX típusú hálózat struktúrára, a 2. ábrán látható. Az ábra bemutatja, hogyan változik a korreláció erőssége a bemenetek számának változása függvényében is. A nagyobb bemenet szám jobb eredményt ad, de növeli a hálózat méretét is. A legjobb eredményt felmutató hálózat típusonként 5 bemenettel rendelkezett és az eltolások a használt bemenetek között 110 volt.



2. ábra. Normalizált kiválasztási függvény NNARX hálózatok esetén az eltolások függvényében

3.3. A hibadiagnosztikai rendszer felépítése

Isemann [21] a hiba észlelésének folyamatát együttvéve a hiba valamely tulajdonságának meghatározásával, hibadiagnosztikának nevezi. A vizsgált rendszer több paraméterének közelítésére használatos modelljeinek felhasználásával egy előrecsatolt neurális hálózat alapokon nyugvó, hibadiagnosztikai struktúra került kifejlesztésre. Ez a hibadiagnosztikai rendszer képes megkülönböztetni a rendszerben fellelhető esetleges meghibásodásokat, mindamelllett, hogy visszajelzést ad a hiba nagyságára is.

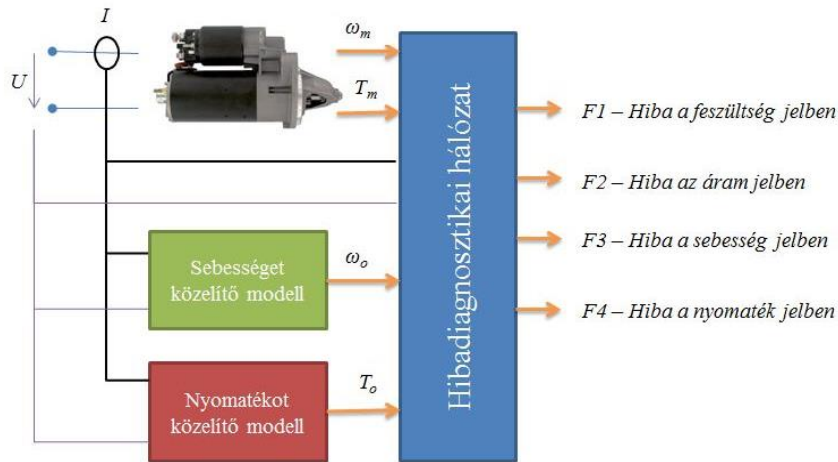
A diagnosztikai rendszernek négy kimenete (F1, F2, F3, F4) van, amelyeken a lehetséges hiba jelenségekkel arányos jelzéseket kapjuk. A négy figyelmeztető jel, négy különböző hibajelenségre utal.

- F1: hiba a feszültség jelben;
- F2: hiba az áram jelben;
- F3: hiba a sebesség jelben;
- F4: hiba a nyomaték jelben.

A feszültség és áram jelben jelentkező hibák utalhatnak az akkumulátor meghibásodására például töltöttségi problémára, de a hőmérséklet behatása is okozhat ilyen jellegű hibát. A sebesség és nyomatékjelben fellépő hibajelenség utalhatnak a motor megakadására, törésre, esetleg a szelepek hibáira.

Ha a kimenet értéke nulla, akkor nincs hiba a rendszerben. Ha nagyobb/kisebb a figyelmeztető jel értéke, mint nulla akkor az adott jel eltérése nagyobb/kisebb, mint a normális esetben lenne. A hibajelzés megjelenése a hiba megjelenésére utal még nagyság a rendszerben lévő hiba nagyságára utal.

A hibadiagnosztikai struktúra bemeneteire a kidolgozott modellek kimenetei illetve a vizsgált rendszer mért paraméterei kerülnek a megfelelő skálázás után (3. ábra).



3. ábra. Hibadiagnosztikai struktúra

A rendszer kialakításakor megvizsgáltuk az NNFIR és NNARX bemeneti konfigurációkat, valamint azokat kiegészítve a megfelelő mért jelek és az azt generáló modell kimenetének normalizált különbségével (sebesség és nyomaték). Az így kapott négy struktúra típus fog megjelenni a vizsgálatok során („FIR”, „ARX”, „FIR és hiba”, „ARX és hiba”). Természetesen a korábban kidolgozott modellek és a diagnosztikai struktúra ugyanazokat feszültség és áram jeleket kapták a vizsgálatok során.

A jobb eredmények elérése érdekében növelni kellett a virtuális bemenetek számát. Több virtuális bemenet konfiguráció is összehasonlításra került.

3.4. Mintakészletek kialakítása

Mivel a hibadiagnosztikai rendszerünk neurális hálózat alapú, ezért a mintakészletek kialakítása az egyik kritikus pont a későbbi jó eredmények elérése szempontjából. Ez befolyásolja mit fog és mit nem megtanulni a hálózatunk.

2. táblázat. Mintakészletek adatai

Paraméter	Tanító mintakészlet	Kiértékelő mintakészlet	Teszt mintakészlet
Kialakított mintakészlet száma [db]	1	1	240
Mintakészlet pontjainak száma [db]	231900	36490	7300
Egy mintakészletben szereplő hibaimpulzusok száma [db]	72	16	3

A szükséges mintakészletek, vagyis a hibákat tartalmazó készletek, mesterségesen kerültek előállításra, a korábban részletezett mérések során szerzett adatokból. A generált hibák megjelenése véletlenszerűen mutatkozik a mérések időtartama alatt. A generált hibák impulzusszerűek, nagyságuk szintén véletlenszerű, de az aktuális jel mérési tartományának

nem nagyobb, mint 30%-a volt. Az impulzusok hossza szintén változott a minták előállítása során.

Két nagyobb mintakészlet került kialakításra: egy tanítási célra, egy pedig a tanítás leállítása, kiértékelése céljából. A tanításhoz és validáláshoz használt készlet több mérést használtunk alapul, még a teszt készletekhez csak egyfajta. Az előbbi készletek többféle hibaimpulzus darabot tartalmaznak. A teszt készletek csak egy-egy hibatípusra mutatnak példát. A széles tartományon való tesztelési lehetőség biztosítása céljából nagyszámú teszt mintakészlet került kialakításra. A nagyszámú teszt készlet a hibafajtákra, hibák nagyságára és a hibaimpulzusok hosszainak széleskörű változtatására biztosít lehetőséget.

Az előállított mintakészletek legfontosabb paramétereit a 2. táblázat tartalmazza.

3.5. A rendszer tanítása

Az előállított mintakészletek segítségével megtörtént több dignosztikai rendszer kidolgozása, betanítása. A minnél jobb eredmény elérése érdekében több fajta neurális hálózat struktúra került betanításra. A tanítási folyamat felgyorsítása érdekében egy speciális aktív tanítási algoritmus került kidolgozásra.

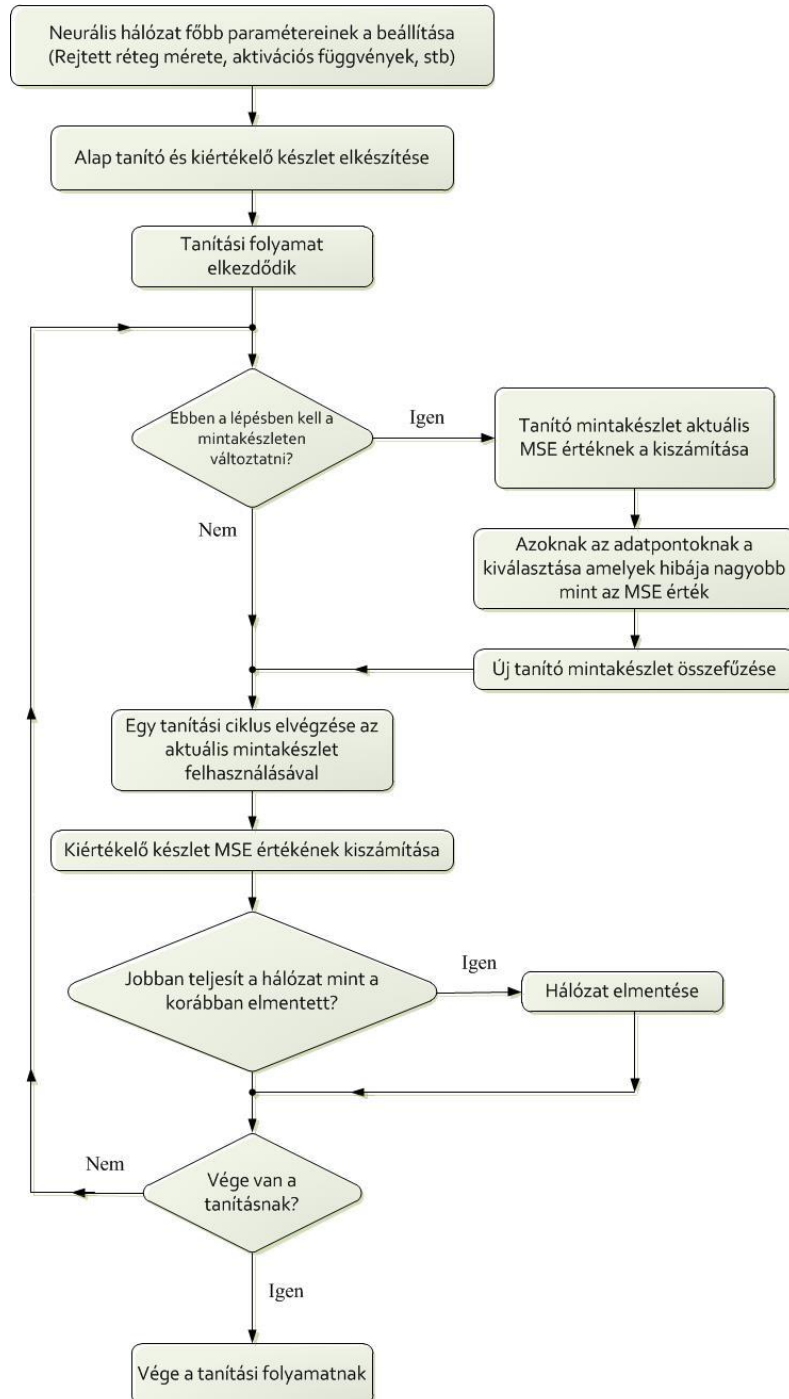
A tanítási módszer lényege az, hogy a tanítási folyamat alatt a használt tanító készlet dinamikusan változik aszerint, hogy mely pontokat sikerült a rendszernek kellő pontossággal elsajátítania. Az alkalmazott tanítási módszer folyamat ábráját a 4. ábra mutatja.

A tanítás legelején a használt neurális hálózat alapparamétereit kell beállítani, mint például bemeneti struktúra, rejtett neuronok száma, ami a bemenetek számának kétszeresére lett választva, választott aktivációs függvények beállítása, stb. A következő lépésben a tanítás kiindulási mintakészleteinek legenerálása következett, amely során a tanító és validáló készletek kerültek kidolgozásra. Ezt követte az effektív tanítás. A tanítási ciklusban két vizsgálat kap helyet: iteráció szám vizsgálat és a validáló készlet MSE vizsgálata. Az első a mintakészlet módosításának ütemezése miatt fontos, mert minden 50 iterációs lépésben történt meg az új tanító készlet előállítása az alap tanító készlet MSE értékének alapján.


A második vizsgálat a tanítási folyamat legjobban teljesítő hálózatának elmentése miatt szükséges. A tanítás véget ér, ha az iterációs szám eléri az előre beállított maximális értéket.

A bemutatott aktív tanítási módszer előnye a hagyományos, passzív mintakészletet használó, módszerrel szemben, hogy ugyanolyan vagy jobb MSE eredményt ér el rövidebb betanítási idő alatt. A módszer alkalmazása során csökken a mintakészlet nagysága (5. ábra/a), ami a szükséges számítások számának lecsökkenését eredményezi, következésképpen a tanításhoz szükséges idő leredukálódik. A módszer hatékonysága kis hálózatoknál mutatkozik, ahol akár 20% időmegtakarítást is nyerhetünk, de nagyobb hálózatoknál ez az időnyereség lecsökken (5. ábra/b).

A kifejlesztett módszer hatékonyságát a hibaszétválasztáshoz és diagnosztikához tartozó feladatok során teszteltük, ahol az alkalmazott neurális hálózat osztályozási feladatokat lát el.



4. ábra. Aktív tanítási módszer



5. ábra. Aktív tanulás hatékonyságának változása a bemenetek számának függvényében

3.6. Módszer kiértékelése és vizsgálata

A legjobban teljesítő diagnosztikai hálózat megtalálása érdekében több hálózat is betanításra került. A különböző strukturájú hálózatok hatékonyságának értékelésére egy összetett kiértékelő folyamatot mutatunk be. A hibadiagnosztikai hálózat hatékonyságát több paraméter is meghatározza. Egyrészt mennyire képes a hálózat időben felismerni a hibákat (hiba felismerés), másrészt pedig a felismert hibák mértékét mennyire pontosan tudja meghatározni a hálózat (hiba nagyság közelítés). Érdekes lehet meghatározni, hogy a felhasznált modell hogyan befolyásolja a kialakított struktúra eredményességét is.

3.6.1. Hiba felismerés

Egy diagnosztikai rendszer talán legfontosabb tulajdonsága, hogy minél kevesebb hibás jelzést adjon és lehetőleg akkor generáljon hibajelzést, ha tényleg hiba van a rendszerben.

A hibadiagnosztikai struktúra hatékonyságának vizsgálatához, a neurális hálózatok kiértékeléshez használt MSE érték nem ad könnyen értelmezhető eredményt. Ezért egy informatívabb mennyiség került kidolgozásra és bevezetésre a kiértékeléshez. Mivel a hálózat hibajelzései, az értékelni kívánt hibás jelalakok, impulzusszerűen jelennek meg, egy kiértékelési szempont lehet az impulzusok fel- és lefutó éleinek vizsgálata tényleges hibák megjelenéséhez és megszűnéséhez képest.

Az élek vizsgálata során három kategóriát különböztethetünk meg:

- a) RE – recognised edges – a megfelelő időben felismert élek csoportja;
- b) ME – missed edges – elhízázott élek kategóriája, azok az élek tartoznak ide, amelyeknél a valós rendszer tényleges hibaéle nem került felismerésre;
- c) BE – rossz élek kategóriája, ahova azok az élek sorolhatók, amelyekre igaz, hogy a diagnosztikai rendszer jelzett, de a valóságban nincs hibajelenség.


A fenti paraméterek segítségével egy élfelismerő képesség (ERA [%]) értelmezhető, amely a következő (4) összefüggéssel számítható ki

$$ERA = \frac{RE}{RE + ME + BE} \cdot 100 \quad (3)$$

Ezzel a mennyiséggel szemléletesen értékelni lehet a szétválasztó, diagnosztikai hálózat hatékonyságát. A mennyiség százalékos, aminél a 100% jelenti az összes él felismerését a

mintakészletben, a 0% arra utal, hogy egyetlen élt se talált a hálózat a valós viszonyokhoz képest.

Az ERA kiszámításához szükséges a vizsgált jelsorozatokban az élek hatékony detektálása. Számos módszer ismert a képfeldolgozásban, ami használható egy jelsorozatban a megjelenő hirtelen értékváltozások (élek) jelzésére egy dimenzióban. Egy hagyományos módszer a jel szűrése után, annak deriváltjainak vizsgálatán alapszik [22]. A módszer könnyen implementálható, de a vizsgált jel zajossága nehézkessé teszi alkalmazását. Bár a mi esetünkben is alkalmazásra került, ez az élkereső módszer, nem hozott jó eredményt az élek megtalálásában.



6. ábra. Diagnosztika struktúrák hatékonysága a különféle hibatípusok esetén, az alkalmazott ERA mennyiségén keresztül

Másik jól ismert eljárás a Canny élfelismerő módszer. Ez az eljárás magában foglal egy optimalizált véges hosszúságú szűrőt, amit a haranggörbe deriváltjából nyer [23]. Az eljárást, annak paramétereinek beállítása után, eredményesen lehetett használni az hibadiagnosztikai rendszeri kimeneti jelzéseinek automatikus kiértékelésére.

Az 6. ábra a betanított különféle diagnosztikai struktúrák hatékonyságát mutatja az ERA paraméteren keresztül. A diagram összesített eredményeket tartalmaz az összes teszt mintakészletre. A diagram négy diagramja a négyféle hiba típus eredményeire utal. Az ábrából jól látszik, hogy a FIR struktúra kevésbé hozott jó eredményeket, mint az ARX struktúra alkalmazása. A plusz bemenetek alkalmazása („FIR és hiba” illetve „ARX és

hiba” bemeneti konfigurációk) nem hozták a jobb eredményeket, mint az várható lett volt a hálózatra adott plusz információk alapján.

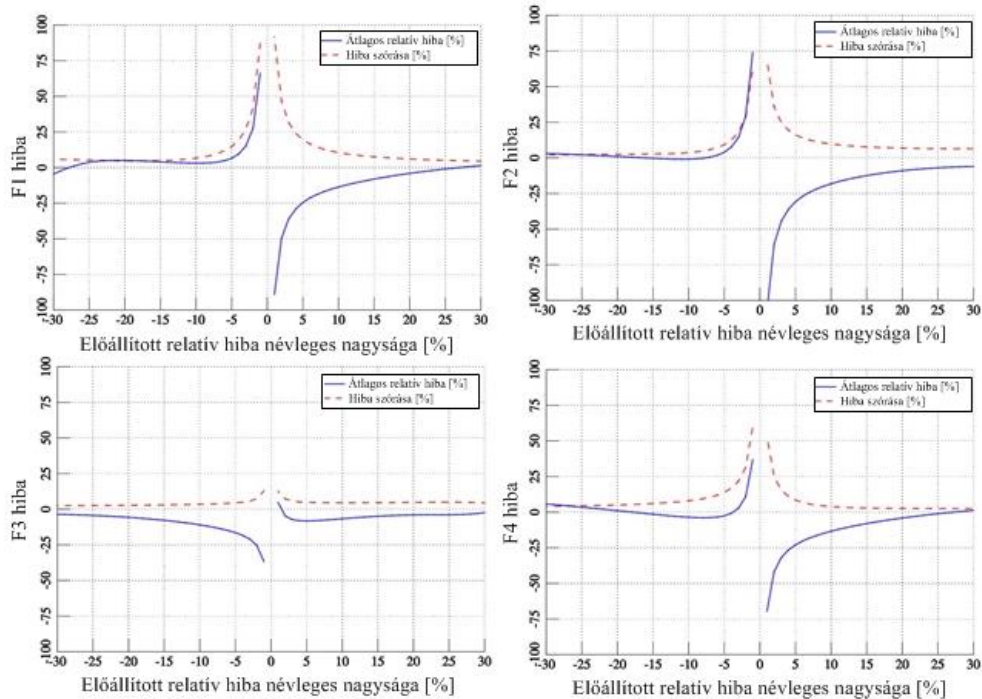
A bemeneti struktúra növelésével, több virtuális bemenet előállításával, szintén nem javultak az eredmények a várakozások ellenére. Az F1 és F4 hiba típusok detektálása hatékonyabb volt, mint az F3 és F2 hibáké. Az utóbbi hibatípus detektálása volt a legnehezebb, ahogy az ábrából is látszódik.

Összességében az NNARX struktúra hozta a legjobb eredményt, Összességében 80-85% hatékonysággal dolgozott, ami 1100 jó észlelést foglal magában a 1440 esetből. A rossz észlelések a Canny algoritmus nehézkes konfigurálásából adódott.

3.6.2. Hiba nagyság közelítés

Másik fontos tulajdonsága a hibadiagnosztikai struktúrának a felismert hibák nagyságának meghatározása. A kialakított tesztkészletek lehetővé teszik, hogy különféle nagyságú mesterséges hibák betekintést mutassanak hibadiagnosztikai rendszer hatékonyságába a különféle nagyságú hibák felismerésekor.

Az előző alfejezetben összehasonlított struktúrák közül a legjobban teljesítő hálózat, vagyis egy virtuális bemenetet használó NNARX struktúra került vizsgálatra. Az eredményeket a 7. ábra tartalmazza. Az ábrán látható négy diagram a négy hibatípusnak megfelelő eredményeket mutatja. Az x-tengelyeken a vizsgált aktuátor rendszer, aktuális hibatípusához tartozó mennyiség értékkészletének extrémimainak különbségére vonatkoztatott relatív hibanagyság százalékos értéke van feltüntetve, a vizsgált -30 és +30 terjedő skálán. Az y-tengelyeken a diagnosztikai rendszer eredményességét mutató mérőszámok átlagos (folytonos vonal) és szórás (szaggatott vonal) értéke. Az ábra azt mutatja, hogy a kis hibák felismerése viszonylag nagy átlagos hiba és szórás mellett volt képes a rendszer. A vizsgált rendszer szempontjából ez azt jelenti, hogy 1%-os mennyiségi eltérést, a diagnosztikai rendszer, 2%-os hibának ismer fel. A diagnosztikai rendszer hatékonysága a felismerni kívánt hiba nagyságának növekedése mellett természetesen növekszik. Nagyobb hibák felismerése, kisebb átlagos hibával (< 5 %) valósult meg. Érdekes tulajdonság, hogy F1, F2, F4 hiba típusok estén a negatív eltérések felismerése jobb eredményt hozott, mint a pozitív hibáké. Az F3 hibatípus felismerés, a felismerni kívánt hiba nagyságának függvényében, kevésbé változott, mint a többi hibatípusok estében. Összességében elmondható, hogy a diagnosztikai rendszer hiba nagyságának meghatározó képessége átlagosan 10-15%-os hibával volt képes dolgozni.



7. ábra. A legjobban teljesítő hibadiagnosztikai struktúra, hiba nagyság közelítő tulajdonságának alakulása a felismerni kívánt hiba nagyságának függvényében, a különböző hibatípusok estén

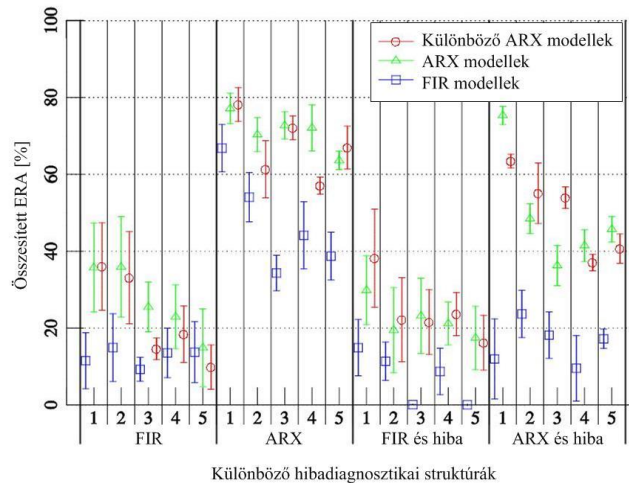
3.6.3. Használt modell szerepe

A bemutatott hibadiagnosztikai rendszer, a vizsgált aktuátor rendszer matematikai modelljeit használja a rendszer hibáinak kimutatására. Felmerül a kérdés, hogy az alkalmazott modellek hogyan befolyásolják a diagnosztikai rendszer hatékonyságát, mint egyfajta érzékenység vizsgálat.

A kidolgozott hibadiagnosztika rendszer betanításához használt modellek NNARX típusú, azonos bemeneti konfigurációt alkalmazó modellek voltak. Azt vizsgáltuk meg, hogy összességében rosszabbul és jobban teljesítő modelltől hogyan befolyásolja a diagnosztikai rendszer működését. Rosszabbul teljesítő modelltől a legjobb FIR modell került kiválasztásra. A jobb modelltől szerepét olyan NNARX modellek (sebesség és nyomaték megfigyelők) töltötték be, amelyek a maguk kategóriájában a legjobbak voltak. Az így nyert két modell bemeneti struktúrái nem egyeztek meg, eltérő számú virtuális bemenettel rendelkeztek, ami magával vonja a más hálózat nagyságát is, illetve a két obszerver más-más eltolási nagysággal is rendelkezett.

A három modelltől alkalmazásból kapott, a teszt készletekre alkalmazott összesített átlagos ERA eredményeket a különböző diagnosztikai hálóstruktúrákra a 8. ábra tartalmazza. Az ábrán a különböző markerek y pozíciója a különböző modellek átlagos paraméterét mutatja, míg a markeren áthúzott függőleges vonal a ERA szórására utal, a teszt készleten végzett tesztek alapján.

Jól látható, hogy FIR megfigyelők rontották a diagnosztikai rendszer hatékonyságát, viszont a jobb modellek (különböző ARX modell megfigyelők) nem hozták a várt nagymértékű eredményjavulást. A vizsgált diagnosztikai struktúrák kevesebb, mint felénél eredményezett a jobb modell, jobb eredményt.



8. ábra. Hibadiagnosztika rendszer eredményességének függése az alkalmazott modellektől

4. Használt szoftverek és a hardveres háttér

A munkában közölt eredmények eléréséhez egyedi C/C++ nyelven íródott programok készültek, mind a neurális hálózatok tanításához illetve az adatok elő- és utófeldolgozásához. A programok elkészítésének a fő oka az volt, hogy az ingyenesen elérhető, szkript alapú programcsomagok (pl.: Scilab, Octave) egyrészt igen hosszadalmas tanítási időket produkálnak még viszonylag kisméretű neurális hálózatok mellett is, másrészt ezeknek a nyelveknek a fájl operációkkal kapcsolatos műveletekhez szükséges időszükséglete, igen nagy lehet, a tapasztalatok szerint.

GCC fordítót használtunk a programok lefordításhoz és futtatásához néhány, igen hasznos függvénykönyvtár alkalmazása mellett. FANN függvénycsomag biztosította a neurális hálózatok elérhetőségét C és C++ nyelveken [24]. A diagramok előállításához jó alapot biztosított a MathGL grafikus könyvtár [25]. A GSL [26] és Armadillo [27] matematikai függvénykönyvtárak megkönnyítették a vektor és mátrix műveletek elvégzését.

A hardveres háttér egy Core2Duo E8400@3GHz PC adta 4GB RAM memória és Fedora 18 operációs rendszer mellett.

5. Összefoglalás

Kidolgozásra került egy új hibadiagnosztikai módszer, ami a neurális hálózatok osztályozási képességét használja fel a vizsgált rendszer különféle hibáinak meghatározására. A módszer nem csak a rendszerben megjelenő hiba jelenlétét mutatja, hanem annak nagyságát is

közelíti. Az előre betanított hibatípusokat jó eredménnyel képes megkülönböztetni a hálózat széles működési tartományán. A módszer hatékonyságát a felhasznált modellek befolyásolják, de a felhasznált neurális hálózat struktúrája is jelentősen befolyásolja az eredményt.

A módszer kidolgozása során, egy összetett kiértékelő eljárást szemléltettünk, amely egyrészt a diagnosztikai hálózat gyorsaságát értékeli, a hibák megjelenésének és megszűnése időpontjainak vizsgálatával. A másik értékelési mód, a hálózat hiba nagyságára történő közelítésének figyelembe vételével történik. Látható, hogy az NNARX típusú struktúra, vagyis a hálózat korábbi kimeneteinek elhelyezése a bemeneti térben, jelentősen javít a struktúra hatásfokán, viszont nagyobb hálózat méretet eredményez. A hibadiagnosztikai feladathoz illesztett új betanítási módszer jelentősen le tudja csökkenteni a tanításra szánt időt és jó eredményt ad.

6. Köszönetnyilvánítás

A kutató munka a Miskolci Egyetem stratégiai kutatási területén működő Mechatronikai és Logisztikai Kiválósági Központ keretében valósult meg.

7. Irodalom

- [1] Zhou Y.; Hahn J.; Mannan M. S.: *Fault Detection and Classification in Chemical Processes based on Neural Networks with Feature Extraction*, ISA Transactions 42, 2003., pp.651-664.
- [2] Azhar S.; Rahman S. A. B.: *Application of Artificial Neural Network in Fault Detection Study of Batch Esterification Process*, Int. Journal of Engineering and Technology IJET-IJENS Vol: 10 N: 03, 2010., pp.36-39.
- [3] Nicholson A. E.; Brady J. M.: *Sensor Validation using Dynamic Belief Networks*, Proc. of the 8th Conference on Uncertainty in Artificial Intelligence, 1992., p. 207.
- [4] Spina P. R.: *Reliability in the Determination of Gas Turbine Operating State*, Proc. of the 39th IEEE Conf. on Decision and Control, Sydney, NSW, Australia, 2001., p.2639.
- [5] Pranatyasto T. N.; Qin S. J.: *Sensor Validation and Process Fault Diagnosis for FCC Units under MPC Feedback*, Contr. Eng. Practice 9, 2001., p. 877.
- [6] Zhang Y.; Dudzic M.; Vaculik V.: *Integrated Monitoring Solution to Start-up and Run-time Operation for Continuous Casting*, Annu. Rev. Contr. 27, 2003., p.141.
- [7] Mehranbod N.; Soroush M.; Panjapornpon C.: *A Method of Sensor Fault Detection and Identification*, Journal of Process Control 15, 2005., pp.321–339.
- [8] Zhang J.: *Improved on-line Process Fault Diagnosis through Information Fusion in Multiple Neural Networks*, Computers & Chemical Engineering 30, 2006., pp.558-571.
- [9] Amann P.; Perronne J. M.; Gissinger G. L.; Frank P. M.: *Identification of Fuzzy Relational Models for Fault Detection*, Control Engineering Practice 9, 2001., pp.555-562.
- [10] Padmakumar S.; Agarwal V.: *A Comparative Study into Observer based Fault Detection and Diagnosis in DC Motors: Part-I*, World Academy of Science, Engineering and Technology 51, 2009., pp.318-323.

- [11] Sainz Palmero G. I.; Juez Santamaria J.; Moya de la Torre E. J.; Peran Gonzalez J. R.: *Fault Detection and Fuzzy Rule Extraction in AC Motors by a Neuro-Fuzzy ART-based System*, Engineering Applications of Artificial Intelligence 18 2005., pp.867–874.
- [12] Kolla S.; Varatharasa L.: *Identifying Three-phase Induction Motor Faults using Artificial Neural Networks*, ISA Trans. 39, 2000., pp. 433–439.
- [13] Ciurys M.; Dudzikowski I.; Gierak D.: *Modelling of a Car Starter with Permanent Magnet Commutator Motor*, COMPEL The Int. Journal for Computation and Mathematics in Electrical and Electronic Engineering, Vol. 28 Iss: 3, 2009., pp.722-729.
- [14] Füvesi V.; Kovács E.: *Modeling Loaded Starter Motor with Neural Network*, Proc. of 12th IEEE Int. Symposium on Computational Intelligence and Informatics, (CINTI2011), Budapest, Hungary, ISBN 978-1-4577-0044-6, 2011., pp.551-554.
- [15] Norgaard M.; Ravn O.; Poulsen K. N.; Hansen L. K.: *Neural Networks for Modelling and Control of Dynamic Systems*, Springer-Verlag, London, 2000., pp.18-34.
- [16] Nguyen D.; Widrow B.: *Improving the Learning Speed of 2-layer Neural Networks by Choosing Initial Values of the Adaptive Weights*. IJCNN, vol III, 1990., pp.21-26.
- [17] Riedmiller M.; Braun H.: *A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP algorithm*, In Proc. of the IEEE Int. Conf. on Neural Networks, San Francisco, CA, 1993., pp.586-591.
- [18] Akaike H.: *A New Look at the Statistical Model Identification*, IEEE Trans. on Automatic Control, vol. 19, 1974., pp.716-723.
- [19] Pizarro J.; Guerrero E.; Galando P. L.: *A Statistical Model Selection Strategy Applied to Neural Networks*, European Symposium on Artificial Neural Networks, 2000., pp.55-60.
- [20] Brown M.; Harris C.: *Neurofuzzy Adaptive Modelling and Control*, Prentice Hall, London, 1994.
- [21] Isermann R.: *Fault diagnosis applications: model based condition monitoring, actuators, drives, machinery, plants, sensors, and fault-tolerant systems*, ISBN 978-3-642-12766-3, Springer, 2011.
- [22] Füvesi V.; Kovács E.: *Separation of Faults of Eletromechanical Drive Chain using Artificial Intelligence Methods*, 18th “Building Services, Mechanical and Building Industry days” Int. Conf., Debrecen, Hungary, 2012., pp.19-27.
- [23] Canny J.: *A Computational Approach to Edge Detection*, IEEE Trans. on Pattern Anylses and Machine Intelligence, Vol. 8, No. 6, November, 1986., pp.679-698.
- [24] Nissen S.: *Implementation of a Fast Artificial Neural Network Library (fann)*, Department of Computer Science University of Copenhagen (DIKU), 2003.
- [25] Balakin A. A.: *MathGL Manual (for version 1.11.2)*, <http://mathgl.sourceforge.net>, GNU Free Documentation, 2008.
- [26] Galassi M.: *GNU Scientific Library Reference Manual - Third Edition*, ISBN 0954612078, GNU Manual, Network Theory Ltd., 2009.
- [27] Sanderson C.: *Armadillo: An Open Source C++ Linear Algebra Library for Fast Prototyping and Computationally Intensive Experiments*, Technical Report, NICTA, 2010.