

MISKOLCI EGYETEM



GÉPÉSZMÉRNÖKI ÉS INFORMATIKAI KAR

Neurális hálózatokon alapuló modellezés és hibadiagnosztika
villamos hajtások példáján keresztül

Doktori (PhD) értekezés tézisei

Füvesi Viktor
okleveles gépészmérnök

SÁLYI ISTVÁN GÉPÉSZETI TUDOMÁNYOK DOKTORI ISKOLA

DOKTORI ISKOLA VEZETŐ:
Dr. Tisza Miklós
a műszaki tudományok doktora, egyetemi tanár

TÉMAVEZETŐ:
Dr. Kovács Ernő
egyetemi docens

TÁRS TÉMAVEZETŐ:
Váradiné Dr. habil Szarka Angéla
egyetemi docens

Miskolc, 2014.

Bíráló bizottság tagjai

Elnök: **Dr. habil. Döbröczöni Ádám**

CSc, professzor emeritus

Miskolci Egyetem

Titkár: **Dr. Szilágyi Attila**

PhD, egyetemi docens

Miskolci Egyetem

Tagok: **Dr. Szabó Tamás**

PhD, egyetemi docens, intézetigazgató

Miskolci Egyetem

Dr. Erdélyi Ferenc

CSc, címzetes egyetemi tanár

Budapesti Műszaki Egyetem

Dr. Chován Tibor

PhD, egyetemi docens

Pannon Egyetem

Hivatalos bírálók: **Dr. Jónap Károly**

PhD, nyugalmazott tudományos főmunkatárs

Dr. Csáki Tibor

CSc, nyugalmazott egyetemi docens

1. Bevezetés

A napjainkra jellemző éles piaci verseny megköveteli a minél nagyobb pontosságot és megbízhatóságot mind a termék, mind a gyártóeszköz vonatkozásában, mert a gyártási rendszer bármely elemében felmerülő hiba jelentős gazdasági károkat okozhat. Jelentős K+F+I előnyt eredményezhet, ha már a tervezési fázis kezdetén megalkotjuk a rendszert alkotó elemek modelljeit, amelyek erősíthetik a termék vagy a gyártás versenyképességet és beemelik a tervezésbe az életciklus szemléletet. A valósághű modell megalkotásával a rendszer különböző működési körülményeinek vizsgálata jelentősen leegyszerűsödhet. A megfelelő modellek megalkotása elősegíti a termék tervezést, könnyebben megtalálhatók a termék gyenge pontjai és így a tervezés hiányosságai már korán felfedezhetők, kijavíthatók. A szimulációs vizsgálatokból nyert információk alapján a termék megbízhatóbbá, versenyképesebbé válhat és akár plusz funkciókhoz is juttathatjuk a terméket [1].

A megalkotott különféle szintű modellek felhasználásának egyik – egyre bővülő – lehetősége a rendszerekben előforduló jellemző hibák automatikus észlelése még azelőtt, hogy nagyobb károk keletkeznének, vagy akár a megbízhatóságra hatással lennének. Bármilyen rendszer üzeméről megállapítani, hogy annak működési állapota egy normál, hibamentes állapot vagy már kialakulóban van valami hiba a rendszerben nem egyszerű, nem magától értetődő feladat. Az irodalomban fellelhető különböző források más és más megközelítést alkalmaznak a rendszer hibájának, mint fogalomnak a definiálására. A [3] szerzői szerint a hiba úgy definiálható, mint a vizsgált rendszer legalább egyik paraméterének, karakterisztikájának egy nem megengedett devianciája annak megengedett értékétől. Más források szerint a hiba felfogható egy olyan plusz bemenetként, ami zavarhatja a rendszer teljesítőképességét, teljesítményét [4], [5]. A hiba a rendszer állapotának megváltozása, amely lehet átmeneti jellegű vagy éppen végleges fizikai változás a [5] forrás szerint.

Hibadiagnosztikai rendszerek segítségével képesek vagyunk a vizsgált rendszer hibáit kimutatni. Ezek a rendszerek egyfajta monitoring rendszerek, amelyeket egyfelől a hibák kimutatására, másfelől hibadiagnosztizálásra használnak. A hiba rendszeren belüli elhelyezkedésének és jelentőségének meghatározási folyamatát hibadiagnózisnak nevezzük [6].

A hibadiagnosztikai rendszer a következő feladatokat végzi:

- Hiba felismerés vagy más néven hibadetektálás esetleg hibakeresés (*fault detection*): Ekkor határozzuk meg, hogy történt-e hiba a rendszerben vagy sem.
- Hiba elszigetelése, hiba leválasztás (*fault isolation*): Azt állapítjuk meg, hogy hol van az adott hiba a rendszeren belül.
- Hiba azonosítás (*fault identification*): A hiba méretének becslése és jellegének megállapítása.

A diagnosztikai rendszer előbbi feladatai közül az első kettőt – hibakeresést és leválasztást – tartják a legfontosabbnak. Hibadiagnosztikán nagyon gyakran a hibakeresésre és az izolálásra (*FDI – fault detection and isolation*) alkalmas módszereket értjük [7], [8].

A dolgozatomban bemutatott hiba detektálás és azonosítás létjogosultságának és használhatóságának bizonyítására két, különböző összetettségű elektromechanikus aktuátor rendszer szolgál példaként.

A munka első felében egy sínen guruló kocsit elektromechanikus hajtásláncjának hibadetektálását végeztem el. A második téma egy egyenáramú indító motor modelljeit és hibadiagnosztikáját mutatja be.

A két érintett területben közös, hogy a bemutatott modellek kidolgozásához a valós aktuátorokon végzett mérésekből indultam ki. A vizsgált rendszerek természetüknél fogva nemlineáris rendszerek, hiszen számos jelenség pl.: a súrlódási jelenségek, mágnesezési veszteségek, melegedésből szárazó ellenállás változás, stb. bonyolítják a modellezni kívánt berendezés vizsgálatát. A mérések kiértékelése, illetve előfeldolgozása után felhasználtam a kapott adatokat a nemlineáris - mesterséges intelligencia családjába tartozó, neurális hálózatokon alapuló - modellek kidolgozásához.

A mesterséges neurális hálózatok (ANN – Artificial Neural Network) az agyban található neuronok szövetében végbemenő folyamatokat megvalósító számítási rendszerek. Számos probléma létezik a mérnöki gyakorlatban, melyeket nem vagy csak nagy energia befektetéssel tudunk megoldani hagyományos algoritmusokkal, de az ember könnyedén megoldja őket. Az agyi folyamatok megfigyeléséből ötleteket nyerhetünk a természetből, a probléma hatékony megoldásához. A begyűjtött megfigyelések és információk alapján számítási rendszereket hozhatunk létre. Erre példa a mesterséges neurális hálózat is. A neurális hálózatok segítségével képesek vagyunk modellezési, osztályozási, optimalizációs, stb. feladatok megoldására, ahogy ezt a későbbiekben bizonyítani is fogom. Ennek az apparátusnak a használata számos előnnyel kecsegtet, de alkalmazásához sok tapasztalat, odafigyelés és türelem szükséges a paraméterek jó beállításához.

2. Célkitűzések

Disszertációmban azt a célt tűztem ki, hogy elektromechanikus aktuátorok mesterséges intelligencia alapú modellezésével foglalkozzak, illetve azok lehetséges hibáit vizsgáljam, kimutatásukra módszereket fejleszsek ki.

Kutatásaim során két rendszert is vizsgáltam. Az első rendszer a Gamma-log természetes gamma-sugárzást mérő berendezés hajtásláncja volt. A mérések és a berendezés használata során számos hibajelenség látott napvilágot, amihez kapcsolódóan hibadetektálási, identifikációs és szeparációs feladatok megoldása került előtérbe. Szükséges volt az irodalomban fellelhető módszerek megismerése is. A módszerek egyik csoportját képezik a modell alapú hibadiagnosztikai megoldások, amelyek kiemelt jelentőséggel bírnak a tudományos szakirodalomban. A módszer alkalmazásához szükséges volt olyan modellek kidolgozása, amelyek tág működési tartományon képesek kiszámítani a kocsik fontosabb paramétereit. A modellek felhasználásával már sikeresen elvégezhetők a kocsik hibáival kapcsolatos feladatok megoldásai.

A második aktuátor, amihez kapcsolódóan kutatásaimat végeztem egy ipari projekt kapcsán megismert indítómotor volt. A projekt részeként szükség volt a motor működési körülményeinek szimulálására alkalmas laboratóriumi mérőpad kialakítására. Kiemelt cél volt a motor modelljének kidolgozása a motoron végzett mérések alapján. Az első feladat kapcsán megismert módszerek gyengeségeinek megismerés után egy hiba szeparációs módszer kezdett körvonalazódni, amely nem csak a hiba észlelésére, hanem a rendszerben található hiba nagyságának meghatározására is alkalmas, mindezt előrecsatolt neurális hálózat segítségével. Mivel már az indítómotor modelljei is rendelkezésre álltak, a mérések alapján mesterségesen előállítottam olyan méréseket, amelyek valamilyen paraméterben hibás részeket tartalmaztak. A hibákkal kiegészített mérési adatbázis alapján kidolgoztam egy eljárást a motor jellemző hibáinak észlelésére.

Az irodalomkutatás során azt tapasztaltam, hogy a cikkek nem foglalkoznak kellő mélységben a modell kiválasztásának menetével és az azok hatékonyságát befolyásoló tényezőkkel, ezért

munkám során arra törekedtem, hogy megmutassam a kidolgozott neurális modellek kiválasztásnak problémáját.

Munkám során számos neurális hálózatot betanítottam. A nagyszámú hálózat kidolgozásához szükséges idő komoly méreteket öltött, ezért a dolgozat második felében már egy aktív tanítási módszert dolgoztam ki, amely csökkenteni tudja a hálózat betanításhoz szükséges időt.

A hibadiagnosztikai feladatok megismerése kapcsán megfigyeltem, hogy a struktúrák kiértékeléséről a cikkek igen keveset szólnak. Ennek orvoslására a hibadiagnosztikai rendszer kiértékelési problémája is a vizsgálódásaim középpontjába került.

3. Irodalomkutatás

Dolgozatomban megvizsgáltam a hajtásláncok modellezéséről napjainkban megjelenő tudományos cikkeket kiemelten a neurális hálózatokhoz kapcsolódó publikációkat, illetve a starter motorokhoz kapcsolódó irodalmat is részletesen feldolgoztam modellezés és hibák szempontjából. Mivel dolgozatom főleg a modell-alapú hibadiagnosztika tudományos kutatásával foglalkozik, ezért elsősorban ezen tématerület sokszínű irodalmának tanulmányozására fordítottam a legnagyobb figyelmet. Az alábbiakban ebbe kívánok rövid betekintést nyújtani.

3.1. Hibadiagnosztika irodalma

A hibadiagnosztika irodalma hatalmas méreteket öltött az elmúlt évtizedben és gyorsan bővül napjainkban is. A vizsgált rendszerek változatossága mellett a vizsgálati módszerek tárháza is bő. Rengeteg eredmény található a különféle típusú problémák megoldására.

A hibadiagnosztika témakörében több, a tudományos irodalmat áttekintő, írás született. Isermann javaslatot tesz a hibafelismerés és elkülönítés legfontosabb módszereinek osztályozására a [3] cikkében, de a bemutatott osztályozási struktúrában főleg a hagyományos módszerek kaptak helyet. Manapság az egyik legnépszerűbb megközelítés a hiba észlelés és diagnosztika témakörében a lágy számítási (*soft computing*) technikák alkalmazása. Ezeknek a módszereknek az áttekintésével foglalkozik az [9] irodalom.

Ha egy rendszeren hibadetektálást és hiba izolációt szeretnénk véghezvinni, két lehetőségünk van. Az egyik lehetőség az, ha fizikai redundanciát építünk a rendszerbe, a másik az analitikus redundancia használata [10].

A fizikai redundancia alkalmazásakor a rendszer vizsgált, kritikus komponenseiből több példány is beépítésre kerül [11]. A rendszerben a hiba jelenlétéről egy szavazó alrendszer dönt, ami a redundáns érzékelők értékeit feldolgozva következtetést von le, majd jelzi a hiba jelenlétét [7]. Ez a technika igen költséges megoldás, hiszen egy paraméter mérésére szolgáló szenzorból több darabot is be kell építeni a berendezésbe. Másrészt a rendszer fenntartási költségei és helyigénye is megnő. Sikeresen alkalmazható a módszer járművek ütközésének elkerüléséhez [12], de akár erőművek érzékelőinek meghibásodási jelzésére is [13].

3.2. Analitikus redundancia

Az analitikus redundancia használatakor a rendszer mért paramétereit vizsgálva vagy azokat felhasználva valamilyen matematikai módszer segítségével hozunk döntést a hiba jelenlétéről.

Az analitikus módszerek foglalkozó irodalom igen színes, ami egyrészt a vizsgált rendszerek sokféleségével, másrészt a vizsgálati módszerek változatosságával magyarázható.

A nemlineáris rendszerek, mint például robot rendszerek, analitikus redundancián alapuló vizsgálata és hibadiagnosztikája viszonylag hamar a kutatói társadalom figyelmének középpontjába került. A [14] és [15] források fehérdoboz modelleket használnak a nemlineáris rendszer modellezésére, a szenzoros mérések mellett. Robot rendszerek megfigyelőkön alapú hibadetektálása során a csuklópozíciók és a csuklók sebességértékeinek közelítését számolják főleg a kidolgozott modellek segítségével [16]. A felépített modellek érdekessége, hogy a robusztusság növelése érdekében az észlelési hibát csatolták vissza a modellezés során.

Gépjárműiparban főleg az IFDIA (Instrument Fault Detection, Isolation, and Accommodation) alkalmazására találunk példákat az analitikus redundancia alkalmazásával [17]. Ennél a feladat típusnál a gépjárművek mérő és vezérlőrendszereiben történő meghibásodásokhoz kapcsolódó figyelmeztetések előállítására a cél. Számos hibadetektáló és a hibákat izolálni képes struktúra született a motorvezérlő rendszerek érzékelőinek és beavatkozói vizsgálatához a [18] cikk tanúsága szerint.

Egy lehetséges felosztása a hiba detektálás módszereinek a [19] és [20] cikkek szerint: tudáson (*knowledge based*), jelfeldolgozáson (*signal processing*) vagy modellen (*model-based*) alapú megközelítésekre. A tudás alapú módszereknél, a vizsgált rendszer mély ismerete nincs birtokunkban, csupán a rendszeren végzett mérésekből származó eredmények állnak rendelkezésre. Ebbe a csoportba sorolja a neurális hálózatokat és fuzzy logika alkalmazásának módszereit is a hiba detektálás és osztályozás témakörében.

A jelfeldolgozáson alapuló technikák a jelsorozatok tulajdonságait (pl.: spektrum, statisztikai információk) használják fel egy jel leírására, aminek feldolgozásából következtetni lehet a hiba bekövetkeztére. Egy ilyen technika alkalmazásáról esik szó egy kompresszor monitorozása kapcsán a [21] sorszámú referenciában. Összetett rendszerek vizsgálataikor is jól használható a módszer, hiszen repülő hidraulikai rendszerének [22], illetve turbina felpörgetésének [23] hibajelenségeit is képes kimutatni. Összességében elmondható, hogy a jelfeldolgozáson alapuló módszerek előnye, hogy segítségével egyszerű a hibás és hibamentes állapot elkülönítése [27].

3.2.1. Modell-alapú módszerek

A modell-alapú technikák hasonlóak a jelfeldolgozáson alapuló módszerekhez, azzal a különbséggel, hogy egy modellt használunk a mért jel közelítésére. A mért és szimulált jel különbségét (*reziduál*) képezve kapunk egy jelsorozatot, ami jelzi a rendszerben történő hiba bekövetkeztét. Bőséges irodalom található ebben a témában, ahogy a későbbiekben látható lesz, illetve a [28] és [29] összefoglaló művek is mutatják.

Az eljárás előnye, hogy nem igényel plusz hardver kiegészítést. Mindemellett a modell-alapú hibadiagnózis a priori, igényli a vizsgált (rendszer, manipulátor, hajtás) beható ismeretét [30].

Isermann volt az egyik első, aki hibadetektálást végzett állapot (*state estimation*) és paraméter (*parameter estimation*) becsléssel [8]. Erre a technikára az a jellemző, hogy a vizsgált rendszer és a rendszert alkotó komponensek mély ismerete szükséges az eredményes alkalmazáshoz. Egy robusztus, tág paraméter tartományon, jó eredményeket adó modell felépítése viszont gyakran költséges és időigényes feladat. A hibadetektálás sikere a felépített modellek pontosságán, megbízhatóságán múlik [8].

Az egyik nagy hagyományokra visszatekintő módszer az obszerverek (*megfigyelők*) felépítése és alkalmazása a hibadiagnózisban. Megfigyelők alkalmazására is bőséges anyag található a nemzetközi irodalomban.

Kálmán-szűrő sztochasztikus állapotbecslésre (*state estimator*) való alkalmazásával találkozhatunk FDI feladatokkal kapcsolatosan a [31] irodalomban. A kiterjesztett Kálmán szűrő alkalmazhatóságát mutatják be, jó eredmények mellett, a [33] és [34] referenciák, nemlineáris folyamatok hibadiagnosztikájához kapcsolódóan. Egy DC motor másodrendű, lineáris állapotváltozós (*second order state variable*) modelljét állítják fel a [32] publikációban. A rendszer állapotváltozói a motor armatúra árama és a motor szögsebessége lett. Négy különböző Kálmán szűrőt használ és hasonlít össze a motor árammérő érzékelőinek ofszet jellegű hibáinak kimutatására.

3.2.1.1. Mesterséges intelligencia alkalmazása

A hagyományos megoldásokon kívül használatosak természetesen, a mesterséges intelligencia módszerei is hibadetektálásra és -diagnosztikára. Mivel a módszerek tárháza igen nagy, így azok hibadetektálásra való alkalmazása is igen széleskörű. Számos technika egyedüli használata is megjelenik, de bőséggel van példa a különböző technikák ötvözésére is, hogy az egyes eljárások gyenge pontjait áthidalják.

Mesterséges intelligencia talán egyik legkedveltebb ágának a neurális hálózatok tekinthetők. Nagyszámú publikáció, könyv és előadás születik a módszer hatékony alkalmazásáról napjainkban is. A neurális hálózatok alkalmazását a hibadetektálás témakörében három nagy kategóriába lehet sorolni. Az első csoportba sorolhatók azok az alkalmazások, ahol a hálózatot a hibás és a hibamentes állapot elkülönítésre használjuk. Máskor a neurális hálózatokat osztályozóként (*classifier*) alkalmazzuk. Ekkor a hibák elkülönítése a folyamat modellje és a mért eredmények különbségéből (*residual*) generált mennyiség felhasználásával történik. A folyamat modellje lehet egy matematikai modell, amelynek alapján a hibadiagnosztikai szerkezet felhasználja a vizsgált folyamatok mechanizmusát, amit a fehérdoz modellek szolgáltatnak, így megkönnyítve a neurális osztályozók tanítását. Abban az esetben, ha nem áll rendelkezésére a vizsgált folyamat részletes fizikai modellje, neurális modell is alkalmazható a reziduál képzés fázisában, majd egy másik hálózat használható a hibák elkülönítésére [35], [36].

Az ANN hibadetektálásra és hibadiagnózisra történő alkalmazása, ennek a matematikai apparátusnak a nagyon jó modellközelítési tulajdonságain és minta-felismerési képességén alapszik [37]. Jó eredményeket lehet elérni a mintafelismerés feladata során, de dinamikus minták felismerése nehézségekbe ütközik. A mintafelismerés felhasználható a hiba identifikációs folyamatának megoldására, amely során a hiba nagyságát határozzuk meg. Erre a folyamatra mutat példát a [38] referencia.

Neurális hálózatok mérőrendszerekben történő alkalmazására találunk példákat a [17], [37] irodalmakban a hibadetektálás témakörében. Mérőrendszer szenzor hibáinak kimutatását taglalják neurális hálózat felhasználásával a [39] és [40] cikkek is.

A [41] referencia szenzor validációját valósítja meg neurális hálózat segítségével. A szerzőcsapat két feladatot old meg, az egyik függvényközelítés NN segítségével, a másik feladat során egy autoasszociatív neurális hálózatot használ a nemlineáris főkomponensek kiválasztásához. A felépített modell, ami egy nemlineáris obszerver, analitikus redundanciaként kerül felhasználásra. A kísérletekhez az adatokat és jeleket a redundánsan kötött szenzorok adják, aminek felhasználásával el tudja különíteni a hibásan működő

érzékelőket a hibátlanoktól. A módszer egy turbóventillátor motorjának szimulációja kapcsán kerül bemutatásra.

Egy UAV repülő hibadetektálást végeztek el a [42] cikk írói MLP segítségével. A neurális hálózat segítségével kidolgozott modell analitikus redundanciaként funkcionál. A modell a repülő elfordulási szögét (*angular rate sensor*) adó szenzor kimeneti jelét közelíti. A repülőgép működése közben történik meg a közelített és a szenzor valós értékeinek összehasonlítása. Hiba esetén, a hibás szenzor értéke helyett, a MLP kimenetét használják a repülő a vezérléséhez. Ilyenkor a repülő csökkentett funkcionalitással működik tovább.

Autoasszociatív neurális hálózatot használ egy rakéta motor érzékelőjének validációjára a [43] forrás. A hibás szenzor értékét le lehet cserélni a felépített modell közelített értékére a szabályozó körben.

Centrifugális szivattyú, mint forgó rendszer, hibadiagnosztikáját végzik előrecsatolt neurális hálózat és adaptív rezonancia hálózat (ART1 – Adaptive Resoance neTwork) segítségével a [44] szerzői. A modellek különféle működési kondíciókban egyaránt jól működtek és hét különféle hiba kimutatása és észlelése volt sikeres.

Egyfázisú, 2 póluspárú, kalickás indukciós motor hibadetektálást végeztek el a [45] referenciában. A vizsgált hibák között szerepelt a szigetelési hiba, aminek megjelenése az indukciós motor állórészi tekercselésének állapotával függ össze. A tekercselés meghibásodása főleg a mechanikai rezgések, a hő, a periodikusan ismétlődő terhelés, vagy a kenőanyag elszennyeződése vezették vissza. Másfelől a motor csapágyazásának hibája is kimutatásra került, amit az extrém igénybevétel, rossz kenés, a motor számára túl sok kenőanyag használata, a motor nem megfelelő terhelése, vagy a rossz összeszerelés okozhat. A cikkben leírtak szerint a motort állandósult üzemiállapotban vizsgálták. A kétféle hiba kimutatásához előrecsatolt neurális hálót használtak, aminek bemeneteként a motor állandósult áramértéke, szögsebessége valamint azok négyzetes tagjai szolgáltak. Két hiba szétválasztása volt sikeres.

Néhány irodalomban [46], [47] a hálózati architektúrák alkalmazhatóságát vizsgálták különféle neurális hálózatok eseteiben. A neurális hálózat felépítése kritikus a modellezni kívánt folyamat szempontjából. A használt struktúra típusa, az átviteli függvények típusai, a rejtett rétegek száma, a rétegekben elhelyezkedő rejtett neuronok mennyisége illetve a tanítási faktor (*learning rate*) nagyban befolyásolják a neurális apparátus eredményes alkalmazhatóságát [35].

A fuzzy logika használata is népszerű az irodalomban. A módszer jól alkalmazható a reziduál képzés fázisában a hibadiagnosztika során. Egy DC motor fuzzy modelljének felépítésére mutat példát [48] cikk. Egy elektromos hajtás és a hozzá tartozó hajtásvezérlő modellezését végzi fuzzy logika használatával a [49] publikáció. Jó eredményeket ér el a DC motorból és DC-DC átalakítóból álló rendszer hibadiagnosztikája során. A közölt módszer alkalmazása olyan esetekben előnyös, amikor a rendszer nemlinearitása nem modellezett, vagy ismert ugyan a rendszer matematikai modellje, de a paraméterek validálása nehézkes a nemlinearitások miatt.

A LLNF modellek rokonok a neurális hálózatokkal és a fuzzy logikával egyaránt [50]. Az alkalmazások egy része (pl.: [51]) a hibadiagnosztika területéről kerül ki, azon belül is főleg a különbségképzés fázisából. Egy kis modellrepülőgép online hibaészlelését mutatja be a [52] cikk, LLNF segítségével. Vegyipari alkalmazásra mutat példát [53] jelzésű publikáció, ahol egy forgó cementégető kemence hibadetektálását készítik el. A közölt módszer a LLNF modell rendőségének (*késleltetés – time delay*) meghatározására Lipschitz-elméleten alapuló módszert használtak. A publikációban közölt modell betanításához LOLIMOT algoritmus

került felhasználásra. Három hibajelenség jelzése volt sikeres, amiből kettőt korábban is kimutattak, de a harmadik még a szakértők számára is ismeretlen volt.

3.2.1.2. Hibrid, összetett módszerek a hibadiagnosztikában

Minden tiszta módszer alkalmazásának vannak előnyei és hátrányai. Azért hogy a gyenge pontokat kiküszöböljék, más módszerek alkalmazásával is vizsgálatokat végeztek az alábbi cikkek szerzői.

A [54] cikkben egy dízel és egy benzines belsőégésű motor vizsgálatát végezték. A rendszereken végzett mérésekből származó adatok vizsgálatához főkomponens elemzést használtak. A mért adatok rendszerezésére egy adatbázist hoztak létre még hozzá úgy, hogy vizsgálták az új adatpontok illeszkedését a korábbiakhoz. Ehhez az adatbázis adatpontjainak eloszlásfüggvényeit közelítették. A közelítéshez ellipszis bázisú függvény hálózatot használtak, ami a LLNF egy fajtája. Ezeknek a LLNF modelleknek ellipszis volt a haranggörbék alapsíkjával vett metszete. Ezeknek a speciális bázisfüggvényeknek az alkalmazása azért volt előnyös, mert jobb illeszkedést eredményezett, mint az a kör metszetű hálózatstruktúra esetén tapasztalható volt.

A [55] jelzésű cikkben egy gázturbina motor indítási folyamatának hibadetektálását mutatják be. Több technika, mint például statisztikai, jelfeldolgozási és lágy számítási technikák, együttes alkalmazása mellett kerül sor a rendszer hibaészlelésére. Főkomponens elemzéssel csökkentik a feldolgozásra szánt adatok mennyiségét. Költségfüggvény használatával, a megfelelő tulajdonság vektorok kiválasztása mellett neurális hálózatot alkalmaztak a hibák osztályozására.

Indukciós motor hibadetektálására és a hibák elválasztására mutat példát lágy számítási technika használatával a [56] cikk. A felépített modell kerneljét egy neuro-fuzzy rendszer adja a FasArt, ami egy ART alapú adaptív fuzzy rendszer (ART based Fuzzy Adaptive System). A bemutatott módszer segítségével 15 nem destruktív hiba kimutatása és szétválasztása történt meg. Ez a módszer nem modellalapú, mert a mérések alapján létrehozott adatbázisból volt képes a hibák detektálására és szétválasztására. A kimutatott hibák között szerepel aszimmetrikus tápforrás, a feszültségmérő hibája, ellenállások hibája, enkóder hibája, kiegyensúlyozatlan mechanikai terhelés valamint, feszültségmérők és árammérők hibái. A cikk foglalkozik még a tudás (*knowledge*), nyers adatokból való kinyerésének folyamatával is.

Az ismert technikák hierarchikus majd az egyes szinteken belül a különféle módszerek együttes használatából született eljárás az adatfűzés technika. Ezt a módszert ott alkalmazzák, ahol több érzékelő jele is a rendelkezésre áll egyszerre. A nagy mennyiségű adat feldolgozása és kiértékelése komoly feladat. Érzékelők hibáinak kimutatását végzik a [57], [58] irodalmakban hadászati illetve békés célú felhasználásra egyaránt.

A korábbiak alapján látható hogy nagyon színes az alkalmazott módszerek tárháza. Minden technikának megvan maga előnye és hátránya, de egyértelműen nem mondható ki az, hogy egy adott problémára egyik vagy másik eljárás a megfelelő, egyedüli megoldás.

Összefoglalva elmondható, hogy a fizikai redundancia alkalmazása csak olyan helyeken jellemző, ahol követelmény a biztonságos működés és a módszer alkalmazásával járó költség vonzat nem jelent akadályt. Az „egyszerűbb” alkalmazásokban jelfeldolgozáson és modelleken alapuló módszerek alkalmazása az elterjedt. Az előbbi főleg a vizsgált rendszer hibás és hibátlan működésének elkülönítésére alkalmas, utóbbi komolyabb hibaanalízist tesz lehetővé. Abban az esetben, ha rendelkezésre áll a vizsgált rendszer beható ismerete és rendszer jól közelíthető lineáris egyenletekkel, akkor a paritás egyenletek és obszerverek

alkalmazása lehet a célravezető. Ezeknél a módszereknél a vizsgált rendszer változáskövetés viszonylag kis energia befektetéssel kivitelezhető. A komolyabb nemlinearitásokat tartalmazó folyamatok és rendszerek vizsgálatához a mesterséges intelligencia különféle módszerei magukban vagy több módszer együttes alkalmazásával is célravezető lehet. A módszerek szinergiájával egészen odáig el lehet jutni, hogy többszintű hierarchikus hibadiagnosztikai szakértő rendszerekről beszélünk.

4. Vizsgálati módszerek a hajtáslánc esetén


A disszertációnak ebben a részében egy hajtáslánc modellezésével és hibadiagnosztikájával foglalkozom. A hajtásláncokhoz kapcsolódó irodalom áttekintése után röviden bemutatom a vizsgált rendszert, majd a felépített modelleket. A fejezet utolsó részében a rendszer hibáinak észleléséhez kapcsolódó feladatot mutatom be és végzem el a vizsgált berendezés pár lehetséges hibájának ismertetése mellett. Megmutatom az egyik hiba identifikációját és a különféle hibák szétválasztását is elvégzem. A munka során vizsgálom a kifejlesztett módszerekben alkalmazott neurális hálózatok struktúrájának hatását a hibadiagnosztikai feladatok eredményeire.

4.1. A vizsgált rendszer

A kísérleti olajfúrások során a furatból kiemelt kőzetmag korának egyik legfontosabb jellemzője a kőzetben lévő kálium, urán és nátrium gamma spektrumának mértéke. A helyszíni gamma-log regisztrátum mélységadatainak pontosításához a kiemelt kőzetszelvényeket laboratóriumi körülmények között is megvizsgálják. A fúrás helyszíni eredményeinek és a laboratóriumi vizsgálatok eredményeinek korrelációjából a kőzet mélységének meghatározása pontosítható. A mérések során az egyik legfontosabb kritérium, hogy a felvett gamma spektrum és a hozzá tartozó mélységértékek ne csússzanak el egymáshoz képest. Ehhez a gammasugárzás mérő detektor minél pontosabb mozgására van szükség. Egy mobil gamma-log berendezés (MGL-01F) került kifejlesztésre a Miskolci Egyetem Alkalmazott Földtudományi Kutatóintézetének, Műszerfejlesztési és Informatika Osztályán. A gammasugárzást mérő detektor egy kis kocsiban található, ami egy speciális sínrendszeren halad, a kőzetmag felett. A kocsi mozgásához szükséges villamos energia, a mért adatok valamint a vezérlő-számítógép felől kapott parancsok egy energialánc segítségével jutnak el a kocsira.

A berendezés hajtását egy 200 W-os AC szervomotor adja, ami valójában egy PMSM motor nagy felbontású növekményes jeladóval felszerelve. A motor kihajtótengelyére egy 70-es lassító áttételű csigahajtómű csatlakozik. A kocsi bal hátsó kereke a hajtott kerék. A rendszer pontosságáról egy jeladó gondoskodik, ami a berendezés bal első kerekéhez csatlakozik. A jeladó a kocsi sínen történő haladásának pontos visszajelzéséért felelős. A rendszerkomponensek főbb paraméterei valamint azok elhelyezése a 1. ábrán látható.

A modellezés során ezt a hajtásláncot vizsgáltam, modelleztem és a rendszerben előforduló hibák észlelését megvalósító módszert mutatok be.



1. ábra:

A Gamma-log hajtáslánca és jeladója

4.2. Vizsgált lehetséges hibák

A hibavizsgálatok során, három a rendszerben bekövetkező, lehetséges hibát szimuláltam, detektáltam, identifikáltam és izoláltam. Ezek a hibák a rendszerbe épített szenzorok meghibásodásához köthetők, de a mechanikai konstrukció hibáiból is fakadhatnak.

A három vizsgált hiba, a kész Gamma-log rendszeren történt előzetes vizsgálatok alapján a következők lettek: a) a jeladó működésének teljes leállása; b) rendszerben mérhető, visszavisszatérő, rendszeres hiba, valamint c) a motor armatúrájában bekövetkező változás okán létrejövő feszültség emelkedés.

Annak érdekében, hogy minősíteni lehessen a hibadiagnosztikára kidolgozott módszer jószágát, annak reakcióidejét és pontosságát vizsgálom a különféle esetekre.

A hibajelenségeket mesterségesen hoztam létre a mérésekből származó formázott mintakészleteken. Az azonos típusú hibák számának és az előfordulásuk pontos idejének ismeretében létrehozható a hiba bekövetkeztének idejére utaló riasztás függvény. Ez a függvény lesz a neurális hálózatoktól megkívánt jelsorozat. Az egyes hálózat típusok közelítése és a riasztás függvény különbsége vizsgálható és az eredmények alapján értékelhető a felépített hibadiagnosztikai módszer pl.: detektáló-képesség. Az egyes esetekben vizsgáljuk a módszerek képességeit és korlátait, valamint a használt hálóstruktúrák eredményre gyakorolt hatásait is.

4.3. Eredmények bemutatása

Megalkottam egy AC szervo hajtást, csigahajtóművet tartalmazó hajtáslánc, tág paraméter tartományon megfelelő pontossággal működő elmozdulás és sebesség közelítését megvalósító nemlineáris, LLNF alapú modelljeit. A becslők bemenetként a gerjesztő áram és a vonali

feszültségek saját koordináta-rendszereikbe transzformált alakjukat használják. A modellek kidolgozásához szükséges mennyiségeket, pl.: transzformált áram, transzformált feszültség, a valós rendszeren történt mérésekből származtattam. A modellek kidolgozása során megvizsgáltam a regresszor modellre gyakorolt hatását és bemutattam, hogy az általam választott PCC értéken alapuló teljesítményindex meghatározás jobb eredményt mutat, mint az irodalmakban javasolt MSE-n alapuló megoldás.

Megvizsgáltam a hajtáslánc, valamint a Gamma-log kocsik lehetséges hibáit. A mérésekből nyert adatok felhasználásával, mesterségesen előállítottam három, a kocsira jellemző hibatípus mintát, melyek felhasználásra kerültek a hibamentes állapot és a különféle impulzusszerű hibatípusok külön-külön jelzésére alkalmas, multi-modell alapú, analitikus redundancia témaköréhez tartozó, mesterséges intelligenciára épülő, hibadetektáló rendszer kiépítéséhez.

A detektáláson túl kidolgoztam az egyik hiba azonosítását elvégezni képes eljárást is.

A különféle hibák szétválasztására és időben történő jelzésére kidolgoztam egy hibadiagnosztikai rendszert, amely jó hatásfokkal képes a hibák szétválasztására.

Megvizsgáltam a módszereket befolyásoló tényezőket, úgy, mint az alkalmazott neuronok száma, hálóstruktúra, neuronstruktúra. Arra a következtetésre jutottam, hogy Elliott-neurontípus alkalmazása a rejtett és a kimeneti rétegben jobb eredményt produkál, előnyösebb, mint az irodalomban elterjedten alkalmazott szigmoid és lineáris kombinációjú aktivációs függvények használata. Ez a megállapítás a hibadetektálási és szétválasztási feladatokhoz kapcsolódóan érvényes.

5. Indítómotor hibadiagnosztikáját megvalósító módszer

Disszertációmnak ebben a fejezetében, az irodalom áttekintése után, egy indítómotort modellezek kétféle, a mesterséges intelligencia témakörébe tartozó módszer segítségével. A különféle eljárások összehasonlítása, alkalmazási előnyeiknek és hátrányaiknak felderítése nagy figyelmet érdemlő terület a tudományos kutatásnak. Fontos a modellek objektív összehasonlítása, az eredmények kritikus értékelése. Ehhez kapcsolódóan végeztem kutatásaimat. Modelleket dolgoztam ki, amelyek a valós eszközön történt mérések alapján kerültek kialakításra.

A modellek felhasználásával egy több-modelles hibadiagnosztikai rendszert fejlesztettem ki, amely képes a rendszert jellemző mennyiségek additív, ofszetszerű hibáinak kimutatására. A módszert impulzusszerű hibák észlelésére fejlesztettem ki, így a kiértékelést is ennek figyelembe vételével alakítottam ki. A bemutatott módszer nemcsak a hibák szétválasztását képes megtenni, hanem információt is ad a rendszerben lévő hiba nagyságáról is.

A vizsgálatok során alkalmazott kiértékelési eljárás két részből áll, egyrészt értékeltem a hibák pontos megjelenéseinek és megszűnéseinek idő viszonyait a tényleges eseményekhez, másrészt meghatározásra kerül, hogy a diagnosztikai rendszernek a detektált hiba nagyságára való közelítése mennyire korrelál a tényleges hibanagysággal. A hibadiagnosztikai módszernél megvizsgáltam a felhasznált modellek eredményre gyakorolt hatását is.

A hibadiagnosztikai struktúra alapjául egy neurális hálózat szolgál, aminek tanításánál egy aktív tanítási módszert fejlesztettem ki, ami hibadiagnosztikai esetekben lerövidíti a tanítás idejét és lecsökkenti az erőforrás-szükségletet is.

Az irodalmi források csak keveset szólnak a leghatékonyabb modell megtalálásának módjáról, inkább csak eredményeket közölnek. Szintén kevés szó esik a szétválasztó, osztályozó

struktúrák eredményességének értékelési mechanizmusáról. Általában a kiértékelés procedúrájának leírása hiányos, kevés részletet bemutató. A struktúrák érzékenység vizsgálatának eredményei sem kerülnek közlésre a vizsgált referenciákban. Ezeknek a tulajdonságoknak a vizsgálata fontos a módszerek finomhangolása szempontjából.

5.1. Legjellemzőbb hibalehetőségek az indítási folyamat alatt

Egy jármű indítási folyamata során, rövid idő leforgása alatt, kell az indítózáshoz beszerelt aktuátornak nagy teljesítményt leadnia. A nagy igénybevétel miatt, az indítási folyamat során, számos hibalehetőség fordulhat elő, aminek elkerüléséhez nagy odafigyelésre van szükség a felhasználó és a mérnökök szempontjából egyaránt. A leggyakrabban előforduló, legnagyobb odafigyelést igénylő hibák a következők lehetnek az [59] irodalom alapján.

- Összeszerelési pontatlanság miatt fellépő mechanikai hibák.
- Akkumulátor tápfeszültség hiba.
- Indító kábel meghibásodása, átmeneti ellenállás növekedése.
- A hajtófogaskerék hibája, kopása. [60].
- A starter motor tekercseinek sérülése, menetzárlata.
- Csatlakozási pontokon az ellenállás növekedés.
- A kefe hibák.

5.2. Eredmények bemutatása

Kidolgoztam egy indítómotor sebesség és nyomaték értékeinek közelítésére alkalmas, prediktív, nemlineáris NARX MISO előrecsatolt neurális hálózaton alapuló modelljeit, amelyek tág bemeneti paraméter tartományon működnek a motor áramának és kapocsfeszültségének felhasználásával.

A kidolgozott modelleket összehasonlítottam más modell típusokkal és bizonyítottam, hogy a felépített NARX, MISO modell jobban teljesít hasonló körülmények között, mint az értékeléshez használt SISO és keresőtáblás modellek teljesítménye.

A kiválasztott modellek felhasználásával elvégeztem a rendszer modell alapú, többmodelles, hibadiagnosztikáját előrecsatolt neurális hálózat segítségével. A felépített diagnosztikai rendszer nem csak a hibák bekövetkezési idejének megállapítására, hanem a hiba nagyságának közelítésére is alkalmas. A felépített struktúra működéséhez szükséges egy-egy a sebesség és a nyomaték közelítésére alkalmas megfigyelő, továbbá a kimenetek korábbi időpillanathoz tartozó értékei. A hiba szétválasztására és diagnosztikára alkalmas struktúra tanításához, értékeléséhez és teszteléséhez mintakészleteket alakítottam ki a korábban elvégzett mérések felhasználásával.

Kidolgoztam egy algoritmust, amelynek alkalmazása mellett, az előrecsatolt neurális hálózatok osztályozási feladatokra visszavezethető, hibadiagnosztikai alkalmazásokban a hálózat betanítási ideje jelentősen lerövidül. A kidolgozott eljárás az aktív tanulás módszerét alkalmazza, vagyis a tanítási procedúra alatt a mintakészlet pontjai és így vele a hossza is változtatásra kerül. Az algoritmus az MSE kritériumfüggvényt használja a szükséges pontok beválogatásához. A közölt módszer, implementálásra került C/C++ nyelven.

Kidolgoztam egy, a hibadiagnosztikai feladatok értékelésére alkalmas eljárást, amely külön értékeli a hiba detektálásának hatékonyságát és a hiba nagyságának közelítési képességét.

A hiba észlelés pontosságát a hibák megjelenési és megszűnési időinek vizsgálataival, illetve a valós és a közelítő hibák viszonyainak módszeres összehasonlításával éri el. A jelsorozatokban az élek megtalálásához Canny éldetektáló algoritmust használtam. Az észlelés kiértékeléshez bevezettem egy ÉFK [%] mérőszámot.

Elvégeztem a hiba diagnosztikai rendszer modellekre történő érzékenység vizsgálatát és arra következtetésre jutottam, hogy a hibadiagnosztikához használt neurális módszer teljesítménye jelentősen romlik, ha a betanításhoz használt modellnél gyengébb teljesítményű modelleket alkalmazunk. Jobb teljesítményű modellek alkalmazása a kidolgozott eljárás eredményességét jelentősen nem befolyásolja.

Új tudományos eredmények

Az értekezés új tudományos eredményeit az alábbi tézisek foglalják össze:

1. Tézis

Neurális hálózatokon alapuló módszert dolgoztam ki egy elektromechanikus hajtáslánc modellezésére és megalkottam a rendszer tág paraméter tartományos működő, az aktuátor elmozdulásának és sebességének becslésére alkalmas nemlineáris, LLNF alapú modelljeit. A modellek felhasználásával megvizsgáltam több jellemző hiba típus észleléséhez szükséges neurális hálózat kialakítást és megállapítottam, hogy a detektáló MLP hálózat, NARX dinamika használata mellett, az Elliott neurontípus alkalmazása a rejtett és a kimeneti rétegben jobb eredményt ért el, mint az irodalomban elterjedtebb szigmoid és lineáris aktivációs függvények. [s5], [s13], [s32], [s33], [s34], [s37]

A felépített modell bemenetként a gerjesztő áram és vonali feszültségek transzformáltját használja. A valós rendszeren történt mérésekből előállítottam a hálózat betanításához szükséges mintakészleteket. Az optimális modell megtalálásához egy PCC alapú teljesítményindexet használtam.

A modell hatékonyságát igazolja, hogy a modellt felhasználtam hibadiagnosztikai feladatok elvégzéséhez, amihez megvizsgáltam a hajtáslánc, valamint a Gamma-log kocsi lehetséges hibalehetőségeit. A mérésekből nyert adatok felhasználásával, mesterségesen előállítottam három, a vizsgált kocsi jellemző hibatípus mintáit, amelyek felhasználásra kerültek a hibamentes állapot és a különféle hibatípusok külön-külön jelzésére alkalmas, multi-modell alapú, analitikus redundancia témakörébe tartozó, mesterséges intelligenciát alkalmazó, hibadetektáló rendszer kiépítéséhez.

Ugyancsak a korábban felépített modellek felhasználásával kidolgoztam az egyik hiba identifikációját elvégezni képes, előrecsatolt neurális hálózatot alkalmazó struktúrát és vizsgáltam a struktúra eredményre gyakorolt hatásait.

A különféle hibák szétválasztására és időben való jelzésére kidolgoztam egy hibadiagnosztikai rendszert. Megvizsgáltam a módszert befolyásoló tényezőket úgy, mint rejtett réteg neuronjainak száma, alkalmazott hálóstruktúra.

2. Tézis

Kidolgoztam egy többmodelles, előrecsatolt neurális hálózatot alkalmazó hibadiagnosztikai módszert. Igazoltam, hogy a módszer alkalmas a vizsgált rendszerben felmerülő jellemző hibák észlelésére és a hiba nagyságának becslésére. [s4], [s8], [s9], [s16], [s28], [s30], [s31]

A felépített struktúra működéséhez szükséges a vizsgált aktuátor rendszer megfelelő pontosságú, kimeneti mennyiségeinek (pl.: sebesség és nyomaték) vagy azok deriváltjainak becslését szolgáltató modellek létezése, illetve a kimenetek korábbi időpillanathoz tartozó értéke.

A kidolgozott rendszer kimeneteinek száma megegyezik a rendszerben található, jelzésre szánt hibák számával. A generált hibajelek megjelenése a rendszerben megjelenő hibáira utal, a nagysága arányos a rendszerben található hiba nagyságával.

A módszer hatékonyságát a 3. tézisben meghatározott modell felhasználásával bizonyítottam.

3. Tézis

Kidolgoztam egy indítómotor tág működési tartományon érvényes, nemlineáris, többretegű neurális hálózaton alapuló, NARX regresszorral ellátott, MISO modelljét. A modell felhasználásával hibadiagnosztikai rendszert dolgoztam ki. A kidolgozott hibadiagnosztikai rendszer érzékenységvizsgálata során megállapítottam, hogy a diagnosztikai rendszer eredményessége jelentősen romlik a betanításhoz alkalmazott modellek MSE értékéhez képest alacsonyabb MSE értékű modellek alkalmazásakor, míg egy ahhoz képest jelentősen pontosabb modell használata nem növeli érdemben a diagnosztika teljesítményét. [s4], [s8], [s9], [s16], [s28], [s30], [s31], [s35]

A modell bemenetként a kapocsfeszültséget és a gerjesztő áramot használja. A modell felépítéshez szükséges eredményeket a valós aktuátoron készült mérésekből nyertem. A felépített modell teljesítményét összehasonlítottam alapjaiban más elveken működő modellek hatékonyságával.

A hiba szétválasztására és diagnosztikára alkalmas struktúra tanításához, értékeléséhez és teszteléséhez mintakészleteket alakítottam ki a korábban elvégzett mérések felhasználásával.

4. Tézis

Kidolgoztam egy aktív tanításon alapuló algoritmust, amelynek alkalmazása mellett, az előrecsatolt neurális hálózatok osztályozási feladatokra visszavezethető hibadiagnosztikai alkalmazásokban a hálózat betanítási ideje jelentősen lerövidül. [s34], [s35], [s38]

A módszer az aktív tanulás módszerét alkalmazza, vagyis a tanítási procedúra alatt a mintakészlet pontjai és így vele a hossza is dinamikusan változtatásra kerül. Az algoritmus az négyzetes hiba kritériumfüggvényt használja szükséges pontok beválogatásához.

Megvizsgáltam az algoritmust legjobban befolyásoló paramétereiket, mint új mintakészlet előállítási frekvencia, a tanított hálózat bemeneteinek száma, az alkalmazott tanítási algoritmus, különféle alkalmazott hálózat struktúra típusok. Arra a következtetésre jutottam, hogy NFIR és NARX struktúrákhoz egyaránt jól használható illetve az algoritmus alkalmazásával elért tanítási idő nyereség, a hálózat nagyságával arányosan csökken. Azonos kiindulási feltételek mellett összehasonlítottam az algoritmus teljesítményét több hagyományos passzív tanító algoritmussal és megállapítottam, hogy az algoritmus Rprop tanítási eljárás használata mellett produkálja az időnyereséget legnagyobb mértékben.

5. Tézis

Kidolgoztam egy, a hibadiagnosztikai feladatok értékelésére alkalmas eljárást, amely külön értékeli a hiba detektálásának hatékonyságát és a hiba nagyság becslésének teljesítményét. [s34], [s35], [s38]

A hiba észlelés pontosságát a hibák megjelenési és megszűnési idejeinek vizsgálataival, illetve a rendszerben lévő valós és a diagnosztikai rendszer generálta közelítő hibák viszonyainak módszeres összehasonlításával éri el. A jelsorozatokban az élek megtalálásához Canny éldetektáló algoritmus használata javasolt. Az impulzusszerű hibák kiértékeléséhez bevezettem a hibadiagnosztikai rendszer kimeneti jelsorozataiban megjelenő generált élek és a vizsgált rendszerben észlelt hibaimpulzusok felütásainak és megszűnéseinek viszonyából számítható ÉFK [%] mérőszámot. A mérőszámot több feladatnál sikeresen alkalmaztam a kiértékelés leegyszerűsítésére. A hiba nagyság összehasonlításához és kiértékeléshez az átlagos relatív hibát használtam.

Továbbfejlesztési lehetőségek

A modell alapú szabályozások és hibadiagnosztikák egy-egy igen dinamikus fejlődő részterületei a mai műszaki tudománynak. A széles alkalmazási terület jelentős továbbfejlesztési teret kínál a kidolgozott módszereknek. A kidolgozott módszerek gyakorlatilag minden nemlineáris modellt felhasználó területen eredményesen alkalmazhatók. Az alábbiakban néhány szorosan kötődő ötletet emelek csak ki a rendelkezésre álló nagyszámú lehetőségéből:

Az aktuátorok modellezésének témaköre számos nyitott kérdést kínál a kutatók és az érdeklődők számára. Összetett, sok nemlineáris elemet tartalmazó mechatronikai rendszerekben különösen ígéretes a mesterséges intelligencia módszereinek használata. Miután a mesterséges intelligencia tudománya is folyamatosan fejlődik, így fontos feladat az új módszerek és eszközök megismerése és hasznosítása a témakörben. Visszacsatolt hálózatok alkalmazási lehetőségei, dinamikus neuron típusok hálózatszintű alkalmazása, ami természetesen magával vonja a stabilitási problémákat és egyéb kérdéseket. Az adaptív és az öntanuló neurális hálózat-alapú módszerek fejlesztése is további eredményeket hozhat.

Az elektro-hidraulikus és elektro-pneumatikus aktuátorok – jellegüknél fogva – még az elektromechanikus aktuátorokhoz képest is jelentősebb nemlinearításokat tartalmaznak. Ilyen rendszereknél a mesterséges intelligencia módszerek alkalmazásának kiemelt jelentősége van.

A hálózat típusokon túl érdekes kérdés lehet az optimális mintakészletek kialakításának problémája. Erre részben, osztályozási feladatok esetére, megoldást adhat az aktív tanítás módszere, de annak alkalmazhatóságához még maradtak nyitva kérdések, amiknek tisztázása további munkát igényel.

A neurális hálózatok tanításánál érdekes kutatási téma lehet, a bemeneti vektor dimenziójának meghatározása (*dimenziócsökkentés, tulajdonság kiválasztás, transzformációk alkalmazási lehetőségei*) a gyorsabb konvergencia érdekében illetve javaslat a mintakészletek információi alapján az optimális neurális hálózat nagyságára.

Közvetlen ipari alkalmazásokban az elosztott folyamatirányító rendszerekben (DCS – Distributed Control System), felsőszintű vezérlés (host szinten), általában adottak a mesterséges intelligencia egynéhány ágának (neurális hálózatok és fuzzy logika) alkalmazási lehetőségei. Lehetséges egy aktuátor egység vagy intelligens szenzor például szabályozószelep modell alapú hibadiagnosztikájának implementálása ipari környezetben. A modell alapú hibadiagnosztikával lehetőség adódna a vizsgált folyamat és az aktuátorok figyelmeztető jelzéseinek csökkentésére illetve a hamis hibajelzések számának csökkentésére.

Az indítómotoros fejezetben közölt diagnosztikai rendszer felkészítése további hibatípusok jelzésére, azok szétválasztására egy további feladat lehetne. Az intelligens starter motorok megjelenésével lehetőség van a kidolgozott módszernek a motor vezérlőrendszerébe történő integrálására.

Továbblépési irány lehet az aktív tanítási módszer alkalmazási lehetőségeinek vizsgálata a különféle regressziós feladatok, különféle mintakészletek és különféle neuron típusok eseteire. Az aktív tanítási feladat adaptivitásának vizsgálata, amely során a konvergencia növeléséhez a mintakészlet frissítési periódusát is változtatni lehetne. Ezzel nem csak a mintakészlet változna, hanem a mintakészlet változtatásának periódusa is.

Summary

This dissertation deals with the modelling of a simple and a complex actuator using artificial intelligence methods. The required data to develop the models were collected from measurements carried out on real actuators. During the development of non-linear models I focussed on the examination of the applied mathematical structure and the results of the models. I investigated the influence of the regressor of a neural network on the results. The developed models, which work on wide range of parameters, used the transformed current and voltage as inputs and generate the estimation of velocity or torque as the output with a narrow margin of error.

The developed nonlinear models were used to solve problems of fault diagnostics. The elaborated neural structures for fault diagnostic, fault identification and fault separation, which work at above 90 % efficiency, are introduced in the first part of the dissertation. During the investigation of the applied structures the size and type of networks are analysed.

In the second part of the dissertation a method is introduced for fault diagnostics that is based on a feedforward neural network. The demonstrated structure can determine the occurrence of fault in the system and can generate a fault signal which is proportional with the fault in the system. The method requires the estimators of the proper parameters of the analysed system. The detailed separator structure uses the measured parameters, outputs of observers of the actuator and the transformed value of the inputs. The number of inputs of the structure is equal to the number of faults of the analysed system. The value of the outputs is proportional with the extent of the fault in the actuator system.

For the evaluation of the neural diagnostic system test epochs were generated, which can be used to test the structure in a unique way. The ability to determine the occurrence of faults and the ability to estimate fault size were evaluated separately. The evaluation of the occurrence of faults was analysed by the, the appearance and disappearance of the impulse shaped faults, and a systematic comparison was carried out of the relations of faults in the real system and the generated fault signals of the neural network. An automatic Canny edge detection algorithm base method was developed to find the edges in the signals. The ERA (Edge Recognition Ability) percentile index number was introduced and developed to evaluate the relation of the detected rising and falling edges in the epochs. The influence of the regressors in the separator, the complexity of the structure and the observers used to detect to the efficiency of the elaborated separator structure were analysed.

An active training algorithm, which can reduce the training time of the networks in classification problems in fault diagnostic applications, was developed to train the fault diagnostic neural networks. The developed algorithm is based on the active training method. This means that the training epoch is changed in determined epochs during the training process. The data points of the new epoch are selected using squared error (SE) value of the actual point from the base training set. If the SE of the selected data point is higher than the mean squared error of the base training epoch, the data point is sorted to the new epoch. A significant reduction in training time can be achieved using the developed algorithm. I investigate the efficiency of the algorithm in different parameter configurations of the networks (e.g. refreshing period of the training epoch, size of the network, applied training algorithm). I conclude from the investigation the main parameters of the active training algorithm.

New scientific results

Thesis 1

A neural network based method was developed for modelling electromechanical drive chain and nonlinear LLNF based models, which work on a wide range of parameters of the system. The models were created to estimate the movement and velocity of the system. Using the developed models I investigate several neural network configurations which were capable of detecting typical fault types of the system. From the investigation I determined that a separator MLP network structure using NARX external dynamics achieves better result with an Elliott activation function in hidden and output layers than using the well-publicised sigmoid and linear neuron types. [s5], [s13], [s32], [s33], [s34], [s37]

The developed models use the transformed values of the excited current and line-voltages as inputs. The training datasets for the networks were developed using measurements on a real system. A PCC based performance index was used to find the optimal models.

The application of the models for fault diagnostic problems verifies the efficiency of the models. For this reason I investigated the passible fault of the system and Gamma log. I artificially generated three patterns of the analysed typical fault of the track using the data of the measurements, which I used to develop a multi-model, artificial intelligence based analytical redundancy fault detection system for the fault detection of sets.

I worked out a feedforward neural network structure to solve the fault identification problem for one type of faults using previously developed models. I investigated the influence of the structure of the neural network on the result.

I devised a fault diagnostic system which is capable of detecting the fault of the system in time and can distinguish between the different faults of the system. I investigate the method such as number of hidden neurons and applied neural structure.

Thesis 2

I devised a multi-model, feedforward neural network based fault diagnostic method. I certify that the method is suitable for detecting typical faults in the system and it can estimate the size of the faults. [s4], [s8], [s9], [s16], [s28], [s30], [s31]

The operation of the structure requires observers which are able to generate accurate output values (e.g. velocity or torque) or a derivative of the outputs of the analysed actuator system and the values of the outputs in earlier time steps.

The number of the outputs of the developed system is equal to the number of indicated faults in the system. The appearance of a fault signal alludes to the presence of the fault in the real system, while the size of the signal is proportional with the size of the fault in the system.

I verify the efficiency of the method using the model from Thesis 3.

Thesis 3

I set up a nonlinear, multilayer neural network based MISO model with NARX regressor of a starter motor, which is valid in a wide operational range. I developed a fault diagnostic system using the model. I determined during the sensitivity analyses of the developed fault diagnostic system that the efficiency of the diagnostic system significantly decays when using lower MSE valued models compared to the MSE value of the models from the training

process, but significantly more accurate models do not modify notably the result of the diagnostics. [s4], [s8], [s9], [s16], [s28], [s30], [s31], [s35]

The model uses the terminal voltages and exceeding current as inputs. The models were developed based the data of measurement on the real system. I compared the efficiency of the developed model with fundamentally different models.

I set up datasets of fault separation and the diagnostic system for training, evaluation and test purposes, using the earlier measurements.

Thesis 4

I devised a heuristic algorithm based on active training, which can reduce the training time of feedforward neural networks in fault diagnostic application in the case of classification problems. [s34], [s35], [s38]

The method uses the active training algorithm, thus the points of training dataset and also the size of the set can change dynamically. The algorithm uses the mean squared error as the criteria to select the points for the new dataset.

I investigated the main parameters of the algorithm: frequency of epoch generation epoch, number of inputs of trained network, applied training algorithm, different type of networks structures. I was led to the conclusion that the algorithm is compatible with NFIR and NARX structures and the amount of time saved proportionately decreases with increasing network size. I compared the efficiency of the developed algorithm with the original algorithm using the same initial parameters and several training algorithms, and I established that the new method produces the most significant time savings if a Rprop algorithm is applied.

Thesis 5

I devised a method for evaluation of fault diagnostic problems which separately evaluates the efficiency of the detection and estimation of the size of the fault. [s34], [s35], [s38]

The method measures the accuracy of the fault detection using the appearance and disappearance of faults, in addition to the comparison of real faults in the system and the generated fault signals of the detection system. A Canny edge detection algorithm is recommended to find the edges in the signals. I introduce the EFK index number to evaluate the impulse shaped faults, which can be calculated from the rising and falling edges of the output signals of fault diagnostic system and detected fault impulses in the real system. The index number was used in several cases successfully to simplify the evaluation of the problem. Mean squared error was used to evaluate and compare the size of the fault.

Felhasznált irodalom

- [1] Raffai, M.: *Az információrendszerek fejlesztésének módszertana*, Egyetemi jegyzet, Széchenyi Egyetem, 2014.
- [2] Botzheim, J.: *Intelligens számítástechnikai modellek identifikációja evolúciós és gradiens alapú tanuló algoritmusokkal*, Ph.D. Értekezés, Budapesti Műszaki és Gazdaságtudományi Egyetem, Villamosmérnöki és Informatikai Kar, Távközlési és Médiainformatikai Tanszék, Budapest, 2007.
- [3] Isermann, R.; Balle, P.: *Trends in the application of model based fault detection and diagnosis of technical processes*. 13th World Congress of IFAC, San Francisco, USA, 1996, pp. 1–12.
- [4] Frank, P. M.; Koppen-Seliger, B.: *New developments using AI in fault diagnosis*, Engineering Applications of Artificial Intelligence, 10, 1997, pp. 3–14.
- [5] Frank, P. M.; Koppen-Seliger, B.: *Fuzzy logic and neural network applications to fault diagnosis*, International Journal of Approximate Reasoning, 16, 1997, pp. 67–88.
- [6] Leger, R. P.; Garland, W. J.; Poehlman, W. F. S.: *Fault detection and diagnosis using statistical control charts and artificial neural networks*, Artificial Intelligence in Engineering, 12, 1998, pp. 35–47.
- [7] Palade, V.; Bocaniala, C. D.; Jain, L.: *Computational Intelligence in Fault Diagnosis*, Springer-Verlag, London, Limited, 2010.
- [8] Isermann, R.: *Process fault detection based on modelling and estimation methods; A survey*, Automatica, 1984, pp. 387–404.
- [9] Calado, J. M. F.; Korbicz, J.; Patan, K.; Patton, R. J.; Sa Da Costa, J. M. G.: *Soft computing approaches to fault diagnosis for dynamic systems*, European Journal of Control, 7, 2001, pp. 248–286.
- [10] Mehranbod, N.; Soroush, M.; Panjapornpon, C.: *A method of sensor fault detection and identification*, Journal of Process Control, 15, 2005, pp. 321–339.
- [11] Park, S.; Lee, C. S. G.: *Fusion-based sensor fault detection*, Proceedings of International Symposium on Intelligent Control, Chicago, IL, 1993, p. 156.
- [12] Alag, S.; Goebel, K.; Agogino, A.: *A methodology for intelligent sensor validation and fusion used in tracking and avoidance of objects for automated vehicles*, Proceedings of American Control Conference, Seattle, WA, 1995, p. 3647.
- [13] Dorr, R.; Kratz, F.; Ragot, J.; Loisy, F.; Germain, J. L.: *Detection, isolation, and identification of sensor faults in nuclear power plants*, IEEE Trans. Contr. Syst. Techn., 5, (1), 1997, p. 42.
- [14] Frank, P. M.: *Fault diagnosis in dynamic system using analytical and knowledge based redundancy-a survey and some new results*, Automatica, Vol. 26, No. 3, 1990, pp. 459–474.
- [15] Michael, A. D.; Marios, M. P.: *Incipient fault diagnosis of dynamical systems using online approximations*, IEEE Transactions on Automation Control, Vol. 43, No. 11, 1998, pp. 1612–1617.
- [16] Fabrizio, C.; Walker, D. I.: *Observer-based fault detection for robot manipulators*, Proc. of the IEEE Int. Conf. on Robotics and Automation, Vol. 4, No. 3, 1997, pp. 2881–2884.

- [17] Betta, G.; Pietrosanto, A.: *Instrument fault detection and isolation: state of the art and new research trends*, IEEE Trans. on Instrumentation and Measurement, Vol. 49, (1), 2000, pp. 100–107.
- [18] Rizzoni, G.; Min, P. S.: *Detection of sensor failures in automotive engines*, IEEE Trans. on Vehicular Technology, 40, 1991, pp. 487–500.
- [19] Boullart, L.; Krijgsman, A.; Vingerhoeds, R. A.: *Application of Artificial Intelligence*, Process Control, Oxford: Pergamon Press, 1992.
- [20] Oosterom, M.; Babuska, R.; Verbruggen, H. B.: *Soft computing applications in aircraft sensor management and flight control law reconfiguration*, IEEE Trans. on Systems, Man and Cybernetics, Part C, Vol. 32, 2002, pp. 125–139.
- [21] Zhang, Y.; Jiang, J.; Flatley, M.; Hill, B.: *Condition monitoring and fault detection of a compressor using signal processing techniques*, Proc. of American Control Conference 2001, 2001, pp. 4460–4465.
- [22] Mackey, R.: *Generalized cross-signal anomaly detection on aircraft hydraulic system*, IEEE Proc. Aerospace Conference 2001, Vol. 2, 2001, pp. 657–668.
- [23] Menon, S.; Uluyol, O.; Kini, K.; Nwadiogbu, E. O.: *Startup fault detection and diagnosis in turbine engines*, Proc. of IEEE Aerospace Conference 2003, 2003, pp. 3069–3074.
- [24] Aravindh Kumar, B.; Saranya, G.; Selvakumar, R.; Swetha Shree, R.; Saranya, M.; Sumesh, E. P.: *Fault detection in Induction motor using WPT and Multiple SVM*, Int. Journal of Control and Automation Vol. 3, No. 2, 2010, pp. 9–20.
- [25] Gertler, J. J.; Li, W.; Huang, Y.; McAvoy, T. J.: *Isolation enhanced principal component analysis*, AIChE Journal, Vol. 45, (2), 1999, pp. 323–334.
- [26] Piovoso, M. J.; Kosanovich, K. A.; Yuk, J. P.: *Process data chemometrics*, IEEE Trans. Instrum. Measur., Vol. 41, (2), 1992, pp. 262–268.
- [27] Deriche, M.: *Bearing fault diagnosis using wavelet analysis*, 1st Int. Conf. on Computers, Communications, & Signal Processing with Special Track on Biomedical Engineering 2005, CCSP 2005, 2005, pp. 197–201.
- [28] Patton, R. J.; Frank, P. M.; Clark, R. N.: *Issues of fault diagnosis for dynamic systems*, Springer, London, 2000.
- [29] Gertler, J. J.: *Fault Detection and Diagnosis in Engineering Systems*, Marcel Dekker Inc, 1998.
- [30] Visinsky, M. L.; Walker Cavallaro, I. D.: *New dynamic model-based fault detection thresholds for robot manipulators*, IEEE Int. Conf. Robotics and Automation, Vol. 2, No. 8-13, 1994, pp. 1388–1395.
- [31] Scheduling, S; Nebot, E.; Durrant-Whyte, H.: *The detection of faults in navigation systems: a frequency domain approach*, Proc. of IEEE Int. Conf. on Robotics and Automation, Leuven, Belgium, Vol. 3, 1998, pp. 2217–2222.
- [32] 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, Vol. 51, 2009, pp. 318–323
- [33] Watanabe, K.; Himmelblau, D. M.: *Instrument fault detection in systems with uncertainties*, Int. J. Syst. Sci., Vol. 13, (2), 1982, pp. 137–158.
- [34] Watanabe, K.; Komori, A.; Kiyama, T.: *Diagnosis of instrument fault*, Proc. of IEEE IMTC 94, Hamamatsu, Japan, Vol. 1, 1994, pp. 386–389.

- [35] Zhou, Y.; Hahn, J.; Mannan, M. S.: *Fault detection and classification in chemical processes based on neural networks with feature extraction*, ISA Transactions Vol. 42, 2006, pp. 651–664.
- [36] Lipnickas, A.: *Two-stage neural network based classifier system for fault diagnosis*, *Computational intelligence in fault diagnosis*, Springer-Verlag, London, 2006, pp 209–230.
- [37] Rajakarunakaran, S.; Venkumar, P.; Devaraj, D.; Surya Prakasa Rao, K.: *Artificial neural network approach for fault detection in rotary system*, *Applied Soft Computing*, 8, 2008, pp. 740–748.
- [38] Simani, S.; Fantuzzi, C.; Patton, R. J.: *Model-based systems using identification techniques*, Springer-Verlag, London Limited, Great Britain, 2003.
- [39] Betta, G.; Liguori, C.; Pietrosanto, A.: *An Advanced Neural Network Based Instrument Fault Detection and Isolation Scheme*, *IEEE Trans. on Instrumentation and Measurement*, 47, (2), 1998, pp. 507–512.
- [40] Betta, G.; Bernieri, A.; Pietrosanto, A.; Sansone, C.: *A neural network approach to instrument fault detection and isolation*, *IEEE Trans. on Instrumentation and Measurement*, 44, 1995, pp. 747–750.
- [41] Mattern, D. L.; Jaw, L. C.; Guo, T. H.; Graham, R.; McCoy, W.: *Using Neural Networks for Sensor Validation*, 34th Joint Propulsion Conference, Cleveland, Ohio, 1998, pp. 1–11.
- [42] Cork, L. R.; Walker, R. A.; Dunn, S.: *Fault Detection, Identification and Accommodation Techniques for Unmanned Airborne Vehicle*, Australian International Aerospace Congress, Melbourne, 2005.
- [43] Guo, T. H.; Musgrave, J.; Lin, C.: *Neural Network Based Sensor Validation for Reusable Rocket Engines*, 1995 American Control Conference, Seattle, WA, 1995.
- [44] Rajakarunakaran, S.; Venkumar, P.; Devaraj, D.; Surya Prakasa Rao, K.: *Artificial neural network approach for fault detection in rotary system*, *Applied Soft Computing*, 8, 2008, pp. 740–748
- [45] Gulez, K.; Karlik, B.; Vakkas Ustun, S.: *Designing Artificial Neural Networks for Fault Detection in Induction Motors with the TMS320C30 DSP*, ESIEE, Paris, 1996, pp. 1–19.
- [46] Zhang, J.: *Improved on-line process fault diagnosis through information fusion in multiple neural networks*, *Computers & Chemical Engineering*, 30, 2006, pp. 558–571.
- [47] Patton, R. J.; Chen, J.; Siew, T. M.: *Fault diagnosis in nonlinear dynamic systems via neural networks*, *Int. Conf. on Control '94*, Warwick, Coventry, UK, 1994, pp. 1346–1351.
- [48] Costa Branco, P. J.; Dente, J. A.: *An experiment in automatic modelling an electrical drive system using fuzzy logic*, *IEEE Trans. on Systems, Man, and Cybernetics Part C: Applications and Reviews*, 28, (2), 1998, pp. 254–261.
- [49] Costa Branco, P. J.; Dente, J. A.: *Automatic Modeling of an Electrical Drive System using Fuzzy Logic*, NAFIPS/IFIS/NASA '94. Proc. of the 1st Int. Joint Conf. of The North American Fuzzy Information Processing Society Biannual Conference. The Industrial Fuzzy Control and Intelligent Systems Conference, and the NASA Joint Technology Workshop on Neural Networks and Fuzzy Logic, San Antonio, TX , pp. 441–443.

- [50] Patton, R. J.; Korbicz, J.: *Advances in Computational Intelligence for Fault Diagnosis Systems*, International Journal of Applied Mathematics and Computer Science (Special Issue), 9, (3), 1999.
- [51] Ayoubi, M; Isermann, R.: *Neuro-fuzzy systems for diagnosis*, Fuzzy Sets and System, 89, (3), 1997, pp. 289–307.
- [52] Ichtev, A.; Hellendoorn, J.; Babuska, R.: *Fault detection and isolation using multiple Takagi-Sugeno fuzzy models*, The 10th IEEE Int. Conf. on Fuzzy Systems, 2001, Vol. 3, pp. 1498–1502.
- [53] Makaremi, I.; Fatehi, A.; Araabi, B. N.; Azizi, M.; Cheloeian, A.: *Abnormal condition detection in a cement rotary kiln with system identification methods*, Journal of Process Control, 19, 2009, pp. 1538–1545.
- [54] Jakubek, S. M.; Strasser, T. I.: *Artificial neural networks for fault detection in large-scale data acquisition systems*, Engineering Applications of Artificial Intelligence, 17, 2004, pp. 233–248.
- [55] Uluyol, O.; Kim, K.; Menon, S.; Nwadiogbu, E. O.: *Synergistic use of soft computing technologies for fault detection in gasturbine engines*, Proc. of the 2003 IEEE International Workshop on Soft Computing in Industrial Applications, SMCia/03, 2003, pp. 115–120.
- [56] 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.
- [57] Hall, D. L.; Llinas, J.: *An introduction to multisensor data fusion*, Proc. IEEE, Vol. 85, 1997, pp. 6–23.
- [58] Klein, L. A.: *Sensor and Data Fusion Concepts and Applications*, SPIE Optical Engineering Press. Bellingham, WA: Tutorial Texts, Vol. 14, 1993, p. 131.
- [59] Murugesan, V. M.; Chandramohan, G.; Senthil Kumar, M.; Rudramoorthy, R.; Ashok Kumar, L.; Suresh Kumar, R.; Basha, D.; Vishnu Murthy, K.: *An Overview of Automobile Starting System Faults and Fault Diagnosis Method*, ARPN Journal of Engineering and Applied Sciences, Vol. 7, No. 7, 2012, pp. 812–819.
- [60] Wang, W. L.: *FEA-based Structure Optimization for the Drive End Housing of an Automotive Starter*, IEEE Int. Computer Society, 2008, pp. 447–450.

Saját Publikációk

Magyar nyelvű publikáció

Nem lektorált konferencia cikk

- [s1] Kovács E., **Füvesi V.**, Szalontai L., Szabó L., *Villamos aktuátor modellezése Scilab környezetben*, IX. ENELKO International Conference on Energetics – Electrical Engineering, Csíksomlyó, 2008. október 9–12, ISSN 1842-4546, pp. 26–31.
- [s2] Szalontai L., Kovács E., **Füvesi V.**: *Indítómotor behúzótekercsének szimulációs vizsgálata*, X. ENELKO International Conference on Energetics–Electrical Engineering, Marosvásárhely, 2009. október 8–11., ISSN 1842–4546, pp. 88–92.
- [s3] Kovács E., **Füvesi V.**, Szabó L.: *Aktuátor rendszer kaotikus viselkedésének vizsgálata*, X. ENELKO International Conference on Energetics–Electrical Engineering, Marosvásárhely, 2009. október 8–11, ISSN 1842–4546, pp. 84–87.
- [s4] Kovács E., **Füvesi V.**: *Indítómotor neurális háló modelljének kiválasztása információs kritériumok segítségével*, XI. ENELKO International Conference on Energetics – Electrical Engineering, Szatmárnémeti, 2010. október 7–10., ISSN 1842–4546, pp. 49–53.
- [s5] **Füvesi V.**, Kovács E., Jónap K., Vörös Cs.: *Mobil Gamma-log berendezés hajtásláncának modellezése LOLIMOT használatával*, XII. Nemzetközi Energetikai–Elektrotechnikai Konferencia, ENELKO 2011, Erdélyi Magyar Műszaki Tudományos Társaság, Románia, Kolozsvár, 2011, ISSN 1842–4546, pp. 38–41.
- [s6] **Füvesi V.**, Kovács E.: *Összetett mechatronikai rendszer hibadetektálása és hiba identifikációja*, XIII. Nemzetközi Energetika - Elektrotechnika Konferencia, ENELKO 2012, 2012. október 11–14., Gyulaférvár, ISSN 1842–4546, pp. 61–66.

Lektorált konferencia cikk

- [s7] Kovács E., **Füvesi V.**, *Robot rendszer modellezés Scilab környezetben*, DFTH 2008, 2008. november 10-14., A Dunújvárosi Főiskola Közleményei, XXX/1, 1. kötet, Gépészeti szekció, ISSN 1586–8567, pp. 51–58.
- [s8] Kovács E., **Füvesi V.**: *Indítómotor modellezése különféle módszerekkel*, Műszaki Tudomány az Észak–Kelet Magyarországi Régióban 2011, Debrecen, 2011, ISBN 978–963–7064–25–8, pp. 339–345.
- [s9] **Füvesi V.**, Kovács E.: *Aktuátor modell kiválasztása és objektív összehasonlítása*, Proc. of XXVII. microCAD Int. Scientific Conf., Section H: Electrical Engineering, University of Miskolc, 21–22th March, 2013, ISBN 978–963–358–018, CD kiadvány.
- [s10] **Füvesi V.**, Kovács E.: *Elektromechanikus hajtáslánc hibáinak detektálása mesterséges intelligenciás módszerek segítségével*, Műszaki Tudomány az

Észak-kelet Magyarországi Régióban 2012, Szolnok, 2012. május 10., ISBN 978-963-7064-28-9, pp. 99-108.

- [s11] Vörös Cs., **Füvesi V.**, Jónap K.: *Automatikus vegyszeradagoló rendszerek gáztermeléshez*, Műszaki Tudomány az Észak-kelet Magyarországi Régióban 2012, Szolnok, 2012. május 10., ISBN 978-963-7064-28-9, pp. 331-339.

Nem lektorált folyóirat cikk

- [s12] Kovács E., **Füvesi V.**: *5 tengelyű robot kinematikai és dinamikai vizsgálata*, Doktoranduszok Fóruma 2007, Gépészmérnöki és Informatikai Kar szekciókiadványa, 2007., pp. 45-50.
- [s13] Kovács E., **Füvesi V.**: *Lineáris aktuátorok villamos hajtásainak modellezése*, Doktoranduszok Fóruma, Gépészmérnöki és Informatikai Kar szekciókiadványa, 2008. november 13, Miskolc., pp. 19-22.
- [s14] Kovács E., **Füvesi V.**: *Kefenélküli egyenáramú motorról működtetett aktuátor kaotikus viselkedésének vizsgálata*, Doktoranduszok Fóruma, Gépészmérnöki és Informatikai Kar szekciókiadványa, Miskolc, 2009., November, pp. 59-64.

Lektorált folyóirat cikk

- [s15] **Füvesi V.**: *Intelligens hatlábú mobil robot kinematikai vizsgálata*, GÉP c. folyóirat, LVIII. évfolyam, 2007/10-11 szám, Miskolc, ISSN 0016-8572, pp. 47-50.
- [s16] Kovács E., **Füvesi V.**: *Indítomotorok modellezésére alkalmas módszerek összehasonlító elemzése*, Miskolci Egyetem Közleményei, Interdiszciplináris tudományok, 1. kötet (2011), 1. szám, Miskolci Egyetemi Kiadó, Miskolc, 2011, ISSN 2062-9737, pp. 197-204.
- [s17] **Füvesi V.**, Kovács E.: *Módszer inkrementális jeladó modell alapú hibadetektálására*, GÉP c. folyóirat, LXIII. évfolyam, 2012/3. szám, Miskolc, ISSN 0016-8572, pp. 91-94.
- [s18] **Füvesi V.**, Kovács E.: *Mesterséges intelligencián alapuló módszer elektromechanikus aktuátor hibadiagnosztikájára*, Multidiszciplináris tudományok, 3. kötet, 2013, 2, Miskolc, ISSN 2062-9737, pp. 225-240.

Idegen nyelvű publikáció

Nem lektorált konferencia cikk

- [s19] G. Fekete, E. Kovács, **V. Füvesi**, L. Szalontai, J. Lengyel, Á. Nyerges: *Measuring the Difference in Output Power Between Fixed and Rotatable PV Arrays*, Proceedings of the 1st Knowbridge Conference on Renewables, September 27-28th, 2010, Miskolc, ISBN 978-963-661-944-2, pp. 119-122.
- [s20] J. Subert, **V. Füvesi**: *Development and tests of hydrate inhibitor technology on Foundation Fieldbus system*, Distributed Control Systems 18th Meeting, 24-26th October 2012., Miskolc – Lillafüred. [Előadás anyag – CD kiadvány].

- [s21] Cs. Vörös, **V. Füvesi**, Á. Pintér: *Design of a new chemical injection pump system*, Proc. of Factory Automation Conference, University of Pannon, May. 2013., Veszprém, Hungary, pp. 124–127.

Lektorált konferencia cikk

- [s22] E. Kovács, **V. Füvesi**: *Dynamic analization of a 5-axed robot in Scilab enviroment*, MicroCAD International Scientific Conference 2008, Miskolc, J Section, ISBN: 978-963-661-821-6, pp. 19-24.
- [s23] E. Kovács, **V. Füvesi**, L. Szabó, M. Ruba: *Model based dynamic analysis of a robot actuator with BLDC drive*, XXIII. MicroCAD Internastional Scientific Conference 2009, Miskolc, J Section, ISBN 978–963–661–875–9, pp. 45–50.
- [s24] M. Ruba, L. Szabó, **V. Füvesi**, E. Kovács: *Diagnosis of Advanced Fault Tolerant Switched Reluctance Machines used in Safety Automated Industrial Systems*, XXIII. MicroCAD Internastional Scientific Conference 2009, Miskolc, J Section, ISBN 978–963–661–875–9, pp. 87–92.
- [s25] E. Kovács, L. Szalontai, **V. Füvesi**: *Vibration analysis of a linear actuator*, XXIII. MicroCAD Internastional Scientific Conference 2009, Miskolc, J Section, ISBN 978–963–661–875–9, pp. 51–55.
- [s26] E. Kovács, **V. Füvesi**, L. Szabó: *Analyses of servomechanism with BLDC motor drive*, DFTH2009, 2009. november 10–14., Dunaújváros. (befogadott, nem megjelent)
- [s27] E. Kovács, **V. Füvesi**, L. Szabó: *Analyses of a nonsmooth actuator drive*, XXIV. MicroCAD Internastional Scientific Conference 2010, Miskolc, ISBN 978–963–661–915–2, pp. 139-144.
- [s28] **V. Füvesi**, E. Kovács, Cs. Blága: *Measurement and identification of a starter motor system*, MACRo2010, International Conference on Recent Achievements in Mechatronics, Automation Computer Science and Robotics, 14–15th, may 2010, Marosvásárhely, ISBN 978–973–1970–39–4, pp. 183–188.
- [s29] **V. Füvesi**, E. Kovács: *Analyses the modelling capability of feedforwarded neural network*, Proceedings of XXV. microCAD International Scientific Conference, Section I: Electrical Engineering, Miskolc, 2011, pp. 29–34.
- [s30] E. Kovács, **V. Füvesi**: *Modelling of a starter motor with feedforward neural network*, Proceedings of 17th International Conference on Electrical Drives and Power Electronics, EDPE 2011, September, 2011, Stará Lesná, Slovakia, ISBN 978–80–553–0734–3, pp. 205–209.
- [s31] **V. Füvesi**, E. Kovács: *Modelling Loaded Starter Motor with Neural Network*, Proceedings of 12th IEEE International Symposium on Computational Intelligence and Informatics, (CINTI2011), Budapest, Hungary, November 2011, ISBN 978–1–4577–0044–6, pp. 551–554.
- [s32] **Füvesi, V.**, Kovács, E.: *Process model based fault detection with LLNF model - An overview and case study*, Proc. of XXVI. microCAD Int. Scientific Conf., Section H: Electrical Engineering, University of Miskolc, 29–30th March, 2012, ISBN 978–963–661–773–8, CD kiadvány.

- [s33] **V. Füvesi**, E. Kovács: *Fault detection based on modelling electromechanical drive chain*, Proc. of 2012 Int. Symposium on Power Electronics, Electrical Drives, Automation and Motion, SPEEDAM 2012, Sorrento, Italy, 20-22 June, 2012, ISBN 978-1-4673-1300-1, pp. 1336-1341.
- [s34] **V. Füvesi**, E. Kovács: *Separation of faults of electromechanical drive chain using artificial intelligence methods*, Recent innovations in mechatronics, Proc. of 18th „Building Services, Mechanical and Building Industry days” Int. Conf, 11-12 October 2012, Debrecen, Hungary, ISBN 978-963-473-463-5, pp. 19-27.
- [s35] **V. Füvesi**, E. Kovács: *Neural network multi-model based Fault detection based method of fault diagnostics of actuators*, Proc. of 2014 Int. Symposium on Power Electronics, Electrical Drives, Automation and Motion, SPEEDAM 2014, Ischia, Italy, 18-20 June, 2014, ISBN 978-1-4799-4750-8, pp. 207-212.

Lektorált folyóirat cikk

- [s36] L. Szabó, M. Ruba, E. Kovács, **V. Füvesi**: *Fault Tolerant Modular Linear Motor for Safe-Critical Automated Industrial Applications*, Journal of Computer Science and Control Systems, 2009, Vol. 2/1, Oradea, Romania, ISSN 1844-6043, pp. 128-131.
- [s37] **V. Füvesi**, E. Kovács, Cs. Vörös: *Identification of a complex drive chain based on local linear model tree*, Production Systems and Information Engineering, Volume 6, 2013., Miskolc, ISSN 1785-1270, pp. 3-14.
- [s38] **V. Füvesi**, E. Kovács: *Separation of faults of electromechanical drive chain using artificial intelligence method*, Int. Rev. Appl. Sci. Eng. 4, (2013) 1, ISSN 2062-0810, Budapest, DOI: 10.1556/IRASE.4.2013.1.5, pp. 35-41.

