

MÓDSZER INKREMENTÁLIS JELADÓ MODELL- ALAPÚ HIBA-DETEKTÁLÁSÁRA

METHOD FOR MODEL BASED FAULT DETECTION OF AN ENCODER

Füvesi Viktor*, Kovács Ernő**

ABSTRACT

The paper introduces a nonlinear modelling of a complex drive chain of a moving measurement equipment using Locally Linear Neuro-Fuzzy (LLNF) model. The developed model was used for detecting the systematic impulse fault of the built in sensor. The model was developed based on collected data from the real system but the faults were artificially generated. Different structured neural networks were used to sign the occurrence of faults.

A rendszer hibáinak kimutatására számos módszer található az irodalomban: pl. a paritás egyenletek [1] és obszerverek [3] alkalmazásán alapuló eljárások, de a paraméter-közelítéses eljárásra [2] és neurális hálózatok alkalmazására is van példa [5, 7].

A cikk egy speciális neuro-fuzzy modell kifejlesztését és alkalmazását mutatja be a vizsgált ipari mérőrendszerben található egyik érzékelő hibájának észlelésére. Többretegű, előretrétegzett neurális hálózat került felhasználásra a különbségképzésből származó jelsorozat és a hibát kimutató jel előállítására.

1. BEVEZETÉS

Az ipari rendszerek alap követelményei közé tartozik a pontosság, megbízhatóság és biztonság. A vizsgált rendszerekben felmerülő hibák minél korábban történő észlelése segíthet a rendszerleállások, anyagi károk elkerülésében vagy súlyosabb esetben az emberi élet megővésében is. Azt a folyamatot, amikor a rendszer esetleges hibáinak kimutatását végezzük, hiba-detektálásnak nevezzük. A sikeres hiba-detektálás kihathat akár a termelékenységre is.

A különféle szenzorok és érzékelők a manapság használatos ipari berendezések fontos építőköveivé váltak. A hibásan működő érzékelők vagy a rendszer mechanikájában felmerülő egyéb hibák hátrányosan befolyásolják a rendszer működését.

Számos elméleti eredmény született az analitikus redundancián alapuló hiba diagnózis témakörében a 80-es évek elejétől napjainkig. A módszerek nagy része a vizsgált rendszer modelljének segítségével végzi a hiba kimutatását. A monitorozott rendszer modellje felhasználható egy ún. hibajel-képzésre (residual), amely egy olyan mennyiség, ami érzékeny a rendszer hibás működésére, üzemzavaraira [1].

*tudományos segédmunkatárs, Miskolci Egyetem, Alkalmazott Földtudományi Kutatóintézet, Műszerfejlesztési és Informatikai Osztály

**egyetemi docens, Miskolci Egyetem, Elektrotechnikai-Elektronikai Tanszék

2. VIZSGÁLT RENDSZER BEMUTATÁSA

A szárazföldi kísérleti olajfúrások során, az esetlegesen kőolajat magában foglaló, kiemelt kőzetmag mélységnek pontos meghatározásához, a kőzet természetes gamma sugárzásából származó gamma spektrumot használják. 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. Ezért a gamma sugárzás mérő detektor minél pontosabb mozgására van szükség.



1. ábra MGL-01F Gamma-log rendszer

A ME AFKI Műszerfejlesztési és Informatika Osztálya egy mobil gamma-log berendezést (MGL-01F) fejlesztett ki. A gamma-sugárzásmérő detektor egy kis kocsiban foglal helyet, ami egy speciális sínrendszeren halad. A vizsgált közetmag pedig sínrendszer közepén, a kialakított tartóban foglal helyet.

A berendezés hajtását egy 200W-os AC szervomotor adja. 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 kerékhez van csatlakoztatva.

3. A RENDSZER MODELLEZÉSE

A vizsgált rendszer viselkedésének leírásához szükség van a rendszer minél pontosabb matematikai modelljére. A vizsgált hajtásláncból és mechanikából álló rendszer egy, a természeténél fogva dinamikai rendszer. A modellalkotás során a bemenetek és kimenetek közti rejtett összefüggést próbáljuk felfedni. Ebben az esetben a rendszer leírható egy több bemenetű, egy kimenetű modell segítségével (MISO).

A modell a valós rendszeren történt mérések alapján lett kifejlesztve. A mérések során változtatásra került a kocsi gyorsulása és sebessége, a megtett út viszont állandó maradt. Az így született mérésekből egy adatbázis került kialakításra, amiből a modellezéshez felhasznált betanító, hitelesítő és teszt mintakészletek lettek összeállítva, úgy hogy a három mintakészlet egymástól független adatokat tartalmazott. A mérések során mértük a három fázisfeszültséget és fázisáramot valamint a jeladó impulzussorozatát. A nyers adatok elő-feldolgozáson estek át, mint szűrés (a zajok eltávolítása miatt) és újra-mintavételezés a későbbi betanítás felgyorsítása érdekében).

A rendszer a neurális hálózatok egy speciális fajtájával került modellezésre.

3.1. LLNF modell és LOLIMOT algoritmus

A radiális bázis függvény (RBF) hálózat egy kiterjesztéseként ismert lokálisan lineáris neurális hálózatot (Local Linear Neuro Fuzzy, LLNF) használtuk a rendszer modellezésére. Ebben a struktúrában a kimeneti réteg neuronjainak súlyai, a neuronok bemenetének lineáris kombinációjával kerültek helyettesítésre. Az RBF hálózatot skálázni és normalizálni kell a feldolgozáshoz [6, 7, 8].

A LOLIMOT hálózat kimenete (y_e) a következő módon számítható (1) [17]:

$$y_e = \sum_{i=1}^M \phi_i(\underline{u})(w_{i0} + w_{i1}u_1 + \dots + w_{ip}u_p) \quad (1)$$

Ahol: M neuronok és egyben a részmodellek száma; \underline{u} a bementi vektor; p a bemenetek száma; w_{xy} az x . neuronban az y . súly; Φ_i a normalizált Gauss-féle érvényességi függvény (2),(3).

$$\phi_i(\underline{u}) = \frac{\mu_i(\underline{u})}{\sum_{j=1}^M \mu_j(\underline{u})} \quad (2)$$

$$\mu_i(\underline{u}) = \prod_{j=1}^p \exp\left(-\frac{1}{2} \left(\frac{u_j - c_{ij}}{\sigma_{ij}}\right)^2\right) \quad (3)$$


Ahol c a centert és σ a szórást jelenti. A modellben a w paraméterek lineáris paraméterek még a c és σ nemlineáris paraméterek.

A hálózat betanítása a lokálisan lineáris modell fa algoritmussal (LOLIMOT) lehetséges, ami stabil és gyors konvergálást biztosít. A betanítás folyamata két részből áll: a) a betanítás első felében a bemeneti teret képezzük le az érvényességi függvény paramétereinek meghatározásával, b) a második lépés során a lokális modellek (LLM) optimalizációja folyik a legkisebb négyzetek módszerének segítségével.

Alapesetben ez a hálóstruktúra nem alkalmas dinamikai rendszer modellezésére, ezért külső dinamikai bemeneti konfigurációt alkalmaztunk. A transzformált áram és feszültség szolgált bemenetként és a kocsi mozgását leíró időfüggvény pedig kimenetként.

3.2. ARX külső dinamika

A berendezésen végzett mérések alapján betanításra került FIR (Finite Impulse Respond) típusú külső dinamikával rendelkező hálózat is, de nem szolgáltatott megfelelő eredményt. Jó és stabil megoldást adott azonban az ARX (Autoregressive with eXogenous), ami FIR esetén is használt u_1 és u_2 bemenetek mellett, a kívánt y kimenetet is a bemeneti térbe helyezi.



2. ábra ARX típusú háló-struktúra


A formázott és transzformált mérési paraméterek alapján felépített, a kocsi elmozdulást közelíteni képes

modell született, amelyet felhasználtunk a rendszer egyik hibafajtájának kimutatására is.

4. HIBADETEKTÁLÁS MÓDSZERE

A felépített modellel a rendszer számos hibája kimutatható. A cikk keretében a jeladó szenzor egyik hibájának detektálása kerül bemutatásra. A hibás jelsorozatok mesterségesen lettek előállítva a mérésekből. A hiba kimutatásának folyamata a következő (3. ábra):

- A folyamattal vagy vizsgált rendszerrel párhuzamosan futtatjuk a korábban felépített modellt. Mind a két rendszer a modell és a valós rendszer ugyanazt a bemenetet kapják. A modell és a rendszer kimeneteiből számítható egy különbség, ami nagyon kis érték a rendszer hibátlan működése esetén és a használt modell pontosságának függvényében.
- Ha hiba keletkezik a rendszerben, akkor a generált különbségnek az értéke megnő. A hibás és hibátlan állapot szétválasztására a neurális hálózatok nagyon jó osztályozási képességét használjuk ki. A generált különbség felhasználható egy többrétegű neurális hálózat bemeneteként, ami a kimeneten hibajelzést hoz létre.



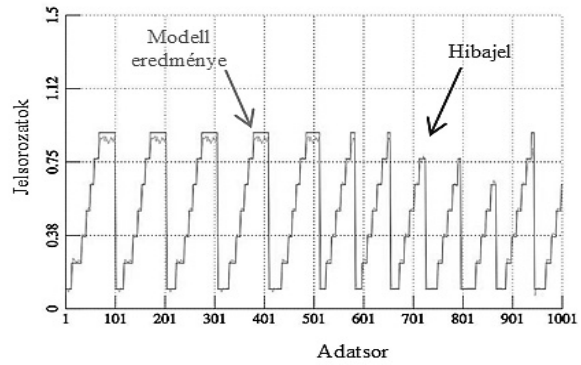
3. ábra Hibadetektálás módszere

5. RENDSZERES SZENZOR HIBA

A forgó jeladók egy lehetséges hibája, hogy az egy fordulat alatt leadott impulzusok száma rendszeresen eltér a specifikált értéktől. Látszólag teljesen hibátlanul működik a jeladó, de a leadott impulzusszám nem megfelelő. Ezt a hibatípust okozhatja a jeladó mechanikus vagy elektronikus hibája, de a berendezés egyéb mechanikus hibája is.

A feltételezés az volt, hogy a jeladó négy impulzussal kevesebbet szolgáltat fordulatanként és a hiba egy körülfordulás alatt két alkalommal is előfordul, így egy hiba alkalmával két impulzus veszik el.

A hibamentes és a hibásan működő jeladó impulzusszámának különbségét képezve egy lépcsőzetesen változó függvényt kapunk. Egy körülfordulás alatt két lépcső születik. Az egyik legjobb eredményt produkáló háló eredménye és a kívánt kimenet a 4. ábrán látható.



4. ábra Az egyik legjobb eredményt produkáló hálózat kimenete és a hálózattól megkívánt kimenet

A hibadetektálást végző neurális háló betanításához három független mintakészlet készült: a) a hálózat tanításához, b) a tanítás leállításához, ami azért fontos, hogy a hálózat elsajátítsa a tanító mintakészletbe foglaltakat, de képes legyen még extrapolációra is, c) a teszteléshez, ami különféle háló-típusok összehasonlításához volt szükséges. A mintakészletek a kocsli különféle sebessége és gyorsulása mellett született mérésekből származó, előfeldolgozott jelsorozatok összefűzéséből születtek. A szimulációkban változtattuk a hiba első megjelenésének időpontját is.

STRUKTÚRA	TÍPUS	MEGVALÓSÍTOTT FÜGGVÉNY
1. Konfig.	NNFIR	$y_s(t) = f(u(t))$
2. Konfig.	NNFIR	$y_s(t) = f(u(t), u(t-1))$
3. Konfig.	NNFIR	$y_s(t) = f(u(t), u(t-1), u(t) - u(t-1))$
4. Konfig.	NNARX	$y_s(t) = f(u(t), u(t-1), \dots, y(t-1))$
5. Konfig.	NNARX	$y_s(t) = f(u(t), u(t-1), \dots, y(t-1), y(t-2))$
6. Konfig.	NNARX	$y_s(t) = f(u(t), u(t-1), \dots, y(t-1), y(t-2), \dots, y(t-1) - y(t-2))$

1. táblázat Vizsgált háló-konfigurációk struktúrája

Több háló-konfigurációt teszteltünk a hibajel előállítás érdekében. A vizsgált struktúrákban változtattuk a rejtett rétegben elhelyezett neuronok számát és a struktúra bemeneti konfigurációját. Hat bemeneti konfigurációt teszteltünk és öt rejtett neuron számot használtunk a vizsgálat során. A különféle hálókonfigurációk, a hálózat típusok és a hálózat által megvalósított átviteli függvényt az 1. táblázat tartalmazza.

Általában a neurális hálózat jóságát az átlagos négyzetes hibával (MSE) értékelik. Jelen esetben a különféle háló-struktúrák értékelésére a neurális struktúra hibajelének deriváltja használható fel. A korábban említett lépcsős hibajel a deriválás során

impulzusokká fajul. Az így képzett jelsorozat jól kiértékelhető.


A teszt jelsorozat 66 hibát tartalmazott összesen. Az aktuálisan vizsgált hálózat teljesítményét két tényező határozza meg: a) a valós hiba felismerése (RF), b) hibás hibafelismerés (BA). A helyes időben képzett hibajelek számából és a hibás hibaimpulzusokból a (4) képlet szerint képeztünk egy relatív hibaimpulzus számot, ami a vizsgált, betanított neurális hálózat hiba felismerő képességét (HFK) relatív hiba jellegű mennyiségként értékeli.

$$HFK = \frac{RF}{RF + BA + MF} \cdot 100\% \quad (4)$$

Ahol RF: felismert hibák száma, BA: a hibás jelzések száma, MF: téveszett jelzések száma.

A kiértékelés során az számított jó hibajelzésnek, ahol a hálózat kimenetéből generált impulzus nagysága elérte a megkívánt impulzus nagyságának 30%-át.

Az 5. ábra mutatja a különféle neurális hálóstruktúrák eredményeinek összesítését. A vizsgált hálózatkonfigurációk közül az NNARX típusú hálóstruktúrák produkálták a legjobb eredményeket (pl. 5. konfiguráció). Az NNFIR típusú hálózatoknál 4 rejtett neuronnál érte el az eredményt, míg az NNARX esetén több neuronra volt szükség.



5. ábra A vizsgált hálóstruktúrák eredményeinek értékelése

6. ÖSSZEFOGLALÁS

A cikkben egy az olajiparban használatos eszköz nemlineáris modelljét építettük fel neurális hálózat segítségével. A modell felépítése és betanítása a rendszeren történt mérések felhasználásával történt.

Bemutattunk egy módszert a mérőrendszer inkrementális jeladója egyik hibájának detektálására. A módszer a valós rendszer kimenete és a vele párhuzamosan futó modell kimenete által generált különbségből egy neurális hálózat segítségével létrehozott hiba-detektáló jel megalkotásán alapul.

A neurális hálózat osztályozási tulajdonságát kihasználva képesek voltunk a vizsgált kocsikerekek körülfordulása során 2 alkalommal jelentkező szenzorhiba 100%-os pontossággal észlelésére.

A vizsgálatok során több hálózatot elemeztünk és megállapítottuk, hogy a legjobb eredményt az NNARX struktúra szolgáltatja.

7. KÖSZÖNETNYILVÁNÍTÁS

A bemutatott kutató munka a TÁMOP-4.2.1.B-10/2/KONV-2010-0001 jelű projekt részeként az Európai Unió támogatásával, az Európai Szociális Alap társfinanszírozásával valósul meg.

IRODALOM

- [1] SCHWARTE, A.; ISERMANN, R.: Neural Network Applications for Model Based Fault Detection with Parity Equations, Proc. of 15th Triennial World Congress of the International Federation of Automatic Control, Barcelona, 21–26 July 2002, Vol. 15, Part 1.
- [2] LU, Y.; COLLINS, E. G.; SELEKWA, M. F.: Parity Relation Based Fault Detection, Isolation and Reconfiguration for Autonomous Ground Vehicle Localization Sensors. Proc. of 24th Army Science Conference, 2004.
- [3] JIANG, B.; CHOWDHURY, F. N.: Parameter fault detection and estimation of a class of nonlinear systems using observer. Journal of the Franklin Institute, Vol. 342, Iss. 7, November 2006, pp. 726-736.
- [4] CAPRIGLIONE, D.; LIGUORI, C.; PIANESE, C.; PIETROSANTO, A.: On-line Sensor Fault Detection, Isolation and Accommodation in Automotive Engines. IEEE Trans. on Instrumentation and Measurement, Vol. 52, Iss. 4, Aug. 2003, pp. 1182-1189.
- [5] BÖRNER, M.; STRAKY, H.; WEISPFENNING, T.; ISERMANN, R.: Model based fault detection of vehicle suspension and hydraulic brake systems. Mechatronics, Vol. 12, Iss. 8, October 2002, pp. 999-1010.
- [6] RAZAVI-FAR, R.; DAVILU, H.; PALADE, V.; LUCAS, C.: Model-based fault detection and isolation of a steam generator using neuro-fuzzy networks, Neurocomputing 72, 2009, pp. 2939–2951.
- [7] NEKOU, M.A.; SAJADIFAR, S.M.: Nonlinear System Identification using Locally Linear Model Tree and Particle Swarm Optimization, IEEE International Conference on Industrial Technology, 2006., (ICIT 2006), pp. 1563-1568.
- [8] NELLES, O., FINK, A.; ISERMANN, R.: Local linear model trees (LOLMOT) toolbox for nonlinear system identification, In IFAC Symposium on System Identification (SYSID), Santa Barbara, USA, June 2000.