

A gumiabroncs-nyomás monitorozás korszerű módszerei

Modern Methods of Tire Pressure Monitoring

FODOR Dénes¹, SZOKOLI Csongor², MÁRTON Zoltán²

¹Széchenyi István Egyetem, Járműipari Kutató Központ,
²Pannon Egyetem, Műszaki Tudományok Kutató- Fejlesztő Központ,
9026 Győr, Egyetem tér. 1.
fodor.denes@ga.sze.hu

Abstract

As tyre pressure is a major determinant of vehicle energy consumption and driving safety, it is important to have information on the status of tyre pressures. There are basically two main types of tyre pressure measurement: direct pressure measurement and indirect pressure estimation methods. Direct, or direct measuring, systems involve the installation of a pressure sensor in the valve, which allows the pressure of the tyre to be accurately determined, but this method also has its drawbacks. Problems include the power supply required to operate the sensor and the transmission of the measured values to the vehicle's central unit. Indirect methods, on the other hand, use signals from wheel speed sensors, which can also use information from suspension sensors, to estimate tyre pressure. Current methods use the Fourier transform (frequency analysis) to determine the natural frequency of the wheel as a function of tyre pressure from the wheel speed sensor signals, but other alternative methods exist [2]. Nowadays, artificial intelligence methods are also playing an increasingly important role in the implementation of indirect tyre pressure determination systems. A major advantage of indirect pressure estimation systems over direct pressure measurement systems is their lower cost. This paper will discuss the state-of-the-art indirect methods in comparison to direct methods, touching on the potential for further development of indirect methods.

Keywords: *direct and indirect tyre pressure monitoring, Hybrid Wavelet-Fourier transform, artificial intelligence, convolutional neural network*

Kivonat

Mivel a gumiabroncs-nyomás jelentősen meghatározza a jármű energiafogyasztása mellett a jármű menetbiztonságát is, fontos, hogy információnk legyen a gumiabroncsok nyomásainak állapotáról. A gumiabroncs-nyomás meghatározására alapvetően két főbb csoportot tudunk megkülönböztetni: a közvetlen nyomásmérő és az indirekt, azaz közvetett nyomásbecslő módszereket. A direkt, vagy közvetlen módon mérő rendszereknél egy nyomásmérő szenzor kerül beépítésre a szelepbe, melynek segítségével az abroncs nyomása megmérhető, azonban ennek a módszernek vannak hátrulói. Problémát jelent a szenzor működéséhez szükséges energiaellátás, valamint a mért értékek eljuttatása a jármű központi feldolgozó egységébe. Ezzel szemben az indirekt módszerek a keréksebesség szenzorok mellett, a felfüggesztés érzékelőinek információira is támaszkodva becsülik meg a gumiabroncsok nyomását. A napjainkban elterjedt módszerek a keréksebesség szenzorok jeleiből Fourier-transzformáció segítségével (frekvencia analízissel) határozzák meg a kerék gumiabroncs nyomásától függő saját frekvenciáját, de léteznek egyéb alternatív módszerek is [2]. Manapság a mesterséges intelligencia módszerei is egyre nagyobb szerepet kapnak az indirekt guminyomás-meghatározó rendszerek megvalósításában. Az indirekt nyomásbecslő rendszerek egyik nagy előnye a direkt nyomásmérő rendszerekhez képest, hogy alacsonyabbak a költségei. A dolgozat a korszerű indirekt módszerek bemutatására tér ki a direkt módszerekkel szemben, érintve az indirekt módszerekben rejlő továbbfejlesztési lehetőségeket.

Kulcsszavak: *direkt és indirekt gumiabroncsnyomás meghatározás, Hibrid Wavelet-Fourier transzformáció, DDS- Deflation Detection System, TPMS-Tyre Pressure Measurement System, mesterséges intelligencia, konvolúciós neurális háló;*

1. BEVEZETÉS


A gumiabroncs-nyomás nyomon követésének kulcsfontosságú szerepe van a járművekben. A gumiabroncs-nyomás jelentősen befolyásolhatja egy autó viselkedését, működését, hiszen a gumiabroncs létesít kapcsolatot a közlekedés során az útfelülettel, így a jármű menetbiztonsága miatt is fontos, hogy megfelelő állapotban legyenek az abroncsok. Egy 2006-os mérés szerint, amelyet a Michelin tett közzé, 20 300 jármű vizsgálatánál mindössze 6,5 százalékának volt megfelelő mind a négy abroncs nyomása, több mint 39,5 százalékánál pedig legalább egy abroncs nyomása 1,5 bar alatt volt, ami már nagyon alacsonynak minősül [1], és baleseti kockázatot jelent. A gumiabroncs-nyomás az abroncs korai elhasználódása mellett az autó fogyasztását is nagymértékben befolyásolja. Ennek következtében az Európai Unióban (2014-től) és az Egyesült Államokban (2007-től) törvény által megkövetelve az alapfelszerelés része lett az újabb gyártású járműveknél a gumiabroncs-nyomást monitorozó rendszer (TPMS-Tire Pressure Monitoring System, vagy más elnevezéssel DDS-Deflation Detection System). Napjaink járművei mellett az önvezető, vagy autonóm járművek elterjedésében is fontos szerepet töltenek be TPMS-ek. Az önvezető rendszereknek szükséges, hogy az autó minden állapotáról megfelelő információval rendelkezzen, ehhez pedig a gumiabroncs-nyomás vizsgálatára is szükség van [2]. TPMS-ből két fő típust lehet megkülönböztetni: a direkt gumiabroncs-nyomásmérő rendszereket, valamint az indirekt nyomásbecslő módszereket. A direkt, vagy közvetlen módon mérő rendszereknél egy nyomásmérő szenzor kerül beépítésre a szelepbe, ennek következtében pedig pontosan tudja az abroncs nyomását meghatározni. Ezzel szemben az indirekt módszerek a keréksebesség szenzorok – emellett felhasználhatja a felfüggesztés érzékelőinek információit is – jeleinek segítségével becsülik meg a gumiabroncsok nyomását. A napjainkban elterjedt módszerek a keréksebesség szenzorok jeleiből Fourier-transzformáció segítségével (frekvencia analízissel) határozzák meg a kerék gumiabroncs nyomásától függő saját frekvenciáját, de léteznek egyéb alternatív módszerek is [2], [3]. A kezdeti indirekt módszerek a keréksebesség szenzorok jeleinek az egymáshoz viszonyításából határozták meg a gumiabroncsok nyomás értékének megváltozását ezzel a módszerrel legfeljebb 3 szimultán gumiabroncsban bekövetkezett nyomáscsökkenés volt kimutatható [4]. Ugyanakkor a Fourier-transzformáció nagy számítás igénye miatt a kutatók és mérnökök vizsgálják alternatív módszerek (pl.: Kálmán-szűrő, AR- Auto Regressive modell, Wavelet transzformáció, mesterséges intelligencia) használhatóságát is. Cikkünkben a korszerű MI-Mesterséges Intelligencia alapú módszert kívánjuk röviden bemutatni.

2. A DIREKT ÉS INDIREKT MÓDSZEREK ÁTTEKINTÉSE

2.1. Közvetlen (direkt) TPMS

A direkt TPMS az abroncsokban elhelyezett nyomás- és hőmérsékletérzékelők segítségével vizsgálja a gumiabroncsok állapotát. A közvetlen nyomásmérő rendszerek megbízhatóbbnak minősülnek, mint az indirekt nyomásbecslő rendszerek, hiszen a fellépő nyomást és hőmérsékletet érzékelik, nem pedig a keréksebesség szenzorok jeléből próbálják azt meghatározni. A direkt nyomásmérő rendszerek működéséhez azonban szükséges a megfelelő tápellátás. Ebből a szempontból további két megoldásra lehet bontani a direkt TPMS-eket: aktív és passzív. Az aktív TPMS lényege, hogy a nyomásérzékelő közvetlen áramforráshoz csatlakozik (lítium akkumulátor), egy jeladó pedig vezeték nélküli moduláció segítségével a jármű fedélzeti számítógépéhez juttatja az abroncsban mért adatokat. Ezzel ellentétben a passzív rendszerek nem használnak közvetlen energiaellátást, hanem ezt RFID (Radio Frequency IDentification) segítségével biztosítják. Az RFID alapvetően egy automatikus vezeték nélküli azonosításhoz és adatközléshez használt technológia, ebben az esetben viszont elektromágneses hullámok segítségével biztosítják a nyomásérzékelők energiaellátását [3]. A legelterjedtebb megoldás a beépített gombelem használata, amely képes hosszú évekig ellátni a mérőegységeket a szükséges energiával. Az elem kicserélésére viszont nincs lehetőség, mivel ezek, az érzékelő áramkörrel egyetemben, a fröccsöntött burok belsejében találhatóak, elzárva a külső környezettől. Ezt a megfontolást azért használják, hogy az érzékeny elektronikai egység a kerék belsejében ne szenvedhessen károsodást, illetve minimálisra csökkentsék az alkatrészek elmozdulási lehetőségét, amely hibás mérési eredményekhez vezethet [7]. Az előbb felsorolt információk alapján tehát érzékelhető, hogy a direkt TPMS-ek esetében az egyik legnagyobb probléma, a megfelelő tápellátás biztosítása, valamint az aktív rendszerek esetében a rövid élettartam. Emellett még hátráltató tényező, hogy a szenzorok nem minden gumiabronccsal képesek a zavartalan működésre, a Faraday-kalitka hatás miatt. Ugyanis a sugárzott rádióhullámok tompítása érdekében a műszerek tokozásába egy Faraday-hálót is szükséges beépíteni, így azok csak a közvetlen

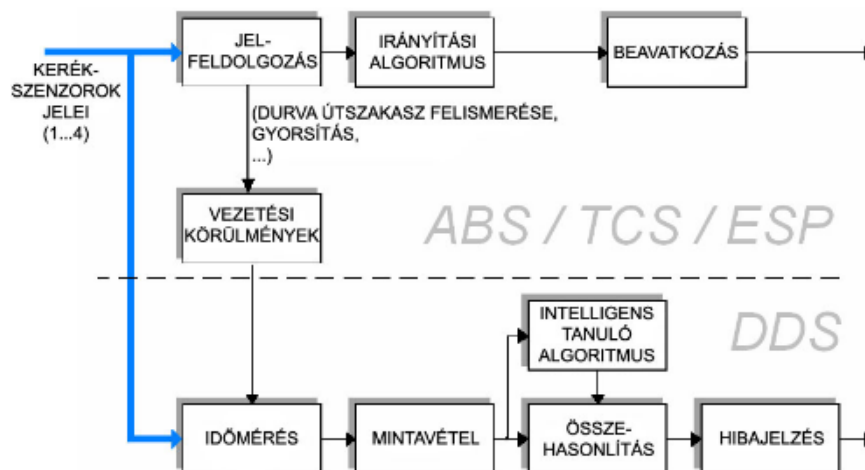
környezetükbe képesek sugározni (1. ábra). Így használatuk elsősorban a gyártó által meghatározott abroncs típusokra terjed ki, amelyek sikeresen teljesítették a jelerősség mérő tesztek [7].



1. ábra: Gumiabroncs szerkezete [7]

2.2. Közvetett (Indirekt) TPMS


Az indirekt módszerek ugyan pontatlanabbak, de azért, hogy a keréksebesség szenzorok (WSS) jeleit dolgozzák fel, a direkt rendszereknél említett problémák nem érintik. A modern indirekt TPMS (iTPMS)-ek korszerű jelfeldolgozáson alapulnak, a legtöbb esetben valamilyen transzformáció segítségével előállítanak a keréksebesség szenzorok jeléből egy frekvencia spektrumot, mely segítségével meghatározzák a gumiabroncsnyomásától függő sajátfrekvenciáját. Az indirekt nyomásfigyelés elsősorban költséghatékonysági megfontolásból alakult ki, ugyanis a már beépített alkatrészek és szenzorok mérési tulajdonságait felhasználva szintén megoldható a keréknyomás monitorozása. Így nincs szükség további alkatrészek beépítésére, mert a méréseket hosszabb élettartamú eszközök végzik el, amelyek biztonsági funkcionalitásuk következtében mindig csak megbízható és pontos eredményeket szolgáltathatnak. Ebből fakadóan az indirekt rendszerek igen nagy ütemben jelennek meg az egyes gyártóknál. Ilyen típusú rendszer a DDS mozaiknevű nyomásfigyelő rendszer is, aminek blokkdiagramját a második ábra szemlélteti [7]. Léteznek modell alapú módszerek is, pl. Kálmán-szűrő alapú megfigyelővel, de ezek tárgyalására itt nem térünk ki. A transzformáció azonban csak az első lépés a gumiabroncs-nyomás becslésében. Az így kapott spektrumok nem csak a gumiabroncsnyomásáról, hanem a jármű többi eleméről (motor, erőátvitel), valamint az útfelületről is hordoznak információt, ezért további feldolgozás/szűrés szükséges. A sajátfrekvencia keresésére az egyik leggyorsabb módszer a csúcskeresés, a másik kis számítási igényű eljárás a súlypont módszer, valamint konvolúciós neurális hálózaton alapuló módszer is megfelelő lehet [2]. A dolgozat a spektrumok meghatározására alkalmas gyors Fourier-transzformáció (FFT) [4],[5] és a Hibrid Wavelet-Fourier transzformáció (HWFT) alapú módszerek eredményeire tér ki a továbbiakban, valamint a sajátfrekvencia meghatározására szolgáló korszerű konvolúciós neurális hálózaton alapuló módszert kívánja röviden ismertetni.



2. ábra: A DDS és a menetdinamikai szabályozórendszerek kapcsolata [7]


3. A SEBESSÉG ÉRZÉKELŐ JELEINEK SPEKTRUM ANALÍZISE

Az indirekt TPMS-ek a keréksebességszenzorok jeleiből határozzák meg a gumiabroncs nyomásától függő sajátfrekvenciát. A sajátfrekvencia meghatározásához azonban első lépésként szükség van a spektrumok meghatározására. A legelterjedtebb módszer a spektrumok meghatározására a Fourier-transzformáció, a Wavelet transzformáció viszont a jelfeldolgozásban inkább a tranziens analízisnél bizonyult megfelelő eszköznek. A kettő együttes alkalmazása, a Hibrid Wavelet-Fourier transzformáció azonban megoldás lehet a spektrumok pontosabb meghatározására [2]. Ezen módszerek matematikai tárgyalásával egy korábbi OGÉT cikkben már foglalkoztunk, így itt ezekre nem térünk ki [12], [13], [14]. A HWFT alkalmazásának az egyik alapját adja, hogy nem szükséges minden Wavelet frekvenciasávon Fourier transzformációt végeznünk, így a számunkra megfelelő sáv kiválasztásával jelentősen csökkenteni tudjuk a számításigényét [2], [11]. A korábbi kutatási eredmények alapján elmondható, hogy a gumiabroncs sajátfrekvenciájához másodpercenkénti 1024 minta esetén a 64 mintából álló Wavelet frekvenciasáv felel meg (3. ábra: Amplitúdó-Wavelet frekvencia sáv).



3. ábra: A WSS jel Hibrid Wavelet-Fourier transzformáltja [11]

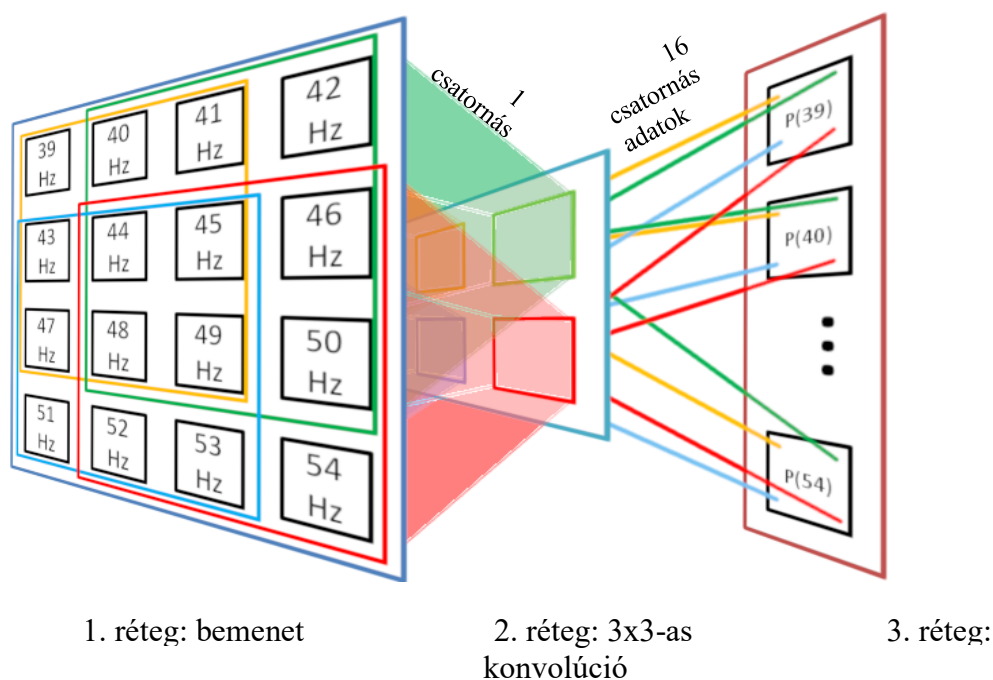
Ugyanakkor jelentősen kisebb erőforrás és számítási kapacitás igényvel rendelkezik (4. ábra), ami lehetővé teszi a felszabaduló számítási kapacitás felhasználását más számítások elvégzésére, vagy gyengébb és kisebb áramfogyasztással rendelkező hardver alkalmazására, vagy a mintaszám megnövelésére, amivel a gumiabroncsnyomás becslésének pontossága növelhető [2] [11].



4. ábra: Gyors Fourier transzformáció és a Hibrid Wavelet-Fourier transzformáció számítási igényének az összehasonlítása mintaszám alapján [2]

4. A SAJÁTFREKVENCIA MEGHATÁROZÁSA NEURÁLIS HÁLÓT ALKALMAZVA

Miután transzformáció segítségével sikerült meghatározni a frekvencia spektrumokat, a következő lépés a guminyomáshoz tartozó sajátfrekvencia meghatározása. Az iTPMS rendszerekben ez az egyik legfontosabb lépés, hiszen ezzel a lépéssel határozzuk meg a számunkra szükséges információt. Számos módszer létezik, ami képes a sajátfrekvencia meghatározására, a csúcsok azonosítására, vagy detektálására egy frekvenciaspektrumban. A megoldási módszerek jóságát az érzékenység, több csúcs kezelésének képessége, zajérzékenység, pontosság határozza meg [2]. Mivel a cél a zavarásokkal, illetve a zajjal szembeni jobb tűréssel rendelkező, de a csúcskereső módszerektől nem rosszabb felbontású neurális háló alapú rendszer kidolgozása volt, ezért 16 osztályt határoztunk meg. A sajátfrekvencia 16 Hz-es környezete miatt, így 16 bemenettel is kell, hogy a neurális hálózat rendelkezzen. Ezáltal a bemeneti réteg mérete is meghatározott lett. Ebből adódóan a legegyszerűbb elképzelhető neurális hálózat a bemeneti rétegen kívül csupán egyetlen teljesen összekötött rétegből állt. Annak érdekében, hogy a rendszer a zavarásokra is érzéketlen legyen, melyek a motorból és az erőátviteli rendszerből származnak, a betanító mintákat úgy kellett meghatározni, hogy mesterségesen különböző frekvenciákon nagy amplitúdóval rendelkező csúcsok jelenjenek meg a keresési tartományon belül a frekvencia-spektrumban. A betanítás során ez az egyszerű hálózat elégtelennek bizonyult, így ezt a továbbiakban bővítettük. A rendszerbe a bemeneti és a kimeneti réteg közé egy konvolúciós réteg került beillesztésre, mely neuronjainak a kimenetei 16 dimenziós vektorokból állnak. Így ez a réteg 4 ponton képes 16 jellemzőt szolgáltatni az adott frekvencia spektrum szakaszról a döntési funkciókat ellátó utolsó réteg felé (5. ábra). Ez a hálózat már betanítható volt arra, hogy a sajátfrekvenciát meghatározza a különböző zavarások megléte mellett is [2], [9], [11]. A neurális hálózat betanítására egy jó keréknyomáshoz tartozó spektrum lett felhasználva, melyből a gumiabroncs sajátfrekvenciájának 16 Hz-es környezete került kiválasztásra. A zavarást tartalmazó minták előállításához a keresési tartományon belül elhelyeztek motor és erőátviteli rendszerekből eredő, a sajátfrekvenciánál másfélszer nagyobb amplitúdóval rendelkező frekvencia komponenset [2], [11]. A kiértékelés során megállapítható, hogy a neurális hálózattal meghatározott sajátfrekvencia pontosabb és megbízhatóbb eredményeket adott, összehasonlítva a csúcskeresővel és a súlypont módszerrel. Az FFT-nél látható, hogy ha a keresési tartományon belül a zavarás kisebb amplitúdóval jelenik meg, mint a sajátfrekvenciához tartozó csúcs, akkor a csúcskereső stabilabb eredményt ad, mint a súlypont módszer. A legstabilabban az új konvolúciós neurális hálózat határozta meg a sajátfrekvenciákat [2], [11].



5. ábra: A konvolúciós neurális hálózat szerkezete [11]

Az eredmények az 1.-es táblázatban láthatók: 1. táblázat: A teszt eredménye [2]

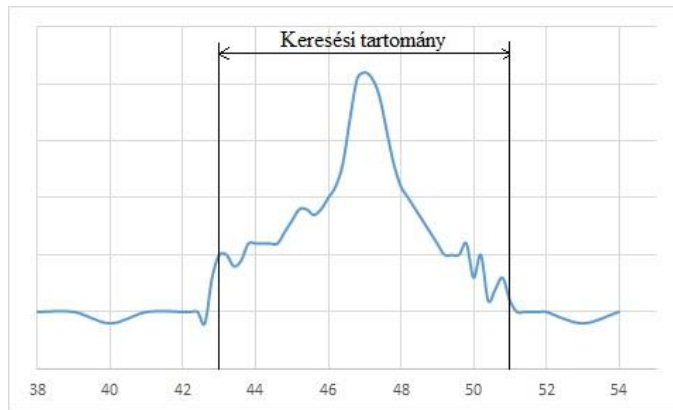
Teszt	Ref. Frek. [Hz]	Transzf.	Frekv. megh.	Átlag [Hz]	Pontosság [%]
Szim.	47	FFT	Peak Search	46.181	75.475
		FCT		46.41	48.636
		HWFT-64		46.359	66.182
		FFT	CoG	46.682	79.986
		FCT		46.78	78.616
		HWFT-64		46.613	78.029
		FFT	CNN	46.995	99.853
		FCT		46.94	95.724
		HWFT-64		46.994	99.347
Szim.	43	FFT	Peak Search	42.997	99.539
		FCT		43.255	57.852
		HWFT-64		43.174	82.529
		FFT	CoG	43.73	99.214
		FCT		43.806	89.367
		HWFT-64		43.886	79.345
		FFT	CNN	43.011	99.414
		FCT		43.446	82.38
		HWFT-64		43.092	91.363
Valós	45.58	FFT	Peak Search	45.21	The reference frequency was given in the metadata provided by the measurements and it was calculated by a closed source software in off-line processing. Hence, there is no guarantee that the reference frequency is always correct. The correctness values are omitted.
		FCT		46.013	
		HWFT-64		45.775	
		FFT	CoG	46.59	
		FCT		46.671	
		HWFT-64		47.225	
FFT	CNN	45.202			
FCT		45.254			
HWFT-64		45.487			
Valós	47.03	FFT	Peak Search	46.949	
		FCT		47.374	
		HWFT-64		46.901	
		FFT	CoG	47.339	
		FCT		47.259	
		HWFT-64		47.695	
FFT	CNN	46.711			
FCT		46.817			
HWFT-64		47.103			

5. A KONVOLUCIÓS NEURÁLIS HÁLÓZAT MÓDOSÍTÁSA

Célunk, hogy a korábbi eredményeket továbbfejlesztve egy pontosabb és robusztusabb sajátfrekvencia meghatározására alkalmas módszert mutasson be. Az eddigi mérések alapján egyértelműen meg lehet állapítani, hogy a legpontosabb sajátfrekvencia meghatározására alkalmazott módszer az FFT és a CNN együttes használata. Előírt nyomáson (47 Hz), valamint 30%-al leeresztett gumibroncs esetén is szinte tökéletes pontossággal működött. A HWFT [6] és CNN [9] együttes alkalmazása szintén pontos eredményeket szállított az előírt gumibroncs-nyomáson, viszont alacsonyabb nyomás esetén már kevésbé volt megbízható. Azonban, mint korábban említésre került, a gyors Fourier-transzformáció egyetlen nagy hátránya a Hibrid Wavelet-Fourier transzformációhoz képest a nagy számítási igény (4. ábra). Ennek következtében, a továbbiakban a HWFT-CNN módszert próbáljuk pontosabbá tenni, egy kis számítási igényű és jó felbontású rendszer érdekében.

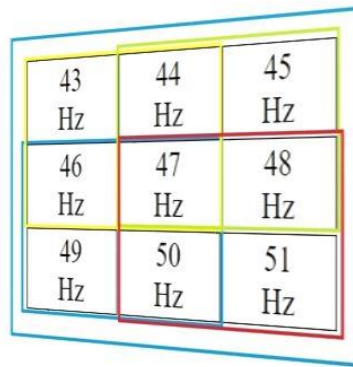
5.1 Sajátfrekvencia meghatározás új módszerrel

Az előző vizsgálat során a Konvolúciós Neurális Hálózatnak egy 16 Hz-es tartomány került betanításra. Azonban ismert, hogy a viszonylag nagyinak mondható, 30 százalékos guminyomás csökkenés (2,5 bar előírt nyomás esetén már 0,75 barral csökken az abroncs nyomása) is mindössze 4 Hz-el alacsonyabb sajátfrekvenciát eredményez. Ennek következtében az az ötlet született, hogy kisebb tartomány kerüljön betanításra a CNN-nek, így pontosítani lehetne az előírt nyomáson, valamint a csökkent nyomáson is a nyomásbecslést. Ebben az esetben tehát az előírt nyomás (47 Hz) körüli 9 Hz-es tartományt vizsgáljuk (6. ábra):



6. ábra: A keresési tartomány

A tartomány megváltoztatása miatt a Konvolúciós Neurális Hálózat nem 16, hanem 9 bemenettel rendelkezik (7. ábra).



7. ábra: A bemeneti réteg

A CNN betanítása után a korábbiakkal megegyező mérési adatsorokon elvégeztük a sajátfrekvencia meghatározását az új neurális hálózattal. Az előző ponthoz hasonlóan, a spektrumok meghatározása ismét mind a három módszerrel megtörtént (FFT, FCT, HWFT), a vizsgálat eredményei a 2. és 3. táblázatban láthatók.

2. táblázat: A kiértékelés eredménye előírt nyomáson

		Átlag [Hz]	Eltérés [Hz]	Pontosság [%]
FFT	CNN	46,319	0,885	98,08
FCT		47,492	1,808	96,19
HWFT-64		46,662	0,832	98,21

3. táblázat: A kiértékelés eredménye 30%-al alacsonyabb (43 Hz) nyomáson

		Átlag [Hz]	Eltérés [Hz]	Pontosság [%]
FFT	CNN	43,820	1,757	95,986
FCT		44,437	3,232	92,715
HWFT-64		44,049	1,902	95,673

A 2. táblázatban megfigyelhető, hogy továbbra is az FCT-CNN együttes használata adja a leginkább pontatlan eredményt a három módszer közül, míg FFT-vel és HWFT-vel az új módszer is 98 százalék feletti pontossággal rendelkezik. Az 3. táblázat eredményeit, ha összevetjük a 2. táblázatban látható értékekkel, akkor megfigyelhető, hogy az új FFT-CNN módszer pontossága némileg csökkent alacsonyabb nyomáson, viszont a HWFT és CNN együttes alkalmazása esetén, az új módszerrel precízebb lett a sajátfrekvencia meghatározása.

6. ÖSSZEFOGLALÁS

Az új korszerű módszer célja az volt, hogy a HWFT és CNN alapú sajátfrekvencia meghatározás még pontosabb legyen. Az 1. táblázatban látható eredményekkel összevetve, ugyan előírt nyomáson csökkent az új módszer pontossága (1 százalékkal), de alacsony nyomáson precízebb lett, több mint 4 százalékkal. Fontos kiemelni, hogy az összehasonlító adatok (2.-3. táblázat), csupán átlagértékek, voltak adatsorok, ahol pontosabb, volt, ahol pontatlanabb eredményeket adott az új módszer. Azonban a közel 96 százalékos pontosságú meghatározás már egészen jónak tekinthető, főleg ha azt vesszük, hogy jóval kisebb számítási igényrel rendelkezik a HWFT-64, mint az FFT. Az új módszernek köszönhetően még azt is ki lehet emelni, hogy a HWFT-CNN alapú rendszer tovább fejleszthető, ha a CNN számára a 9 Hz-es tartományt jobban felbontjuk, fél értékekre, esetleg tizedes értékekre. Ez a változtatás azért jelenthetne előrelépést, mivel a HWFT használatával felszabadult kapacitást a CNN javára fordíthatjuk, így egy még jobb felbontású és robusztusabb verzió jönne létre, ezáltal pedig még pontosabb guminyomás becslést tudna biztosítani.

KÖSZÖNETNYILVÁNÍTÁS

A TKP2021-NKTA-48 számú projekt az Innovációs és Technológiai Minisztérium Nemzeti Kutatási Fejlesztési és Innovációs Alapból nyújtott támogatásával, a TKP2021-NKTA pályázati program finanszírozásában valósult meg.

IRODALOMJEGYZÉK

- [1] R. Isermann, D. Wesemeier : Indirect Vehicle Tire Pressure Monitoring with Wheel and Suspension Sensors, In: Proceedings of the 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes. Barcelona, June 30 - July 3, 2009
- [2] Dr. Fodor Dénes, Márton Zoltán: New Hybrid Wavelet and CNN-Based Indirect Tire-Pressure Monitoring System for Autonomous Vehicles. In: Hungarian Journal of Industry and Chemistry, 48. (2020) 1. sz. 123-130.
- [3] Xu Yuan: Research of Tire Pressure Monitoring System, Baoding, In: Advanced Research and Technology in Industry Applications, 2. (2016)
- [4] Dr. Fodor Dénes: Digitális jelfeldolgozás. 2. kiadás. Veszprém, 2014.
- [5] Yan-Bin Jia: Polynomial Multiplication and Fast Fourier Transform. 2020.
- [6] Tomasz Tarasiuk: Hybrid Wavelet-Fourier Spectrum Analysis. In: IEEE Transactions on Power Delivery. (2004) 19. sz. 957-964. p.
- [7] http://moodle.autolab.uni-pannon.hu/Mecha_tananyag/jarmufedezeti_elektronika/ch08.html#ch-8.1
- [8] Dr. Fodor Dénes, Márton Zoltán: Convolution Neural Network Based Eigenfrequency Determination for Tire Pressure Monitoring Systems, Veszprém, 2015.
- [9] Introduction to Convolutional Neural Networks, Stanford University, 2018, - https://web.stanford.edu/class/cs231a/lectures/intro_cnn.pdf
- [10] Hijazi, S.; Kumar, R.; Rowen, C.: Using Convolutional Neural Networks for Image Recognition, IP Group, Cadence, 2015.
- [11] Dr. Fodor Dénes, Márton Zoltán: Indirect Tire Pressure Monitoring Systems in Autonomous Vehicles. Veszprém, 2015.
- [12] Zoltán Márton, Dénes Fodor, Krisztián Enisz, Klaudia Nagy, Frequency Analysis Based Tire Pressure Monitoring , IEEE International Electric Vehicle Conference (2014)., IEEE, 2014.
- [13] Márton Zoltán, Fodor Dénes, Indirekt gumibroncsnyomás meghatározás Wavelet transzformációval, XVII. ENELKO, 2016, p89-93
- [14] Continental Teves, Hungary (2008). Continental Training Handbook, Continental Teves AG. & Co. oHG.