

Jármű guminyomásának előrejelzése mélytanulási algoritmusokra épülő zajanalízis módszerével

Predicting vehicle tire pressure using a noise analysis method based on deep learning algorithms

TÓTH-NAGY Csaba, Ph.D., Abdelrahman ALABDALLAH, KRUCSÓ Tamás

Széchenyi István Egyetem, Audi Hungaria Járómérnöki Kar,
Járóműhajtás Technológia és Teljesítményelektronika Tanszék,
Győr 9011 egyetem tér 1, +36302774030, toth-nagy.csaba@ga.sze.hu

Abstract

It is possible to detect and predict faulty vehicle components and functions based on the unique noise characteristics of the failed component, which enables predictive maintenance. The hypothesis of the research was that tire pressure can also be determined from the noise characteristics. Tire pressure is easily modified, but it is not perceptible to the human ear. The method presented in this study, which can predict tire pressure based on subtle noise differences resulting from tire pressure changes, may also prove robust in detecting degradation of other components. The research used a smartphone with two integrated microphones. The tire noise was recorded by a mobile phone placed in the vehicle cabin. After processing, the measurement data were used to train an artificial neural network, which, after training, was able to predict the tire pressure in the car based on cabin noise with an accuracy of 0.3 bar in more than 90% of cases.

Keywords: NVH, deep learning, predictive maintenance, tire pressure

Kivonat

A járművek hibás alkatrészeinek és funkcióinak felismerése és előrejelzése lehetséges a meghibásodott alkatrész egyedi zajkarakterisztikája alapján, ami lehetővé teszi a prediktív karbantartást. A kutatás hipotézise az volt, hogy a gumibroncs nyomása is meghatározható a zajkarakterisztikából. A guminyomás könnyen módosítható, ugyanakkor emberi füllel nem érzékelhető. A jelen tanulmányban bemutatott módszer, amely az abroncs nyomásváltozásból adódó finom zajkülönbségeket alapján képes guminyomást előrejelezni, robusztusnak bizonyulhat más alkatrészek degradációjának detektálásánál is. A kutatás egy okostelefont használt, amely két integrált mikrofonnal rendelkezik. Az gumibroncszaj a jármű kabinjában elhelyezett mobiltelefon rögzítette. A mérési adatok feldolgozás után egy mesterséges neurális hálózat tanítására lettek felhasználva, amely betanítás után a gumibroncs nyomását az autóban detektál kabinzaj alapján, 0,3 bar pontossággal tudta megjósolni az esetek több mint 90%-ában.

Kulcsszavak: NVH, mélytanulás, prediktív karbantartás, gumibroncs nyomása

1. BEVEZETÉS

A prediktív karbantartás új távlatokat nyit a járműiparban. A gépek komplexitásának és az azokba integrált szenzoroknak köszönhetően, vannak olyan alkatrészek, amelyek meghibásodása előre jelezhető. A mély tanulás és gépi tanulás alkalmazása lehetővé teszi a gépek valós idejű, komponens szintű monitorozását. Az mai okostelefonok a beépített mikrofonjaival és szenzoraival új lehetőségeket kínálnak az előrejelzésben. A telefonok megfizethetősége és elérhetősége miatt hatékonyabb megoldást kínálnak a hagyományos szenzoros-adatgyűjtős megközelítéshez képest [1]. A prediktív karbantartást különböző területeken támogatják valós méréseken alapuló, mesterséges intelligencia alapú tanulási módszerekkel [4-6].

Az autóiparban az NVH (Noise, Vibration and Harshness) elemzés kritikus szerepet játszik. Az abroncs-útfelület interakciójából származó zajjelek lehetővé teszik az abroncs állapotának, köztük a nyomásának megbecsülését. Az utastér zajjeleit az okostelefon mikrofonjai rögzítették, majd mélytanulási algoritmusok megtanulták a rögzített menetzaj információtartalmát. A szakirodalom szerint a mélytanulási módszerek


alkalmasak a bonyolult nemlineáris összefüggések jellemzésére [2-3]. Pardeshi és társai [7] egy motorkerékpár guminyomását prediktálják rezgésszenzorok adataiból mesterséges intelligencia segítségével. Lin [8] mesterséges intelligenciával támogatott képfelismerő módszert alkalmaz a guminyomás kívülről történő meghatározására. Dhore és társai [9] nyomásérzékelőket alkalmaznak a guminyomás és a defekt meghatározására. Kubba és társa [10] 1688 cikket feldolgozó guminyomás meghatározására fókuszáló review cikke sok módszert megemlít, de a különböző gumiabroncsnyomás érzékelő vagy prediktáló rendszerek között a szakirodalom nem mutatott olyat, ami légzaj alapján prediktálja a guminyomást.

Ez a kutatás azt mutatja, hogy a neurális hálózatok képesek az abroncs nyomását az utastérben rögzített zajjelekből bizonyos pontossággal megbecsülni.

2. ESZKÖZÖK ÉS MÓDSZEREK

A kutatás integrálta a kísérleti tervezést, hangrögzítést és gépi tanulást egy jármű gumiabroncsnyomás-detektálási rendszer kifejlesztéséhez. A tanulmány szisztematikusan vizsgálta az abroncs nyomásfluktuációi (1,0–2,0 bar) és az abroncs-útfelület zajkarakterisztikái közötti kapcsolatot egy közepes méretű szedánban, szabályozott körülmények között. Az adatfeldolgozás MATLAB segítségével történt, amely spektrális jellemzőket nyert ki és betanította a neurális hálózatot.

A zajadatokat egy Samsung Galaxy S24 Ultra okostelefon rögzítette, amelyet négy mikrofonnal szereltek fel. Az adatrögzítő eszköz elhelyezkedését az 1. ábra mutatja, ami úgy lett kiválasztva, hogy a jövőbeni méréseket, amelyek szolgálják majd 2-4 kerék nyomásának prediktálását is.



1. ábra. A mérést és adatgyűjtést végző mobiltelefon (Samsung Galaxy S24 Ultra) elhelyezkedése a jármű kabinjában

Az abroncs-útfelület zajteszteket 80 km/h állandó sebességen történtek, száraz körülmények között, egy 1,8 km hosszú, egyenletes aszfaltúton. Az adatgyűjtés szisztematikus protokoll alapján történt: a gumiabroncs nyomása precíziós manométerrel lett beállítva, és 100 másodperces hangfelvételeket készültek 2 kHz-es mintavételezési frekvenciával minden nyomásszinten (1; 1,2; 1,4; 1,6; 1,8; 2 bar).

3. JELFELDOLGOZÁS ÉS NEURÁLIS HÁLÓZAT TRÉNING

A kétsatornás hangrögzítés eredményei külön adatként lettek feldolgozva, így dupla annyi adat állt rendelkezésre a mesterséges neurális hálózat tanítására. Az adatfeldolgozási lánc az adatok szegmentálással kezdődött: minden 100 másodperces felvétel 0,4 másodperces szegmensekre lett osztva finomabb időbeli felbontáshoz. Az érvénytelen értékeket (Not a Number – NaN) tartalmazó szegmenseket az adatfeldolgozó program eltávolította. Ezt követően az adatok átestek egy Fast Fourier Transzformáción (FFT). Azután egy

érzékenységtanulási megállapította, hogy a 0–500 Hz frekvenciatartományban rejlenek a szükséges adatok, amely a gumiabroncs keltette zajokat tartalmazta.

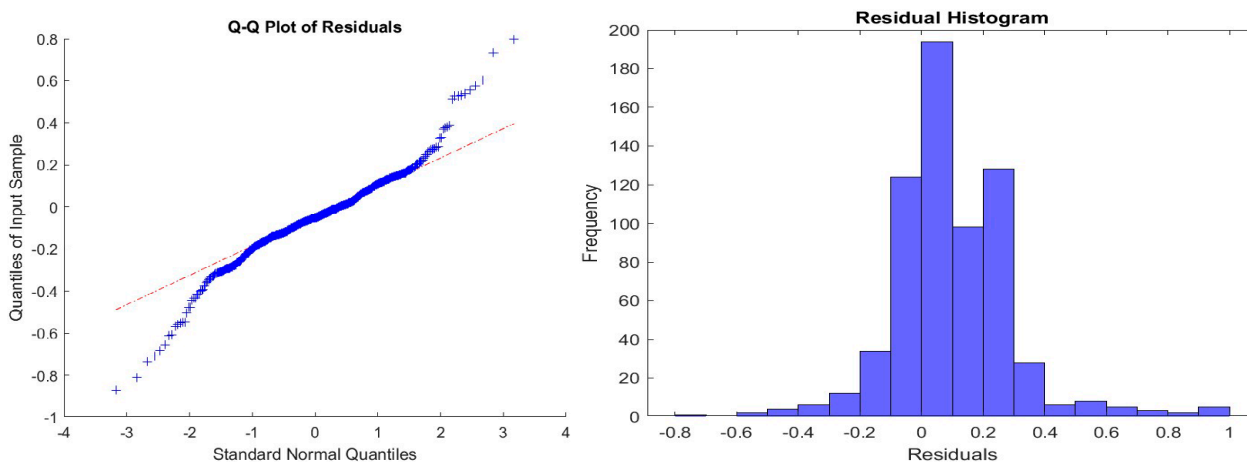
Azután a betanítás fázisa következett. Az optimalizált neurális hálózat három rejtett réteget tartalmazott: 800, 4000 és 50 neuronnal rétegenként. Az Adam optimalizálót használtuk 0,001-es tanulási sebességgel, és a modellt 150 epochon keresztül tanulta a jellemzőket, ellenőrzési veszteség alapján történő korai leállítással. Ez a konfiguráció lehetővé tette, hogy a neurális hálózat a komplex, nemlineáris kapcsolatot az abroncs nyomása és az akusztikus jellemzők között hatékonyan megtanulja és a guminyomást prediktálja.

4. EREDMÉNYEK

A mélytanulási modell megfelelő teljesítményt nyújtott. Az átlagos abszolút hiba (MAE) 0,131 bar, az átlagos négyzetes hiba gyöke (RMSE) 0,194 bar volt, és az R^2 érték 0,676 a tesztadathalmazon. A praktikus hibatarományokon belüli teljesítmény: az előrejelzések 48%-a 0,1 bar-on belül, 68%-a 0,2 bar-on belül, és 90%-a 0,3 bar-on belül esett. Ez a 68%-os pontosság a $\pm 0,2$ bar-os küszöbön belül megfelel az indirekt abroncsnyomás-monitorozó rendszerek (TPMS) képességeinek.

A modell teljesítménye a nyomástartomány során változott. Az 1,5–2,0 bar-os tartományban – amely a tipikus ajánlott abroncsnyomásnak felel meg – a modell a legjobban működött, 0,105 bar-os MAE-vel és 0,133 bar-os RMSE-vel. Az 1,0–1,5 bar-os alacsony nyomástartományban magasabb hibák léptek fel, amely az alacsony nyomásszinteken az akusztikus jelek fokozottabb variabilitásának tulajdonítható.

A maradék analízis azt mutatta, hogy a DNN (Deep Neural Network-mély neurális hálózat) jellegzetes túlbecsülési tendenciát mutatott, amit a negatív ferdeség (-1,015) és a magas kurtózis érték (6,999) jelez. A Q-Q diagramok (2-es ábra) azonban azt mutatták, hogy a hibák az eloszlás központi mennyiségei között szorosan az elméleti normál eloszláshoz igazodnak, csupán az szélsőértékek végén láthatók eltérések, ami megfelel a szakirodalomban található eredményeknek [5].



2. ábra. Baloldali ábra: az eredmények eloszlásának Q-Q ábrája, ami a eredmény eloszlását mutatja egy normáeloszláshoz képest. Jobb oldali ábra: az optimalizált neurális hálózati modell reziduális hisztogramja

5. KONKLÚZIÓK

A jelen kutatás bizonyítja, hogy az okostelefon-alapú akusztikus analízis gépi tanulási algoritmusok segítségével képes az abroncs nyomását megfelelő pontossággal becsülni. A mélytanulási neurális hálózatok értékelése azt mutatja, hogy míg a hagyományos gépi tanulási megközelítések az alapvető akusztikus-nyomás-kapcsolatot képesek megragadni, a mélytanulás jelentősen magasabb pontosságot biztosít erre az alkalmazásra. A 68%-a 0,2 bar-on belüli predikációs képesség aláhúzza a járműves akusztikus szignálok összetett, nemlineáris mintázatait, amelyek hierarchikus jelfeldolgozásból profitálnak.

A kutatás azt is kimutatta, hogy az okostelefonnal történő mentzaj-alapú gumiabroncsnyomás-beclsés gyakorlatilag megvalósítható. Ez új lehetőségeket nyit az elérhető járműdiagnosztikák felé, amelyek nem igényelnek speciális felszerelést.

6. JÖVŐBENI TERVEK

A jövőbeni kutatások a több kerékre és a járművek közötti általánosíthatóságra és a különböző környezeti feltételekre történő robusztusság tesztelésére irányuljanak, biztosítva az általános alkalmazhatóságot az autópálya több szegmensében.

IRODALMI HIVATKOZÁSOK

- [1] Hirschmiller, M.; Schlosser, K.; Rössle, M.; Fernandes, M.: Design and Prototype Development of an AI-Based Application for Predictive Maintenance Using Smart Device and Airborne Noise Data. *Procedia Computer Science*, 225, 486–495, 2023
- [2] Virt, M. Zöldy, M. „Mesterséges neurális hálózatok motorteknikai alkalmazása”, XXX. Nemzetközi Gépészeti Konferencia, 2022
- [3] M. Virt, M. Zöldy: Artificial Neural Network Based Prediction of Engine Combustion and Emissions from a High Resolution Dataset, 1st IEEE International Conference on Cognitive Mobility, 2022, <https://doi.org/10.1109/CogMob55547.2022.10118200>
- [4] Dias, R. A.; Von Hertwig, P. A Machine Learning Approach for Temporal Vibration Analysis Applied to Predictive Maintenance; 2020; Vol. 175
- [5] Hirschmiller, M.; Schlosser, K.; Rössle, M.; Fernandes, M.: Design and Prototype Development of an AI-Based Application for Predictive Maintenance Using Smart Device and Airborne Noise Data. In *Procedia Computer Science*; Elsevier B.V., 2023; Vol. 225, pp 486–495. <https://doi.org/10.1016/j.procs.2023.10.033>
- [6] Sisode, M.; Devare, M.: A Review on Machine Learning Techniques for Predictive Maintenance in Industry 4.0. 2023, 774–783. https://doi.org/10.2991/978-94-6463-136-4_67
- [7] S. S. Pardeshi, A. D. Patange, R. Jegadeeshwaran, and M. R. Bhosale, “Tyre Pressure Supervision of Two Wheeler Using Machine Learning,” *Structural Durability Health Monit.*, vol. 16, no. 3, pp. 271–290, 2022. <https://doi.org/10.32604/sdhm.2022.010622>
- [8] S. Lin, “AI-Based Tire Pressure Detection Using an Enhanced Deep Learning Architecture,” *Comput. Mater. Contin.*, vol. 83, no. 1, pp. 537–557, 2025. <https://doi.org/10.32604/cmc.2025.061379>
- [9] M. L. Dhore, A. Patthe, K. Pawar, A. Pawar and S. Pawar, "Advancing Automotive Safety: Integrated Tyre Pressure Monitoring and Puncture Detection System for Proactive Tyre Health Management," *2024 4th Asian Conference on Innovation in Technology (ASIANCON)*, Pimari Chinchwad, India, 2024, pp. 1-6, doi: 10.1109/ASIANCON62057.2024.10837891
- [10] Kubba, A. E., & Jiang, K. (2014). A Comprehensive Study on Technologies of Tyre Monitoring Systems and Possible Energy Solutions. *Sensors*, 14(6), 10306-10345. <https://doi.org/10.3390/s140610306>