

Pannon Egyetem
Műszaki Informatikai Kar
Informatikai Tudományok Doktori Iskola

Tézisek

Kontos János

BIZTONSÁGKRITIKUS JÁRMŰDINAMIKAI PARAMÉTEREK MODELLEZÉSE NEURÁLIS HÁLÓZATOK SEGÍTSÉGÉVEL

Témavezetők

Dr. Fogarassyné dr. Vathy Ágnes
Dr. Kráncz Balázs

Veszprém
2025

1 Bevezetés

Az autóipar napjainkban alapvető átalakuláson megy keresztül, amelynek során a járműveken futó szoftverek szerepe egyre meghatározóbbá válik a hagyományos mechanikai rendszerekkel szemben. Ez a szemléletváltás fejlettebb, szoftveralapú járművek megjelenéséhez vezet, amelyek a járműfunkciók teljes spektrumát, a vezetéstámogató megoldásoktól a biztonsági rendszerekig, tartalmazzák, elősegítve ezzel az összekapcsolt és autonóm mobilitási koncepciók elterjedését [1]. Ezt a technológiai fejlődést elősegítik a meghatározó iparági trendek, különösen az elektrifikáció [2], valamint a járműdinamika területén tapasztalható folyamatos innovációk. Ez utóbbi csoportba tartoznak a korszerű hajtáslánc-kialakítások, adaptív felfüggesztések és aktív futóműszabályozók, amelyek célja a járművek stabilitásának, biztonságának és általános menetdinamikai teljesítményének növelése [3].

A modern járműdinamikai szabályozások alapját az elektromos fékrendszer képezi, amely a normál fékezés mellett számos biztonságkritikus és kényelmi funkcióért felel [4]. Erre a technológiai platformra épülnek az olyan alapvető biztonsági rendszerek, mint a blokkolásgátló (ABS), az elektronikus menetstabilizáló (ESC), a magasabb súlypontú járművek (pl. Sport Utility Vehicle (SUV)-ok) térnyerésével egyre fontosabbá váló aktív borulásvédelem (ARP), valamint a fejlett vezetéstámogató rendszerek (ADAS) egyre bővülő portfóliója [5, 8]. E technológiai fejlődés csúcsát az autonóm vezetési funkciók képviselik, amelyek a jármű teljes irányításának átvételével a legfejlettebb megoldásokat igénylik [7]. Ahhoz, hogy mindezen funkciók megbízhatóan működjenek, folyamatosan pontos adatokra van szükség a járműben található nagy számú érzékelőtől. Ilyen adat például a hossz- és oldalirányú gyorsulások, a perdületi és billenési szögsebességek, a kerekek sebessége és a kormánykerékszög. Napjainkban a szenzoradatok megbízhatóságát ellenőrző algoritmusokkal és egyre gyakrabban virtuális szenzorokkal biztosítják [6]. Ezek a szoftveres modellek helyettesíthetik a fizikai érzékelőket, így akkor is működőképes marad a rendszer, ha egy szenzor részlegesen meghibásodik.

A hagyományos, fizikai modelleken alapuló megközelítéseknek azonban jelentős korlátai vannak. Járműspecifikus kalibrációt igényelnek, amihez olyan járműfüggő paraméterek (pl. tömegeloszlás, felfüggesztés-karakterisztikák) szükségesek, amelyek a fejlesztés korai szakaszaiban gyakran nem állnak rendelkezésre vagy folyamatosan változnak [9]. Bár a mesterséges intelligencia alapú módszerek ígéretes alternatívát kínálnak a predikcióra, sok esetben nagy számítási igényük miatt alkalmazásuk a korlátozott erőforrású autóiipari vezérlőegységeken nehézségekbe ütközik [10].

A bemutatott kihívások következtében egyre nagyobb az igény az olyan modellezési eljárásokra, amelyek a nagy pontosságot alacsony erőforrásigénnyel ötvözik, így jól alkalmazhatóak a beágyazott autóiipari hardvereken. Ezek a robusztus és hatékony prediktív modellek jó alapot szolgáltatnak a járműbiztonsági technológiák továbbfejlesztéséhez, a menetstabilizáló algoritmusok finomításához, valamint a fejlettebb autonóm vezetési funkciók megvalósításához.

2 Célkitűzések és alkalmazott módszerek

Kutatásom célja olyan robusztus és számítási szempontból hatékony, mesterséges neurális hálózaton alapuló modellek fejlesztése és validálása, amelyek képesek a járműdinamikai kulcsparaméterek, mint a hosszirányú és oldalirányú gyorsulás, valamint a perdületi és dőlési szögsebesség, becslésére és jövőbeli predikciójára. Ezen adatok alapvető beme-

netet képeznek a fejlett fék- és menetstabilizáló rendszerek számára [11, 12]. A fejlesztés során kulcsfontosságú szempontként kezeltem, hogy a modellek alacsony erőforrásigényük révén alkalmazhatóak legyenek a beágyazott rendszereken, kizárólag a modern járművekben megtalálható alapvető szenzorok jeleit felhasználva [13]. Ezzel a megközelítéssel a járművezérlő rendszerek prediktív képességei járműspecifikus kalibráció és drága, redundáns szenzorok nélkül növelhetők, ami széles körű alkalmazhatóságot biztosít a különböző járműplatformokon és felhasználási körülmények között.

Kutatásom alapját egy 2022-es évjáratú, kereskedelmi forgalomban kapható SUV járművel végzett, kiterjedt kísérleti adatgyűjtés és -előkészítés képezte. A méréseket több helyszínen, a veszprémi Continental tesztpályán, Veszprém városi forgalmában, valamint a Brimley-ben található (Michigan, USA) tereppályán rögzítettem hivatalos tesztszofőrök segítségével. Az adatgyűjtést 100 Hz-es mintavételezési frekvenciával történt. A gyűjtött jelek a négy kerék sebessége, az első tengely kormánysszöge, a hosszirányú és oldalirányú gyorsulások, valamint a perdületi és dőlési szögsebességek voltak.

A nyílt tudomány elveit követve, a reprodukálhatóság elősegítése érdekében közzéttem azt az előkészített adathalmazt, amely több órányi vezetési adatot tartalmaz, különféle vezetési stílusokat lefedve (például nyugodt, agresszív, városi). Ez az adatgyűjtés értékes forrást jelenthet az adatvezérelt járműdinamikai modellezéssel foglalkozó kutatók számára [14].

A kitűzött célok elérése érdekében az alábbi lépéseket valósítottam meg:

- A valós idejű oldalirányú gyorsulás becslésére egy kisméretű, előrecsatolt neurális hálózatot terveztem. A modellt kifejezetten alacsony számítási igényre optimalizáltam, lehetővé téve annak közvetlen szenzorszintű integrációját [15].
- Az idősoros adatokban rejlő komplex időbeli függőségek leírására Long short-term memory (LSTM) alapú modelleket alkalmaztam. Ezekkel valósítottam meg a hosszirányú gyorsulás [16], a perdületi szögsebesség [17] és a dőlési szögsebesség [18] rövid távú előrejelzését.
- A fejlesztett modellek predikciós képességét összevettem a szakirodalomban fellelhető modellekkel. Az eredmények igazolták, hogy a létrehozott modellek alacsonyabb erőforrásigény mellett is jobb prediktív teljesítményt nyújtanak.
- A perdületi szögsebesség-előrejelző modell robusztusságát átfogó érzékenységvizsgálattal elemeztem. A tesztek kiterjedtek a gumibroncsnyomás, az utasterhelés és a járműfelépítmény változásainak hatásaira. A kapott eredmények megerősítik a modell megbízhatóságát változó működési körülmények között is [19].

E módszertani lépések együttesen tették lehetővé olyan nagy pontosságú, megbízható és autóiipari környezetbe hatékonyan integrálható prediktív modellek létrehozását, amelyek hozzájárulnak a járművek biztonságának növeléséhez.

3 Új tudományos eredmények

Neurális hálózaton alapuló becslések a jármű különböző gyorsulási értékeire

2.1. Tézis

Kifejlesztettem és optimalizáltam egy erőforrás-hatékony, előre-csatolt neurális hálózatot, amely egyetlen, öt neuront tartalmazó rejtett réteggel rendelkezik, és képes a járművek oldalirányú gyorsulásának pontos becslésére a modern gépjárművekben jelenlévő szenzorok jeleinek alapján. A hálózat tanítása, validálása és tesztelése kizárólag kísérleti adatok felhasználásával történt. A modell bemenetként a keréksebességeket, az első tengely kormányzási szögét és a hosszirányú gyorsulást használja. A tesztalacson elért $R^2 > 0,97$ és $0,0172$ g átlagos abszolút hiba (MAE) értékkel a kifejlesztett modell nagy pontosságot mutat. Minimális számítási igénye miatt kiválóan alkalmas közvetlen integrációra szenzorokba vagy az elektronikus fékvezérlőbe, mint virtuális szenzor.

2.2. Tézis

Létrehoztam egy erőforrás-hatékony (LSTM) alapú neurális hálózatot, amely a historikus szenzorjelek felhasználásával képes nagy pontossággal előre jelezni a jármű hosszirányú gyorsulását. A modell $R^2 > 0,97$ értéket és $5,30 \times 10^{-3}$ g MAE-t ért el, még a maximális 100 ms-os előrejelzés esetén is. Annak ellenére, hogy csupán egyetlen, öt LSTM neuront tartalmazó rejtett réteggel rendelkezik, a hálózat képes a sokkal nagyobb méretű és lényegesen magasabb számítási igényekkel rendelkező meglévő megközelítésekénél jobb becslést adni. A tanítási, validálási és tesztelési fázisok során kizárólag kísérleti adatokat használtam fel, hogy valós körülmények között is biztosítani tudjam a modell megbízhatóságát.

Perdülési és dőlési szögsebességek LSTM-alapú előrejelzése és érzékenységvizsgálata

3.1. Tézis

Kifejlesztettem egy LSTM neurális hálózatot, amely képes előre jelezni a gépkocsi perdülési szögsebességét akár 200 ms-os időhorizonttal. A modellt általános alkalmazhatóságra terveztem, kizárólag olyan szabványos szenzorjelek felhasználásával – mint a hosszirányú és oldalirányú gyorsulás, a perdülési szögsebesség, az első tengely kormányzási szöge, valamint a keréksebességek –, amelyek megtalálhatók a modern járművekben. A modell nem igényel járműspecifikus paramétereket bemenetként. Az architektúra egyetlen rejtett rétegből áll, amely 5 LSTM neuront tartalmaz. A kis paraméterszám ellenére a modell magas predikciós teljesítményt ért el a független tesztalacson: $R^2 = 0,9984$, $MAE = 0,316^\circ \text{ s}^{-1}$, ami alátámasztja a megoldásom robusztus alkalmazhatóságát.

3.2. Tézis

Létrehoztam egy LSTM-alapú modellt a jármű dőlési szögsebességének előrejelzésére, komplex terepi körülményekre. Több predikciós horizont vizsgálata után a 40 ms-os

előrejelzési időtáv bizonyult ideálisnak, amely elég rövid ahhoz, hogy az aktív borulásvédelemhez (ARP) időben szolgáltatassak adatot, miközben még nem csökken érezhetően a pontosság. Az egyetlen, 7 LSTM neuront tartalmazó rejtett réteggel rendelkező modell $R^2 = 0,9593$, $MAE = 1,107 \text{ }^\circ\text{s}^{-1}$ értékeket ért el független tesztalacson, robusztus teljesítményt mutatva terepi alkalmazásokhoz, így a kifejlesztett modell teljesíti az ASIL B biztonsági szintet.

3.3. Tézis

Érzékenységvizsgálatot végeztem a perdülési szögsebesség-előrejelző modell robusztusságának és általánosíthatóságának felmérése érdekében, mely eredményei igazolták, a kifejlesztett modell a működési körülmények széles skáláján is robusztus. A csökkentett gumiabroncsnyomás és a változó utasterhelés mindössze minimális pontosságromlást okozott: még agresszív vezetési stílus mellett is a MAE eltérések $0,5 \text{ }^\circ\text{s}^{-1}$ alatt maradtak. A különböző járműtípusokon végzett átvihetőségi tesztek szintén $0,5 \text{ }^\circ\text{s}^{-1}$ alatti MAE-eltéréseket mutattak. Következtetésként levonható, hogy a járművek tömegeloszlása kritikusabb tényező, mint a teljes tömeg, különösen a hibrid és elektromos modellek esetében. Mindezekre építve azt is meghatároztam, hogy mennyi tanítóadat szükséges: tapasztalataim szerint 10–15 percnyi változatos, dinamikus vezetési adat már elegendő pontosságot biztosít a nem biztonságkritikus alkalmazásokhoz, míg a biztonságkritikus rendszerekben a maximális robusztusság érdekében továbbra is a minél több mérési adatot tartalmazó adathalmazra van szükség.

4 Az eredmények hasznosítása

A kifejlesztett neurális hálózati architektúrák képesek pontosan előre jelezni az oldalirányú és hosszirányú gyorsulást, a perdülési szögsebességet és a dőlési szögsebességet a modern gépjárművek részét képező járműszensor-bemenetek felhasználásával. Ezek az előrejelzések kulcsfontosságúak a biztonságkritikus rendszerek funkcionalitásának javításához.

Kutatásom egyik kulcsfontosságú eredményeként kifejlesztettem egy kompakt, előre-csatolt neurális hálózatot, amely az oldalirányú gyorsulást becsüli. A modellt felépítéséből adódóan, közvetlenül a szenzorhardverbe integrálható, így virtuális szenzorként is funkcionálhat.

Ezen túlmenően LSTM hálózatokat hoztam létre a hosszirányú gyorsulás (0,1 s), a perdületi szögsebesség (0,2 s) és a terepi dőlési szögsebesség (0,04 s) hatékony előrejelzésére. Elvégeztem a perdületi szögsebesség-modell átfogó érzékenységvizsgálatát, amellyel igazoltam, hogy a modell a gumiabroncsnyomás, az utasterhelés és a járműstruktúra változásai mellett is megbízhatóan, a biztonsági előírásoknak megfelelően működik.

A kifejlesztett modellek a szakirodalomban fellelhető megoldásokhoz képest magasabb pontosságot mutatnak, miközben lényegesen alacsonyabb számítási igényt támasztanak. Ez rendkívül alkalmassá teszi őket korlátozott feldolgozási teljesítményű, beágyazott autóiipari rendszerekben való integrálásra.

A kiterjedt kísérleti adatokon végzett validálás igazolta a kifejlesztett modellek megbízhatóságát valós körülmények között, és kimutatta, hogy alkalmazkodóképességük és hatékonyságuk révén az önvezető rendszerekben is nagy potenciállal bírnak. Fontos azonban kiemelni, hogy a modellek alkalmazhatósága jelenleg a tanítási adathalmaz rögzítése során alkalmazott specifikus körülményekre korlátozódik. Ez magában foglalja a

vizsgált sebességtartományokat (az egyes modelleknél 135 km/h, 50 km/h, illetve 30 km/h felső határral), valamint az elsődlegesen használt SUV járműtípust. Következésképpen, a szélesebb körű, biztonságkritikus alkalmazásuk további validációs lépéseket igényel.

Publikációk

Modellfejlesztéshez használt adathalmazok

- P1** János Kontos, László Bódis and Ágnes Vathy-Fogarassy (2025). Experimental Sensor Data from Vehicles for Dynamic Vehicle Models [Dataset]. figshare. <https://doi.org/10.6084/m9.figshare.28078274.v1>

Neurális hálózaton alapuló becslések a jármű különböző gyorsulási értékeire

- P2** János Kontos, Balázs Kránicz and Ágnes Vathy-Fogarassy (2022). Neural network-based prediction for lateral acceleration of vehicles. *2022 IEEE 2nd Conference on Information Technology and Data Science (CITDS)*, 153–158. Debrecen, Hungary. <https://doi.org/10.1109/CITDS54976.2022.9914270>
- P3** János Kontos, László Bódis, Ágnes Vathy-Fogarassy (2024). Forecasting longitudinal acceleration in urban vehicles. In I. Maglogiannis, L. Iliadis, J. Macintyre, M. Avlonitis, & A. Papaleonidas (Eds.), *Artificial intelligence applications and innovations* (Q3), (Vol. 713, pp. 85-98). Springer. https://doi.org/10.1007/978-3-031-63219-8_7
- P4** János Kontos, Ágnes Vathy-Fogarassy and Balázs Kránicz (2021). Phase plane-based approaches for event detection and plausibility check of vehicle dynamics. *2021 IEEE 25th International Conference on Intelligent Engineering Systems (INES)*, 31–36. Budapest, Hungary. <https://doi.org/10.1109/INES52918.2021.9512897>

Perdülési és dőlési szögsebességek LSTM-alapú előrejelzése és érzékenységvizsgálata

- P5** János Kontos, László Bódis, Ágnes Vathy-Fogarassy (2025). Sensitivity analysis of Long Short-Term Memory-based Neural Network Model for Vehicle Yaw Rate Prediction. *Sensors* (Q2), 25 (5), 1363. <https://doi.org/10.3390/s25051363>
- P6** János Kontos, László Bódis, Ágnes Vathy-Fogarassy (2023). Prediction for Future Yaw Rate Values of Vehicles Using Long Short-Term Memory Network. *Sensors* (Q2), 23(12), 5670. <https://doi.org/10.3390/s23125670>
- P7** János Kontos, László Bódis, Ágnes Vathy-Fogarassy (2024). Forecasting Roll Rate for Sensor Plausibility Check in Off-Road Vehicle Conditions. *2024 IEEE 3rd Conference on Information Technology and Data Science (CITDS)*, 1–6. Debrecen, Hungary. [10.1109/CITDS62610.2024.10791355](https://doi.org/10.1109/CITDS62610.2024.10791355)

MTMT profil

<https://m2.mtmt.hu/gui2/?type=authors&mode=browse&sel=10060628>



Irodalomjegyzék

- [1] P. V. Teixeira, D. Raposo, R. Lopes, and S. Sargento, „Deterministic and reliable software-defined vehicles: Key building blocks, challenges, and vision,” 2025. [Online]. Available: <https://arxiv.org/abs/2407.17287>
- [2] B. Frieske, S. Hasselwander, O. Deniz, S. Stieler, and S. Schumich, „Scenario-based analysis of electrification effects on value creation and employment structures for the automotive industry in the federal state of baden-wuerttemberg, germany,” *World Electric Vehicle Journal*, vol. 15, no. 10, 2024.
- [3] I. Dridi, A. Hamza, and N. B. Yahia, „A new approach to controlling an active suspension system based on reinforcement learning,” *Advances in Mechanical Engineering*, vol. 15, no. 6, p. 16878132231180480, 2023.
- [4] P. Sli´z and E. Wycinka, „Identification of factors that differentiate motor vehicles that have experienced wear or failure of brake system components during the warranty service period,” *Eksploatacja I Niezawodnosc-maintenance and Reliability*, vol. 23, pp. 430–442, 2021.
- [5] V. Guarenghi, R. Pizzi, A. Depetris, and G. Pinto, „Analysis of road safety implementation strategies to support the easiest introduction of autonomous braking products for complex vehicle combinations,” SAE International, Tech. Rep. 2024-36-0319, 2024.
- [6] P. Sinha, „Architectural design and reliability analysis of a fail-operational brake-by-wire system from iso 26262 perspectives,” *Reliability Engineering & System Safety*, vol. 96, no. 10, pp. 1349–1359, 2011.
- [7] Y. Wiseman, „Autonomous vehicles,” in *Encyclopedia of Information Science and Technology, Fifth Edition*, M. Khosrow-Pour, Ed. IGI Global Scientific Publishing, 2021, pp. 1–11.
- [8] B. Lenzo, *Vehicle Dynamics: Fundamentals and Ultimate Trends*, ser. CISM International Centre for Mechanical Sciences. Springer International Publishing, 2021.
- [9] L. Cui, J. Hu, B. Park, and P. Bujanovic, „Development of a simulation platform for safety impact analysis considering vehicle dynamics, sensor errors, and communication latencies: Assessing cooperative adaptive cruise control under cyber attack,” *Transportation Research Part C Emerging Technologies*, vol. 97, 12 2018.

- [10] E. A. Etukudoh, S. Sonko, K. I. Ibekwe, V. I. Ilojianya, and C. D. Daudu, „A comprehensive review of embedded systems in autonomous vehicles: Trends, challenges, and future directions,” *World Journal of Advanced Research and Reviews*, 2024.
- [11] C. Zhang, Y. Wang, Y. Fu, X. Qiao, M. S. Nazir, and T. Peng, „A novel dwtimesnet-based short-term multi-step wind power forecasting model using feature selection and auto-tuning methods,” *Energy Conversion and Management*, 2024.
- [12] Y. Huang and Y. Chen, „Vehicle lateral stability control based on shiftable stability regions and dynamic margins,” *IEEE Transactions on Vehicular Technology*, vol. 69, pp. 14727–14738, 2020.
- [13] A. Isbitirici, L. Giarré, W. Xu, and P. Falcone, „Lstm-based virtual load sensor for heavy-duty vehicles,” *Sensors (Basel, Switzerland)*, vol. 24, 2023.
- [14] J. Kontos, L. Bódis and Á. Vathy-Fogarassy, „Experimental Sensor Data from Vehicles for Dynamic Vehicle Models [Dataset],” *figshare*, 2025. <https://doi.org/10.6084/m9.figshare.28078274.v1>
- [15] J. Kontos, B. Kránicz and Á. Vathy-Fogarassy, „Neural network-based prediction for lateral acceleration of vehicles,” in *2022 IEEE 2nd Conference on Information Technology and Data Science (CITDS)*, Debrecen, Hungary, 2022, pp. 153–158.
- [16] J. Kontos, L. Bódis, Á. Vathy-Fogarassy, „Forecasting longitudinal acceleration in urban vehicles,” in *Artificial intelligence applications and innovations (Q3)*, I. Maglogiannis, L. Iliadis, J. Macintyre, M. Avlonitis, & A. Papaleonidas (Eds.), Vol. 713, pp. 85-98. Springer, 2024.
- [17] J. Kontos, L. Bódis, Á. Vathy-Fogarassy, „Prediction for Future Yaw Rate Values of Vehicles Using Long Short-Term Memory Network,” *Sensors*, vol. 23, no. 12, p. 5670, 2023.
- [18] J. Kontos, L. Bódis, Á. Vathy-Fogarassy, „Forecasting Roll Rate for Sensor Plausibility Check in Off-Road Vehicle Conditions,” in *2024 IEEE 3rd Conference on Information Technology and Data Science (CITDS)*, Debrecen, Hungary, 2024, pp. 1–6.
- [19] J. Kontos, L. Bódis, Á. Vathy-Fogarassy, „Sensitivity analysis of Long Short-Term Memory-based Neural Network Model for Vehicle Yaw Rate Prediction,” *Sensors*, vol. 25, no. 5, p. 1363, 2025.