

Alacsony hőmérsékletű égésfolyamatok mesterséges intelligencia alapú analízise

AI-based analysis of low temperature combustion

VIRT Márton¹, Dr. ZÖLDY Máté¹

1 – Budapesti Műszaki és Gazdaságtudományi Egyetem, 1111 Budapest, Műegyetem rkp. 3., tel.: +36 1 463-1111, fax: +36 1 463-1110, info@bme.hu, www.bme.hu

Abstract

Heavy-duty vehicles and other commercial vehicles require high energy-density onboard energy storage provided by internal combustion engines, along with cost efficiency. Therefore, their environmental impact must be further reduced in the future. Low temperature combustion (LTC) offer an excellent solution, as it can simultaneously reduce nitrogen oxide and soot emissions in compression ignition engines while improving efficiency. However, controlling such unstable combustion processes is challenging, making the use of model predictive controllers (MPC) essential for market applications, as they can regulate combustion on a cycle-to-cycle basis. Instead of traditional physical models, artificial intelligence (AI) based models can be more effective due to their simplicity, making them a viable option for MPC development. This paper presents AI-based models capable of predicting the key parameters of the combustion process during both conventional diesel and LTC operation. The applied LTC process is modulated kinetics (MK), that utilizes high levels of exhaust gas recirculation (EGR). The models were trained and validated using 113 different inlet oxygen concentrations to accurately model the effects of EGR. The results show that the models are accurate, making it possible to implement an MPC using them in future research.

Keywords: Artificial Intelligence, Low temperature combustion, Model predictive control, AI prediction, Modulated kinetics

Kivonat

A nehézgépjárművek és a szállítmányozás egyéb haszongépjárművei megkövetelik a belsőégésű motorok által nyújtott nagy energiasűrűségű fedélzeti energiatárolást és a költséghatékonyságot, így ezek környezetterhelését a jövőben tovább kell csökkenteni. Erre az alacsony hőmérsékletű égésfolyamatok (LTC) kitűnő megoldást nyújtanak, hiszen alkalmazásukkal egyidejűleg csökkenthető a kompressziógyújtású motorok nitrogén-oxid és korom emissziója, valamint a hatásfok is növelhető. Ugyanakkor az ilyen instabil égésfolyamatok irányítása nehéz, emiatt a piaci alkalmazások esetén elengedhetetlen a modell prediktív vezérlők (MPC) használata, melyek ciklusról ciklusra irányíthatják az égésfolyamatot. A hagyományos fizikai modellek helyett a mesterséges intelligencia (AI) alapú modellek hatékonyabbak lehetnek egyszerűségük miatt, ezért az MPC készítése során is érdemes lehet erre támaszkodni. Ebben a cikkben mesterséges intelligencia alapú modellek kerülnek bemutatásra, melyek képesek az égésfolyamat legfontosabb paramétereit előrejelezni normál dízel illetve LTC üzem során. A létrehozott LTC folyamat modulált kinetika (MK) típusú, mely nagyarányú kipufogógáz visszavezetést (EGR) alkalmaz. A modellek így 113 különböző szívóoldali oxigénkoncentráció mellett lettek betanítva és validálva, hogy az EGR hatása megfelelően modellezésre kerüljön. Az eredmények azt mutatják, hogy a modellek pontosak, így a jövőbeni kutatások során ezek felhasználásával lehetséges egy MPC implementálása.

Kulcsszavak: Mesterséges intelligencia, Alacsony hőmérsékletű égésfolyamat, Model prediktív vezérlés, AI predikció, Modulált kinetika

1. BEVEZETÉS

Az Európai Unió az európai zöld megállapodás részeként 2050-ig nem csak a klímasemlegességet tűzte ki célul, hanem a légszennyezés emberre nem veszélyes mértékre történő csökkentését is [1]. Ezek a rendkívül ambiciózus célok csak több ipari és gazdasági szektor szoros együttműködésével valósulhatnak meg. Az európai közeledés ebben kritikus szerepet játszik, hiszen nem csak a légszennyezés terén jelentős, hanem a kontinens széndioxid emissziójának 24%-áért is felelős [2]. A jelenlegi piaci tendenciák azt mutatják, hogy a személygépjármű szektor elektrifikációja lassan halad [3], illetve haszongépjárművek esetén olyan technológiai akadályok lépnek fel melyek még hosszabb távon sem teszik költséghatékonyá az elektrifikációt. A klímasemlegesség és a légszennyezés csökkentése más alternatív megoldásokkal is elérhető [4]. Az egyik ilyen a megújuló tüzelőanyagok használata, melyek segítségével a meglévő járműpark is klímasemlegessé tehető [5, 6]. Ugyanakkor a motorteknikai fejlesztések továbbra is fontosak, különösen a haszonjármű szektorban, ahol még hosszabb távon a belsőégésű motorokra fognak támaszkodni a hajtásrendszerek. Az alacsony hőmérsékletű égésfolyamatok (LTC) olyan motorteknikai újítást képviselnek, amely a haszonjárművek kompressziógyújtású motorjait kevésbé szennyezővé teheti [7]. Az LTC lényege az, hogy homogén szegény keveréket hozunk létre az égéstérben, melyet nagy maradékgáz tartalom mellett kompressziógyújtással elégetünk [8]. A töltet homogenitása hozzájárul a kisebb koromképződéshez, a nagy maradékgáztartalom pedig a nitrogén oxid (NO_x) emisszió csökkenéséhez az általa okozott alacsonyabb égési hőmérséklet miatt. A NO_x és a koromképződés közt fennálló kompromisszum javításán túl a motor hatásfoka is jobb lehet, hiszen a kompressziógyújtás és a fojtószelep hiányából fakadó jó hatásfokot az alacsonyabb hőmérséklet okozta kisebb hőveszteség is fokozza [9]. A homogén töltet kompressziógyújtása gyors térfogati égésfolyamatot eredményez. A nagyarányú maradékgáz tartalom, illetve a szegény keverék alkalmazása az égésfolyamat intenzitását oly mértékben képes korlátozni, hogy az már biztonságos motorüzemet eredményez. Ugyanakkor ez a technológia számos problémával küzd, melyek még megakadályozzák a piacra lépést. Ilyen probléma például a szegény keverék és a nagy nyomásgradiensek okozta korlátozott motorüzem, valamint a nehézkes égésfolyamat szabályzás. Számos különböző LTC megvalósítási forma létezik, melyek különböző módokon orvosolják a problémákat, leginkább az LTC előnyei és hátrányai közti megfelelő kompromisszum felállításával. Ilyen megoldás a modulált kinetika (MK), mely hagyományos időzítésű közvetlen befecskendezést, valamint nagyon nagy arányú kipufogógáz visszavezetést (EGR) alkalmaz intenzív perdületes áramlást keltő égéstérben [10]. Az ideális LTC megvalósítási formának tekinthető homogén töltetű kompressziógyújtáshoz (HCCI) képest az MK jobb kezelhetőséget és egyszerűbb megvalósíthatóságot kínál, viszont a koromkibocsátása és hatásfoka valamivel rosszabb. Emiatt az ilyen kompromisszummal járó technikák alkalmazása nem ideális megoldás. A HCCI stabil vezérlésére irányuló fejlesztések, mint például a modell prediktív vezérlőkön (MPC) alapuló ciklusról ciklusra történő szabályzás olyan megoldást adhat az LTC problémáira, mely sokkal kisebb környezetterhelésű motortekológiát eredményezhet.

A modell prediktív vezérlők jellemzően fizikai modelleket alkalmaznak a megfelelő szabályzás eléréséhez. A fizikai modellek gyakran komplikáltak és számításgényesek, valamint limitált tartományon alkalmazhatóak kellő pontossággal. Emiatt a legújabb kutatások a mesterséges intelligencia (AI) alapú MPC-k alkalmazását vizsgálják. Az AI segítségével sokkal egyszerűbb modellek hozhatóak létre, melyek nagyobb működési tartományon is jó pontossággal működnek [11]. A motorteknikában az egyik legelterjedtebb AI megoldás a többrétegű perceptronos (MLP) mesterséges neurális hálózatok (ANN) alkalmazása. Ezek a hálózatok egy bemeneti és egy kimeneti rétegből, valamint a köztük lévő rejtett rétegekből állnak. Struktúra szempontjából minden réteg neuronjai kapcsolatban állnak az előző réteg összes neuronjával. Az LTC motorok AI alapú modell prediktív vezérlése egy új terület számos kutatási résszel. Ugyanakkor az irodalomban már fellelhető kevés számú ilyen kutatás is, például Batoöl és tsai. akik 92.4%-os pontossággal voltak képesek égésfüggvények AI alapú osztályzására, majd az égési súlypont és indikált középnyomás pontos szabályzására [12]. Bao és tsai. egy reaktivitás vezérelt kompressziógyújtású motoron [13], Vaughan és tsai. pedig egy HCCI motoron [14] értek el hasonlóan jó eredményeket AI alapú MPC alkalmazásával.

Ebben a munkában célunk olyan AI alapú égésfolyamat modellek készítése, melyek alapján a későbbiekben olyan modell prediktív vezérlést hozhatunk létre, ami pontosabban működik, mint az irodalomban bemutatott megoldások. A vezérlő elkészítéséhez összesen öt különböző égésfolyamat paraméter predikcióját valósítjuk meg MLP hálózatok segítségével. Ezek az égéskezdet (SoC), égés vége (EoC), égési súlypont (CoHR), égésfüggvény maximum (HRR_{max}), és égésfüggvény maximum helyzete (ϕ_{HRR}). A modelleket egy olyan 113 mintát tartalmazó adatsoron tanítottuk és elemeztük, mely normál dízel és MK típusú LTC égésfolyamatokat is tartalmaz különböző szívóoldali oxigénkoncentrációk mellett. Az oxigénkoncentrációkat alacsony nyomású kipufogógáz visszavezetés (LP-EGR) segítségével szabályoztuk.

A modellek betanítása egy olyan sajátfejlesztésű költséghatékony módszertan szerint történt, mely a korábbi kutatásaink során jött létre [15].

2. ALKALMAZOTT ESZKÖZÖK ÉS MÓDSZEREK

2.1 AI modellek készítése

A sajátfejlesztésű módszertan [15] alapján készülő MLP hálózatokat Python környezetben, a Keras és TensorFlow könyvtárak alkalmazásával készítjük el. Az adatsor előfeldolgozása az első lépés, mely során a bemeneti jellemzőket 0 és 1 közötti tartományba skáláztuk, hogy ezzel megelőzzük az esetleges túlszóródásokat. Az adatsor összesen 113 mintát tartalmaz, valamint összesen 4 lehetséges bemeneti jellemzőt. Ezek a szívóoldali oxigén koncentráció, az LP-EGR szelep állása, a MEB szelep állása, valamint a szívóoldali nyomás. Az 5 előrejelezni kívánt paraméterhez 5 különböző modellt tanítunk be. Az egyes modellek esetén rekurzív jellemzőeltávolítási módszert (RFE) alkalmazunk a ténylegesen szükséges bemeneti paraméterek azonosítására. Az adatsort három részre osztottuk: egy tanító adatsorra 85 mintával, egy validációs adatsorra 16 mintával, valamint egy teszt adatsorra 12 mintával. A tanító adatsort az AI tanítás során alkalmazzuk. A tanításhoz Adam algoritmust használtunk mely gyorsan és pontosan képes optimalizálni a hálózat súlyait. A hálózatban ReLU típusú aktivációs függvényeket alkalmaztunk, hogy az eltűnő gradiensek problémáját megelőzzük. A túltanulást korai leállítási módszerrel akadályoztuk meg, mely a validációs adatsor pontosságát figyelve detektálja azt a pontot, ahol a tanítást abba kell hagyni. A validációs adatsort ezen kívül hiperparaméter optimalizációra is használtuk, például a helyes architektúra azonosítására. A hálózat struktúráját egy konstruktív architektúra kiválasztási módszerrel határoztuk meg. Ez az iteratív módszer egy kis kapacitású hálózat betanításával kezdődik, majd az iteráció során a neuronok és rejtett rétegek számát addig növeli, amíg nem jelentkezik túltanulás. Az AI tanítás véletlenszerűségét oly módon vettük figyelembe az optimalizáció során, hogy 8 betanított modell átlagos pontosságát vettük figyelembe. A végleges hálózatokat a teszt adatsoron elemeztük, mellyel a folyamat során nem találkozott a háló. Az értékelést a leggyakrabban használt mérőszámok alapján végeztük. Ezek az átlagos abszolút hiba (MAE), az átlagos négyzetes hiba gyöke (RMSE) és a determinációs együttható (R^2).

2.2 A mérőrendszer

A motorfékpad méréseket egy Cummins ISBe 170 30 típusú haszonjármű dízelmotoron végeztük el, mely egy négyhengeres, turbófeltöltött, közös nyomócsöves motor. Főbb paraméterei az 1. táblázatban találhatóak. Egy örvényáramú fékgép segítségével egyetlen munkapontot, állítottunk be 1250 rpm fordulatszám és 50 Nm nyomaték mellett. Korábbi tapasztalataink azt mutatták, hogy az MK égésfolyamatot ezen a munkaponton hatékonyan el tudjuk érni LP-EGR alkalmazásával [16]. Az EGR szelepet CAN-en keresztül működtettük, valamint ezen kívül egy kipufogóféket (MEB) is, mely segítségével jóval nagyobb arányú kipufogógáz visszavezetést valósíthattunk meg. Az oxigén koncentrációt a szívó és kipufogó oldalon is egy Continental UniNOx szenzor segítségével mértük meg. Az égésfolyamatot egy AVL indikáló rendszer segítségével analizáltuk, mely AVL GH13P típusú piezoelektromos nyomásérzékelőkön, egy AVL 365C főtenge ly szögjeladón, és egy AVL 612 IndiSmarton alapul. Égéskezdetnek azt a főtenge ly szöget tekintjük, ahol a felszabadult teljes hőmennyiség 5%-a szabadult fel. Az égés súlypontja és vége esetén ezek a szögértékek 50, illetve 90% hőfelszabadulás esetén értelmezendők.

A mérőmotor főbb paraméterei

1. táblázat

Lökettérfogat	Furat	Löket	Kompresszióviszony	Névleges effektív teljesítmény
3922 cm ³	102 mm	120 mm	17.3	125 kW

3. EREDMÉNYEK

A nagyarányú LP-EGR és a perdületes áramlást biztosító égéstér segítségével sikeresen megvalósítottuk az MK égésfolyamatot, melynek eredményei a korábbi vizsgálatunknak megfelelően alakultak [16]. Az EGR jelentősen késleltette az égésfolyamat beindulását, ezáltal a megnövekedett gyulladási késedelem alatt a befecskendezett tüzelőanyag képes volt előkevert töltetet formálni. Az MK

égésfüggvénye közel szimmetrikus égésfolyamatot mutat melyet az előkevert fázis dominál, nincs olyan jól megkülönböztethető diffúziós szakasz, mint a hagyományos dízel égésfolyamat esetén.

A mérősorozat során 9,2 és 20,4% szívóoldali oxigénkoncentráció közt vettünk fel mérési pontokat 0,1% felbontás mellett. Így összesen 113 statikus munkapontot rögzítettünk 1250 rpm fordulatszám és 50 Nm nyomaték mellett. Ezt a 113 munkapontot a 2.1 fejezet módszerei szerint felhasználtuk neurális hálózatok betanítására. Így összesen 5 különböző modellt készítettünk. Ezek közül az első az égéskezdet modell. Az RFE eljárás során az MEB szelep pozíciója és a szívóoldali oxigénkoncentráció került kiválasztásra bemeneti paraméterként. Ez logikus, hiszen az oxigénkoncentráció volt a mérés egyik beállított paramétere, illetve főként a MEB szelep állításával szabályoztuk az EGR rátát. Az architektúra azonosítás során egy kis kapacitású modell került meghatározásra egyetlen rejtett réteggel, melyben 30 neuron található. A modell struktúrája így: 2-30-1. A 2. táblázatban láthatóak a modell pontosságát jellemző mérőszámok. Az eredmények azt mutatják, hogy az SoC modell a kis kapacitás ellenére rendkívül pontos. A 0,5°ft körüli átlagos abszolút hiba megfelelően pontosan leírja az égés kezdő helyzetét, a determinációs együtthatók pedig 1-hez közeli értékűek. Így ez a modell megfelelő.

Az égéskezdet modell eredményei

2. táblázat

	MAE [°ft]	RMSE [°ft]	R ² [-]
Tanító adatsor	0,285	0,372	0,993
Validációs adatsor	0,522	0,636	0,972
Teszt adatsor	0,321	0,362	0,993

A következő modell az égés végét jelzi előre. Ez a modell mindössze a szívóoldali oxigénkoncentrációt alkalmazza bemenetként, struktúrája pedig igen nagy kapacitású, három rejtett réteggel rendelkezik. A modell struktúrája 1-40-40-40-1. A nagy kapacitás ellenére ez a modell viszonylag pontatlan. A 3. Táblázatban látható adatok szerint körülbelül 1°ft pontossággal adható meg az égésfolyamat vége, illetve a determinációs együttható is messzebb van az 1-es értéktől. Ez feltehetően azért alakult így, mert az égés vége függ a pontos kezdőszögtől, illetve az égéstartamtól. Mindkét paraméterre önmagában hatást gyakorol a kipufogógáz visszavezetés és az égéstér hőmérséklete is, így ezek az egymásra épülések egy komplex folyamatot képeznek, mely még nagy modellkapacitás esetén sem jelezhető előre. A további kapacitásnövelés, illetve bemenő jellemzők hozzáadása a modell túltanulásához vezetett a kísérletek során. Ez azt jelenti, hogy a tanító adatsorra vetített pontosság jóval nagyobb lenne, mint a teszt adatsor pontossága, ezáltal a modell generalizációs képessége romlana. Így az adott mérési adatsorból az itt bemutatott modellt jelentősen tovább fejleszteni nem lehetséges. Ettől függetlenül a 0,9 feletti R² még mindig jó eredménynek mondható.

Az égés vége modell eredményei

3. táblázat

	MAE [°ft]	RMSE [°ft]	R ² [-]
Tanító adatsor	0,794	0,985	0,913
Validációs adatsor	0,844	1,045	0,918
Teszt adatsor	0,869	1,023	0,903

Az égési súlypont egy kifejezetten fontos paraméter, hiszen ennek segítségével a motor hatásfoka könnyen optimalizálható. Ez a paraméter, hasonlóan az EoC modellhez komplex összefüggésben áll az égéskezdettel és a kipufogógáz különböző reakciókinetikára gyakorolt hatásaival. Az RFE eljárás szerint itt 3 bemeneti paraméter alkalmazása szükséges. Ezek az LP-EGR és MEB szelep pozíciók, valamint a szívó oldali oxigén koncentrációk. A modell viszonylag nagyobb kapacitású az optimalizáció során létrehozott két rejtett réteggel. Az architektúra: 3-45-15-1. A 4. táblázatban közölt eredmények kiváló pontosságot mutatnak. A 0,25 °ft körüli abszolút hiba a későbbi modell prediktív vezérlő készítésénél lehetővé teszi az égésfolyamat könnyű szabályzását. A modell 0,99 körüli determinációs együtthatója szintén a kiemelkedő pontosságot mutatja.

Az égési súlypont modell eredményei

4. táblázat

	MAE [$^{\circ}\text{ft}$]	RMSE [$^{\circ}\text{ft}$]	R^2 [-]
Tanító adatsor	0,233	0,295	0,990
Validációs adatsor	0,244	0,293	0,987
Teszt adatsor	0,260	0,310	0,992

További lényeges paraméter az égésfüggvény csúcscértéke, hiszen ennek értéke összefügg a nyomásgradiens nagyságával, így LTC motorok esetén ennek becslése fontos. Az egyetlen lényeges paraméternek a bemeneti oxigénkoncentráció bizonyult, illetve ez a modell rendelkezik a legnagyobb kapacitással 1-50-50-50-1 struktúrája révén. Ennek ellenére ez a modell a legpontosatlanabb. Az 5. táblázatban látható, hogy a csúcscérték csak $3,5 \text{ J}/^{\circ}\text{ft}$ körüli pontossággal jelezhető előre. Az adatsorban jellemzően $60 \text{ J}/^{\circ}\text{ft}$ körüli csúcscértékek jelentkeznek, így ehhez képest ez nem olyan nagy eltérés, de a determinációs együtthatók 0,9 alattiak. Ezen kívül a tanító és teszt adatsor R^2 értékeit összehasonlítva látható, hogy további kapacitás növelés már a túltanulás veszélyét hordozná. A biztonságos motorüzem érdekében ez a modell más mérési paraméterek beiktatásával tovább javítandó az MPC-ben való alkalmazást megelőzően.

Az égésfüggvény maximum modell eredményei

5. táblázat

	MAE [$\text{J}/^{\circ}\text{ft}$]	RMSE [$\text{J}/^{\circ}\text{ft}$]	R^2 [-]
Tanító adatsor	3,658	4,455	0,878
Validációs adatsor	3,377	4,474	0,852
Teszt adatsor	3,655	4,661	0,802

Az utolsó előrejelzett paraméter az égésfüggvény csúcscértékének helyzete. Ez a modell három paramétertől függ: Az LP-EGR és a MEB szelep pozíciójától, valamint a szívóoldali oxigénkoncentrációtól. Két rejtett réteggel egy nagyobb kapacitású modelltől beszélhetünk, a választott architektúra: 3-50-40-1. Ez a modell szintén elegendően pontosnak számít, a 6. táblázat szerint 1°ft alatti abszolút hibával képes előrejelezni az égésfüggvény csúcscértékét. A 0,97 feletti determinációs együttható szintén elfogadhatóan közel van az ideális 1-es értékhez.

Az égésfüggvény csúcscérték szöghelyzet modell eredményei

6. táblázat

	MAE [$^{\circ}\text{ft}$]	RMSE [$^{\circ}\text{ft}$]	R^2 [-]
Tanító adatsor	0,511	0,797	0,980
Validációs adatsor	0,633	0,977	0,970
Teszt adatsor	0,701	0,911	0,975

4. KONKLÚZIÓ

A bemutatott kutatás során olyan AI modellek kerültek meghatározásra, melyek az égésfolyamat főbb paramétereit képesek gyorsan és egyszerűen előrejelezni a különböző üzemi viszonyok alapján normál és LTC módban is. Ezek a modellek a későbbi kutatások során alkalmasak arra, hogy modell prediktív vezérlőt készíthessünk ezek felhasználásával, hogy ezáltal az LTC égésfolyamatok ciklusról ciklusra történő szabályzása egyszerűbben megvalósulhasson. A bemutatott modellek közül az égési súlypont és az égéskezdet modellek lettek a legpontosabbak, determinációs együtthatóik jellemzően 0,99 körüli értékűek. Ezek a paraméterek különösen fontosak, hiszen az égésfolyamat pozicionálása nagyban befolyásolja a motor

hatásfokát és emisszióját. A legrosszabb modell az égésfüggvény csúcserőértékét előrejelző modell lett. A modell pontossága fejlesztendő a valós MPC alkalmazások előtt. Ez további mérési paraméterek bevezetésével, például az előző munkaciklusok csúcshőmérsékleteinek rögzítésével lehet megvalósítható, hiszen a paraméter fluktuációja függ a korábbi ciklusok eseményeitől is. A kutatás további lépéseiben a modellek finomhangolása, illetve a modell prediktív vezérlés megvalósítása a cél.

KÖSZÖNETNYILVÁNÍTÁS

A 2024-2.1.1-EKÖP-2024-00003 számú projekt a Kulturális és Innovációs Minisztérium Nemzeti Kutatási Fejlesztési és Innovációs Alapból nyújtott támogatásával, a EKÖP-24-3 pályázati program finanszírozásában valósult meg.

IRODALMI HIVATKOZÁSOK

- [1] European Commission: Directorate-General for Research and Innovation, European Green Deal – Research & innovation call, Publications Office of the European Union, 2021, <https://data.europa.eu/doi/10.2777/33415>
- [2] EEA. Annual European Union Greenhouse Gas Inventory 1990–2015 and Inventory Report 2017; European Environment Agency, 2017. Available online: <https://www.eea.europa.eu/publications/european-union-greenhouse-gas-inventory-2017> (accessed on 14 February 2025).
- [3] Rizopoulos D., Esztergár-Kiss D. (2024) A modal share scenario evaluation framework including electric vehicles, *Research in Transportation Business & Management*, Vol. 56, paper 101201, DOI: 10.1016/j.rtbm.2024.101201
- [4] Kocsis Szürke, S., Kovács, G., Sysyn, M., Liu, J., & Fischer, S. (2023). Numerical Optimization of Battery Heat Management of Electric Vehicles. *Journal of Applied and Computational Mechanics*, 9(4), 1076–1092. <https://doi.org/10.22055/jacm.2023.43703.4119>.
- [5] Zöldy M. (2007). Bioethanol-biodiesel-diesel oil blends effect on cetane number and viscosity, 6th International Colloquium Fuels 2007, Technische Akademie Esslingen.
- [6] Emőd, I., Füle, M., Tanczos, K., & Zöldy, M. (2005). A bioetanol magyarországi bevezetésének műszaki, gazdasági és környezetvédelmi feltételei. *Magyar tudomány*, 50, 278–286.
- [7] Agarwal, A. K., Singh, A. P., Maurya, R. K. (2017). Evolution, challenges and path forward for low temperature combustion engines. *Progress in Energy and Combustion Science*. 61, 1–56. DOI: <https://doi.org/m5vx>
- [8] Krishnamoorthi, M., Malayalamurthi, R., He, Z., Kandasamy, S. (2019). A review on low temperature combustion engines: Performance, combustion and emission characteristics. *Renewable and Sustainable Energy Reviews*. 116, 109404. DOI: <https://doi.org/m5v2>
- [9] Singh, A. P., Agarwal, A. K. (2018). Low-Temperature Combustion: An Advanced Technology for Internal Combustion Engines. In: Srivastava, D., Agarwal, A., Datta, A., Maurya, R. (eds): *Advances in Internal Combustion Engine Research. Energy, Environment, and Sustainability*. Springer, Singapore. 9–41. DOI: <https://doi.org/gjip9t>
- [10] Lee, Y., Huh, K. Y. (2014) Analysis of different modes of low temperature combustion by ultra-high EGR and modulated kinetics in a heavy duty diesel engine. *Applied Thermal Engineering*. 70(1), 776–787. DOI: <https://doi.org/f6gnm2>
- [11] Li, Y.; Liu, L. Physics-Informed Neural Network-Based Nonlinear Model Predictive Control for Automated Guided Vehicle Trajectory Tracking. *World Electr. Veh. J.* 2024, 15, 460. <https://doi.org/10.3390/wevj15100460>
- [12] Sadaf Batool, Jeffrey D. Naber, Mahdi Shahbakhti “Machine learning approaches for identification of heat release shapes in a low temperature combustion engine for control applications”, *Control Engineering Practice*, Volume 144, 2024, 105838, <https://doi.org/10.1016/j.conengprac.2023.105838>.
- [13] Bao, Y, Mohammadpour Velni, J, & Shahbakhti, M. "An Online Transfer Learning Approach for Identification and Predictive Control Design With Application to RCCI Engines." *Proceedings of the ASME 2020 Dynamic Systems and Control Conference*. Volume 1, Online. October 5–7, 2020, ASME, <https://doi.org/10.1115/DSCC2020-3210>.
- [14] Adam Vaughan, Stanislav V. Bohac “Real-time, adaptive machine learning for non-stationary, near chaotic gasoline engine combustion time series”, *Neural Networks*, Volume 70, 2015, pp. 18–26, <https://doi.org/10.1016/j.neunet.2015.04.007>.
- [15] Virt, M., Zöldy, M. "Cost Efficient Training Method for Artificial Neural Networks based on Engine Measurements", *Acta Polytechnica Hungarica*, 21(7), pp 123–145, 2024. <https://doi.org/10.12700/APH.21.7.2024.7.8>
- [16] Virt, M., Zöldy, M. (2024). Realization of Low Temperature Combustion in an Unmodified Diesel Engine. *Cognitive Sustainability*, 3(2). <https://doi.org/10.55343/cogsust.104>