



BUDAPEST MŰSZAKI ÉS GAZDASÁGTUDOMÁNYI EGYETEM

GÉPÉSZMÉRNÖKI KAR

ENERGETIKAI GÉPEK ÉS RENDSZEREK TANSZÉK



Égések zaj alapú elemzése mesterséges intelligenciával

Tudományos Diákköri Konferencia Budapest, 2021

Készítette:

Pitlik Marcell

mechatronikai mérnök MSc hallgató

Konzulens

Dr. Józsa Viktor

egyetemi docens

NYILATKOZAT AZ ÖNÁLLÓ MUNKÁRÓL

Alulírott, Pitlik Marcell (ZUBYPT), a Budapesti Műszaki és Gazdaságtudományi Egyetem hallgatója, büntetőjogi és fegyelmi felelősségem tudatában kijelentem és sajátkezű aláírással igazolom, hogy ezt a TDK dolgozatot meg nem engedett segítség nélkül, saját magam készítettem, és a TDK dolgozatomban csak a megadott forrásokat használtam fel. Minden olyan részt, melyet szó szerint vagy azonos értelemben, de átfogalmazva más forrásból átvettem, egyértelműen, a forrás megadásával megjelöltem.

Budapest, 2021. november 7.



Pitlik Marcell

.

Tartalomjegyzék

Absztrakt.....	5
Abstract	7
1. Előszó.....	9
2. Motiváció a tüzelés akusztikai jelének vizsgálatára	10
2.1. A valós idejű szabályozás előkészítése mesterséges intelligencia alapon	11
2.2. Miért érdemes mesterséges intelligencia alapon is vizsgálni a jelenségeket?	12
3. A megvalósított mérés	13
3.1. A vizsgált rendszer	13
3.2. A megvizsgált tüzelési beállítások.....	15
4. A mérési adatok kiértékelése	16
4.1. Rendelkezésre álló adatok	16
4.1.1. Folyamat-szenzor-adatok	16
4.1.2. Akusztikus jelek	17
4.1.3. Füstgáz-emisszió	17
4.2. Az akusztikai adatok feldolgozása és adatkonszolidáció	17
4.3. Akusztikai jelsűrítés.....	18
4.4. FFT-vel kapott akusztikai jelek bemutatása	18
5. A mesterséges intelligencia alapú adatelemzés	24
5.1. A hasonlóságelemzés matematikája.....	24
5.1.1. COCO-STD (Standard).....	25
5.1.2. COCO-Y0.....	25
5.1.3. COCO-MCM.....	26
5.1.4. Részletes példa bemutatása	26

6. Elemzések bemutatása	27
6.1. Röviden az előzményekről	27
6.2. Az elemzések célja.....	27
6.3. X_i magyarázó változók kiválasztásának lehetőségei	27
6.3.1. A dupla modell jelentése COCO modellek esetén	28
6.3.2. P02 tanulása csak 8 amplitúdó alapján COCO-STD modellel.....	29
6.3.3. P02 tanulása csak 8 frekvencia alapján COCO-STD modellel.....	30
6.3.4. P02 tanulása 4-4 amplitúdó és frekvencia alapján STD modellel ...	31
6.3.5. P02 tanulása 8-8 amplitúdó és frekvencia alapján STD modellel ...	32
6.3.6. Tanulás jóságának javítása hibrid modellel	32
6.3.7. Az akusztikai jeltől közvetlenül nem függő szenzoradatok.....	33
6.3.8. Véletlen számok magyarázása akusztikai jellel.....	34
6.3.9. Miért volt fontos a folyamat-szenzoradatok tanulhatósága	35
6.4. Füstgáz komponensek tanulhatósága	36
6.4.1. Füstgáz komponensek tanulása 8-8 amplitúdó és frekvencia alapján STD modellel	36
6.4.2. Füstgáz komponensek tanulása 8-8 amplitúdó és frekvencia alapján hibrid STD modellel	38
6.4.3. Hogyan hat az Y eltolása az X_i magyarázó változóhoz képest füstgáz komponensek esetén?.....	39
6.5. Füstgáz komponensek előrejelezhetősége.....	40
6.5.1. NO előrejelezhetősége	40
6.5.2. CO előrejelezhetősége	41
6.5.3. O ₂ előrejelezhetősége	42
6.5.4. CO ₂ előrejelezhetősége	43
7. Összefoglalás/Eredmények értékelése.....	44

7.1. Eredmények és jövőkép.....	44
7.2. Javaslatok/Következtetések/Tanulságok	44
8. Felhasznált források.....	45

ABSZTRAKT

Előzmények: Jelen TDK dolgozat előzményeként már készült a témában a szerző által egy TDK [1] és egy szakdolgozat [2]. A már ott is megfogalmazott célhoz vezető úton történt meg a következő lépés, aminek eredményeit ez a dolgozat ismerteti.

Kihívások: A tüzelőberendezések üzemeltetésére egyre szigorúbb rendeletek [3] írnak elő a károsanyag kibocsátás kapcsán. A kívánt károsanyag kibocsátást eddig főként különböző passzív szabályzó elemekkel próbálták meg elérni. Ilyen passzív szabályzó elem lehet a fúvóka átmérője, az alkalmazott diffúzor [4] geometriája. Ezen passzív szabályzó elemek hatását pedig a füstgáz visszamérésével határozták meg. Emellett ismert, hogy különböző lángalakokhoz jól megkülönböztethető mennyiségű károsanyag kibocsátás tartozik. A dolgozatban is bemutatott kísérleti berendezés esetében már eddig is ismertek voltak a tüzelés egyéb paraméterei, mint a lángalak, különböző rendszernyomások (pl.: porlasztó-nyomás), égéslevegő hőmérséklete stb. Ezen paraméterek optimális beállítása lesz az aktív szabályzókör feladata. A legfontosabb paraméter a károsanyag-emisszió, hiszen erre vonatkoznak a törvényi előírások. Ha ezt továbbra is füstgázból szeretnénk visszamérni, akkor nem valósulhatna meg a kvázi valós idejű szabályzás, mivel ez a mérés kémiai úton történik, amihez akár 1 perces késleltetést is jelenthet.

Feladatok: A kvázi valós idejű tüzelés szabályzáshoz kvázi valós idejű input adatokra van szükség. Ehhez a tüzelés akusztika jeléből kell tudni levezetni függvényyszerű kapcsolaton keresztül a füstgáz komponenseket. Majd a már korábban bemutatott [2] módon a füstgáz komponensekből mesterséges intelligenciával (MI) levezetett idealitás-index genetikai potenciál keretében feltárt mozgástér alapján lehet meghatározni, az ideális paramétereket, amik adott teljesítmény és láng alak mellett a legkisebb károsanyagkibocsátást eredményezik. Az MI bevonása a mért adatok értelmezésébe azért szükséges,

mert így lehet a legmagasabb minőségbiztosítási szinten a szabályozáshoz szükséges termelési függvényeket ($Y=f(X_1;\dots;X_i)$) automatizáltan előállítani.

Eredmények: Az akusztikai jelek gyors Fourier-transzformációja (FFT) után létrejött magyarázó változókkal (X_i), mint az akusztikai jel amplitúdója és a hozzá tartozó frekvencia kvázi tetszőleges pontosságú modellezés/tanulás érhető el a folyamat-szenzor adatok (nyomás, hőmérséklet, térfogatáram) esetében. Ennek az igazi jelentősége majd akkor lesz fontos, ha már csak akusztikai jel alapján szeretnénk szabályozni és nem is áll rendelkezésre ennyi folyamat-szenzor jel, mint ennél a kísérleti berendezésnél.

A füstgáz komponensek tanulhatósága is magas korrelációról indul (~ 0.9), amit hibrid modellek még tovább lehet javítani. A négy füstgáz komponens (CO, NO, CO₂, O₂) közül három (NO, CO₂, O₂) közel mérési hibahatáron belül jelezhető előre.

ABSTRACT

Prior activities: Before this study two other studies have been published (one study for the Scientific Students' Associations Conference 2020, other for Bachelor thesis 2021). The results of the next steps prescribed through the previous research activities will be presented here and now.

Challenges: Regulations for combustion chambers are continuously stringent, especially for pollutant emissions. The emission can be influenced through passive elements like advanced nozzle geometry and/or diverging nozzle/quarl. The effect of these passive elements can be evaluated from pollutant emission analysis data. Besides geometry, the flow field also largely influences emissions. The corresponding features include, e.g., flame shape, pressure, and temperature fields. Control of these parameters is usually realized by active systems. However, the reaction time of pollutant emission sensors is in the range of 60 seconds, hence, an alternative solution is necessary for online control.

Tasks: Online combustion control needs real-time input about the features of combustion. Pollutant emission can however be derived from the acoustical signs of the combustion. Both the aggregated index values about the ideality of the emitted gases are calculated through artificial intelligence (AI), ensuring the expected real-time characteristics. The AI is necessary to ensure a high-levelled quality management during the automated derivation processes of production function like $Y=f(X_1;\dots;X_n)$.

Results: Based on a relatively fast Fourier transformation of the acoustic signs, the most characteristic amplitudes and frequencies make possible a quasi arbitrary fitting of models concerning the physical attributes like pressure, temperature, volumetric flow. The relevance of the acoustic signals will be visible in case of a noise-based control process without any other sensor data.

The model correlations concerning the emitted gases started from a high level of ~0.90, and these correlation values could be increased through model hybridisation close to the maximum. It means, 3 (NO, CO₂, O₂) from 4 gases (+ CO) could be modelled with a fitting near to the measurement accuracies.

1. ELŐSZÓ

A dolgozat célja a hasonló témában készült TDK [1] (ahol a füstgáz komponensekből képzett ideáltás-index és folyamat-szenzor adatok (nyomás, hőmérséklet, térfogatáram) közötti függvényszerű kapcsolatok kerültek levezetésre) és szakdolgozat [2] (ahol a korábbi TDK-hoz képest kiegészítésre került a mesterséges intelligencia alapon való modellezhetőség a rendszer genetikai potenciáljának bemutatásával) által bemutatott elemzések a tüzeléstechnikában kiterjesztése a korábban vizsgált füstgáz komponensek, fizikai rendszerparaméterek (nyomás, hőmérséklet, térfogatáram), spektrális emisszió mellett az akusztikai adatokra is. Az akusztikai mérés kiforrottságából, és érzékenységből fakadóan előzetes elvárás, hogy az égés zajából az eddigi eredményekhez képest [1][2] pontosabban lehessen szimulálni és előre jelezni a rendszer paramétereit és a füstgáz összetételét komponensenként, s ez által az égés aggregált idealitás-indexét, mint univerzális vezérlő/szabályozó jelenséget.

A dolgozatban „” idézőjelek között jelölöm azokat a részeket, amiket szó szerint emeltem át a korábbi munkáimból, mert szükségesek a dolgozat megértéséhez, és leíró információkat tartalmaznak.

2. MOTIVÁCIÓ A TÜZELÉS AKUSZTIKAI JELÉNEK VIZSGÁLATÁRA

Jelen TDK dolgozat célja a korábban készült TDK [1] és szakdolgozat [2] mesterséges intelligencia alapú elemzésének kiterjesztése az akusztikai adatokra.

A korábbi eredmények összefoglalásaként elmondható, hogy a BME DCS épületében üzemelő kísérleti ipari tüzelőberendezés mesterséges intelligenciával elemezve is fizika rendszernek tekinthető, mert a tüzelés során mért nyomás, hőmérséklet, térfogatáram, füstgáz komponensek (CO , CO_2 , NO , O_2) és spektrális emissziós adatok egymást magyarázva robosztus, konzisztens és magas korrelációjú modelleket eredményeztek. A fizikaiság adat-alapú felismerése egyben a mérések helyességének visszaigazolását is jelenti, ill. az alkalmazott MI alkalmasságát támasztja alá a valóság helyes értelmezésén keresztül.

Már a szakdolgozatban említésre került egy valós idejű szabályzás mesterséges intelligencia alapon, aminek a költséghatékony és számos helyen adaptálható megvalósítása a zaj alapú szabályozás lenne, mivel a hőmérséklet, nyomás és térfogatáram mérése sok szenzor beépítését jelenti, a spektrális emisszió mérése nm-es felbontás mellett még nem kiforrott és főleg nem olcsó technológia, amellett, hogy a tüzelési tér nagyon elenyésző részéről lehet mérést végezni, ha egyáltalán van kialakított betekintő nyílás (nagyságrendileg $1\text{-}100\text{ cm}^2$). Ezzel szemben a tüzelése akusztikus jele relatíve egyszerűen egy mikrofonnal mérhető több kHz frekvencián, amivel kiküszöbölhető a kémiai úton mért füstgázösszetétel időkésleltetése, ami 30-60 másodperc között van. Ehhez "csupán" arra van szükség, hogy a mért akusztikai jel és a füstgáz komponensek között (pl. mesterséges intelligenciával) feltárható matematikai összefüggés álljon fent.

Jelen dolgozat célja és fókusza a mért adatoktól, az adatfeldolgozáson és modell alkotási stratégiákon át, a tanulás és előrejelzés eredményéig bemutatni, hogyan lehet az akusztikai jel és a füstgáz pl. oxigén tartalma között szinte tökéletesen modellezhető kapcsolatot teremteni mesterséges intelligenciával (hasonlóság elemzéssel). A szinte tökéletes megfogalmazás nem véletlen: tökéletesen pontos mérés nincs, így tökéletesen pontos modellek sem alkothatók, de az esetleges mérési pontatlanságok és hibatűró modellezési technikák kölcsönhatásaként előálló fizikaiság-érzet ennek ellenére levezethető.

2.1. A valós idejű szabályozás előkészítése mesterséges intelligencia alapon

Az előző bekezdés konklúziója tehát az, hogy a kvázi valós idejű tüzelés szabályozáshoz kvázi valós idejű input adatokra van szükség. A láng akusztikai jelének vizsgálata lehetővé teszi, hogy kvázi valós időben működő szabályzó kerüljön meghatározásra az ipari tüzelőberendezések üzemeltetéséhez. A dolgozat célja tehát bizonyítani, hogy a füstgázösszetétel jelentős késleltetéssel rendelkezésre álló értékei a kvázi azonnal rendelkezésre álló akusztikai adatok alapján is modellezhetők, vagyis a MI-alapú modellek képesek az akusztikai adatok időnyerő hatását hermeneutikai rendszerükön keresztül garantálni a későbbi szabályozási folyamatokhoz. Az MI bevonása a mért adatok értelmezésébe azért szükséges, mert így lehet a legmagasabb minőségbiztosítási szinten a szabályozáshoz szükséges termelési függvényeket ($Y=f(X_1;\dots;X_n)$) automatizáltan előállítani hasonlóságelemzéssel. Az ilyen MI-alapú megoldásokkal a szerző már korábban tapasztalatokat szerzett a MY-X kutatócsoport tagjaként.

2.2. Miért érdemes mesterséges intelligencia alapon is vizsgálni a jelenségeket?


A rendelkezésre álló BIG DATA jellegű adatvagyonban mesterséges intelligenciákkal feltárássra kerülhetnek, olyan összefüggések melyekre korábban nem is gondolt volna az ember. A hasonlóságelemzés is így készült, hogy a KNUTH-i elveknek [5] megfelelően az emberi intuíció által megértett komplexitások kerültek át a robot számára is érthető forráskódba.

3. A MEGVALÓSÍTOTT MÉRÉS

3.1. *A vizsgált rendszer*

A vizsgált tüzelőberendezés a BME DCs épületében található. A 3-1. ábra: bemutatott sematikus rendszer esetén, jól látható, hogy a rendszer számos pontján szenzorok monitorozzák az égés a folyamatát. A kísérleti tüzelőberendezés közel állandó 13.35 kW-os teljesítményen üzemeltethető, miközben különböző tüzelőanyagokat (a méréshez dízel olajat használtunk) lehet benne felügyelt és változtatható körülmények között elégetni. A porlasztáshoz és az égéshez adott levegő mennyiségével lehet befolyásolni a kialakuló láng alakját, ami önmagában is jelentősen befolyásolja a károsanyag kibocsátást.

A 3-1. ábra: fontos kiemelni a korábbi munkákban nem ismertetett mikrofon helyzetét, ami az égőtér aljától 35 mm-re található az égőtérben egy hűtéssel ellátott foglalatba helyezve.



3-1. ábra: A vizsgált rendszer sematikus ábrája – forrás: EGR tanszék

3.2. A megvizsgált tüzelési beállítások

idő	p porl	v porl	O ₂	motor	akusztika	time	lángalak
óó:pp	[barg]	[l/min]	%	frekvencia Hz			...
15:00							
15:12					file	time	
15:17	0.3	25.6	3.0	7.0		1 15:17:01	e
15:20	0.5	30.9	3.0	6.0		2 15:20:19	e
15:22	0.6	35.1	3.0	5.0		3 15:22:30	e
15:25	0.8	39.7	3.0	3.3		4 15:25:29	e
15:31	0.9	43.4	3.0	1.1		5 15:31:07	e
15:35	0.3	24.7	5.0	9.0		6 15:35:29	e
15:37	0.5	30.3	5.0	7.9		7 15:37:42	e-t
15:40	0.6	34.5	5.0	6.0		8 15:40:23	t
15:43	0.8	38.9	5.0	4.8		9 15:43:01	t
15:45	0.9	43.0	5.0	3.8		10 15:45:35	t
15:47							
15:50	0.3	25.0	7.0	10.8		11 15:50:33	e-v
15:53	0.5	29.9	7.0	9.5		12 15:53:13	t-e
15:55	0.6	34.6	7.3	9.2		13 15:55:00	t
15:56	0.6	34.8	7.0	9.0		14 15:56:10	t
15:58	0.8	38.8	7.0	7.8		15 15:58:41	t
16:01	0.9	43.2	7.0	7.5		16 16:01:21	t
16:04	0.3	24.5	9.0	12.2		17 16:04:55	v
16:08	0.5	30.5	9.0	12.0		18 16:08:25	t
16:11	0.6	34.7	9.0	11.5		19 16:11:04	t
16:12	0.8	39.1	9.0	10.8		20 16:12:54	t
16:14	0.9	43.1	9.0	10.3		21 16:14:41	t
16:16							
16:19							

3-2. ábra: Mérési terv – forrás: saját ábrázolás

Magyarázat a 3-2. ábra:hoz:

1. oszlop: időpecsét, hogy mikortól volt stabil a beállított égés
2. oszlop: porlasztó levegő nyomása
3. oszlop: porlasztó levegő térfogatárama
4. oszlop: a füstgáz százalékos oxigéntartalma (vö. „O₂”), melyből számítható a légfelesleg tényező (λ)
5. oszlop: égéslevegő motor frekvencia
6. oszlop: az akusztikai mérés sorszáma
7. oszlop: időpecsét, hogy mikor kezdődött az akusztikai mérés
8. oszlop: lángtípus: 'e' mint egyenes, 'v' mint V alakú, 't' mint térfogati

4. A MÉRÉSI ADATOK KIÉRTÉKELÉSE

4.1. Rendelkezésre álló adatok

A fejezetben bemutatásra kerül, hogy az egyes mérőeszközöknél mennyi és milyen struktúrájú adat áll rendelkezésre.

4.1.1. FOLYAMAT-SZENZOR-ADATOK

„A 3.1 pontban megemlített szenzorok a folyamat több pontján (vö: 3-1. ábra:) mérnek nyomást, hőmérsékletet és térfogatáramot. Ezek az adatok idősorosan 5 mp-es felbontással állnak rendelkezésre.”

A 4-1. ábra: mutatja, hogy pontosan mely paraméterei kerülnek rögzítésre a rendszernek:

P01	égéslevegő nyomás
P02	porlasztólevegő nyomás
P03	perdület beállító levegő nyomás
P04	gáz nyomás
P05	tartály_1 nyomás
P06	tartály_2 nyomás
P07	-
P08	-
P09	air main nyomás
F01	égéslevegő térfogatáram
F02	porlasztólevegő térfogatáram
F03	perdület beállító levegő térfogatáram
F04	gáz térfogatáram
F05	tartály_1 térfogatáram
F06	tartály_2 térfogatáram
TC1	égéslevegő előmelegítő fölötti hőmérséklet
TC2	égéslevegő előmelegítést szabályzóban a hőmérséklet
TC3	áramlásegyenletesítés utáni égéslevegő hőmérséklet
TC4	környezeti levegő hőmérséklet
TC5	füstgáz hőmérséklet az égőtér tetején
TC6	füstgáz hőmérséklet a füstgázventilátor előtt
Pt01	égéslevegő hőmérséklet
Pt02	porlasztólevegő hőmérséklet
Pt03	perdület beállító levegő hőmérséklet
Pt04	gáz hőmérséklet
Pt05	tartály_1 hőmérséklet
Pt06	tartály_2 hőmérséklet
Pt07	-
Pt08	-
Pt09	air main hőmérséklet
Pt10	-
Pt11	mikrofon
Pt12	mikrofon
Pt13	mikrofon

4-1. ábra: Adatgyűjtő szenzorok listája – forrás: [1]

4.1.2. AKUSZTIKUS JELEK

A mérés 20 kHz-es mintavételezéssel 30 mp-es szakaszokat rögzített. Ami azt jelenti, hogy egy mérési file 600.000 rekordot tartalmaz.

Az akusztikai jelek GRAS 146AE 1/2" CCP Free-field Microphone-nal [6] kerültek rögzítésre

4.1.3. FÜSTGÁZ-EMISSION

„2 mp-es felbontással állnak rendelkezésre a füstgázban található komponensek mennyiségei/arányai.”

4.2. Az akusztikai adatok feldolgozása és adatkonszolidáció

Az előző TDK-ban és szakdolgozatban a folyamat-szenzor adatok és a füstgáz időpecsétjének legkisebb közös többszöröse volt a számításoknál az időegység ($2 \cdot 5 = 10$ mp).

Ez azt eredményezné, hogy egy beállításról csak 3 akusztikai jelsűrítést lehetne végezni, így összesen $21 \cdot 3 = 63$ időegység lenne az idősor hossza, amit mesterséges intelligenciával elemezni lehetne.

A modellezési tapasztalat pedig éppen azt mondja, hogy minél hosszabb az adatsor/ minél nagyobb a minta annál nagyobb tanulási minta áll a robot rendelkezésére, ami jobb tanulást tesz lehetővé.

Ezért az új időegység az 5 mp lett. Amihez a füstgáz adatokat is igazítani kellett, mivel két időegység között minimálisan ingadozik az érték, így lineáris interpoláció nélkül az 5 mp-es legközelebbi értéket rendeltem az adott időegységhez a füstgáz leíró időpecsétek esetében. Ez után még szükség volt azoknak a rekordoknak a kiválasztására, ahol akusztikai jel mérés is történt.

4.3. Akusztikai jelsűrités

A hasonlóság elemzéshez szükség van arra, hogy a következmény változó Y és a magyarázó változók között X_i létre lehessen hozni az Objektum-Attribútum-Mátrixot (OAM), ahol a sorok az időegységek/megfigyelések az oszlopok a magyarázó változók X_i és az Y . Mivel az akusztikai jel másodpercenként is 20.000 mérési pontból áll ezért szükség van a mért jel valamilyen jellemző értékeivel való reprezentálására. Erre egy megoldás a gyors Fourier transzformáció (FFT), ami lehetővé teszi, hogy a diszkrét időben mért jel felbontásra kerüljön szinusz függvények összegeként, ahol különböző a szinusz függvények frekvenciája, ill. amplitúdója.

Matlab program segítségével végeztem el a Fourier-transzformációt 5 mp-es időegységekre (100.000 mért pontra). Azért 5 mp-re, mert a többi mért jel ilyen pontossággal állt most rendelkezésre. A módszer bemutatása szempontjából kvázi lényegtelen, hogy hány mp-es egységekben történik a Fourier-transzformálás. A relatíve nagy érték valószínűleg az apró rövid ideig tartó változásokat elnyomja, így később a modellpontosság fejlesztése érdekében érdemes lesz rövidebb időközönként Fourier- transzformálni és a kapott Amplitúdó és hozzá tartozó frekvencia értékek statisztikai mutatóival (minimum, maximum, átlag, szórás) dolgozni magyarázó változóként.

4.4. FFT-vel kapott akusztikai jelek bemutatása

Ahogy az előző fejezetben bemutatásra került jelenleg a 100 legnagyobb amplitúdó és a hozzá tartó frekvencia érték került meghatározásra. Viszont ezek közül a modellezéshez csak a 8 legnagyobb amplitúdó és hozzá tartozó frekvencia került feldolgozásra a későbbiekben, mert már ennyi magyarázó adat X_i is elegendő volt a legtöbb esetben, hogy hibátlan tanulást érjünk el a folyamat-szenzor adatok és füstgáz emisszió mért jeleire.

A 4-2. ábra: - 4-5. ábra: mutatja, hogy be az FFT-vel kapott 8 legnagyobb amplitúdó és frekvencia értékét a 4 ábra közül az első kettőn, majd a következő két ábra mutatja be ezeknek az értékeknek a sorszámozott nézetét, ami már a hasonlóságelemzés bemeneti jeléül fog szolgálni.

Az ábrákon az első oszlop a korábban említett mérésen belüli beállítás ID (1-21), így összesen $21 \cdot 6 = 126$ soros tanulási mintákkal fogok dolgozni a későbbiekben.

A Max1-Max8 a 8 legnagyobb amplitúdót, míg az A1-A8 az ehhez tartozó frekvencia értékeket adja meg. Az első két képen Voltban és Hz-ben, míg a következő két képen a sorszámozás miatt dimenziótlanul. A sorszámozásnál a minél nagyobb annál jobb irány került bemutatásra. (vö. 4-2. ábra; 4-3. ábra; ill. 4-4. ábra; 4-5. ábra:). Az ábrák színezése tudatos, hiszen egy fajta hő térképként mutatja meg, hogy hogyan oszlik el a magyarázó változók nagysága, ill. ez a nagyság hogyan változik meg a sorszámozás hatására.)

ID	Max1	Max2	Max3	Max4	Max5	Max6	Max7	Max8	A1	A2	A3	A4	A5	A6	A7	A8
1	0.0107	0.0096	0.0084	0.0083	0.0081	0.0080	0.0077	0.0074	236.2	220.6	236.4	240.8	230.9	289.0	233.3	184.9
1	0.0120	0.0096	0.0085	0.0084	0.0076	0.0076	0.0076	0.0075	233.6	235.6	236.5	290.5	235.4	289.6	243.7	282.9
1	0.0100	0.0090	0.0085	0.0084	0.0082	0.0079	0.0077	0.0076	227.1	284.3	240.5	293.4	238.3	284.9	284.1	284.0
1	0.0121	0.0094	0.0076	0.0074	0.0073	0.0071	0.0067	0.0067	215.9	238.5	289.8	224.0	239.0	208.1	243.5	221.3
1	0.0084	0.0076	0.0075	0.0073	0.0073	0.0072	0.0071	0.0071	235.0	191.5	286.0	285.5	215.2	245.1	230.6	373.4
1	0.0158	0.0100	0.0098	0.0093	0.0090	0.0082	0.0078	0.0075	233.2	234.8	285.8	246.6	229.5	235.3	264.4	239.4
2	0.0098	0.0092	0.0089	0.0084	0.0072	0.0071	0.0071	0.0069	242.9	930.3	233.8	284.9	234.2	193.5	189.5	241.4
2	0.0105	0.0095	0.0089	0.0085	0.0082	0.0082	0.0079	0.0072	282.6	241.6	210.4	235.6	236.4	238.5	233.5	235.8
2	0.0091	0.0091	0.0080	0.0076	0.0074	0.0073	0.0070	0.0069	236.4	289.0	287.3	227.1	230.3	240.3	221.0	213.2
2	0.0086	0.0083	0.0079	0.0078	0.0067	0.0067	0.0066	0.0064	215.0	235.1	225.4	929.4	204.2	233.6	205.4	287.6
2	0.0089	0.0082	0.0081	0.0081	0.0081	0.0080	0.0077	0.0076	237.3	288.7	233.2	235.1	288.5	239.4	370.5	262.3
2	0.0095	0.0094	0.0086	0.0080	0.0079	0.0078	0.0073	0.0072	233.5	231.5	229.8	285.3	235.0	240.2	219.6	232.4
3	0.0088	0.0082	0.0081	0.0080	0.0078	0.0072	0.0070	0.0066	928.7	218.1	287.9	215.0	241.4	232.5	232.1	1007.2
3	0.0079	0.0074	0.0070	0.0069	0.0069	0.0067	0.0065	0.0064	1440.7	1434.5	290.8	932.0	240.0	213.2	213.8	270.4
3	0.0088	0.0084	0.0079	0.0072	0.0072	0.0066	0.0062	0.0062	236.5	228.0	928.8	282.6	287.5	933.2	291.6	1436.2
3	0.0098	0.0086	0.0083	0.0079	0.0076	0.0074	0.0073	0.0072	929.7	284.9	233.8	290.1	284.1	238.3	210.9	264.7
3	0.0116	0.0097	0.0088	0.0086	0.0078	0.0077	0.0077	0.0074	926.7	927.4	236.7	232.9	927.3	215.2	1008.1	229.0
3	0.0097	0.0088	0.0086	0.0080	0.0078	0.0077	0.0074	0.0072	930.9	232.4	234.7	1008.8	229.3	929.1	246.0	245.7
4	0.0078	0.0078	0.0076	0.0073	0.0072	0.0070	0.0070	0.0068	1010.4	1440.1	1431.9	1449.0	1438.6	1449.1	233.9	1444.4
4	0.0082	0.0081	0.0079	0.0078	0.0077	0.0077	0.0077	0.0075	1430.2	1432.8	217.4	236.8	229.0	932.2	235.9	218.1
4	0.0072	0.0071	0.0070	0.0067	0.0064	0.0064	0.0063	0.0061	213.8	217.1	1008.6	207.4	1429.3	939.6	1444.2	1445.9
4	0.0081	0.0073	0.0070	0.0069	0.0067	0.0065	0.0065	0.0063	235.1	1440.7	930.3	1443.3	215.2	1481.2	1005.7	931.7
4	0.0107	0.0089	0.0082	0.0079	0.0076	0.0076	0.0073	0.0072	216.5	216.4	234.7	242.5	285.8	1433.4	1498.0	190.0
4	0.0087	0.0083	0.0078	0.0074	0.0073	0.0070	0.0070	0.0069	233.0	228.6	181.7	227.8	232.5	245.5	233.2	222.9
5	0.0094	0.0092	0.0086	0.0085	0.0084	0.0084	0.0084	0.0081	228.6	1437.1	236.4	1437.7	210.3	230.4	1443.9	238.2
5	0.0124	0.0096	0.0091	0.0088	0.0088	0.0087	0.0086	0.0083	1438.8	207.4	243.2	245.2	205.5	219.3	201.1	1438.9
5	0.0104	0.0093	0.0088	0.0088	0.0082	0.0082	0.0081	0.0081	928.8	215.3	211.9	201.9	236.2	284.7	1430.5	1432.8
5	0.0093	0.0087	0.0086	0.0085	0.0081	0.0079	0.0075	0.0075	218.5	216.7	232.5	262.9	927.7	229.0	281.5	1435.1
5	0.0110	0.0109	0.0096	0.0091	0.0081	0.0076	0.0076	0.0075	228.3	235.4	234.2	238.8	195.8	229.8	216.1	283.8
5	0.0088	0.0085	0.0082	0.0079	0.0078	0.0078	0.0078	0.0075	215.6	232.7	188.3	1437.8	931.4	1010.1	229.6	207.4
6	0.0130	0.0122	0.0120	0.0113	0.0112	0.0107	0.0105	0.0104	230.1	222.0	231.8	209.5	192.6	236.7	230.6	236.8
6	0.0120	0.0118	0.0115	0.0115	0.0114	0.0113	0.0113	0.0108	217.6	234.2	239.0	58.9	189.1	213.0	288.2	221.1
6	0.0165	0.0129	0.0123	0.0111	0.0110	0.0108	0.0101	0.0098	232.7	234.5	189.1	205.8	234.1	209.5	213.6	189.5
6	0.0124	0.0121	0.0121	0.0119	0.0119	0.0114	0.0111	0.0109	188.6	285.3	241.7	225.8	231.8	235.3	221.7	214.8
6	0.0141	0.0134	0.0131	0.0122	0.0111	0.0106	0.0106	0.0104	191.7	208.4	221.9	216.1	210.0	245.8	246.0	229.2
6	0.0160	0.0137	0.0135	0.0129	0.0127	0.0118	0.0116	0.0112	232.4	236.5	188.0	189.7	57.5	203.1	187.7	238.5
7	0.0119	0.0097	0.0094	0.0092	0.0091	0.0090	0.0088	0.0088	227.8	286.7	231.3	222.3	235.3	242.6	210.3	244.5
7	0.0102	0.0087	0.0086	0.0084	0.0081	0.0079	0.0078	0.0078	235.8	206.9	244.9	207.2	234.5	218.7	239.0	231.5
7	0.0134	0.0117	0.0106	0.0105	0.0096	0.0095	0.0090	0.0088	222.6	214.4	235.1	236.1	246.0	211.5	238.8	237.4
7	0.0114	0.0111	0.0108	0.0103	0.0102	0.0090	0.0086	0.0084	230.7	232.4	215.6	210.4	236.5	237.7	235.3	224.0
7	0.0142	0.0113	0.0103	0.0098	0.0092	0.0090	0.0087	0.0086	240.5	236.1	234.5	222.8	223.4	236.2	222.9	239.3
7	0.0134	0.0123	0.0113	0.0104	0.0103	0.0100	0.0100	0.0098	285.0	235.8	236.2	237.3	229.6	215.6	238.8	236.5
8	0.0046	0.0043	0.0041	0.0040	0.0039	0.0037	0.0035	0.0035	34.5	231.9	44.9	34.0	49.7	44.3	43.0	38.9
8	0.0046	0.0043	0.0042	0.0041	0.0041	0.0037	0.0035	0.0035	229.2	52.9	71.1	53.1	49.4	32.7	34.8	239.9
8	0.0049	0.0045	0.0043	0.0042	0.0041	0.0040	0.0038	0.0036	64.1	60.1	54.2	45.8	45.6	21.1	31.4	45.0
8	0.0040	0.0036	0.0036	0.0036	0.0033	0.0032	0.0032	0.0031	231.5	52.6	61.8	236.2	54.2	62.9	190.0	76.8
8	0.0040	0.0039	0.0038	0.0038	0.0037	0.0037	0.0037	0.0037	64.1	31.1	53.1	189.8	56.9	41.8	43.0	231.2
8	0.0042	0.0041	0.0040	0.0037	0.0037	0.0035	0.0035	0.0034	190.0	28.5	34.8	40.1	75.1	31.9	233.3	231.3
9	0.0049	0.0040	0.0039	0.0038	0.0036	0.0035	0.0033	0.0033	43.9	43.2	237.4	24.3	37.8	58.7	47.8	77.8
9	0.0044	0.0044	0.0040	0.0040	0.0039	0.0038	0.0038	0.0038	26.2	190.0	50.8	71.0	31.4	49.0	27.9	239.3
9	0.0050	0.0045	0.0044	0.0040	0.0038	0.0036	0.0034	0.0034	49.3	36.2	45.2	237.6	37.4	192.4	45.0	25.6
9	0.0039	0.0037	0.0036	0.0034	0.0034	0.0034	0.0034	0.0031	239.4	74.6	51.1	24.7	237.6	32.0	29.4	231.8
9	0.0051	0.0045	0.0045	0.0042	0.0041	0.0041	0.0039	0.0038	40.7	63.3	30.4	64.2	25.8	55.5	45.8	53.6
9	0.0042	0.0037	0.0036	0.0036	0.0036	0.0035	0.0035	0.0034	33.1	33.4	62.1	52.2	64.5	40.4	30.8	108.0
10	0.0059	0.0047	0.0044	0.0043	0.0041	0.0040	0.0038	0.0036	44.3	40.7	38.6	40.6	82.9	41.0	17.5	41.5
10	0.0045	0.0039	0.0036	0.0036	0.0035	0.0033	0.0032	0.0032	43.0	55.2	44.3	38.6	190.0	36.5	64.1	61.6
10	0.0038	0.0037	0.0036	0.0036	0.0036	0.0035	0.0035	0.0034	47.3	30.7	237.3	235.6	45.3	39.7	49.6	33.1
10	0.0050	0.0039	0.0037	0.0036	0.0033	0.0032	0.0031	0.0031	49.9	39.2	230.3	33.7	17.2	232.9	44.7	47.2
10	0.0053	0.0047	0.0045	0.0037	0.0036	0.0036	0.0035	0.0035	39.5	31.9	40.4	27.9	218.5	190.0	32.5	47.8

4-2. ábra: Akusztikai jelek nyers érték I. – forrás: saját ábrázolás

ID	Max1	Max2	Max3	Max4	Max5	Max6	Max7	Max8	A1	A2	A3	A4	A5	A6	A7	A8
10	0.0038	0.0038	0.0037	0.0037	0.0036	0.0035	0.0035	0.0034	30.7	44.7	47.2	29.9	53.6	239.7	192.9	26.9
11	0.0214	0.0203	0.0184	0.0171	0.0155	0.0147	0.0140	0.0139	56.0	213.2	208.0	211.3	191.4	208.4	204.8	52.6
11	0.0154	0.0154	0.0152	0.0144	0.0144	0.0141	0.0140	0.0140	220.2	195.5	56.6	215.3	57.4	186.6	55.7	237.6
11	0.0174	0.0156	0.0154	0.0152	0.0151	0.0147	0.0146	0.0145	208.0	232.5	228.9	205.2	200.0	234.5	228.3	241.6
11	0.0168	0.0167	0.0163	0.0157	0.0156	0.0156	0.0152	0.0152	52.8	234.2	195.6	57.5	232.9	228.1	56.3	56.0
11	0.0185	0.0183	0.0177	0.0176	0.0144	0.0144	0.0143	0.0140	56.2	56.9	54.6	54.8	55.7	183.4	202.8	193.5
11	0.0213	0.0174	0.0161	0.0161	0.0153	0.0146	0.0140	0.0137	57.5	55.4	222.6	193.8	228.3	53.9	213.6	208.4
12	0.0049	0.0044	0.0040	0.0038	0.0035	0.0032	0.0032	0.0031	37.5	47.2	44.7	237.6	49.3	33.4	190.1	31.7
12	0.0111	0.0107	0.0096	0.0094	0.0086	0.0082	0.0080	0.0077	210.9	210.7	239.0	235.8	217.3	214.7	213.9	73.2
12	0.0089	0.0085	0.0079	0.0078	0.0073	0.0073	0.0072	0.0071	220.8	233.0	221.1	230.7	217.0	234.1	232.5	216.1
12	0.0042	0.0039	0.0037	0.0035	0.0035	0.0035	0.0035	0.0034	50.8	48.1	195.5	48.5	49.4	33.6	232.1	41.0
12	0.0069	0.0066	0.0064	0.0058	0.0058	0.0057	0.0056	0.0055	285.2	239.6	207.4	239.1	238.3	208.1	246.7	204.9
12	0.0043	0.0039	0.0037	0.0036	0.0035	0.0032	0.0032	0.0032	51.9	57.2	39.7	65.8	230.7	24.1	190.1	237.7
13	0.0042	0.0034	0.0033	0.0032	0.0030	0.0028	0.0028	0.0028	48.4	199.3	65.3	237.1	26.7	42.7	62.7	231.9
13	0.0035	0.0035	0.0032	0.0029	0.0029	0.0029	0.0028	0.0027	51.9	27.9	38.3	34.9	27.5	230.0	232.7	23.7
13	0.0033	0.0033	0.0032	0.0032	0.0030	0.0030	0.0030	0.0029	31.9	28.7	44.6	37.7	230.6	87.6	37.5	55.4
13	0.0043	0.0039	0.0036	0.0036	0.0030	0.0029	0.0029	0.0028	26.4	237.7	190.1	42.4	37.2	44.9	47.9	41.5
13	0.0038	0.0036	0.0036	0.0033	0.0030	0.0027	0.0027	0.0026	53.4	38.9	24.3	237.6	39.5	28.1	285.2	15.3
13	0.0031	0.0030	0.0030	0.0029	0.0029	0.0028	0.0027	0.0027	230.6	196.8	58.0	40.9	43.6	33.0	231.6	26.7
14	0.0034	0.0033	0.0032	0.0030	0.0030	0.0030	0.0029	0.0029	237.7	33.6	69.1	27.8	58.4	25.5	39.7	190.1
14	0.0037	0.0035	0.0033	0.0032	0.0031	0.0030	0.0029	0.0028	237.7	233.0	49.0	190.1	44.7	42.6	44.6	33.4
14	0.0037	0.0033	0.0033	0.0033	0.0032	0.0031	0.0030	0.0030	41.5	229.0	37.5	21.1	45.0	190.1	235.0	31.6
14	0.0033	0.0033	0.0032	0.0032	0.0032	0.0031	0.0030	0.0030	48.7	190.1	196.2	38.1	231.6	193.3	17.4	32.5
14	0.0033	0.0031	0.0030	0.0029	0.0028	0.0028	0.0028	0.0028	234.7	24.9	36.9	192.3	243.2	58.9	16.5	53.1
14	0.0039	0.0037	0.0036	0.0032	0.0031	0.0031	0.0029	0.0028	236.1	238.0	27.3	63.8	27.6	39.5	49.1	23.2
15	0.0044	0.0031	0.0029	0.0026	0.0025	0.0025	0.0024	0.0024	18.5	29.0	16.3	233.5	15.6	14.2	232.4	32.0
15	0.0043	0.0032	0.0031	0.0030	0.0029	0.0028	0.0028	0.0027	190.0	25.5	227.7	38.5	236.8	38.1	28.5	31.1
15	0.0042	0.0038	0.0037	0.0034	0.0034	0.0032	0.0030	0.0030	23.8	196.4	196.2	232.2	237.7	39.2	34.2	23.7
15	0.0035	0.0033	0.0032	0.0031	0.0028	0.0025	0.0024	0.0024	24.7	28.4	37.8	285.2	233.9	26.9	210.0	28.2
15	0.0032	0.0030	0.0027	0.0027	0.0026	0.0025	0.0025	0.0025	27.3	13.4	41.0	208.6	12.7	18.0	202.6	233.5
15	0.0036	0.0032	0.0031	0.0031	0.0030	0.0030	0.0029	0.0028	190.1	201.1	196.2	198.1	31.7	202.0	29.4	31.6
16	0.0032	0.0032	0.0030	0.0026	0.0025	0.0024	0.0024	0.0024	31.6	110.5	34.5	16.3	49.1	285.2	19.5	33.1
16	0.0039	0.0034	0.0030	0.0029	0.0028	0.0027	0.0026	0.0025	190.1	40.0	45.2	27.9	50.5	26.2	232.4	216.2
16	0.0035	0.0029	0.0029	0.0029	0.0027	0.0027	0.0026	0.0025	190.3	45.9	19.4	233.8	193.5	238.5	237.3	19.5
16	0.0046	0.0033	0.0032	0.0032	0.0030	0.0029	0.0029	0.0029	237.7	37.2	46.4	21.1	32.0	41.2	237.3	18.9
16	0.0037	0.0035	0.0030	0.0028	0.0027	0.0026	0.0026	0.0025	34.3	18.8	42.9	232.4	232.9	54.6	29.3	70.8
16	0.0034	0.0033	0.0033	0.0032	0.0031	0.0031	0.0029	0.0029	285.3	20.8	43.3	230.7	43.2	36.9	26.6	190.3
17	0.0113	0.0091	0.0083	0.0078	0.0077	0.0075	0.0072	0.0069	69.0	65.8	83.9	69.1	77.5	67.7	72.3	67.4
17	0.0138	0.0138	0.0098	0.0097	0.0088	0.0080	0.0073	0.0072	67.1	67.0	67.9	75.4	67.4	69.3	56.6	66.7
17	0.0121	0.0099	0.0086	0.0078	0.0073	0.0072	0.0070	0.0067	66.2	61.2	76.8	61.0	73.1	64.9	80.4	68.4
17	0.0139	0.0118	0.0099	0.0091	0.0078	0.0074	0.0072	0.0066	66.5	66.8	67.6	59.2	64.7	76.1	70.5	69.0
17	0.0101	0.0081	0.0075	0.0074	0.0074	0.0069	0.0065	0.0064	66.5	66.8	64.9	69.6	72.5	69.1	55.7	78.3
17	0.0096	0.0094	0.0085	0.0085	0.0081	0.0081	0.0076	0.0072	66.4	64.7	70.0	67.9	89.3	76.1	66.8	80.3
18	0.0038	0.0037	0.0035	0.0035	0.0032	0.0026	0.0024	0.0024	237.7	46.2	60.4	285.2	236.4	41.8	236.8	18.2
18	0.0034	0.0033	0.0029	0.0029	0.0029	0.0026	0.0026	0.0025	38.3	230.0	50.2	190.3	58.9	199.3	285.5	56.0
18	0.0031	0.0029	0.0027	0.0026	0.0025	0.0025	0.0025	0.0024	30.5	190.1	28.8	44.1	36.8	14.8	197.0	34.3
18	0.0034	0.0030	0.0028	0.0027	0.0027	0.0025	0.0024	0.0024	54.3	33.3	190.3	193.8	60.1	56.5	44.3	30.8
18	0.0034	0.0029	0.0028	0.0028	0.0027	0.0027	0.0027	0.0027	36.8	233.6	44.6	235.0	24.4	54.8	17.2	27.0
18	0.0031	0.0030	0.0029	0.0027	0.0026	0.0026	0.0026	0.0025	31.9	234.2	31.7	8.4	190.1	238.2	34.3	47.5
19	0.0029	0.0029	0.0028	0.0027	0.0024	0.0023	0.0022	0.0022	51.9	233.9	237.7	190.3	22.9	16.6	38.0	235.8
19	0.0039	0.0032	0.0028	0.0027	0.0027	0.0026	0.0025	0.0023	237.7	233.3	198.2	29.9	235.9	196.7	235.1	34.3
19	0.0031	0.0029	0.0026	0.0026	0.0025	0.0024	0.0023	0.0023	200.4	11.3	42.9	232.5	235.1	25.0	22.0	23.8
19	0.0030	0.0028	0.0028	0.0023	0.0022	0.0022	0.0021	0.0021	190.3	230.3	285.3	199.6	31.3	229.5	49.9	28.7
19	0.0038	0.0027	0.0026	0.0025	0.0022	0.0021	0.0021	0.0020	237.7	193.5	285.3	199.9	15.3	190.1	45.9	285.0
19	0.0040	0.0034	0.0029	0.0026	0.0025	0.0025	0.0024	0.0023	237.7	28.5	35.4	237.9	18.9	235.6	45.0	232.5
20	0.0048	0.0029	0.0027	0.0027	0.0025	0.0022	0.0021	0.0020	237.7	32.2	36.5	18.6	18.5	111.5	47.5	48.8
20	0.0029	0.0026	0.0026	0.0025	0.0025	0.0024	0.0024	0.0023	190.3	199.9	36.5	28.2	27.3	23.2	194.1	28.7
20	0.0029	0.0026	0.0025	0.0025	0.0025	0.0024	0.0024	0.0024	23.5	286.1	195.0	237.7	41.4	198.1	235.6	25.2
20	0.0030	0.0029	0.0026	0.0026	0.0024	0.0023	0.0021	0.0021	237.7	190.3	197.9	19.2	198.2	6.4	23.5	29.0
20	0.0033	0.0027	0.0026	0.0025	0.0024	0.0024	0.0024	0.0023	190.3	9.0	40.1	237.3	193.0	238.5	26.4	71.6
20	0.0041	0.0025	0.0025	0.0025	0.0024	0.0023	0.0022	0.0021	237.7	193.3	18.2	23.0	27.0	234.5	233.8	47.8
21	0.0027	0.0025	0.0025	0.0023	0.0023	0.0023	0.0021	0.0020	239.6	40.1	230.3	15.7	26.4	220.3	36.2	1.1
21	0.0040	0.0031	0.0028	0.0027	0.0026	0.0024	0.0024	0.0022	237.7	237.9	201.0	194.1	285.3	190.3	15.0	234.2
21	0.0027	0.0027	0.0026	0.0025	0.0023	0.0021	0.0021	0.0020	237.9	1.1	28.7	24.4	238.3	238.8	34.3	22.7
21	0.0030	0.0027	0.0026	0.0023	0.0022	0.0021	0.0021	0.0021	23.8	237.9	199.3	235.0	237.3	229.0	232.7	200.7
21	0.0027	0.0024	0.0022	0.0021	0.0020	0.0020	0.0020	0.0019	234.7	228.7	12.1	50.2	233.6	237.7	200.8	237.9
21	0.0029	0.0024	0.0021	0.0021	0.0020	0.0019	0.0019	0.0019	190.3	22.0	199.7	233.9	190.1	32.7	232.9	25.0

4-3. ábra: Akusztikai jelek nyers érték II. – forrás: saját ábrázolás

ID	Max1	Max2	Max3	Max4	Max5	Max6	Max7	Max8	A1	A2	A3	A4	A5	A6	A7	A8
1	15	14	19	18	15	14	15	16	17	26	13	11	22	6	18	33
1	11	13	18	16	21	19	17	16	21	13	12	5	15	5	10	8
1	18	19	18	17	13	15	14	12	28	8	9	5	9	7	7	7
1	11	16	26	26	24	25	26	24	31	9	4	27	8	30	10	25
1	26	27	27	27	23	23	23	21	19	36	5	6	28	9	24	5
1	5	11	10	10	10	11	13	13	22	15	6	10	24	17	8	12
2	19	17	13	16	26	24	22	22	8	4	17	8	17	34	38	11
2	16	15	13	15	12	11	12	18	7	8	26	19	13	12	17	18
2	22	19	23	24	22	22	24	22	17	5	5	26	23	10	27	28
2	26	24	25	22	28	27	26	27	32	14	22	4	31	20	32	6
2	23	25	22	18	16	14	14	13	16	5	18	20	4	11	4	9
2	21	15	17	19	17	17	20	20	21	22	21	7	16	10	27	20
3	24	25	22	20	18	24	24	25	5	27	4	30	7	21	22	4
3	28	28	29	28	27	27	27	26	1	3	3	4	8	28	29	8
3	24	23	23	27	26	28	29	28	16	25	3	9	4	4	5	3
3	19	22	20	21	22	21	20	19	4	7	17	6	6	14	30	9
3	13	12	14	13	19	18	16	17	5	4	12	23	3	27	3	24
3	20	20	16	19	18	18	18	19	3	21	15	3	25	5	9	10
4	28	27	26	26	27	25	25	24	3	2	1	1	1	2	16	2
4	27	26	24	23	20	17	15	14	2	3	24	17	25	4	14	26
4	29	29	28	29	29	29	28	29	33	27	2	32	2	3	2	1
4	27	28	28	28	28	28	28	28	19	1	2	2	28	1	4	5
4	16	20	21	20	21	20	19	18	31	28	15	11	5	2	1	32
4	25	24	25	25	24	26	25	23	22	25	35	26	20	8	19	25
5	21	18	15	14	12	10	10	10	26	2	13	3	29	21	2	14
5	10	14	12	12	11	10	9	10	2	31	8	10	30	25	34	2
5	17	17	14	13	13	12	11	11	4	29	25	34	14	7	3	4
5	22	21	16	14	16	16	18	14	30	28	18	9	3	23	7	3
5	15	10	11	11	14	19	17	15	27	14	16	12	32	22	28	7
5	25	23	21	21	17	16	13	15	32	20	34	2	2	3	25	29
6	9	7	6	6	6	6	6	6	25	26	19	31	34	16	24	17
6	12	8	7	6	5	5	5	5	30	16	9	46	36	28	5	26
6	4	6	5	7	7	6	7	7	23	15	34	33	18	29	29	33
6	9	7	6	5	5	5	5	5	40	7	8	27	21	17	26	28
6	6	5	5	5	6	7	6	6	35	31	23	29	30	8	9	23
6	4	5	4	4	4	4	4	4	23	12	35	40	43	31	38	14
7	12	13	12	11	9	8	8	8	27	6	19	28	15	9	31	10
7	17	21	17	17	15	15	12	11	18	32	7	33	17	26	11	22
7	8	9	8	7	8	8	8	8	28	29	14	18	6	29	11	16
7	13	10	8	8	8	9	10	9	24	21	25	31	12	15	15	24
7	6	9	9	9	9	9	9	9	8	12	16	28	26	16	26	13
7	8	6	7	8	7	7	7	7	7	13	14	15	24	26	11	17
8	35	34	33	32	32	32	34	32	56	22	48	55	46	47	50	48
8	35	33	32	31	30	33	33	33	26	46	37	47	47	56	53	12
8	33	32	32	30	30	31	31	31	43	43	43	49	49	61	56	46
8	42	42	42	39	40	39	38	40	24	46	41	17	45	42	37	36
8	43	36	35	34	34	32	32	31	43	56	44	40	44	49	50	23
8	39	34	34	35	33	35	34	36	39	58	58	52	38	57	18	22
9	32	35	35	34	35	36	37	37	52	49	11	60	53	43	46	35
9	36	33	33	33	32	31	30	30	61	38	45	41	56	46	59	13
9	31	31	31	32	33	33	36	35	50	53	47	14	53	35	48	58
9	44	40	39	41	39	37	37	39	9	39	44	59	11	57	57	21
9	31	31	30	31	31	30	30	30	54	42	60	44	60	44	47	42
9	40	40	40	38	36	35	35	35	57	54	40	48	41	51	56	34
10	30	30	31	30	31	30	31	32	52	50	54	51	37	50	62	46
10	36	36	39	37	38	38	39	38	53	45	50	52	36	54	41	40
10	46	41	41	36	36	37	35	36	51	56	11	19	49	51	44	50
10	32	38	38	37	40	40	40	39	49	51	20	55	62	20	49	45
10	30	30	30	36	34	34	32	33	54	55	53	57	27	37	55	44

4-4. ábra: Akusztikai jelek sorszámozott érték I. – forrás: saját ábrázolás

ID	Max1	Max2	Max3	Max4	Max5	Max6	Max7	Max8	A1	A2	A3	A4	A5	A6	A7	A8
10	47	39	36	35	35	34	33	34	59	49	46	56	45	11	36	57
11	1	1	1	2	2	2	4	3	45	30	26	30	34	30	32	43
11	5	4	4	4	4	4	4	3	29	35	42	29	43	37	43	16
11	3	3	3	3	3	2	2	2	34	20	21	34	31	18	25	11
11	3	3	2	3	1	1	1	1	47	16	31	46	19	24	42	40
11	2	2	2	1	3	3	2	2	45	44	43	47	44	38	33	31
11	2	2	3	2	2	3	3	4	44	45	23	37	26	46	29	29
12	33	32	34	33	37	38	39	38	55	47	49	14	48	55	36	52
12	14	11	11	10	11	12	11	12	33	30	9	18	27	27	28	36
12	23	22	24	23	25	22	21	21	29	19	24	25	28	19	21	27
12	40	37	37	40	38	36	36	34	49	47	32	49	47	54	22	47
12	29	29	29	29	29	29	29	29	6	9	27	12	9	30	8	30
12	38	37	36	38	37	39	38	37	47	44	54	43	22	60	36	15
13	41	44	43	44	44	47	46	46	51	33	39	16	59	48	41	21
13	50	43	47	48	47	46	47	47	47	59	55	54	57	22	20	60
13	54	48	46	45	46	43	41	42	58	57	49	54	23	39	52	41
13	38	35	40	39	45	45	43	44	61	11	33	50	54	47	45	46
13	46	42	41	42	44	49	49	49	46	52	62	14	52	58	6	63
13	58	53	49	49	48	47	48	48	25	34	42	51	51	55	23	57
14	52	49	47	48	46	44	44	43	10	53	38	58	42	59	51	32
14	49	44	43	45	43	44	45	45	10	19	46	39	50	48	49	49
14	48	46	44	42	41	41	40	40	53	24	56	61	50	36	16	52
14	55	47	45	43	41	41	41	41	50	37	30	53	21	34	62	51
14	55	52	51	50	50	46	46	46	20	60	56	38	7	43	63	42
14	44	39	38	43	43	42	45	45	18	10	61	44	57	52	45	61
15	37	53	52	56	57	55	56	55	64	57	63	22	63	63	21	51
15	37	50	48	47	48	48	47	47	39	60	22	53	12	53	58	53
15	39	38	37	41	39	40	42	41	62	34	30	24	10	52	55	60
15	51	47	46	47	50	53	53	52	62	59	55	7	18	58	31	56
15	56	54	58	54	54	53	52	52	60	62	52	32	64	62	33	19
15	50	50	48	46	45	43	42	44	38	32	30	36	55	32	57	52
16	57	51	50	57	56	57	55	54	59	39	59	63	48	6	61	50
16	45	45	50	50	49	50	49	49	38	51	47	57	46	59	21	27
16	51	55	53	51	51	48	50	51	35	48	62	22	33	12	12	62
16	34	46	45	46	47	45	44	43	10	52	47	61	55	50	12	62
16	49	43	49	51	52	51	51	50	57	62	51	24	19	45	58	37
16	53	48	44	44	42	42	43	42	6	61	51	25	51	53	59	31
17	14	18	20	24	20	20	21	23	40	41	36	42	38	41	39	39
17	7	4	10	9	10	13	19	20	41	40	38	41	40	40	42	39
17	10	12	15	22	25	23	23	25	43	43	36	45	39	42	39	38
17	7	8	9	12	19	21	22	26	41	40	39	45	40	39	40	38
17	18	26	27	25	23	26	27	27	41	40	40	42	39	41	43	35
17	20	16	19	15	14	13	16	17	42	42	37	43	37	39	40	34
18	47	41	42	40	42	52	57	55	10	48	41	7	13	49	13	63
18	54	49	51	49	49	52	51	51	55	23	45	38	42	32	6	40
18	58	57	57	56	55	54	53	53	60	37	60	50	54	63	35	48
18	52	55	55	52	52	55	54	54	46	54	33	37	41	44	50	54
18	53	56	54	52	51	49	48	48	56	18	49	20	60	45	63	56
18	57	54	52	53	53	51	50	50	58	16	59	64	35	14	54	45
19	61	58	54	54	60	59	59	58	47	17	10	38	61	62	52	18
19	45	51	56	55	53	50	52	57	10	18	29	56	14	33	15	48
19	59	57	60	58	58	58	58	57	34	63	51	23	16	60	61	59
19	60	59	56	62	62	61	60	60	35	23	6	35	56	23	44	55
19	48	59	61	60	62	62	60	63	10	35	6	35	63	36	47	6
19	43	45	53	57	56	54	58	56	10	58	58	13	61	17	48	20
20	34	56	57	53	55	61	61	62	10	55	57	62	62	38	46	43
20	62	61	61	59	57	58	57	58	35	33	57	57	58	61	35	55
20	62	62	62	60	58	56	54	53	63	6	32	13	52	33	14	58
20	60	58	60	58	59	59	62	61	10	37	29	62	32	64	60	54
20	56	60	59	61	59	56	56	56	35	63	53	15	33	12	60	37
20	41	62	62	61	60	60	59	59	10	36	63	60	58	18	17	44
21	64	63	63	62	61	60	61	61	9	50	20	63	59	25	53	64
21	42	52	55	55	54	57	55	59	10	10	27	36	5	35	64	19
21	63	61	59	59	61	62	63	62	10	64	61	59	9	12	54	61
21	59	60	58	63	63	63	62	60	62	10	28	20	11	23	20	30
21	63	63	63	64	63	63	63	64	20	24	64	48	19	15	34	15
21	61	64	64	63	64	64	64	63	35	61	28	21	35	56	19	59

4-5. ábra: Akusztikai jelek sorszámozott érték II. – forrás: saját ábrázolás

5. A MESTERSÉGES INTELLIGENCIA ALAPÚ ADATELEMZÉS

5.1. A hasonlóságelemzés matematikája

„A Dobó Andor matematikus által kialakított hasonlóságok hasonlósága (JOKER) [7] gondolatvilág és a mesterséges neurális hálók előnyeinek integrálásából született meg a hasonlóságelemzés online keretrendszere egy INNOCSEKK-projekt keretében: (vö. php-alapú megoldás, ezt használtam a mostani számításokhoz is)”

„Az online rendszer neve: COCO – component-based object comparison for objectivity. Alapvetően 3 modellje van a hasonlóságelemzésnek, mely a zaj elemzésekhez is tökéletesen alkalmazható. Időközben technológia oldalról több megoldást is született ugyan azoknak az egyenletrendszereknek a technikai megoldására: Excel-alapú manuális megoldás, Excel-alapú macro-alapú megoldás, Javascript-alapú megoldás, php-alapú megoldás, Mathematica-alapú megoldás, sql-alapú megoldás (Seacon), ill. Google-spreadsheet-alapú megoldás, ahol a Mathematica-alapú megoldást én készítettem az Alkalmazott számítógépes analízis (BMETE927205) című tantárgy keretében. Minden megoldás támaszkodik valamilyen ún. külső optimalizáló (LP) motorra annak érdekében, hogy a tanulási folyamatnak nevezhető réteg előre tervezetten (optimum-közeli állapotban) önmagától terminálódjon.”

5.1.1. COCO-STD (STANDARD)

A COCO-STD modelljében rejltő lehetőség, hogy valós Y -változót (pl. füstgáz komponens idősoros értékeit, az X_i -változók lépcsős függvényeként közelítjük, vagyis minden X_i változóhoz meghatározunk egy-egy lépcsős függvényt, ahol az X -tömb csak pozitív egész számokat, azaz rangsor-számokat tartalmaz.

A COCO-STD modell esetében a lépcsőkre vonatkozó megkötése: a következő lépcső legyen kisebb egyenlő, mint az azt megelőző (csak monotonitás).

5.1.2. COCO-Y0

„Az anti-diszkriminációs számítások-- más néven az ideálkereső, mesterséges fogalom-alkotó modell jelölése --, ahol minden X esetén az idealitás irányába ható irány megadása után optimalizálás keretében keressük az átlagtól leginkább eltérő objektumot úgy, hogy az optimalizálás célja mindvégig az objektumok azonosságának kikényszeríteni akarása (vö. lehet-e minden objektum másként egyforma – azaz létezik-e az adott fogalom ábrázolási skálája: vö. gázelegy-összetétel idealitás-index meghatározása [1][2]).

Y_0 modell esetén a lépcsők nagysága minimum 1 egység, vagyis a következő lépcső értéke legyen minimum 1 egységgel kisebb, mint az azt megelőző (szigorú monotonitás).”

Az Y_0 modell alkalmazható egy ez egyben STD modellként is, vagyis valós Y vektort kell megmagyarázni a bementei változókból, azzal a megkötéssel, hogy a lépcsőértékek legyenek szigorúan monoton csökkenők.

5.1.3. COCO-MCM

„Monte-Carlo Módszer logikáját közelítő lépcső-keresési eljárás: a COCO-alapú hasonlóságelemzés azon modulja, mely keretében nincs semmilyen korlátozó feltétel megadva az optimalizálás kapcsán, vagyis az attribútumok szintjei és az output szintek közötti tetszőleges alakzatú (polinomizálódó), legnagyobb magyarázó erejű összefüggés feltárása a cél.”

A COCO-STD dupla modell ennek a flexibilis tanulási lehetőségnek a felügyeltebb változata, annak érdekében, hogy a kapott lépcsős függvények értelmezhetőek maradjanak, vagyis a polinomizálódást elkerülve 3 állapotot vehessen fel a dupla modell esetén a két összetartozó lépcsős függvény összege: egyenesen arányos, fordítottan arányos, optimum jellegű.

5.1.4. RÉSZLETES PÉLDA BEMUTATÁSA

Azok az olvasók, akik szeretnék a COCO mögötti matematikát alaposabban megérteni, a szakdolgozatom mellékletében találnak egy részletesen kidolgozott tanító példát.

Emellett a dolgozatban közölt össze eredmény és mögöttes számítások elérhetőek az megadott linken [8].

6. ELEMZÉSEK BEMUTATÁSA

6.1. Röviden az előzményekről

A korábban írt TDK és szakdolgozat fókuszsa az volt, hogy az akkor csak füstgáz alapon számolt idealitás indexet mennyire jól lehet magyarázni a folyamat-szenzor adatokkal, ill. a spektrális emisszióval. A modellekben lévő genetikai potenciál is bemutatásra került, amivel fel lehet tártani, hogy adott változtatás esetén el lehet-e mozdulni adott időpillanatban a kiszámolt idealitás indextől.

6.2. Az elemzések célja

Ez a dolgozat most (egyelőre) idealitás index nélkül, direktben igyekszik kapcsolatot teremteni a sűrített akusztikai jel és a folyamat-szenzor adatok, ill. a füstgáz komponensek között. A következőkben ezen kapcsolatteremtés hasonlóságelemzés-i lépései kerülnek bemutatásra a kapott eredményekkel együtt.

6.3. X_i magyarázó változók kiválasztásának lehetőségei

Első lépésként csak a 8 legnagyobb amplitúdóval próbáltam meg megmagyarázni a folyamat-szenzor adatokat és a füstgáz komponenseket. Már ennyi magyarázó változó is elegendő volt ahhoz, hogy a legtöbb esetben hibátlan tanulásról lehessen beszélni. Azonban volt egy két eset, ahol a tény és becslés között "csak" 0.9 körüli korrelációt adott a tanulás. Egy ilyen eset a P02 szenzor a porlasztólevegő nyomása. A következőkben a magyarázó változók intelligens, irányított, monoton-komponensekre támaszkodó, nem polinomizálódó transzformációin keresztül bemutatom (vö. explainable/interpretable neural

networks probléma [9]), hogyan lehet szinte egyre pontosabb tanulás eredményt elérni.

6.3.1. A DUPLA MODELL JELENTÉSE COCO MODELLEK ESETÉN

Mivel a hasonlóságelemzés STD és Y0 modelljei monoton, illetve szigorúan monoton diszkrét értékekben értelmezett lépcsősfüggvényeket határoznak meg az egyes X_i változók és az Y között ezért szükség van minden X_i változónak a fordított irányban rangsorolt nézetére is. Így érhető el, hogy az optimum jellegű magyarázó változók is ki tudják fejteni a hatásukat, ahol nem igaz, hogy minél nagyobb az érték annál jobb, illetve minél kisebb az érték annál jobb.


A hasonlóságelemzés esetén az ún. dupla modellek minden esetben a X_i bemeneti változók és az Y érték hatására dől el, hogy az egyes X_i változók mögötti lépcsős függvények direkt és inverz nézetének összege végül milyen összefüggést eredményez: egyenesen arányos, fordítottan arányos, optimum jellegű, vagy ritkán hullámzó.

A COCO MCM modellje alkalmas az exploratív modellezésre, ahol nem cél, hogy lineáris és másodfokú összefüggésekkel kérjünk el jó tanulási eredményt. Hanem megengedett a modellek polinomizációja, vagyis a modellhiba csökkentés érdekében a tetszőleges lépcső érték felvétel, hiszen MCM esetén nincs megkötés a lépcsők közötti elmozdulás értékére.

6.3.2. P02 TANULÁSA CSAK 8 AMPLITÚDÓ ALAPJÁN COCO-STD MODELLEL

A porlasztó levegő tanulása dupla modellel, ahol a mért jel 1000-es értékével számoltam, mert modellezési tapasztalat, hogy a tanulási mintánál legyen 2-3 nagyságrenddel nagyobb az $Y(P02)$. A 6-1. ábra: jól látható, hogy a jelenség alapvetően megtanulásra került, már csak "finomhangolásra" van szükség.


Amplitúdó alapján a COCO-Y0 modell is hasonló eredményre jutott.



6-1. ábra: A P02 tanulása korreláció: 0.91 (Y0 esetén is) – forrás: saját ábrázolás


Szemléltetés képen megmutatom, hogy a P02 és Max1-Max8 (nyers értékek) között milyen korrelációk állnak fent. A frekvenciák esetén majd látható, hogy sokkal kisebb korrelációkból jobb tanulás érhető el.

Tapasztalatként elmondható, hogy magas korreláció (0.5 felett) mellett elvárható a jó tanulási eredmény viszont fordítva sincs kizárva, hogy alacsony korreláció együttállásai esetén ne lehetne jól tanuló modellt építeni.



6-2. ábra: Korreláció a P02 és Max1-Max8 között – forrás: saját ábrázolás


6.3.3. P02 TANULÁSA CSAK 8 FREKVENCIA ALAPJÁN COCO-STD MODELLEL



6-3. ábra: Korreláció a P02 és A1-A8 között, ahol A1 a Max1-hez tartozó frekvencia

forrás: saját ábrázolás

A frekvenciák esetében szinte nincs összefüggés az X_i és Y között. Ennek ellenére a COCO-STD modell és a COCO-Y0 is jobban teljesített.




6-4. ábra: P02 tanulása STD modellel frekvencia alapon korreláció: 0.96 (Y0 esetén is)

forrás: saját ábrázolás

Mivel nem tapasztaltam érdemi különbséget a STD modell és az Y0 között, így a későbbiekben csak STD modellel folytattam tovább az elemzéseket. Úgy, hogy egyszerre használom a magyarázó változóként az amplitúdót és a frekvenciát is.

6.3.4. P02 TANULÁSA 4-4 AMPLITÚDÓ ÉS FREKVENCIA ALAPJÁN STD MODELLEL




6-5. ábra: P02 tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.96

forrás: saját ábrázolás

Ugyan annyi $(2 \cdot (4+4))=16$ magyarázó változó esetén, de amplitúdó és frekvencia alapon a korreláció még nem nőtt.

6.3.5. P02 TANULÁSA 8-8 AMPLITÚDÓ ÉS FREKVENCIA ALAPJÁN STD MODELLEL



6-6. ábra: P02 tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.98

forrás: saját ábrázolás

Kétszer annyi magyarázó változóval, mint eddig már kvázi hibátlan tanulásról lehet beszélni.


6.3.6. TANULÁS JÓSÁGÁNAK JAVÍTÁSA HIBRID MODELLEL

Az előző fejezetekben bemutatásra került, hogy a magyarázó változók mennyiségét és fajtáját befolyásolva el lehet érni kvázi hibátlan tanulást.

Ebben a fejezetben bemutatom, hogy hibrid modellel hibátlan tanulást is el lehet érni, ehhez arra van szükség, hogy egy vagy több (korábbi) modell beclését (egy fajta elősűrített változóként) újra felhasználjuk magyarázó változóként.

A konkrét példa esetében 8 amplitúdó alapján korreláció: 0.91-es tanulást lehetett elérni STD modellel. Ha a 7 legnagyobb amplitúdót és ennek a modellnek

a becslését használom fel magyarázó változóként továbbra is dupla STD modellnél akkor a tanulás hibátlan lesz.




6-7. ábra: P02 tanulása hibrid STD modellel amplitúdó alapon korreláció: 1.00

forrás: saját ábrázolás

6.3.7. AZ AKUSZTIKAI JELTŐL KÖZVETLENÜL NEM FÜGGŐ SZENZORADATOK


Az elemzés közben kapott eredmények még 8 amplitúdó és 8 frekvencia esetében sem eredményezett mindenhol hibátlan tanulást.

A TC2 szabályzóban lévő hőmérséklet és a P09 légköri nyomás a teremben elvárható módon rosszabb tanulási eredményt kell, hogy produkáljon, mint a többi az égést, így a keletkező akusztikai jelet közvetlenül befolyásoló paraméter.



6-8. ábra: P09 tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.94

forrás: saját ábrázolás




6-9. ábra: TC2 tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.98

forrás: saját ábrázolás

6.3.8. VÉLETLEN SZÁMOK MAGYARÁZÁSA AKUSZTIKAI JELLEL

A szinte minden esetben kvázi hibátlanul tanuló modelleket látva felmerült, hogy akusztikai jellel szinte bármit meg lehet magyarázni? Ezért készítettem egy modellt véletlen számokkal (Y) is, ahol a becslés leginkább egy mozgóátlagra hasonlít. A véletlenszámok alacsonyabb szintű reprodukálhatósága adott modellezési keretrendszer által azt bizonyítja, hogy ott, ahol a modellezési

keretrendszer valós mérési adatokkal dolgozik, az eredmények nem matematikai "varázslásnak" köszönhetők, hanem az adatok információtartalmának.



6-10. ábra: Véletlen tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.55

forrás: saját ábrázolás


6.3.9. MIÉRT VOLT FONTOS A FOLYAMAT-SZENZORADATOK TANULHATÓSÁGA

Azzal, hogy bemutatásra került, hogy az akusztikai kvázi jelből tetszőleges pontossággal tanulható és valószínű nagy pontossággal reprodukálható a folyamat-szenzorok jele összekapcsolásra került a korábbi és a mostani munka, ill. magam számára is teljes bizonyóságot nyert, hogy akusztikai jelek esetén is igaz, hogy megtanulható a rendszer, hiszen fizikai törvényszerűségek következménye az égés és ez leképezhető az akusztikai jeleken keresztül IS.

6.4. Füstgáz komponensek tanulhatósága

6.4.1. FÜSTGÁZ KOMPONENSEK TANULÁSA 8-8 AMPLITÚDÓ ÉS FREKVENCIA ALAPJÁN STD MODELLEL


A folyamat-szenzor adatoknál bevált 8 amplitúdó és a 8 hozzátartozó frekvencia alapján dupla modellekkel az alábbi tanulási minták érhetők el.



6-11. ábra: NO tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.93


forrás: saját ábrázolás

A 6-11. ábra: jól látszik, hogy vannak olyan beállítások amiknek a megtanulhatósága szinte tökéletes, míg máshol a relatíve rossz a becslés. Ennek feltárása nem volt a jelen dolgozat célja, de a későbbiekben mindenképp feltárásra kerül, hogy mi okozza azt, hogy nem szisztematikus alul/felülbecslése történik a jelnek, hanem főleg a minta elején úgy tűnik, hogy a robot számára nem került megértésre a jelenség.




6-12. ábra: CO tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.86

forrás: saját ábrázolás



6-13. ábra: CO₂ tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.996

forrás: saját ábrázolás



6-14. ábra: O₂ tanulása STD modellel amplitúdó és frekvencia alapon korreláció: 0.95

forrás: saját ábrázolás

6.4.2. FÜSTGÁZ KOMPONENSEK TANULÁSA 8-8 AMPLITÚDÓ ÉS FREKVENCIA ALAPJÁN HIBRID STD MODELLEL


A már korábban bemutatott hibrid modell ötletét használtam most is, annyi kiegészítéssel, hogy a most a 8 amplitúdó és 8 frekvenciából dupla modellel készítettem egy-egy becslést és ezeket is felhasználva 4 amplitúdó 4 frekvencia 2 becslés dupla modellje lett a végső becslés. Mivel a számításokhoz használt php alapú online megoldásnak vannak méretbeli korlátai, ami nem teszi lehetővé, hogy a magyarázó változók számát akár milyen nagyra emeljem.

Eredményül hasonló korrelációs értékeket, mint az előző fejezetben bemutatottak, így az oxigénen kívül, minden esetben nőtt a tanulás jóságát reprezentáló korrelációs érték a CO₂ esetében ez elérte az 1.00-et is. Az O₂ esetében a romló 0.95-ről 0.89-re csökkent ennek az az oka, hogy a Max5-Max8 és A5-A8 magyarázó változók már nem voltak benne a modellben és a 0.95 esetben ezeket is felhasználta a robot.

6.4.3. HOGYAN HAT AZ Y ELTOLÁSA AZ X_i MAGYARÁZÓ VÁLTOZÓHOZ KÉPEST

FÜSTGÁZ KOMPONENSEK ESETÉN?

A feltételezés az, hogy az akusztikai jelekhez előrébb hozva a füstgáz komponenseknél mért értéket javulni fog a tanulási modell korrelációja egészen addig, amíg már korábban keletkezett füstgáz értékeket szeretnénk később létrejött akusztikai jellel magyarázva. Ehhez el is végeztem az 5 mp-es időbeni eltolásokat +5 és -60 mp-es időintervallumban, ahol a negatív irány jelenti azt, hogy a füstgáz értéket közelebb hozom az akusztikai jelhez. Az alábbi eredményt kaptam modell-korrelációkban bemutatva:



6-15. ábra: Korreláció változás: NO időbeni eltolása az akusztikai jelhez képest

forrás: saját ábrázolás

A 6-15. ábra: értelmezése: azért nincs optimum hatás a korrelációk és időbeni eltolás mögött, mert egy beállításon belül kvázi stacionárius tüzelési jelenségről beszélhetünk, ami azt jelenti, hogy a füstgáz komponensek érdemben nem változnak 5 mp-es megfigyelés esetén. Illetve, ha az akusztikai jel mintázatában meg is jelenik a kis változás, ami a füstgáz komponensek ingadozását jelenti, azt a relatíve nagy 5 mp-es időablak, amivel most történt a FFT elnyomja. Mivel a füstgáz komponensek 2 mp-ként kerültek megmérésre, így érdemes elvégezni nem csak a korreláció optimumkeresést, hanem a teljes füstgáz elemzést új időegységgel is.

6.5. Füstgáz komponensek előrejelezhetősége

Az eddig tartó előkészítő munka alapozta meg a dolgozat fő üzenetét, hogy milyen pontossággal lehet előrejelezni a füstgáz komponensek értékét, amivel így ki lehet küszöbölni a kémiai úton mért jelkésés 30-60 mp-es késleltetését. [10]

Hasonlóságelemzéssel a következőképpen lehet előrejelezni. A tanulási minta méretét kell csökkenteni a jelenlegi 126-ról. Az új kisebb tanulási minta által meghatározott lépcsős függvényekbe behelyettesítve a sorszámozott de a tanuláshoz fel nem használt értékeket kapjuk az előrejelzést. Kétféle előrejelzést is csináltam. Az egyik esetben 6 időegységet az-az egy teljes megfigyelést hagytam ki a tanulási mintából, így 120 elemű lett a tanulási minta. A másik esetben csak az utolsó időegységet hagytam ki a tanulási mintából így 125 elemű lett a tanulási minta. A két eset között fontos elméleti különbség van. Ha csak 1 elemet szeretnék megbecsülni akkor rendelkezésre áll az utolsó beállítás 6 időegységéből 5 a tanulási mintában, viszont 6 elem előrejelzésekor egy teljesen új a megtanult beállításoktól eltérő esetben kell előrejelezni. Az előrejelzéshez a nem hibrid 8+8 elemű dupla modelleket használtam.

6.5.1. NO ELŐREJELEZHETŐSÉGE

A 6-11. ábra: látható, hogy az utolsó hat időegységben felül lett becsülve a 126 elemű tanulási minta esetén az NO tény érték.

Becslés	Tény	%	
9.9	6.0	65.767	
36.5	6.0	508.05	
12.6	6.0	110.36	
20.0	6.0	233.54	
22.4	5.0	348.27	
12.8	5.0	156.21	
19.05	5.67	237.03	Átlag
Becslés	tény	%	
7.58	5.0	51.566	

6-16. ábra: NO előrejelzése – forrás: saját ábrázolás

A 6-16. ábra: esetében is felülbecslést kapunk a tény értékhez képest. Jobb tanulási minta esetén, ahol sikerül pontosabban megtanulni 126 elem esetén az utolsó beállítást is elvárható, hogy az előrejelzés is pontosabb legyen (vö. felső blokk).

A 6-16. ábra: alsó részén látszik, hogy 125 elemű tanulási minta esetén a becslés már a szenzor mérési hibáján [10] belül van (± 5 ppm)

6.5.2. CO ELŐREJELEZHETŐSÉGE

A 6-12. ábra: látható, hogy az utolsó hat időegységben alul lett becslülve a 126 elemű tanulási minta esetén a CO tény érték.


Becslés	Tény	%	
5.51	140.00	-96.063	
3.18	94.00	-96.621	
4.88	95.00	-94.864	
4.84	94.00	-94.856	
4.36	120.00	-96.37	
5.91	186.00	-96.825	
4.78	121.50	-95.93	Átlag
Becslés	Tény	%	
85.026	186	-54.287	

6-17. ábra: CO előrejelzése – forrás: saját ábrázolás

A 6-17. ábra: a teljes tanulási mintához hasonlóan alulbecslés látható. A becslések és a tények esetében is megfigyelhető a parabola jelleg. Így itt is elmondható, hogy ha sikerült jobb tanulási eredményt elérni a teljes 126 elemű mintára, akkor várhatóan a becslés is jobb lesz. A 125 elemű tanulási minta ebben az esetben is pontosabb előrejelzésre vezet az elvárásoknak megfelelően. A szenzor pontossága: ± 5 % (40 – 500 ppm)

6.5.3. O₂ ELŐREJELEZHETŐSÉGE

A 6-14. ábra: az NO és CO esetéhez képest most alul- és felülbecslést is látható az utolsó beállításra. Hasonló mintázatot várhatunk az előrejelzéstől is.




6-18. ábra: O₂ előrejelzése – forrás: saját ábrázolás

A 6-18. ábra: az elvárásoknak megfelelően látható az alul és felülbecslés. Az oxigén esetében már a teljes minta tanulásakor is látható volt a tény érték folyamatos alul és felülbecslése. Ebben az esetben is igaz, ha sikerül csak az oxigénre jobban tanuló bemeneti változókat/hibrid modelleket találni, akkor az előrejelzés is várhatóan pontosabb lesz a már most sem rossz eredményhez képest. Hiszen az eddig használt matematikai megoldásokkal nem sikerült kapcsolatot teremteni az égés akusztikai jele és a mérhető füstgázkomponensek között. A szenzor pontossága: $\pm 0.8\%$ (0 – 25 V/V%)

6.5.4. CO₂ ELŐREJELEZHETŐSÉGE

A 6-13. ábra: látható, hogy szinte nincs eltérés a tény és a becslés között CO₂ esetében, így az előző három fejezet alapján itt várható a legjobb előrejelzés.



6-19. ábra: CO₂ előrejelzése – forrás: saját ábrázolás

A 6-19. ábra: látható a CO₂ előrejelzése, ami a megadott [10] $\pm 0.3-1$ V/V% hibahatáron belül van a hat elemű előrejelzés átlagára és az egy elemű előrejelzés esetén is.

Az O₂ és CO₂ esetében fontos megjegyezni, hogy ezeket az értékeket közvetlenül lehet számolni a tüzelési teljesítményből is.

Korábbi hasonlóságelemzési tapasztalataim alapján még fontos megemlíteni, hogy nincs feltétlenül párhuzam a jobban tesztelő/előrejelző és jobban tanuló modellek között, így a jövőben célként nem csak a modellek jobb tanulási eredményét kell kitűzni, hanem azt is, hogy ezzel jobb előrejelzéseket lehessen készíteni akár annak árán is, hogy nem a legjobban tanuló modell a legjobban előrejelző.

7. ÖSSZEFOGLALÁS/EREDMÉNYEK ÉRTÉKELÉSE

7.1. Eredmények és jövőkép

A hasonlóságelemzés modell-alkotási lehetőségeivel sikerült függvényszerű kapcsolatot teremteni közvetlenül a füstgáz komponensek és az akusztikai jel között. Így megtörtént a következő lépés a valós idejű szabályzó megalkotása felé, hiszen már kvázi real-time jelleggel rendelkezésre állnak a füstgáz komponensek becslései akusztikai jelből meghatározva.

A következő (jövőbeni) lépés a szakdolgozatban bemutatott genetikai potenciál vizsgálat továbbfejlesztése, aminek célja és eredménye feltárni, hogy a folyamat-szenzor jelek aktuális értékeinek megadott környezetében várható-e az ideaitás index javulása, így a károsanyag kibocsátás csökkentése. A genetikai potenciál számításához felhasználásra fog kerülni a füstgáz előrejelzés akusztikai alapon a tüzelés idealitás-indexének meghatározásához. Az idealitás-index mindenképpen tartalmazza majd a CO és NO értékeket minél kisebb annál jobb elven való figyelembevétel mellett. Emellett van lehetőség a lángstabilitást is bele venni az idealitás index meghatározásba, amire már van példa a szakirodalomban. [11]

7.2. Javaslatok/Következtetések/Tanulságok

A 100 legnagyobb amplitúdó nem minden esetben fedte le a csúcsokat különböző frekvenciánál, így érdemes lehet csúcskeresés után venni a 8 legnagyobb amplitúdót.

Alternatív megoldás a 100 amplitúdó és frekvencia értékből 10-esével 10 vagy 10-10 dupla modellel hibrid modellt építeni, így mind a 100 érték felhasználásra kerül a tanuláshoz.

8. FELHASZNÁLT FORRÁSOK

- [1] Pitlik Marcell, Térfogati égés optikai vizsgálata és mesterséges intelligencia alapú elemzése, BME TDK, 2020
http://www.combustioninstitute.hu/tdk_dij/2021/PitlikMarcell_TDK2020.pdf
- [2] Pitlik Marcell, Térfogati égés optikai vizsgálata és mesterséges intelligencia alapú elemzése, BME szakdolgozat, 2021
https://miau.my-x.hu/miau/278/szakdoga_PM_final.pdf
- [3] Törvényi előírások a károsanyag kibocsátásra:
<https://net.jogtar.hu/jogszabaly?docid=A1700053.FM>
- [4] Hidegh Gyöngyvér, Diffúzorok alkalmazásának hatása előkeveréses égők károsanyag kibocsátására, BME TDK, 2016
- [5] Knuth, D.E., Foreword. In: Petkovsek, M.; Wilf, H.S.; Zeilberger, D., „A=B”. (s.l.), 1995 <https://www2.math.upenn.edu/~wilf/AeqB.pdf>
- [6] Mikrofon: GRAS 146AE 1/2" CCP Free-field Microphone
<https://www.grasacoustics.com/products/product/771-146AE>
- [7] Dobó, Andor, A hasonlóságelmélet alkalmazása a Joker rendszerben, Prodinform, Budapest, 1992 <https://www.antikvarium.hu/konyv/dobo-andor-a-hasonlosagelmélet-alkalmazása-a-joker-rendszerben-732382>
- [8] Az elvégzett számítások elérése: https://miau.my-x.hu/miau/279/tdk_zaj/
- [9] Feng-Lei Fan, Jinjun Xiong, Mengzhou Li, Ge Wang, Fellow, On Interpretability of Artificial Neural Networks: A Survey, 2001
<https://arxiv.org/ftp/arxiv/papers/2001/2001.02522.pdf>
- [10] testo 350 Combustion & Emission Analyzer.
<https://www.testo.com/en-VN/testo-350/p/0632-3510>
- [11] Long Zhang, Yuan Xue, Qing Xie, Zhuyin Ren, Analysis and neural network prediction of combustion stability for industrial gases, 2021
<https://www.sciencedirect.com/science/article/abs/pii/S0016236120325035>