

Mesterséges intelligencia a tüzeléstechnikában

A. Garami^{1*}

¹ Miskolci Egyetem, Energia- és Minőségügyi Intézet, attila.garami@uni-miskolc.hu

Absztrakt

Az utóbbi időben a különféle energiaforrások hasznosítása, mint például a biomassza energetikai célú felhasználása, globális trenddé vált. Ezen tüzelőanyagok hasznosítása az ipari méretű tüzeléstechnikában számos nehézséggel jár. Pontos és részletes információk hiányában kevésbé megbízható matematikai modellek és vizsgálatok készíthetők, ezért az elméleti modellek helyett empirikus, modell-alapú, korszerű felügyeleti és szabályozó rendszerek alkalmazása adhat megoldást a problémákra. Jelen irodalmi áttekintő ismerteti a manapság széles körben alkalmazott gépi tanuló algoritmusok, különös tekintettel a mesterséges neurális hálózatok, valamint a lángképzés és feldolgozás külön-külön és együttes alkalmazhatóságát a tüzeléstechnikában és a biomasszatüzelésben.

1 Bevezetés

Az utóbbi időben a különféle energiaforrások hasznosítása – azon belül a változó összetételű, heterogén tüzelőanyagok vagy tüzelőanyagkeverékek, mint például a biomassza energetikai célú felhasználása – globális trenddé vált. Ennek oka a könnyen hozzáférhető és gazdaságosan kitermelhető hagyományos fosszilis energiahordozó források csökkenése, a nukleáris energiahasznosítással kapcsolatos aggodalmak és a növekvő környezetvédelmi aggályok. Ezen tüzelőanyagok hasznosítása az ipari méretű tüzeléstechnikában számos nehézséggel jár. Ezek közül a legjelentősebbek a heterogén tüzelőanyag felhasználás okozta bonyolult tüzelésszabályozás, a növekvő károsanyag-kibocsátás [1][2] – azon belül is a füstgázzal elragadott szilárd részecskék emissziójának nagymértékű növekedése [4][5] –, lerakódások képződése a füstjáratokban és hőcserélő felületeken [5], instabil láng kialakulása a tüztérben és a füstgázokkal érintkező szerkezeti elemek korróziója [5][6]. E problémák megoldását számos kutatás célozta, azonban az eredmények ellenére sok megoldandó feladat maradt a tüzelést befolyásoló fizikai és kémiai folyamatok tekintetében. Pontos és részletes információk hiányában kevésbé megbízható matematikai modellek és vizsgálatok készíthetők, ezért az elméleti modellek helyett empirikus, modell-alapú, korszerű felügyeleti és szabályozó rendszerek alkalmazása adhat megoldást a problémákra.

Az online felügyeleti és diagnosztikai rendszerek, amelyek többnyire részei a korszerű tüzelőberendezéseknek, elengedhetetlen eszközei a tüzelési folyamatok optimalizálásának. E rendszerek bemeneti jeleit legtöbb esetben hagyományos mérőműszerekkel mért üzemi paraméterek alkotják. Ezzel szemben a folyamatirányításban széles körben kutatott új, elsősorban információelméleti és mesterséges intelligencia alapú felügyeleti rendszerek alternatív megoldást nyújtanak a technológia hatékonyságának növelésére, a gyakran nagy beruházási költségű és jelentős karbantartást igénylő hagyományos műszerezéssel szemben. Az ilyen indirekt mérő- és monitorozó rendszerek központi eleme az a matematikai modell, ami a mért érték és a számított változók közötti kapcsolatot írja le.

2 Gépi tanulás - mesterséges neurális hálózatok

Manapság a gépi tanulás, mesterséges intelligencia és ezen belül a mesterséges neurális hálózatok (Artificial Neural Networks, ANN) széles körben alkalmazott nemlineáris statisztikai adatmodellező eszközök a tüzeléstechnikában. A tüzeléstechnikára jellemző összetett folyamatokat számos esetben sikeresen és hatékonyan modellezték ANN alkalmazásával [10]. Mesterséges intelligencia alkalmazható optikai, akusztikai vagy más szenzorból származó jel értelmezésére, ami a tüzelési folyamat felügyeletére vagy számszerű jellemzése céljából használható [11]. A gépi tanulási módszerek egyik legígéretesebb alkalmazási területe az erőművek kibocsátásának előrejelzése, amely hozzájárulhat az előírásoknak megfelelő szabályozáshoz. Neurális hálózatokat használtak NO_x kibocsátás előrejelzésére szénttüzelésű [12][13] és gáztüzelésű [14] berendezésekben is. Hasonló algoritmusokat használtak pl. a füstgáz oxigéntartalmának vagy levegő áramlási sebességének becslésére [15], [16]. A légszennyezők kibocsátásának előrejelzése jól ismert nehéz feladat, azonban a nemlineáris folyamatokat közismerten jól leíró ANN alapú modellekkel figyelemreméltó pontosságot értek el [12].

Az utóbbi időben elterjedt az ún. „mély tanulás” (Deep Learning) paradigmán alapuló, mély neurális hálózatokat használó modellezés [17]. Ez a terület az elmúlt években jelentős fejlődésen ment keresztül. Az adatmennyiség folyamatos növekedésével, a nagyteljesítményű, mély neuronhálókat tanítására optimalizált grafikus processzorok elterjedésének és a tudományterület új eredményeinek köszönhetően ma ez az egyik legdinamikusabban fejlődő tudományág. Akintayo és társai például elsők között alkalmazták mély neurális hálózatokat a tüzelés instabilitásának érzékelésére gázturbinákban [18].

A biomassa termokémiai átalakításának folyamata összetett az inhomogén és bizonytalan tüzelőanyag összetétel miatt. A gépi tanulás ígéretes eszköz lehet ezen bonyolult termokémiai folyamatok modellezésére. Eddig több kutatómunka demonstrálta olyan gépi tanulási módszerek hatékony működését, amelyek folyamatos becslést készítenek a biomassa összetételéről és nedvességtartalmáról kisebb méretű berendezések esetén [19], [20]. Hasonló szoftver szenzorokat, amelyek részben a kilépő vízhőmérséklet szabályozását célozták, közepes méretű rendszerekben már tanulmányozták [21]. Liukkonen és társai [22] egy nagyméretű, biomassa tüzelésű, cirkulációs fluidágyas kazánon alkalmaztak szoftver szenzort, ami a tüzelés során kibocsátott NO_x mennyiségét jelezte előre. A tanulmányban megállapították, hogy a nemlineáris ANN modell pontosabb, mint a lineáris modell, továbbá képes előrejelezni az NO_x kibocsátást több órás időtávlatban.

3 Égés vizsgálata optikai módszerekkel

A legtöbb tüzelési folyamatban a tüzelőanyag kémiai átalakulása hőenergiává a lángban megy végbe, ezért az itt megvalósuló folyamatok meghatározók. Emiatt számos felügyeleti módszer közvetlenül a lángból nyerhető információkra összpontosít. Intruzív lángszenzorokat, mint például hőelemeket és ionizációs detektorokat szokás alkalmazni helyi hőmérséklet vagy a füstgázban lévő szervesanyag koncentráció meghatározására. Ezen műszerek költsége ugyan kicsi, azonban csak a vizsgált térfogat kis részéből gyűjtnek információt és legtöbb esetben a folyamat aerodinamikáját is megzavarják. Nem-intruzív módszerek, mint például az optikai szenzorok, nyomásmérő szenzorok és a szilárdtest-alapú gáz szenzorok különböző formái számos esetben kerültek már alkalmazásra.

A legtöbb égést vizsgáló optikai módszer a láng által spontán, azaz külső gerjesztés nélkül kibocsátott, vagy elnyelt fény elemzésén alapul. A láng spontán sugárzása a következő három módon mehet végbe [11]:

- az égésben jelenlévő szilárd részecskék (korom, hamu és karbon szemcsék) ún. fekete test sugárzása;
- nagy hőmérsékleten a lángban jelenlévő gázhalmazállapotú komponensek, főleg a H₂O és a CO₂ sugárzása;
- kemilumineszcencia, vagyis kémiai reakciók útján gerjesztett részecskék (szabad gyökök) egyensúlyi állapotukba kerülésük során kibocsátott sugárzása következtében.

Az egyes jelenségek különböző hullámhossztartományban érzékelhetők. A kemilumineszcencia az ultraibolya és a látható fénytartományban sugároznak, míg nagy hőmérsékleten a feketetestek és a gázok a látható és az infravörös tartományban. E három hatás nagysága és spektruma a láng tulajdonságától függ. Az optikai módszerek feladatuktól függően jellemzően ultraibolya, látható vagy infravörös hullámhossz tartományban működnek. Széles sávú vagy több hullámhossz tartományban működő szenzorok is léteznek. Bár az optikai módszerek nem-intruzívek és nagy frekvencián képesek mintavételezni, általában a láng egy kisebb területére fókuszálnak, pontszerű, vagy optikai úthossz-integrált méréseket végezve.

Bár a gyakorlati alkalmazást célzó munkák a passzív módszerek alkalmazását részesítik előnyben, ugyanakkor érdemes megemlíteni az abszorpciós spektroszkópiában jelenleg a legígéretesebb módszernek számító hangolható diódalézeres abszorpciós mérést (Tunable Diode Laser Absorption Spectroscopy, TDLAS). Az ipari körülmények között is számos esetben jól teljesítő módszer igen gyors válaszidővel közvetlenül képes meghatározni koncentrációt, hőmérsékletet, sebességet és nyomást a tüztérben, ami lehetővé teszi a tüzelés valós idejű felügyeletét és szabályozását, azonban ipari körülmények között működő rendszerekbe való implementálása számos nehézséggel jár [11].

4 Gépi látás - lángképalkotás és feldolgozás

A korszerű digitális eljárások és adatfeldolgozás megjelenésével, a képalkotás és képfeldolgozás jelentős figyelemre tett szert a tüzeléstechnikában a 90-es évek elejétől [23] [24]. Manapság számtalan lézer alapú képalkotási technika adott a tüzeléssel kapcsolatos kísérletek elvégzéséhez [11]. Ezek közül számos módszer, mint például a lézer indukált fluoreszcencia (Laser Induced Fluorescence, LIF) a jövő egy ígéretes ipari szenzora lehet. Elvben ezen diagnosztikai módszerek alkalmasak ipari láng felügyeletére és szabályozására, azonban még gyakorlati okok gátolják rutinszerű ipari körülmények között történő alkalmazásukat. Jelenleg a legígéretesebb technikának a láng látható fénytartományban történő valós idejű optikai képalkotása számít, amely lehetővé teszi az alacsony költségű, robusztus CCD (Charge-Coupled Device) kamera külső fényforrás nélkül alkalmazását. A módszer láng felügyeletre való ipari alkalmazhatóságát számos kutatás demonstrálta [11]. Egy kép, a szenzor színcsatornáihoz tartozó pixel intenzitások rendezett halmaza, vagyis egy adatmátrix, amely pontjai intenzitásuktól függő radiometriai, színüktől függő spektrális és helyüktől függő áramlástani információkat hordoznak [25]. Ezáltal a képek térbeli és időbeli információárama meghaladja a pontszenzorok jelét.

Számtalan tanulmány demonstrálta a tüzeléstechnikában használt látásalapú felügyeleti rendszerek alkalmazhatóságát. Több kutatómunka megállapította, hogy a láng megfigyelt geometriai és

fényintenzitással összefüggő paramétereit információt hordoznak a tüzelési folyamat hatékonyságáról és minőségéről [23][26][27][28][29][30][31][32]. Számos korábbi tanulmány igazolta, hogy a tüzelési folyamat osztályozható [24][33], számszerűsíthető [34][35], előre jelezhető vagy akár irányítható [36][37] on-line képalkotó és gépi tanulást alkalmazó rendszerekkel. A kalibrált színes képek alkalmasak a helyi lánghőmérséklet és koromképződés mértékének meghatározására is [38][39][40]. A mért paraméterek időbeli és térbeli változása lehetőséget biztosít a tüzelési folyamat dinamikájába való betekintésre [41] [42]. Az infra- és a látható hullámhossztartományú képalkotás potenciálja erőművek és hulladékégetők optimalizálásában jól ismert [43][44].

5 Gépi látás és tanulás együttes alkalmazása

Eddig számos tanulmány igazolta a képalkotás és a mesterséges neurális hálózatok együttes alkalmazásának sikerességét különböző levegőszennyezők előrejelzésében ipari és félipari körülmények között [23][45][46][47]. Ezen eredmények arra engednek következtetni, hogy a mesterséges neurális hálózatoknak és a képalkotásnak nagy potenciálja van összetett, nemlineáris előrejelzési problémák megoldásában. Lu és társai két rejtett rétegű ANN alkalmazásával nagy pontosságot értek el bután/levegő lángok képeinek légfelületnyező alapján történő osztályozása során laboratóriumi körülmények között. Ugyanezen kutatócsoport laboratóriumi körülmények között demonstrálta egyetlen rejtett réteget tartalmazó ANN és multispektrális kemilumineszcenciás képalkotás alkalmazásával levegő-tüzelőanyag arány és a NO_x kibocsátás becslését gázlángok képei alapján [48][49].

A szakirodalomban számos tanulmány található, amely biomassza tüzelést vizsgál online képfeldolgozáson keresztül. Néhányuk kizárólag a lángképek számszerű jellemzésével, valamint az így kapott, és a hagyományos eljárásokkal mért üzemi paraméterek közötti kapcsolatok vizsgálatával foglalkozik [41][50][51], míg mások fejlett adatfeldolgozást és gépi tanulási módszereket is alkalmaztak, azonban vizsgálataik többnyire laboratóriumi körülmények között történtek [52][53]. Li és társai [49] levegőszennyezők kibocsátásának előrejelzését valósították meg biomassza lángból laboratóriumi körülmények között, sekély radiális bázisfüggvényes ANN alkalmazásával, eredményeik 7 és 20% közötti hibát mutattak. Ez a kutatócsoport megállapította, hogy Support Vector Machine alkalmazása nagyobb hibát eredményez az ANN-nel szemben, továbbá mély ANN és automatikus adatredukció alkalmazása jelentősen tovább csökkenti a regresszió hibáját, 2-3%-ra [54]. Kotyra és társai [55] képfeldolgozást alkalmaztak a geometriai és radiometrikus képi jellemzők kinyerésére a rögzített képekből, és k-NN regressziót a kazán hőteljesítményének és légfelületének előrejelzésére szén és biomassza együtt-tüzelése során. Arra a következtetésre jutottak, hogy az alkalmazott módszer nem ad elfogadható előrejelzést a légfelületről.

6 Konklúzió

Az utóbbi időben a változó összetételű, heterogén tüzelőanyagok vagy tüzelőanyagkeverékek, mint például a biomassza energetikai célú felhasználása – globális trenddé vált. Ezen tüzelőanyagok hasznosítása az ipari méretű tüzeléstechnikában számos nehézséggel jár. Pontos és részletes információk hiányában kevésbé megbízható matematikai modellek és vizsgálatok készíthetők, ezért az elméleti modellek helyett empirikus, modell-alapú, korszerű felügyeleti és szabályozó rendszerek alkalmazása adhat megoldást a problémákra. A szakirodalomkutatás alapján megállapítható, hogy a tüzeléstechnikára jellemző összetett folyamatokat számos esetben sikeresen és hatékonyan modellezték nemlineáris statisztikai adatmodellező eszközök, mint a gépi tanulás, és ezen belül a mesterséges neurális hálózatok alkalmazásával. Emellett számos példát láthattunk a tüzeléstechnikában használt látásalapú felügyeleti rendszerek alkalmazására. Míg a képző és a mesterséges neurális hálózatok együttes alkalmazásának sikerességét szintén nagy számú publikáció igazolta különböző levegőszennyezők előrejelzésében ipari és félipari körülmények között. Összeségében megállapítható, hogy a gépi tanulásnak és a gépi látásnak külön-külön és együttes alkalmazása is nagy jelentőséggel bír összetett és nemlineáris tüzeléstechnikai vonatkozású előrejelzési problémák megoldásában.

7 Köszönetnyilvánítás

A tématerületi kutatás a Miskolci Egyetem „Társadalmi hasznosság növelő fejlesztések a hazai felszín alatti természeti erőforrások hatékonyabb kiaknázása és hasznosítása területén” című, az Innovációs és Technológia Minisztérium Nemzeti Kutatási, Fejlesztési és Innovációs Alapból nyújtott támogatásával, a Nemzeti Kutatási, Fejlesztési és Innovációs Hivatal által kibocsátott támogatási okirat (Támogatási Okirat ikt. száma: TKP-17-1/PALY-2020) alapján zajló projektje részeként valósult meg.

8 Irodalomjegyzék

- [1] P. Glarborg, A. D. Jensen, and J. E. Johnsson, “Fuel nitrogen conversion in solid fuel fired systems,” *Progress in Energy and Combustion Science*, vol. 29, no. 2. Elsevier Ltd, pp. 89–113, 2003.
- [2] S. C. Hill and L. D. Smoot, “Modeling of nitrogen oxides formation and destruction in combustion systems,” *Progress in Energy and Combustion Science*. 2000.
- [3] J. Pagels et al., “Characteristics of aerosol particles formed during grate combustion of moist forest residue,” *J. Aerosol Sci.*, 2003.
- [4] M. Jöller, T. Brunner, and I. Obernberger, “Modeling of aerosol formation during biomass combustion in grate furnaces and comparison with measurements,” *Energy & fuels*, vol. 19, no. 1, pp. 311–323, 2005.
- [5] H. P. Michelsen, F. Frandsen, K. Dam-Johansen, and O. H. Larsen, “Deposition and high temperature corrosion in a 10 MW straw fired boiler,” *Fuel Process. Technol.*, vol. 54, no. 1–3, pp. 95–108, 1998.
- [6] J. Vos, “Biomass energy for heating and hot water supply in Belarus,” *Contract Rep. (BYE/03/G31)*, BTG, 2006.

- [7] G. D. Gonzalez, J. P. Redard, R. Barrera, and M. Fernandez, "Issues in soft-sensor applications in industrial plants," in *Industrial Electronics, 1994. Symposium Proceedings, ISIE'94., 1994 IEEE International Symposium on, 1994*, pp. 380–385.
- [8] G. D. Gonzalez, "Soft sensors for processing plants," in *Intelligent Processing and Manufacturing of Materials, 1999. IPMM'99. Proceedings of the Second International Conference on, 1999*, vol. 1, pp. 59–69.
- [9] P. Kadlec, B. Gabrys, and S. Strandt, "Data-driven soft sensors in the process industry," *Comput. Chem. Eng.*, vol. 33, no. 4, pp. 795–814, 2009.
- [10] S. A. Kalogirou, "Applications of artificial neural-networks for energy systems," *Appl. Energy*, vol. 67, no. 1–2, pp. 17–35, 2000.
- [11] J. Ballester and T. García-Armingol, "Diagnostic techniques for the monitoring and control of practical flames," *Progress in Energy and Combustion Science*, vol. 36, no. 4. Elsevier Ltd, pp. 375–411, 01-Aug-2010.
- [12] J. Smrekar, P. Potočnik, and A. Senegačnik, "Multi-step-ahead prediction of NO_x emissions for a coal-based boiler," *Appl. Energy*, vol. 106, pp. 89–99, 2013.
- [13] I. Bukovsky and M. Kolovratnik, "A Neural Network Model for Predicting NO_x at the Melnik 1 Coal-powder Power Plant," *Acta Polytech.*, vol. 52, no. 3, pp. 17–22, 2012.
- [14] S. A. Iliyas, M. Elshafei, M. A. Habib, and A. A. Adeniran, "RBF neural network inferential sensor for process emission monitoring," *Control Eng. Pract.*, vol. 21, no. 7, pp. 962–970, 2013.
- [15] Z. Zhou et al., "A comparison study of basic data-driven fault diagnosis methods for variable refrigerant flow system," Elsevier.
- [16] A. Sanz, J. Ballester, R. Hernandez, and L. M. Cerecedo, "Advanced monitoring of industrial burners based on fluctuating flame signals," *Fuel*, vol. 87, no. 7, pp. 1063–1075, 2008.
- [17] I. Goodfellow, Y. Bengio, and A. Courville, "Deep learning," 2015, 2016.
- [18] A. Akintayo, K. G. Lore, S. Sarkar, and S. Sarkar, "Prognostics of combustion instabilities from hi-speed flame video using a deep convolutional selective autoencoder," *Int. J. Progn. Heal. Monit.*, 2016.
- [19] S. Vrana and B. Sulc, "Neural network inference of biomass fuel moisture during combustion process evaluating of directly unmeasurable variables," in *Control Conference (ICCC), 2014 15th International Carpathian, 2014*, pp. 671–674.
- [20] S. Vrána, V. Plaček, C. Oswald, B. Šulc, and P. Neuman, "Neural Network Evaluation of Combustion Process for Continuous Control of Small Scale Biomass Fired Boilers," *IFAC Proc. Vol.*, vol. 47, no. 3, pp. 1440–1445, 2014.
- [21] M. Tóthová and J. Dubják, "Using computational intelligence in biomass combustion control in medium-scale boilers," in *Applied Machine Intelligence and Informatics (SAMI), 2016 IEEE 14th International Symposium on, 2016*, pp. 81–85.
- [22] M. Liukkonen, E. Hälikkää, T. Hiltunen, and Y. Hiltunen, "Dynamic soft sensors for NO_x emissions in a circulating fluidized bed boiler," *Appl. Energy*, vol. 97, pp. 483–490, 2012.

- [23] N. Kurihara et al., "A combustion diagnosis method for pulverized coal boilers using flame-image recognition technology," *IEEE Trans. Energy Convers.*, no. 2, pp. 99–103, 1986.
- [24] M. G. Allen, C. T. Butler, S. A. Johnson, E. Y. Lo, and F. Russo, "An imaging neural network combustion control system for utility boiler applications," *Combust. Flame*, vol. 94, no. 1–2, pp. 205–214, 1993.
- [25] A. González-Cencerrado, B. Peña, and A. Gil, "Coal flame characterization by means of digital image processing in a semi-industrial scale PF swirl burner," *Appl. Energy*, vol. 94, pp. 375–384, 2012.
- [26] G. Lu, G. Gilibert, and Y. Yan, "Vision based monitoring and characterisation of combustion flames," in *Journal of Physics: Conference Series*, 2005, vol. 15, no. 1, p. 194.
- [27] Y. Yan, G. Lu, and M. Colechin, "Monitoring and characterisation of pulverised coal flames using digital imaging techniques," *Fuel*, vol. 81, no. 5, pp. 647–655, 2002.
- [28] G. Lu, Y. Yan, Y. Huang, and A. Reed, "An intelligent vision system for monitoring and control of combustion flames," *Meas. Control*, vol. 32, no. 6, pp. 164–168, 1999.
- [29] W. B. Baek, S. J. Lee, S. Y. Baeg, and C. H. Cho, "Flame image processing and analysis for optimal coal firing of thermal power plant," in *Industrial Electronics, 2001. Proceedings. ISIE 2001. IEEE International Symposium on*, 2001, vol. 2, pp. 928–931.
- [30] H. Yu and J. F. MacGregor, "Monitoring flames in an industrial boiler using multivariate image analysis," *AIChE J.*, vol. 50, no. 7, pp. 1474–1483, 2004.
- [31] M. Chimenti, C. Di Natali, G. Mariotti, E. Paganini, G. Pieri, and O. Salvetti, "An IR image processing approach for characterising combustion instability," *Infrared Phys. Technol.*, vol. 46, no. 1, pp. 41–47, 2004.
- [32] J. S. Marques and P. M. Jorge, "Visual inspection of a combustion process in a thermoelectric plant," *Signal Processing*, vol. 80, no. 8, pp. 1577–1589, 2000.
- [33] R. P. Silva, A. T. Fleury, F. P. R. Martins, W. J. A. Ponge-Ferreira, and F. C. Trigo, "Identification of the state-space dynamics of oil flames through computer vision and modal techniques," *Expert Syst. Appl.*, vol. 42, no. 5, pp. 2421–2428, 2015.
- [34] L. Bertuccio, A. Fichera, G. Nunnari, and A. Pagano, "A cellular neural networks approach to flame image analysis for combustion monitoring," in *Cellular Neural Networks and Their Applications, 2000.(CNNA 2000). Proceedings of the 2000 IEEE International Workshop on*, 2000, pp. 455–459.
- [35] H. Zhou, Q. Tang, L. Yang, Y. Yan, G. Lu, and K. Cen, "Support vector machine based online coal identification through advanced flame monitoring," *Fuel*, vol. 117, pp. 944–951, 2014.
- [36] J. Chen, Y.-H. Chang, and Y.-C. Cheng, "Performance Design of Image-Oxygen Based Cascade Control Loops for Boiler Combustion Processes," *Ind. Eng. Chem. Res.*, vol. 52, no. 6, pp. 2368–2378, 2013.
- [37] J. Chen, Y.-H. Chang, Y.-C. Cheng, and C.-K. Hsu, "Design of image-based control loops for industrial combustion processes," *Appl. Energy*, vol. 94, pp. 13–21, 2012.

- [38] F. Schuler, F. Rampp, J. Martin, and J. Wolfrum, "TACCOS—A thermography-assisted combustion control system for waste incinerators," *Combust. Flame*, vol. 99, no. 2, pp. 431–439, 1994.
- [39] D. Manca and M. Rovaglio, "Infrared thermographic image processing for the operation and control of heterogeneous combustion chambers," *Combust. Flame*, vol. 130, no. 4, pp. 277–297, 2002.
- [40] T. S. Draper, D. Zeltner, D. R. Tree, Y. Xue, and R. Tsiava, "Two-dimensional flame temperature and emissivity measurements of pulverized oxy-coal flames," *Appl. Energy*, vol. 95, pp. 38–44, 2012.
- [41] G. Lu, Y. Yan, S. Cornwell, M. Whitehouse, and G. Riley, "Impact of co-firing coal and biomass on flame characteristics and stability," *Fuel*, vol. 87, no. 7, pp. 1133–1140, 2008.
- [42] L. Xu and Y. Yan, "An improved algorithm for the measurement of flame oscillation frequency," *IEEE Trans. Instrum. Meas.*, vol. 56, no. 5, pp. 2087–2093, 2007.
- [43] P. Daimer, W. Schaefer, H.-U. Hartenstein, and A. Licata, "Using infrared cameras, fuzzy logic and acoustic temperature measurement to improve combustion in MWCs," in *Proc. of the Asian-North American Solid Waste Management Conference, ANACON*, 1998, pp. 184–195.
- [44] S. Zipser, A. Gommlich, J. Matthes, and H. B. Keller, "Combustion plant monitoring and control using infrared and video cameras," *IFAC Proc. Vol.*, vol. 39, no. 7, pp. 249–254, 2006.
- [45] F. Wang et al., "The research on the estimation for the $\{\text{NO}_x\}$ emissive concentration of the pulverized coal boiler by the flame image processing technique," *Fuel*, vol. 81, no. 16, pp. 2113–2120, 2002.
- [46] B. Lin and S. B. Jørgensen, "Soft sensor design by multivariate fusion of image features and process measurements," *J. Process Control*, vol. 21, no. 4, pp. 547–553, 2011.
- [47] R. Hernandez and J. Ballester, "Flame imaging as a diagnostic tool for industrial combustion," *Combust. Flame*, vol. 155, no. 3, pp. 509–528, 2008.
- [48] J. Krabicka, G. Lu, and Y. Yan, "Profiling and characterization of flame radicals by combining spectroscopic imaging and neural network techniques," *IEEE Trans. Instrum. Meas.*, vol. 60, no. 5, pp. 1854–1860, 2011.
- [49] X. Li, D. Sun, G. Lu, J. Krabicka, and Y. Yan, "Prediction of $\{\text{NO}_x\}$ emissions through flame radical imaging and neural network based soft computing," in *2012 IEEE International Conference on Imaging Systems and Techniques Proceedings*, 2012, pp. 502–505.
- [50] P. Molcan, G. Lu, T. Le Bris, Y. Yan, B. Taupin, and S. Caillat, "Characterisation of biomass and coal co-firing on a {3 MWth} combustion test facility using flame imaging and gas/ash sampling techniques," *Fuel*, vol. 88, no. 12, pp. 2328–2334, 2009.
- [51] A. González-Cencerrado, B. Peña, and A. Gil, "Experimental analysis of biomass co-firing flames in a pulverized fuel swirl burner using a {CCD} based visualization system," *Fuel Process. Technol.*, vol. 130, pp. 299–310, 2015.
- [52] N. Li, G. Lu, X. Li, and Y. Yan, "Prediction of pollutant emissions of biomass flames using digital imaging, contourlet transform and radial basis function network techniques," in *2014 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings*, 2014, pp. 697–700.

- [53] N. Li, G. Lu, X. Li, and Y. Yan, "Prediction of pollutant emissions of biomass flames through digital imaging, contourlet transform, and support vector regression modeling," *IEEE Trans. Instrum. Meas.*, vol. 64, no. 9, pp. 2409–2416, 2015.
- [54] N. Li, G. Lu, X. Li, and Y. Yan, "Prediction of NO_x emissions from a biomass fired combustion process based on flame radical imaging and deep learning techniques," *Combust. Sci. Technol.*, vol. 188, no. 2, pp. 233–246, 2016.
- [55] A. Kotyra, W. Wójcik, A. Iskakova, and S. Zhussupbektov, "Identification of biomass co-combustion operating point using image processing," in *13th International Scientific Conference on Optical Sensors and Electronic Sensors*, 2014, p. 929108.