

Michał Lewak^{a)}, Jarosław Tępiński^{b)*}

^{a)} Faculty of Chemical and Process Engineering, Warsaw University of Technology / Wydział Inżynierii Chemicznej i Procesowej, Politechnika Warszawska

^{b)} Scientific and Research Centre for Fire Protection – National Research Institute / Centrum Naukowo-Badawcze Ochrony Przeciwpozarowej im. Józefa Tuliszkowskiego – Państwowy Instytut Badawczy

* Corresponding author / Autor korespondencyjny: jtepinski@cnbop.pl

Application of Artificial Neural Networks for Mathematical Modelling of Horizontal Jet Fires

Wykorzystanie sztucznych sieci neuronowych do modelowania matematycznego poziomych pożarów strumieniowych

ABSTRACT

Aim: This article focuses on the use of artificial neural networks to mathematically describe the parameters that determine the size of a jet fire flame. To teach the neural network, the results of a horizontal propane jet fire, carried out experimentally and using CFD mathematical modelling, were used.

Project and methods: The main part of the work consisted of developing an artificial neural network to describe the flame length and propane-air mixing path lengths with good accuracy, depending on the relevant process parameters. Two types of data series were used to meet the stated objective. The first series of data came from field tests carried out by CNBOP-PIB and from research contained in scientific articles. The second type of data was provided by numerical calculations made by the authors. The methods of computational fluid mechanics were used to develop the numerical simulations. The ANSYS Fluent package was used for this purpose. Matlab 2022a was used to develop the artificial neural network and to verify it.

Results: Using the D_{fuel} function included in Matlab 2022a, an artificial neural network was developed to determine the flame length L_{flame} and the length of the $S_{lift-off}$ mixing path as a function of the diameter of the d_{nozzle} and the mass flux of gas leaving the nozzle. Using Pearson's correlation coefficient, a selection was made of the best number of neurons in the hidden layer to describe the process parameters. The neural network developed allows L_{flame} and $S_{lift-off}$ values to be calculated with good accuracy.

Conclusions: Artificial neural networks allow a function to be developed to describe the parameters that determine flame sizes in relation to process parameters. For this purpose, the results of the CFD simulations and the results of the jet fire experiments were combined to create a single neural network. The result is a ready-made function that can be used in programmes for the rapid determination of flame sizes. Such a function can support the process of creating scenarios in the event of an emergency. A correctly developed neural network provides opportunities for the mathematical description of jet fires wherever experimental measurements are not possible. Solution proposed by the authors does not require a large investment in ongoing calculations, as the network can be implemented in any programming language.

Keywords: computational fluid mechanics, artificial neural networks, jet fire

Type of article: original scientific article

Received: 31.10.2023; Reviewed: 04.12.2023; Accepted: 04.12.2023;

Authors' ORCID IDs: M. Lewak – 0000-0001-9012-8347; J. Tępiński – 0000-0002-5005-2795;

The authors contributed the equally to this article;

Please cite as: SFT Vol. 62 Issue 2, 2023, pp. 34–48, <https://doi.org/10.12845/sft.62.2.2023.2>;

This is an open access article under the CC BY-SA 4.0 license (<https://creativecommons.org/licenses/by-sa/4.0/>).

ABSTRAKT

Cel: W artykule skupiono się na wykorzystaniu sztucznych sieci neuronowych do opisu matematycznego parametrów określających rozmiary płomienia pożaru strumieniowego. Do uczenia sieci neuronowej wykorzystano wyniki badań poziomego pożaru strumieniowego propanu, przeprowadzone doświadczalnie i przy pomocy modelowania matematycznego metodą CFD.

Projekt i metody: Główna część pracy polegała na opracowaniu sztucznej sieci neuronowej, która z dobrą dokładnością będzie opisywała długość płomienia oraz długości drogi mieszania propanu z powietrzem w zależności od istotnych parametrów procesowych. Do realizacji postawionego celu wykorzystano dwa typy serii danych. Pierwsza seria danych pochodziła z badań poligonowych wykonanych przez CNBOP-PIB oraz z badań zawartych w artykułach naukowych. Drugi typ danych dostarczyły obliczenia numeryczne wykonane przez autorów. Do opracowania symulacji numerycznych wy-

korzystano metody obliczeniowej mechaniki płynów. W tym celu zastosowany został pakiet ANSYS Fluent. Do opracowania sztucznej sieci neuronowej oraz jej weryfikacji użyto programu Matlab 2022a.

Wyniki: Korzystając z funkcji n_{flame} , zawartej w programie Matlab 2022a, opracowano sztuczną sieć neuronową do wyznaczenia długości płomienia L_{flame} i długości drogi mieszania $S_{lift-off}$ w zależności od średnicy dyszy d_{nozzle} i strumienia masowego gazu opuszczającego dyszę. Do opisu parametrów procesowych wybrano najbardziej adekwatną liczbę neuronów w warstwie ukrytej. Wykorzystano do tego współczynnik korelacji Pearsona. Opracowana sieć neuronowa pozwala z dobrą dokładnością obliczyć wartości L_{flame} i $S_{lift-off}$.

Wnioski: Sztuczne sieci neuronowe pozwalają na opracowanie funkcji opisującej rozmiar płomienia w zależności od parametrów procesowych. W celu stworzenia jednej sieci neuronowej połączono wyniki symulacji CFD i wyniki doświadczeń pożarów strumieniowych. W rezultacie otrzymano gotową funkcję, która może być użyta w programach służących do szybkiego określania rozmiarów płomienia. Funkcja taka może wspomagać proces tworzenia scenariuszy na wypadek wystąpienia sytuacji awaryjnej. Poprawnie opracowana sieć neuronowa pozwala opisać w sposób matematyczny pożary strumieniowe wszędzie tam, gdzie wykonanie pomiarów doświadczalnych nie jest możliwe. Proponowane rozwiązanie nie wymaga dużych nakładów finansowych na prowadzone obliczenia, ponieważ sieć może być zaimplementowana w dowolnym języku programowania.

Słowa kluczowe: obliczeniowa mechanika płynów, sztuczne sieci neuronowe, pożar strumieniowym

Typ artykułu: oryginalny artykuł naukowy

Przyjęty: 31.10.2023; **Zrecenzowany:** 04.12.2023; **Zaakceptowany:** 04.12.2023;

Identyfikatory ORCID autorów: M. Lewak – 0000-0001-9012-8347; J. Tępiński – 0000-0002-5005-2795;

Autorzy wnieśli równy wkład merytoryczny w powstanie artykułu;

Proszę cytować: SFT Vol. 62 Issue 2, 2023, pp. 34–48, <https://doi.org/10.12845/sft.62.2.2023.2>;

Artykuł udostępniany na licencji CC BY-SA 4.0 (<https://creativecommons.org/licenses/by-sa/4.0/>).

Introduction

A jet fire is usually a sudden and very dangerous phenomenon. The extent of the flame has a significant impact on the safety of both living beings and material assets. Consequently, the scientific interest in this topic is mainly focused on determining the size of the flame as a function of process parameters such as m_{in} gas mass flux and d_{nozzle} diameter, among others. An analysis of articles on the problem of mathematical modelling of jet fires shows that the use of artificial neural networks for this purpose is definitely a new approach. For this reason, there are few scientific articles dealing with the link between neural networks and the modelling of jet fires. In one of these few, an artificial neural network was developed using data from experimental measurements [3]. Therefore, this study proposes to use this type of network to describe the flame size in a horizontal jet fire using data from two separate methods, i.e. polygon tests and CFD methods. In the authors' opinion, this is a certain deepening of the topic in this area. Experimental testing on a laboratory or engineering scale is generally used to determine the flame size of jet fires [1], less commonly mathematical modelling using numerical methods, most commonly computational fluid mechanics CFD [2]. Each of the methods mentioned above for determining flame size has its advantages and disadvantages. Experimental methods, carried out even on a small scale, generate high costs because they require the use of expensive control and measurement equipment. In order to maintain a sufficiently high level of safety, large-scale jet fire investigations should be carried out on training grounds, which requires both a great deal of money and work (scientific, technical and organisational). Moreover, the measurement of large jet fires is burdened by problems with the accuracy of determining the length and width of the flame. Methods based on CFD techniques do not present this disadvantage.

Wprowadzenie

Pożar strumieniowy jest zazwyczaj zjawiskiem nagłym i bardzo niebezpiecznym. Istotny wpływ na bezpieczeństwo – zarówno istot żywych, jak i dóbr materialnych – mają jego rozmiary. W związku z tym zainteresowanie nauki tym tematem skupia się głównie na określeniu wielkości płomienia w zależności od parametrów procesowych, m.in. takich jak strumień masowy gazu m_{in} i średnica dyszy d_{nozzle} . Z analizy artykułów dotyczących problemu modelowania matematycznego pożarów strumieniowych wynika, że wykorzystanie do tego celu sztucznych sieci neuronowych jest zdecydowanie nowym podejściem. Z tego powodu artykułów naukowych zajmujących się powiązaniem sieci neuronowych z modelowaniem pożarów strumieniowych jest niewiele. W jednym z tych nielicznych opracowano sztuczną sieć neuronową, wykorzystując dane pochodzące z pomiarów doświadczalnych [3]. W związku z tym w niniejszej pracy zaproponowano wykorzystanie tego typu sieci do opisu rozmiarów płomienia w poziomym pożarze strumieniowym z użyciem danych pochodzących z dwóch odrębnych metod, tj. badań poligonowych i metod CFD. Jest to – w ocenie autorów – pewne pogłębienie tematu w tym zakresie. Do określenia rozmiarów płomienia pożarów strumieniowych stosuje się z reguły badania doświadczalne w skali laboratoryjnej lub technicznej [1], rzadziej modelowanie matematyczne z wykorzystaniem metod numerycznych, najczęściej obliczeniowej mechaniki płynów CFD [2]. Każda z wyżej wymienionych metod określenia rozmiarów płomienia ma swoje zalety i wady. Metody doświadczalne, realizowane nawet w małej skali, generują duże koszty, ponieważ wymagają wykorzystania kosztownej aparatury kontrolno-pomiarowej. Dla zachowania odpowiednio wysokiego poziomu bezpieczeństwa badania pożarów strumieniowych w dużej skali powinny być przeprowadzane na poligonach, co wymaga zarówno dużych nakładów finansowych, jak i pracy (naukowej, technicznej i organizacyjnej).

Numerical methods also require a considerable amount of money, associated with the purchase of suitably powerful computing servers and CFD simulation software. CFD methods use mathematical models that are based on simplifications related to the description of the combustion process in turbulent flow, which affects the accuracy of their results. The CFD mathematical modelling of large jet fires (where the flame length exceeds several metres) requires a suitably dense numerical grid. Calculations carried out on such grids can take from a few days to even a few weeks – depending on the performance of the computing server used. Experimental methods are most often used to verify the results of CFD calculations or to create correlations, using dimensionless numbers, to determine the flame length of a jet fire. It is virtually impossible to use CFD methods in tools for determining flame sizes included in risk analysis programmes. In this type of programmes, it is only possible to use experimental correlations to estimate flame sizes. Researchers on jet fires mostly use simple literature correlations. However, artificial neural networks [3] ANN (Artificial Neural Network) can provide valuable support for mathematical modelling of fire. These networks can be used to determine flame sizes based on process parameters. The advantage of an artificial neural network is its analytical nature, i.e. the output parameters are represented by a specific function of the input variables.

In this study, an artificial feed-forward neural network (FNN) with one hidden layer was used. A sigmoidal activation function was used for the neurons in the hidden layer. This has resulted in the development of an artificial neural network that allows the calculation of flame size based on relevant process data, such as the mass flux of m_{in} gas leaving a d_{nozzle} . Neural networks can therefore be used in risk assessment programmes, as they do not place a significant burden on the computer during calculations. They offer the possibility of obtaining results quickly without the need for tedious and lengthy CFD simulations. However, a series of numerically expensive CFD calculations or several experimental measurements are required to develop them. This makes it possible to develop a function to calculate the relevant parameters of a jet fire without the need for more CFD simulations or additional field experiments.

Methodology for creating an artificial neural network

Artificial neural networks are used to convert input signals into output signals, acting as a so-called black box in the computational process. This means that the phenomena they describe

Ponadto pomiar dużych pożarów strumieniowych obarczony jest problemem z dokładnością określenia długości i szerokości płomienia. Wadą tą nie są obciążone metody oparte na technikach CFD. Metody numeryczne wymagają również znacznych nakładów finansowych, związanych z zakupem odpowiednio wydajnych serwerów obliczeniowych i programów do symulacji CFD. Metody CFD wykorzystują modele matematyczne, które bazują na uproszczeniach związanych z opisem procesu spalania w przepływie burzliwym, co wpływa na dokładność uzyskiwanych przez nie wyników. Modelowanie matematyczne CFD dużych pożarów strumieniowych (których długość płomienia przekracza kilka metrów) wymaga odpowiednio gęstej siatki numerycznej. Obliczenia prowadzone na takich siatkach mogą trwać od kilku dni do nawet kilku tygodni – w zależności od wydajności wykorzystywanego serwera obliczeniowego. Metody doświadczalne najczęściej służą do weryfikacji wyników obliczeń CFD lub do tworzenia korelacji wykorzystujących do określenia długości płomienia pożaru strumieniowego liczby bezwymiarowe. Stosowanie metod CFD w narzędziach służących do wyznaczania rozmiarów płomienia, wchodzących w skład programów służących do analizy ryzyka, jest praktycznie niemożliwe. W tego typu programach możliwe jest tylko wykorzystanie korelacji doświadczalnych, które pozwalają na oszacowanie rozmiarów płomienia. Naukowcy zajmujący się tematyką pożarów strumieniowych używają najczęściej prostych korelacji literaturowych. Natomiast sztuczne sieci neuronowe [3] ANN mogą stanowić cenne wsparcie w modelowaniu matematycznym pożaru. Sieci te mogą posłużyć do wyznaczenia rozmiarów płomienia na podstawie parametrów procesowych. Zaletą sztucznej sieci neuronowej jest jej analityczny charakter, tj. parametry wyjściowe są reprezentowane przez określoną funkcję zmiennych wejściowych.

W niniejszej pracy wykorzystano sztuczną sieć neuronową typu jednowarstwowa sieć neuronowa z wyprzedzeniem FNN z jedną warstwą ukrytą. W neuronach w warstwie ukrytej użyto sigmoidalnej funkcji aktywacji. Dzięki temu opracowana została sztuczna sieć neuronowa pozwalająca na obliczenie rozmiarów płomienia na podstawie istotnych danych procesowych, takich jak strumień masowy gazu m_{in} opuszczający dyszę o średnicy d_{nozzle} . Sieci neuronowe mogą być zatem zastosowane w programach do oceny ryzyka, ponieważ nie obciążają znacząco komputera podczas obliczeń. Dają możliwość szybkiego uzyskania wyników bez konieczności żmudnych i długotrwałych symulacji CFD. Jednakże do ich opracowania wymagane jest wykonanie serii kosztownych numerycznie obliczeń CFD lub przeprowadzenie kilku pomiarów doświadczalnych. Dzięki temu możliwe jest stworzenie funkcji pozwalającej obliczać istotne parametry pożaru strumieniowego bez konieczności wykonywania większej liczby symulacji CFD czy dodatkowych doświadczeń poligonowych.

Metodyka tworzenia sztucznej sieci neuronowej

Sztuczne sieci neuronowe służą do przetwarzania sygnałów wejściowych na sygnały wyjściowe, pełnią rolę tzw. czarnej skrzynki w procesie obliczeniowym. Oznacza to, że zjawiska

are in no way represented through mathematical forms of notation of laws. The artificial neural network model is a function of the process parameters, represented by the input neurons and the number of neurons in the hidden layer. Output neurons are used to transfer the results of the artificial neural network to the sought parameters describing the jet fire. Figure 1 shows a schematic of the neural network that was developed to determine the flame length L_{flame} and the length of the gas-air mixing path $S_{lift-off}$ of a horizontal propane jet fire. As the value of the $S_{lift-off}$ parameter did not exceed 1 metre and the value of the L_{flame} parameter did not exceed 10 metres, it was not decided to normalise the input data. The detailed data distribution can be found in Figures 9 and 10.

przez nie opisywane nie są w żaden sposób reprezentowane poprzez matematyczne formy zapisu praw. Model sztucznej sieci neuronowej jest funkcją parametrów procesowych, reprezentowanych przez neurony wejściowe oraz liczbę neuronów w warstwie ukrytej. Neurony wyjściowe służą do przekazywania wyników działania sztucznej sieci neuronowej do poszukiwanych parametrów opisujących pożar strumieniowy. Na rycinie 1 przedstawiono schemat sieci neuronowej, która została opracowana do wyznaczania długości płomienia L_{flame} i długości drogi mieszania gazu z powietrzem $S_{lift-off}$ poziomego pożaru strumieniowego propanu. Z uwagi na fakt, że wartość parametru $S_{lift-off}$ nie przekraczała 1 metra, a wartość parametru L_{flame} – 10 metrów, nie zdecydowano się na normalizację danych wejściowych. Szczegółowy rozkład danych można znaleźć na rycinach 9 i 10.

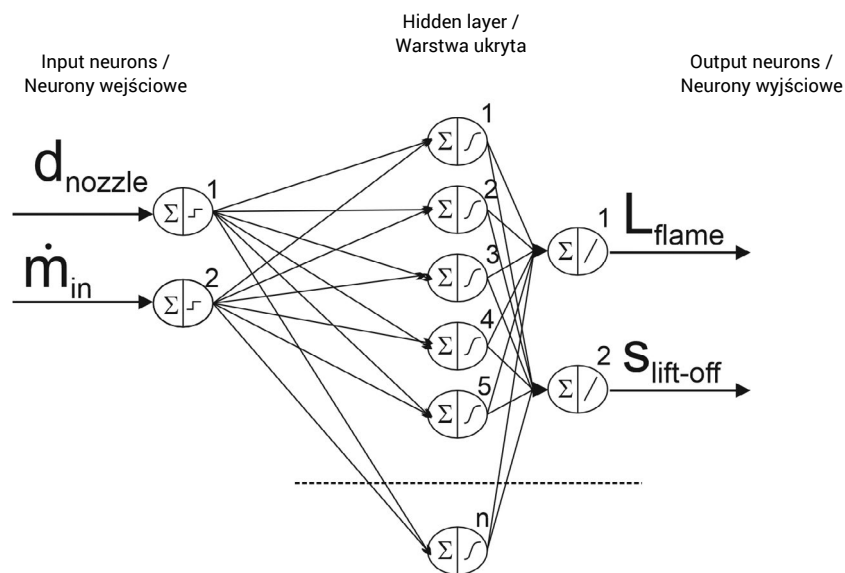


Figure 1. Diagram of the artificial neural network with the input neurons d_{nozzle} , \dot{m}_{in} and the output neurons L_{flame} and $S_{lift-off}$
Rycina 1. Schemat sztucznej sieci neuronowej z naniesionymi neuronami wejściowymi d_{nozzle} , \dot{m}_{in} i neuronami wyjściowymi L_{flame} i $S_{lift-off}$

Source: Own elaboration.
 Źródło: Opracowanie własne.

Each neuron of the artificial neural network contains weights and its activation function. The process of selecting the weights that allow a mathematical description of the neurons is called neural network learning and is most commonly implemented by the local minimum search algorithm developed by Levenberg and Marguardt [4–5]. During the process of finding the weights of a neural network, the initial values of the weights describing the neurons in question must be selected in an appropriate way, for which pseudo-random number determination algorithms are used. This approach yields better results in terms of convergence of the minimum search process and thus better matching [6]. An important issue in the creation of a neural network is to determine the appropriate number of neurons in the hidden layer, for the sake of the best approximation of the experimental data in the neural network learning process. By doing this, it is possible to create a neural network that gives a good approximation of the values used in the learning process. This gives confidence that

Każdy z neuronów sztucznej sieci neuronowej zawiera wagi oraz funkcję jego aktywacji. Proces dobierania wag, pozwalających na opis matematyczny neuronów, nazywa się uczeniem sieci neuronowej i jest najczęściej realizowany przez algorytm poszukiwania minimum lokalnego, opracowany przez Levenberga i Marguardta [4–5]. Podczas procesu poszukiwania wag sieci neuronowej należy w odpowiedni sposób dobrać wartości początkowe wag opisujące dane neurony, do czego wykorzystuje się algorytmy służące do wyznaczania liczb pseudolosowych. Takie podejście daje lepsze wyniki pod względem zbieżności procesu poszukiwania minimum, a tym samym i lepsze dopasowanie [6]. Ważną kwestią w tworzeniu sieci neuronowej jest ustalenie odpowiedniej liczby neuronów w warstwie ukrytej, ze względu na jak najlepszą aproksymację danych doświadczalnych w procesie uczenia sieci neuronowej. Takie działanie pozwala stworzyć sieć neuronową, która z dobrym przybliżeniem określa wartości, jakie użyto w procesie uczenia. Daje to pewność, że opracowana sieć dobrze przewidyje

the developed network predicts experimental results well and can be successfully implemented in the risk assessment software environment under development. Figure 1 shows a schematic of the network, which consists of two input neurons. The input neurons represent the mass flux of propane at the nozzle outlet \dot{m}_c and the nozzle diameter d_{nozzle} , which are key process parameters describing the jet fire. A single hidden layer with neurons using a sigmoidal activation function was used for the simulation. Due to the representation of two input parameters by two input parameters for the development of the artificial neural network, there was no need for more than one hidden layer. Therefore, the focus was on selecting an appropriate number of neurons in the hidden layer so that their number would allow a sufficiently good description of the process parameters determining the size of the flame. The methodology for the numerical calculations consisted of selecting the right number of neurons to prevent so-called neural network overfitting, while at the same time ensuring that the neural network matched the external data. The result of such a network is the determination of two parameters that determine the size of the flame. Each output parameter is represented by output neurons. The length of the flame L_{flame} and the length of the mixing path $S_{lift-off}$ means that the neural network has two output neurons. For the CFD simulations, identical weather conditions to those prevailing during the field tests were used (see Table 1). This allowed the use of two separate methods for determining flame sizes in the neural network process. A particularly important parameter is the L_{flame} parameter, which is used in programmes to generate emergency scenarios in the event of a jet fire.

CFD numerical simulations – data source

In the process of creating the neural network, two types of data were used to describe the stream fire phenomenon. The first type of data came from calculations of mathematical models describing the gas combustion process. Algorithms describing this phenomenon have been implemented in ANSYS software, which allows mathematical modelling of momentum, mass and energy transport problems. Details of the simulations and tests carried out can be found in the publications [2, 7–8]. This article will use data from publication [2], i.e. process parameters and L_{flame} and $s_{lift-off}$ values from CFD simulations for a nozzle diameter of $d_{nozzle} = 30.6$ mm in a horizontal propane fire. Figure 2 shows the results of numerical simulations of jet fires using CFD methods. This data will be used to develop a neural network.

wyniki doświadczalne i może być z powodzeniem zaimplementowana w tworzonym środowisku programistycznym do oceny ryzyka. Na rycinie 1 przedstawiono schemat sieci, która składa się z dwóch neuronów wejściowych. Neurony wejściowe reprezentują strumień masowy propanu na wylocie z dyszy \dot{m}_c oraz średnicę dyszy d_{nozzle} , które są kluczowymi parametrami procesowymi opisującymi pożar strumieniowy. Do symulacji wykorzystano jedną warstwę ukrytą z neuronami, w których zastosowano sigmoidalną funkcję aktywacji. Z uwagi na reprezentację dwóch parametrów wejściowych przez dwa parametry wejściowe do opracowania sztucznej sieci neuronowej nie było potrzeby zastosowania więcej niż jednej warstwy ukrytej. Skupiono się zatem na doborze odpowiedniej liczby neuronów w warstwie ukrytej tak, żeby ich liczba pozwalała odpowiednio dobrze opisać parametry procesowe określające rozmiary płomienia. Metodologia obliczeń numerycznych polegała na dobraniu odpowiedniej liczby neuronów tak, żeby zapobiec tzw. przeczeniu sieci neuronowej, przy jednoczesnym zapewnieniu odpowiedniego stopnia dopasowania sieci neuronowej do danych zewnętrznych. Wynikiem działania takiej sieci jest wyznaczenie dwóch parametrów określających rozmiar płomienia. Każdy z parametrów wyjściowych jest reprezentowany przez neurony wyjściowe. Długość płomienia L_{flame} i długość drogi mieszania $S_{lift-off}$ oznacza, że sieć neuronowa ma dwa neurony wyjściowe. Do symulacji CFD użyto identycznych warunków pogodowych, jak te panujące podczas badań poligonowych (zob. tabela 1). Pozwoliło to na wykorzystanie dwóch odrębnych metod określających rozmiary płomienia w procesie tworzenia sieci neuronowej. Szczególnie istotnym parametrem jest L_{flame} , który wykorzystywany jest w programach służących do generowania scenariuszy awaryjnych w przypadku wystąpienia pożaru strumieniowego.

Symulacje numeryczne CFD – źródło danych

W procesie tworzenia sieci neuronowej posłużono się dwoma rodzajami danych opisujących zjawisko pożaru strumieniowego. Pierwszy rodzaj danych pochodził z obliczeń modeli matematycznych opisujących proces spalania gazu. Algorytmy opisujące to zjawisko zostały zaimplementowane w oprogramowaniu ANSYS, które umożliwia modelowanie matematyczne problemów transportu pędu, masy i energii. Szczegółowe informacje na temat przeprowadzonych symulacji i badań można znaleźć w publikacjach [2, 7–8]. W niniejszym artykule wykorzystano dane zawarte w publikacji [2], tzn. parametry procesowe oraz wartości L_{flame} i $s_{lift-off}$ z symulacji CFD dla średnicy dyszy $d_{nozzle} = 30,6$ mm przy pożarze poziomym propanu. Na rycinie 2 zamieszczone zostały wyniki symulacji numerycznych pożarów strumieniowych z wykorzystaniem metod CFD. Dane te posłużą do opracowania sieci neuronowej.




Figure 2. L_{flame} and $s_{lift-off}$ values from CFD simulations
Rycina 2. Wartości L_{flame} i $s_{lift-off}$ pochodzące z symulacji CFD

Source: Own elaboration based on [8].

Źródło: Opracowanie własne na podstawie [8].

Experimental studies of propane jet fires carried out on a large scale

The second type of data used in the neural network development process came from the development of the results of the polygon experiments. Experimental studies of jet fires were carried out on a test stand (see Figure 3), built as part of the implementation of project No. DOB-BIO7/09/03/2015 acronym EVARIS [9], on the training ground located in Pionki, at the Training Centre of the Provincial Headquarters of the State Fire Service in Warsaw. The test stand, which allows the simulation of leakage events involving flammable gases released under pressure from process equipment, includes components such as a pressure vessel for gas in the liquid phase, an electric vaporiser (heater) for changing the state of the gas from liquid to gas, a gas meter and a pipeline terminated with a nozzle allowing so-called free gas outflow. A construction diagram with the dimensions of the gas installation plotted is shown in Figure 4. A construction diagram with the plotted dimensions of the gas installation is shown in Figure 4.

Badania doświadczalne pożarów strumieniowych propanu przeprowadzone w dużej skali

Drugi typ danych wykorzystywanych w procesie tworzenia sieci neuronowej pochodził z opracowania wyników doświadczeń poligonowych. Badania doświadczalne pożarów strumieniowych przeprowadzono na stanowisku badawczym (zob. ryc. 3), zbudowanym w ramach realizacji projektu nr DOB-BIO7/09/03/2015 akronim EVARIS [9], na terenie poligonu szkoleniowego zlokalizowanego w Pionkach, w Ośrodku Szkolenia Komendy Wojewódzkiej Państwowej Straży Pożarnej w Warszawie. W skład stanowiska badawczego, umożliwiającego symulację zdarzeń przy wycieku łatwopalnych gazów uwalnianych pod ciśnieniem z aparatury procesowej, wchodzi m.in. takie elementy składowe, jak zbiornik ciśnieniowy na gaz w fazie ciekłej, parownik (podgrzewacz) elektryczny służący do zmiany stanu skupienia gazu z ciekłego na gazowy, gazomierz oraz rurociąg zakończony dyszą pozwalającą na tzw. wolny wypływ gazu. Schemat konstrukcyjny z naniesionymi wymiarami instalacji gazowej przedstawiono na rycinie 4.



Figure 3. Jet fire test stand including aboveground pressure vessel, electric evaporator, pipeline and gas system safety features
Rycina 3. Stanowisko do badania pożarów strumieniowych, w tym naziemny zbiornik ciśnieniowy, parownik elektryczny, rurociąg i zabezpieczenia instalacji gazowej

Source: Own elaboration.

Źródło: Opracowanie własne.




Figure 4. Schematic of the jet fire test stand

Rycina 4. Schemat stanowiska do badania pożarów strumieniowych

Source: Own elaboration.

Źródło: Opracowanie własne.

Field experiments were conducted in the propane mass flux range from 0.5 kg/s to 0.9 kg/s. A detailed description of the test stand and measurement system with data acquisition is provided in publications [7, 10]. As part of the study of the combustion of propane coming out of the process apparatus in the gaseous phase, temperature, thermal radiation were measured. The arrangement of the temperature and thermal radiation sensors on the test bench, used to determine the above physical quantities as a function of distance from the flame, is shown in Figure 5. Not all measurement results were used to develop the artificial neural network. The main objective of the research was to support the development of risk assessment software, which was not planned to use artificial neural networks. The development of such a network came later – this article is part of a larger related work.

Doświadczenia poligonowe prowadzono w zakresie strumienia masowego propanu od 0,5 do 0,9 kg/s. Szczegółowy opis stanowiska badawczego i układu pomiarowego z akwizycją danych przedstawiono w publikacjach [7, 10]. W ramach badań spalania propanu wydobywającego się z aparatury procesowej w fazie gazowej przeprowadzono pomiary temperatury, promieniowania ciepłego. Sposób rozmieszczenia na stanowisku badawczym czujników temperatury i promieniowania ciepłego, służących do wyznaczenia powyższych wielkości fizycznych w funkcji odległości od płomienia, przedstawiono na rycinie 5. Nie wszystkie wyniki pomiarów zostały użyte do opracowania sztucznej sieci neuronowej. Głównym celem badań było wsparcie tworzenia oprogramowania do oceny ryzyka, w którym nie planowano wykorzystywać sztucznych sieci neuronowych. Opracowanie takiej sieci pojawiło się później – niniejszy artykuł jest częścią większej pracy związanej z tym tematem.




Figure 5. Schematic of the location of the measuring sensors on the polygon test stand; T – thermocouple, P – thermal radiation sensor, the value in brackets is the height at which the sensor is mounted

Rycina 5. Schemat rozmieszczenia czujników pomiarowych na poligonowym stanowisku badawczym; T – termopara, P – czujnik promieniowania cieplnego, wartość w nawiasie to wysokość, na której zamontowano czujnik

Source: Own elaboration.

Źródło: Opracowanie własne.

During the research, meteorological conditions were monitored using a weather station (see Table 1). When propane was burnt, a horizontally directed flame was formed, which – with increasing distance from the end of the pipeline allowing the gas to flow freely – headed upwards (see Figure 4). In determining the flame size for each mass intensity of propane, the following procedure was performed. By controlling the constant volumetric output and gas pressure at the nozzle exit, the flame image was archived with a camera. The collected data made it possible to determine the size of the flame for each measurement separately. Special stands with scales of specific lengths set up nearby were used for the measurements. A photograph of the flame, with a plotted description of its various dimensions, is shown in Figure 4 and the dimension values in Table 2. The average values, at constant gas output, temperature and thermal radiation, are shown in Figure 5. During the research, a significant influence of the east-northeast (ENE, 67°30') wind direction was observed on the values recorded at the sensors (see Figure 5). A detailed discussion of the propane jet fire results and their analysis is presented in publication [3].

W trakcie badań monitorowano warunki meteorologiczne za pomocą stacji pogodowej (zob. tabela 1). Podczas spalania propanu tworzył się poziomo ukierunkowany płomień, który – wraz ze wzrostem odległości od zakończenia rurociągu, pozwalającego na wolny wypływ gazu – kierował się ku górze (zob. ryc. 4). Przy określeniu rozmiaru płomienia dla każdego natężenia masowego propanu wykonywano następującą procedurę. Kontrolując stały wydatek objętościowy oraz ciśnienie gazu na wylocie z dyszy, archiwizowano za pomocą kamery obraz płomienia. Zebrane dane pozwoliły na określenie rozmiarów płomienia dla każdego z pomiarów osobno. Do pomiarów wykorzystane zostały ustawione w pobliżu specjalne stojaki z podziałkami o określonych długościach. Zdjęcie płomienia wraz z naniesionym opisem poszczególnych jego wymiarów przedstawiono na rycinie 4, a wartości wymiarów w tabeli 2. Średnie wartości, przy stałym wydatku gazu, temperatury i promieniowania cieplnego, przedstawiono na rycinie 5. W trakcie badań zaobserwowano znaczący wpływ wschodnio-północno-wschodniego (ENE, 67°30') kierunku wiatru, na wartości rejestrowane na czujnikach (zob. ryc. 5). Szczegółowe omówienie wyników badań pożaru strumieniowego propanu i ich analizę przedstawiono w publikacji [3].

Table 1. Meteorological conditions during the field tests

Tabela 1. Warunki meteorologiczne w trakcie badań poligonowych

Temperature / Temperatura [°C]	23
Pressure / Ciśnienie [hPa]	1020.4
Humidity / Wilgotność [%]	64
Wind speed / Prędkość wiatru [m/s]	0.2
Wind direction / Kierunek wiatru	ENE – 67°30'

Source: Own elaboration.

Źródło: Opracowanie własne.

Table 2. Dimensions of the propane burnt flame, at constant gas flow setting
Tabela 2. Wymiary płomienia spalnego propanu, przy stałym nastawie wydatku gazu

A [m]	B [m]	C [m]	D [m]
7.5	0.6	3.8	0.35

Source: Own elaboration.
 Źródło: Opracowanie własne.




Figure 6. Photograph of a propane combustion flame; A – distance from nozzle to flame (gas-air mixing zone), B – length of flame, C – height of flame from axis of pipeline upwards, D – height of flame from axis of pipeline downwards
Rycina 6. Zdjęcie płomienia spalnego propanu; A – odległość od dyszy do płomienia (strefa mieszania się gazu i powietrza), B – długość płomienia, C – wysokość płomienia od osi rurociągu w górę, D – wysokość płomienia od osi rurociągu w dół

Source: Own elaboration.
 Źródło: Opracowanie własne.

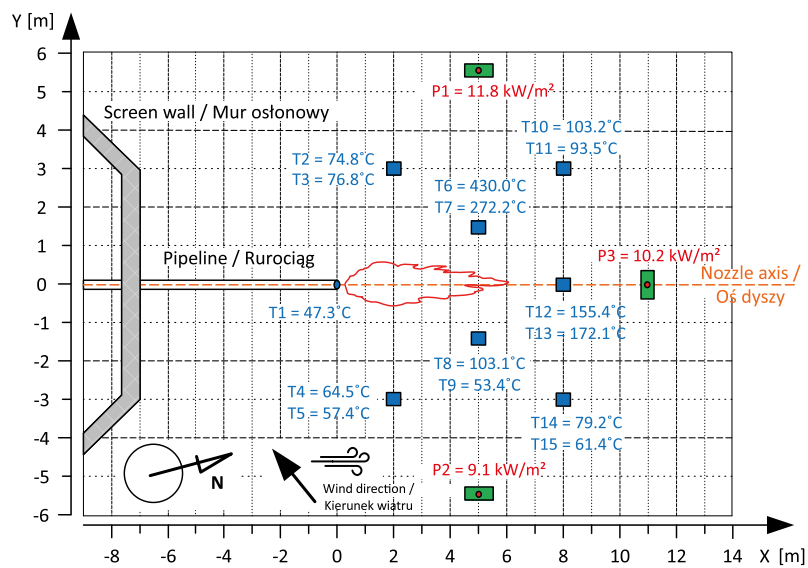


Figure 7. Average values of temperature and thermal radiation recorded by the sensors at constant gas output from the gas system
Rycina 7. Średnie wartości temperatury i promieniowania cieplnego zarejestrowane przez czujniki przy stałym wydatku gazu z instalacji gazowej

Source: Own elaboration.
 Źródło: Opracowanie własne.

The experimentally determined flame lengths in the polygon measurements were used to develop an artificial neural network. In addition, the results of measurements of propane combustion in a jet fire, as presented in publication [1], were also used for the neural network learning process. Table 3 (see [1]) shows the mass flux values for propane, among others, the exit velocity, temperature and pressure of the gas at the nozzle outlet, as well as the flame length and the length of the propane-air mixing path. As a result, a total of three types of data describing flame length and mixing path length were used in the network learning process, depending on propane mass flux and nozzle diameter for two nozzle diameters $d_{nozzle} = 30.6$ mm and $d_{nozzle} = 19.05$ mm. This allowed the collection of data, which was used to create an artificial neural network. The dataset consisted of 50 values including L_{flame} and $s_{lift-off}$ for two different nozzle diameters and different propane mass fluxes at the nozzle outlet.

Artificial neural network

The nftool package included in Matlab 2022a was used to create the neural network. The methodology for creating the neural network was to find the number of neurons for which the flame length and mixing path length, determined from the neural network, were as close as possible to the values used to create the network. The data used to create the network was divided into three parts: one part of the data was used to determine the weights, the second part was used to validate these weights and the last part was used to test the developed neural network. The data was split as follows: the learning set accounted for 70% of the total data, the validation set for 10% of the total data. The remaining data were used for artificial neural network testing. The Pearson correlation coefficient was used to verify the resulting artificial neural network as a function of the number of neurons in the hidden layer. It was calculated based on the artificial neural network developed after the validation stage. For this purpose, Pearson's $R_{L_{flame}}$ and $R_{s_{lift-off}}$ coefficients were calculated separately for each of the variables coming out of the neural network, comparing them with the experimental and CFD simulation data. Values of Pearson's coefficient for flame length and mixing path length with air equal to 1 indicate a perfect fit of the neural network to the experimental data or those calculated using CFD methods.

Figure 8 shows the summary results to determine the best number of neurons to describe the experimental and simulation data. The main objective of this work was to develop an artificial neural network that best described the values of the two relevant parameters L_{flame} and $s_{lift-off}$. It is clear from the data in Figure 8 that, with 12 neurons in the hidden layer, the two coefficients together have values closest to 1. This means that this particular network best predicts both L_{flame} and $s_{lift-off}$ values derived from CFD simulations and field experiments. Although with a different number of neurons the representation of each parameter individually is better, unfortunately their joint description is definitely worse. Therefore, 12 neurons were used in the hidden layer.

Określone doświadczalnie długości płomienia w pomiarach poligonowych zostały użyte do opracowania sztucznej sieci neuronowej. Dodatkowo do procesu uczenia sieci neuronowej wykorzystano również wyniki pomiarów spalania propanu w pożarze strumieniowym, które przedstawiono w publikacji [1]. W tabeli 3 (zob. [1]) przedstawiono wartości strumienia masowego propanu m.in. prędkości wylotowej, temperatury i ciśnienia gazu na wylocie z dyszy oraz długości płomienia i długości drogi mieszania propanu z powietrzem. Dzięki temu w procesie uczenia sieci wykorzystano łącznie trzy typy danych opisujących długość płomienia i długość drogi mieszania, w zależności od strumienia masowego propanu i średnicy dyszy dla dwóch średnic dyszy $d_{nozzle} = 30,6$ mm i $d_{nozzle} = 19,05$ mm. Pozwoliło to na zebranie danych, których użyto do stworzenia sztucznej sieci neuronowej. Zbiór danych składał się z 50 wartości zawierających L_{flame} i $s_{lift-off}$ dla dwóch różnych średnic dyszy i różnych strumieni masowych propanu na wylocie z dyszy.

Sztuczna sieć neuronowa

Do tworzenia sieci neuronowej wykorzystano pakiet n_{ftool} zawarty w programie Matlab 2022a. Metodyka tworzenia sieci neuronowej polegała na poszukiwaniu takiej liczby neuronów, dla której długość płomienia i długość drogi mieszania, określone z sieci neuronowej, były jak najbliższe wartościom użytych do tworzenia sieci. Dane wykorzystane do tworzenia sieci zostały podzielone na trzy części: jedną część danych wykorzystano do określenia wag, drugą – do walidacji tych wag, a ostatnią – do testów opracowanej sieci neuronowej. Dane podzielono w następujący sposób: zbiór uczący stanowił 70% wszystkich danych, zbiór do walidacji – 10% wszystkich danych. Pozostałe dane wykorzystane zostały do testów sztucznej sieci neuronowej. W celu weryfikacji otrzymanej sztucznej sieci neuronowej w zależności od liczby neuronów w warstwie ukrytej wykorzystano współczynnik korelacji Pearsona. Został on obliczony na podstawie sztucznej sieci neuronowej opracowanej po etapie walidacji. W tym celu osobno obliczano współczynnik Pearsona $R_{L_{flame}}$ i $R_{s_{lift-off}}$ dla każdej ze zmiennych wychodzących z sieci neuronowej, porównując je z danymi z doświadczeń i symulacji CFD. Wartości współczynnika Pearsona dla długości płomienia oraz długości drogi mieszania z powietrzem równe 1 oznaczają idealne dopasowanie sieci neuronowej do danych doświadczalnych lub obliczonych przy pomocy metod CFD.

Na rycinie 8 przedstawiono wyniki sumaryczne pozwalające na określenie najlepszej liczby neuronów do opisu danych pochodzących z doświadczeń i symulacji. Głównym celem tej pracy było opracowanie sztucznej sieci neuronowej, która najlepiej opisywała wartości dwóch istotnych parametrów L_{flame} i $s_{lift-off}$. Z danych zamieszczonych na rycinie 8 jasno wynika, że przy 12 neuronach w warstwie ukrytej oba współczynniki mają wspólnie wartości najbliższe 1. Oznacza to, że ta właśnie sieć najlepiej przewiduje obie wartości L_{flame} i $s_{lift-off}$ pochodzące z symulacji CFD i doświadczeń poligonowych. Mimo że przy innej liczbie neuronów odwzorowanie pojedynczo każdego z parametrów jest lepsze, to niestety ich wspólny opis jest zdecydowanie gorszy. W związku z tym zastosowano 12 neuronów w warstwie ukrytej.

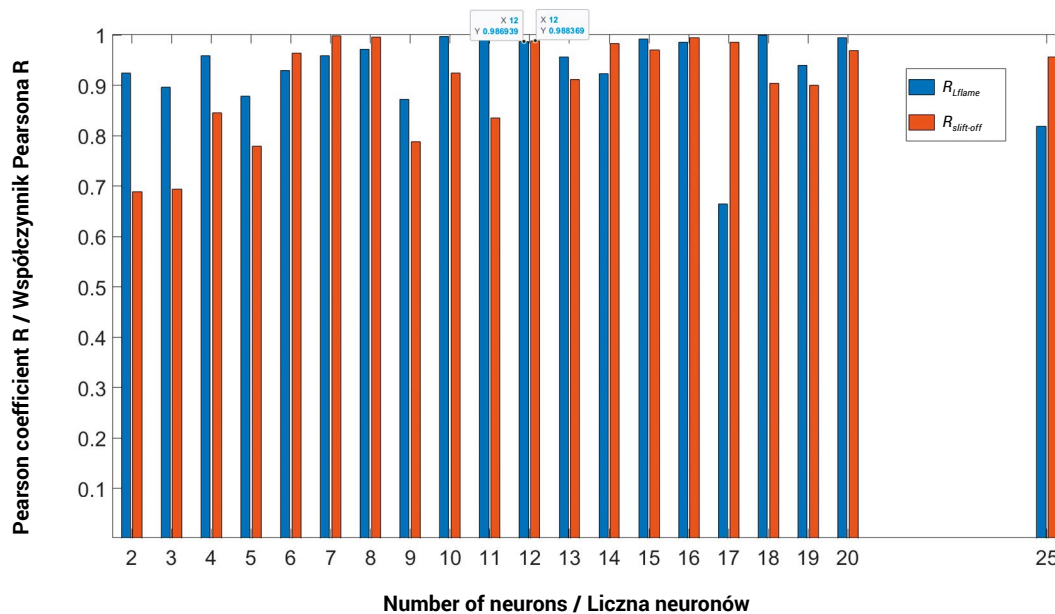


Figure 8. Effect of the number of neurons in the hidden layer on the Pearson correlation coefficient determined for each output neuron
Rycina 8. Wpływ liczby neuronów w warstwie ukrytej na współczynnik korelacji Pearsona określony dla każdego neuronu wyjściowego

Source: Own elaboration.

Źródło: Opracowanie własne.

Using more than 12 neurons in the hidden layer is unhelpful, as this increases computation time and cost without giving a better match between the two output variables. Figure 9 presents the degree of fit of the neural network to the data describing the flame length. The abscissa axis shows the L_{flame} lengths from the dataset and the ordinate axis shows the L_{flame} length values calculated by the artificial neural network (see Figure 9, ANN marking). The figure also shows the regression line $Y_{ANN} = Y_{CFD,dos}$ with a directional coefficient of 1. As can be seen in the figure, the neural network fits the dataset very well, as evidenced by Pearson's coefficient of $R_{Lflame} = 0.987$. The values summarised in the graphs show that the artificial network made up of 12 neurons in the hidden layer predicts the flame length values in a jet fire quite well. All values determined by the developed neural network within the accepted error ($R > 0.95$) reflect the length of the flame in this fire.

Similar conclusions can be reached by comparing the quality of the fit shown in Figure 10. On the abscissa axis, the values for the length of the $s_{lift-off}$ air mixing path from the dataset are presented, and on the ordinate axis the same parameter, but calculated by an artificial neural network (ANN). In addition, the regression line $Y_{ANN} = Y_{CFD,dos}$ is plotted on the figure, with a directional coefficient equal to 1, which represents a perfect fit of the function to the data. Figure 10 shows that the fit is at a similar level to that illustrated in the previous figure (see Figure 9). The correlation coefficient meets the assumption of $R_{slift-off} > 0.95$. In this case, the Pearson coefficient is 0.988.

Wykorzystanie więcej niż 12 neuronów w warstwie ukrytej jest niecelowe, gdyż zwiększa czas i koszty obliczeń, nie dając lepszego dopasowania obu zmiennych wyjściowych. Na rycinie 9 zaprezentowany został stopień dopasowania sieci neuronowej do danych opisujących długość płomienia. Na osi odciętych przedstawiono długości płomienia L_{flame} ze zbioru danych, a na osi rzędnych – wartości długości płomienia L_{flame} wyliczone przez sztuczną sieć neuronową (zob ryc. 9, oznaczenie ANN). Na rycinie zamieszczono także linię regresji $Y_{ANN} = Y_{CFD,dos}$ ze współczynnikiem kierunkowym równym 1. Jak widać na rycinie, sieć neuronowa bardzo dobrze dopasowuje się do danych ze zbioru, o czym świadczy współczynnik Pearsona równy $R_{Lflame} = 0,987$. Zestawione na wykresach wartości pokazują, że sztuczna sieć zbudowana z 12 neuronów w warstwie ukrytej dość dobrze przewiduje wartości długości płomienia w pożarze strumieniowym. Wszystkie wartości wyznaczone przez opracowaną sieć neuronową w granicach przyjętego błęd ($R > 0,95$) odzwierciedlają długość płomienia w tym pożarze.

Do podobnych wniosków można dojść, porównując jakość dopasowania przedstawioną na rycinie 10. Na osi odciętych zaprezentowano wartości długości drogi mieszania $s_{lift-off}$ z powietrzem ze zbioru danych, a na osi rzędnych ten sam parametr, ale obliczony przez sztuczną sieć neuronową (ANN). Dodatkowo na wykres naniiesiono linię regresji $Y_{ANN} = Y_{CFD,dos}$ ze współczynnikiem kierunkowym równym 1, który reprezentuje idealne dopasowanie funkcji do danych. Z ryciny 10 wynika, że dopasowanie jest na poziomie podobnym do tego zobrazowanego na poprzednim rysunku (por. ryc. 9). Współczynnik korelacji spełnia założenie $R_{slift-off} > 0,95$. W tym przypadku współczynnik Pearsona wynosi 0,988.

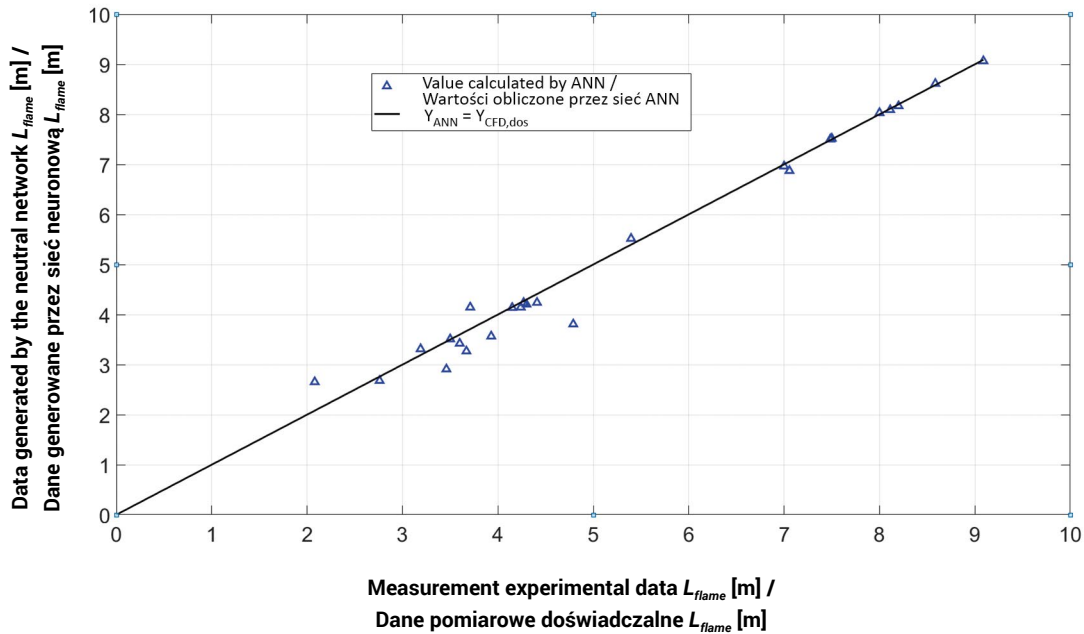


Figure 9. Degree of matching of the flame length L_{flame} by the network built of 12 neurons in the hidden layer, $R_{L_{flame}} = 0.987$ after the validation phase
Rycina 9. Stopień dopasowania długości płomienia L_{flame} przez sieć zbudowaną z 12 neuronów w warstwie ukrytej, $R_{L_{flame}} = 0.987$ po etapie walidacji

Source: Own elaboration.

Źródło: Opracowanie własne.

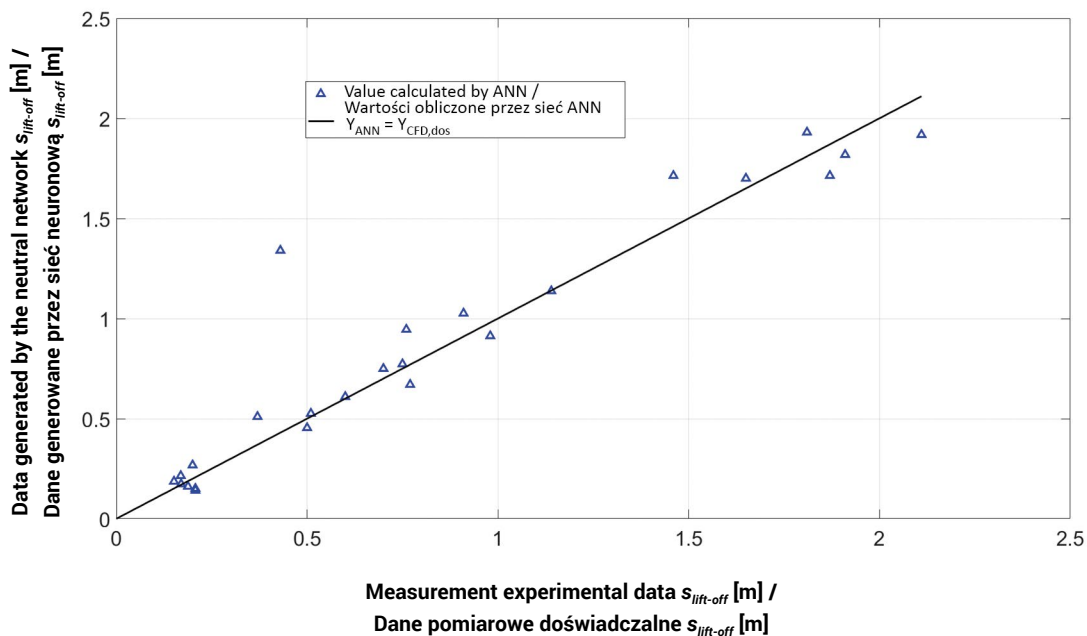


Figure 10. Degree of adaptation of the $s_{lift-off}$ flame length by the network built of 12 neurons in the hidden layer, $R_{s_{lift-off}} = 0.988$ after the validation phase
Rycina 10. Stopień dopasowania długości płomienia $s_{lift-off}$ przez sieć zbudowaną z 12 neuronów w warstwie ukrytej, $R_{s_{lift-off}} = 0.988$ po etapie walidacji

Source: Own elaboration.

Źródło: Opracowanie własne.

Table 3 shows partial results in the process of creating an artificial neural network. Values are presented for the effect of the number of neurons on the number of epochs needed to determine the minimum of the function. In addition, mean squared error values are included separately for each of the network learning steps. As can be seen, for 12 neurons in the hidden layer, the values of all three mean squared errors are acceptable. Additionally, with 12 neurons in the hidden layer, both parameters are calculated with the lowest error. Therefore, the use of a single-layer artificial neural network is fully justified. The developed neural network can be applied to the mathematical description of the L_{flame} and $s_{lift-off}$ parameters in a horizontal jet fire. It can also provide assistance in determining failure scenarios for the following range of process parameters: $19 \text{ mm} \leq d_{nozzle} \leq 30.6 \text{ mm}$ and propane mass flux: $0.015 \text{ kg/s} \leq \dot{m} \leq 1 \text{ kg/s}$.

W tabeli 3 przedstawiono częściowe wyniki w procesie tworzenia sztucznej sieci neuronowej. Zaprezentowano wartości wpływu liczby neuronów na liczbę epok potrzebną do określenia minimum funkcji. Dodatkowo zamieszczono wartości błędu średniokwadratowego osobno dla każdego z etapów uczenia sieci. Jak widać, dla 12 neuronów w warstwie ukrytej wartości wszystkich trzech błędów średniokwadratowych są do zaakceptowania. Dodatkowo przy 12 neuronach w warstwie ukrytej oba parametry są obliczane z najmniejszym błędem. W związku z tym wykorzystanie jednowarstwowej sztucznej sieci neuronowej jest w pełni uzasadnione. Opracowana sieć neuronowa może być zastosowana do opisu matematycznych parametrów L_{flame} i $s_{lift-off}$ w poziomym pożarze strumieniowym. Może także stanowić pomoc przy określaniu scenariuszy awaryjnych dla następującego zakresu parametrów procesowych: $19 \text{ mm} \leq d_{nozzle} \leq 30,6 \text{ mm}$ oraz strumienia masowego propanu: $0,015 \text{ kg/s} \leq \dot{m} \leq 1 \text{ kg/s}$.

Table 3. Parameters describing the selection of the best number of neurons in the hidden layer
Tabela 3. Parametry opisujące wybór najlepszej liczby neuronów w warstwie ukrytej

Number of neurons / Liczba neuronów	Number of epochs / Liczba epok	MSE		
		Training / Trening	Validation / Walidacja	Test / Test
2	15	0.8300	0.5749	0.1338
3	9	1.1628	0.6877	2.9761
4	11	0.3218	2.4875	0.3961
5	11	0.5688	0.2223	0.6548
6	30	0.0274	0.0539	0.2788
7	7	13.6744	0.7212	10.2614
8	27	0.1003	0.0495	8.0232
9	11	0.1198	7.2624	0.0497
10	10	0.2446	0.9986	0.7523
11	12	0.0910	0.0042	4.6058
12	17	0.0996	0.2466	0.2530
14	19	0.0698	0.0379	5.2993
18	11	0.0301	0.1701	26.0775

Source: Own elaboration.
Źródło: Opracowanie własne.

Conclusions

The storage of flammable gases involves the risk of a sudden and uncontrolled phenomenon such as a jet fire. Its size is of particular importance when defining safe zones around the location of a particular tank used for gas storage. In general, the results of jet fires described by the ALOHA programme are relied upon to determine the safe distance from the tank. This programme is

Wnioski

Przechowywanie gazów łatwopalnych wiąże się z ryzykiem powstania nagłego i niekontrolowanego zjawiska, jakim jest pożar strumieniowy. Jego rozmiar ma szczególne znaczenie w przypadku określania stref bezpiecznych wokół miejsca usytuowania konkretnego zbiornika, służącego do przechowywania gazu. Na ogół przy określaniu odległości bezpiecznej od zbiornika polega

based on simple literature correlations that may underestimate the size of the actual flame. Unfortunately, the use of field trials is severely limited – if only by the cost of performing such experiments. Therefore, an approach combining experimental methods with methods involving numerical calculations through the use of artificial neural networks was proposed. These networks have very good approximation properties and are therefore able to represent experimental and numerical data with a limited number of variables. The neural network built is a mathematical function resembling a so-called black box, into which the input data enters and the sought-after parameters describing the size of the jet fire flame come out. The simplicity of such a function makes it possible to use neural networks in risk assessment programmes, without the need for computing servers. The parameters of a jet fire, such as flame length and mixing path length, can be determined with a high degree of accuracy using an uncomplicated single-layer neural network.

Acknowledgements

The publication was developed under project No. DOB-BIO7/09/03/2015 entitled 'Programme for the assessment of the risk of accidents at industrial facilities posing a hazard outside their premises', funded by the National Centre for Research and Development.

List of symbols

d_{nozzle} – nozzle diameter [m]
 L_{flame} – flame length [m]
 m_{in} – propane mass flow [$kg \cdot s^{-1}$]
 R_{Lflame} – pearson correlation coefficient calculated for flame length
 $R_{slift-off}$ – pearson correlation coefficient calculated for the length of the mixing path
 $S_{lift-off}$ – gas mixing path length [m]

Literature / Literatura

- [1] Laboureur D.M., Gopalaswami N., Zhang B., Liu Y., Manan M.S., *Experimental study on propane jet fire hazards: Assessment of the main geometrical features of horizontal jet flames*, "Journal of Loss Prevention in the Process Industries" 2016, 41, 355–364, <https://doi.org/10.1016/j.jlp.2016.02.013>.
- [2] Lewak M., Tępiński J., Klapsa W., *Wykorzystanie modelu burzliwości -k-w SST do modelowania matematycznego*

się na wynikach pożarów strumieniowych opisywanych przez program ALOHA. Program ten bazuje na prostych korelacjach literaturowych, które mogą nie doszacować rozmiarów rzeczywistego płomienia. Niestety korzystanie z badań poligonowych jest mocno ograniczone – chociażby kosztami wykonania takich doświadczeń. W związku z tym zaproponowano podejście polegające na połączeniu metod doświadczalnych z metodami polegającymi na obliczeniach numerycznych za pomocą wykorzystania sztucznych sieci neuronowych. Sieci te mają bardzo dobre własności aproksymacyjne, dzięki czemu są w stanie odwzorować dane doświadczalne i numeryczne za pomocą ograniczonej liczby zmiennych. Zbudowana sieć neuronowa jest funkcją matematyczną przypominającą tzw. czarną skrzynkę, do której wchodzi dane wejściowe, a wychodzą poszukiwane parametry opisujące rozmiar płomienia pożaru strumieniowego. Prostota takiej funkcji umożliwia wykorzystanie sieci neuronowych w programach służących do oceny ryzyka, bez konieczności korzystania z serwerów obliczeniowych. Parametry pożaru strumieniowego, takie jak długość płomienia i długość drogi mieszania, można wyznaczyć z dużą dokładnością za pomocą nieskomplikowanej, jednowarstwowej sieci neuronowej.

Podziękowania

Publikacja została opracowana w ramach projektu nr DOB-BIO7/09/03/2015 pod tytułem „Program do oceny ryzyka wystąpienia awarii w obiektach przemysłowych stwarzających zagrożenie poza swoim terenem” finansowanego przez Narodowe Centrum Badań i Rozwoju.

Spis symboli

d_{nozzle} – średnica dyszy [m]
 L_{flame} – długość płomienia [m]
 m_{in} – strumień masowy propanu [$kg \cdot s^{-1}$]
 R_{Lflame} – współczynnik korelacji Pearsona liczony dla długości płomienia
 $R_{slift-off}$ – współczynnik korelacji Pearsona liczony dla długości drogi mieszania
 $S_{lift-off}$ – długość drogi mieszania gazu [m]

- pożaru strumieniowego*, SFT Vol. 59 Issue 1, 2022, pp. 28–40, <https://doi.org/10.12845/sft.59.1.2022.1>.
- [3] Mashhadimoslem H., Ghaemi A., Palacios A., *Analysis of deep learning neural network combined with experiments to develop predictive models for a propane vertical jet fire*, "Heliyon" 2020, 6, 11, e05511, <https://doi.org/10.1016/j.heliyon.2020.e05511>.
- [4] Levenberg K., *A Method for the Solution of Certain Non-Linear*

- Problems in Least Squares*, "Quarterly of Applied Mathematics" 1944, 2 (2), 164–168, <https://doi.org/10.1090/qam/10666>.
- [5] Marquardt D.W., *An Algorithm for Least-Squares Estimation of Nonlinear Parameters*, "SIAM Journal on Applied Mathematics" 1963, 11(2), 431–441, <https://doi.org/10.1137/0111030>.
- [6] Narkhede M.V., Bartakke P.P., Sutaone M.S., *A review on weight initialization strategies for neural networks*, "Artificial Intelligence Review" 2022, Vol. 55 (2), 1–32, <https://doi.org/10.1007/s10462-021-10033-z>.
- [7] Tępiński J., Połec B., *Badania na rzecz poprawy bezpieczeństwa w zakładach przemysłowych stwarzających zagrożenie poza swoim terenem*, Wydawnictwo CNBOP, Józefów 2020, <https://doi.org/10.17381/2020.1>.
- [8] Lewak M., Tępiński J., Lesiak P., *Modelowanie matematyczne pożarów strumieniowych za pomocą obliczeniowej mechaniki płynów CFD*, „Przemysł chemiczny” 2022, 101(5), 324–329, <https://doi.org/10.15199/62.2022.5.6>.
- [9] Projekt nr DOB-BIO7/09/03/2015 pod tytułem „Program do oceny ryzyka wystąpienia awarii w obiektach przemysłowych stwarzających zagrożenie poza swoim terenem” finansowany przez Narodowe Centrum Badań i Rozwoju.
- [10] Tępiński J., Lewak M., Lesiak P., *Badania pożarów strumieniowych propanu przeprowadzone w dużej skali*, „Przemysł Chemiczny” 2022, 101 (11), 950–956, <https://doi.org/10.15199/62.2022.11.3>.

MICHAŁ LEWAK, PH.D. ENG. – in 2005, he began doctoral studies at the Faculty of Chemical and Process Engineering of the Warsaw University of Technology. In 2011, he obtained a doctoral degree with honours, specialising in chemical engineering. Since 2011, he has been a research and teaching employee at the Warsaw University of Technology. He works as an assistant professor in the Department of Process Kinetics and Thermodynamics in the Faculty of Chemical and Process Engineering. It deals with the mathematical modelling of mass, heat and energy transport phenomena in physicochemical systems. With particular reference to methods related to computational fluid mechanics. In addition, he deals with process safety problems in chemical reactors, mathematical modelling related to jet fire and contaminant spread.

JAROSŁAW TĘPIŃSKI, PH.D. ENG. – in 2008 he graduated with a specialisation in Automation and Computer Engineering from the Faculty of Electrical Engineering at the Warsaw University of Technology. At the same department, he obtained his doctorate in engineering in 2016. He is currently an assistant professor at the Scientific and Research Centre for Fire Protection – National Research Institute in Józefów. Specialising in electrical engineering, automation and technical fire protection systems.

DR INŻ. MICHAŁ LEWAK – w 2005 r. rozpoczął studia doktoranckie na Wydziale Inżynierii Chemicznej i Procesowej Politechniki Warszawskiej. W 2011 r. uzyskał z wyróżnieniem stopień doktora specjalność inżynieria chemiczna. Od 2011 r. jest pracownikiem naukowo-dydaktycznym Politechniki Warszawskiej. Pracuje na stanowisku adiunkta w Zakładzie Kinetyki i Termodynamiki Procesowej na Wydziale Inżynierii chemicznej i Procesowej. Zajmuje się modelowaniem matematycznym zjawisk transportu masy, ciepła i energii w układach fizykochemicznych. Ze szczególnym uwzględnieniem metod związanych z obliczeniową mechaniką płynów. Ponadto zajmuje się problemami bezpieczeństwa procesowego w reaktorach chemicznych, modelowaniem matematycznym związanym z pożarem strumieniowym i rozprzestrzenianiem się zanieczyszczeń.

DR INŻ. JAROSŁAW TĘPIŃSKI – w 2008 r. ukończył studia o specjalności Automatyka i Inżynieria Komputerowa na Wydziale Elektrycznym Politechniki Warszawskiej. Na tym samym wydziale w 2016 r. uzyskał stopień naukowy doktora nauk technicznych. Obecnie jest adiunktem w Centrum Naukowo-Badawczym Ochrony Przeciwożarowej – Państwowym Instytucie Badawczym w Józefowie. Specjalność – elektrotechnika, automatyka oraz techniczne systemy zabezpieczeń przeciwpożarowych.