



Michał MAZUR ORCID 0000-0003-2208-3057, michal.mazur@wat.edu.pl – corresponding author

Michał WIŚNIOŚ ORCID 0000-0003-4642-9585, michal.wisnios@wat.edu.pl

Jacek PAŚ ORCID 0000-0001-8900-1445, jacek.pas@wat.edu.pl

Military University of Technology (Wojskowa Akademia Techniczna)

ANALYSIS OF THE POSSIBILITY OF INCREASING THE LEVEL OF RELIABILITY OF FIRE ALARMS SYSTEMS THROUGH INTEGRATION WITH VIDEO-BASED FLAME DETECTION SYSTEM

Analiza możliwości zwiększenia poziomu niezawodności systemów sygnalizacji pożaru poprzez integrację z systemem wizyjnej detekcji płomienia

Abstract: *Classic Fire Alarm Systems (FAS) are characterized by a high level of false alarms in relation to the number of confirmed reports. To increase the level of reliability of operation of this type of system, it was proposed to integrate it with a Video-Based Flame Detection System (VBFDS). For this purpose, a video-based fire detection algorithm was designed. In addition, methods popular in the literature for increasing the reliability of such systems, such as color filtering, the Tracking Growth Object (TGO) factor, and the use of the Naive-Bayes (NB) classifier, were tested. The purpose of the article is to analyze these methods in comparison with the basic version of the algorithm, as well as the possibility of integrating Video-Based Flame Detection System (VBFDS) with classic FAS.*

Keywords: fire alarm systems, neural networks, video-based flame detection

Streszczenie: *Klasyczne Systemy Sygnalizacji Pożaru (SSP) charakteryzują się wysokim poziomem fałszywych alarmów w stosunku do liczby potwierdzonych zgłoszeń. Aby zwiększyć poziom niezawodności działania tego typu systemów, zaproponowano jego integrację z Systemem Wizyjnej Detekcji Płomienia (SWDP). W tym celu zaprojektowany został algorytm wizyjnej detekcji pożaru. Dodatkowo przetestowane zostały popularne w literaturze metody zwiększenia niezawodności tego typu systemów, takie jak filtracja kolorów, współczynnik TGO (ang. Tracking Growth Object) oraz zastosowanie*



klasyfikatora NB (ang. Naive-Bayes). Celem artykułu jest analiza tych metod w porównaniu z podstawową wersją algorytmu oraz możliwość integracji SWDP z klasycznymi SSP.

Słowa kluczowe: systemy sygnalizacji pożaru, sieci neuronowe, wizyjna detekcja płomienia

Received: April 19, 2024/ Revised: May 24, 2024/ Accepted: June 6, 2024/ Published: June 28, 2024

1. Introduction

According to PKN-CEN/TS 54-14:2020-09, false alarms in Fire Alarm Systems (FAS) are alarms resulting from phenomena other than fire. Examples of such phenomena include:

- phenomena resembling fire (e.g., dust in the room, fog),
- environmental impact (e.g., rain condensation),
- malicious - intentionally causing a fire (known as sabotage),
- initiating a good-faith alarm through misinterpretation,
- failure of the FAS, detection loop or monitoring circuit of the building or floor,
- improper operation and maintenance of the FAS.

According to Statistics Poland data [1], the share of false alarms related to FAS was 42.7% of all false fire alarms in Poland in 2021. The Statistics Poland also released data on actual fire alarms, i.e. incidents requiring action to limit the spread of a fire after emergency services arrive on the scene. In this case, the share of alarms originating from the FAS was only 1.3% of all actual fire alarms.

Classical FASs are characterized by a high level of false alarms in relation to the number of confirmed calls [2]. In order to increase the level of reliability of operation of this type of system, its integration with a system based on a physically separated method of detection of one of the symptoms of fire has been proposed.

2. Literature

The problem of increasing the reliability of Video-Based Fire Detection System (VBFDS) is popular and has been addressed in many articles. In the article [3], the authors note that the vast majority of the analyzed algorithms for video-based fire detection are based on the SVM (Support-Vector Machine) classifier. The method proposed in the mentioned article to increase the reliability of VBFDS is based on changing the popular SVM classifier to a Naive-Bayes (NB) classifier. According to the authors, the NB classifier requires less learning data, is faster, and is less susceptible to phenomena that

are not fire-related but can cause a false alarm in VBFDS, such as sunlight reflections through shiny surfaces, light sources ranging from yellow to red, or moving non-matt objects.

The authors in the paper [4] suggest an algorithm in which detection is supported by the TGO (Tracking Growth Object) factor. The innovation is that the fire is a stationary phenomenon and does not change its position, while it can spread. The algorithm with this method will ignore objects that change position in the image (e.g., car lights) and will prioritize objects or phenomena that do not change their position but occupy more and more space in the analyzed image over time.

The authors of the article [5] focused on color analysis to increase the unreliability of VBFDS. The article touches on a method for pre-filtering the algorithm's input data against color. It involves a preliminary analysis of images, in terms of the pixel values of which they are composed. The discussed method allows to reject images whose pixel values are not within a certain range. This makes it possible to filter out phenomena with high light intensity, but with a color other than that of the flame (e.g., sunlight reflections).

3. Methodology

The research used a video-based flame detection algorithm that uses deep learning techniques to detect flames in images from, for example, building video surveillance cameras [6,7]. The algorithm is based on the Convolutional Neural Network (CNN) CIFAR-10 and learned using the Transfer Learning (TL) method[6,7,8]. In addition, three methods for reducing the number of false alarms in VBFDS found in the literature were tested. The first method is the so-called Color Filtration (CF) [9,10]. It involves pre-filtering the algorithm's input data in terms of sub-pixel values. The second method is the use of a Tracking Growth Object (TGO) coefficient, whose role is to track objects that could potentially be a growing fire [11,12]. The last method is the use of the Naive Bayes (NB) classifier, which in theory requires less learning data and is more accurate at feature extraction compared to the Support-Vector Machine (SVM) classifier used by default [13,14]. Tests of the algorithm were conducted on a database consisting of 2,000 images, 1,000 containing scenes that replicate fire, as well as 1,000 containing no flame. The parameters of the algorithm were calculated using an error matrix.

The input data (2,000 images) is analyzed by the algorithm for the presence of flame. Figure 1 shows the structure of the neural network used. The features of the images are extracted using spline operations in the initial layers of the network (conv layers), then nonlinearity is introduced into the resulting feature matrix (relu layers) and the maximum values of the matrix are extracted (maxpool layers). Then the matrix values are given weights (fc layers) and are classified (softmax and classoutput layers). If the algorithm

detects a flame with a probability of 98% or higher, a frame is applied to the image indicating the area where the flame is located, and the entire image is saved in a folder dedicated to images with positive detection. If the algorithm does not detect the flame, the image without any changes is saved in the folder for negative detection. The parameters of the algorithm were calculated using an error matrix.

The workstation used for testing is equipped with 16Gb of RAM and Windows 10 operating system. The algorithm signals detection when the probability of correct classification exceeds 98%.

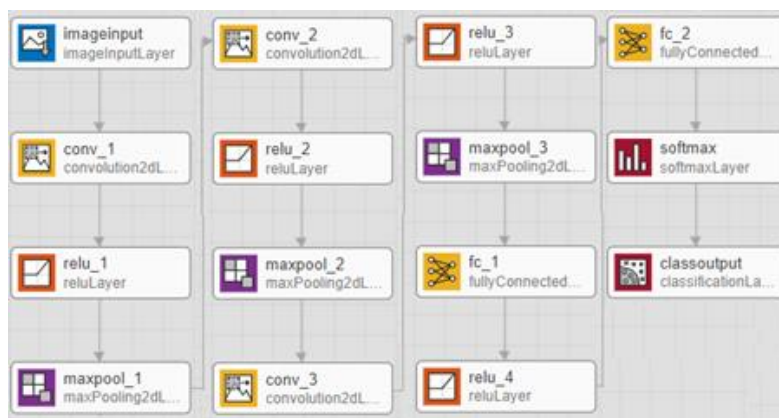


Fig. 1. Neural network layers

4. Results

Finally, the algorithm in the conducted test achieved a maximum efficiency of 87%. The presented solution can contribute to increasing the reliability as well as reducing the detection time in classical Fire Alarm Systems.

Table 1

Test results of the basic version of the algorithm

TP	TN	FN	FP
681	846	319	154

$$TPR = \frac{TP}{TP+FN} = \frac{681}{681+319} = 0,681 \quad (1)$$

$$PPV = \frac{TP}{TP+FP} = \frac{681}{681+154} = 0,816 \quad (2)$$

$$ACC = \frac{TP+TN}{TP+FN+FP+TN} = \frac{1527}{2000} = 0,764 \quad (3)$$

Table 1 shows the test results of the basic version of the network, i.e. without implemented false alarm reduction methods. Parameters such as sensitivity (TPR), precision (PPV) and accuracy (ACC) were determined [15]. Cases of detection or lack thereof were classified as follows:

- TP (True Positive) - there is a flame in the image, the algorithm correctly detects and indicates its position,
- TN (True Negative) - no flame in the image, the algorithm does not signal detection,
- FN (False Negative) - the image contains a flame, the algorithm does not signal detection,
- FP (False Positive) - the image does not contain a flame, the algorithm signals detection and points to an object other than a flame.

Analogous to Table 1, Table 2 shows the results of the algorithm test, in this case with implemented methods for reducing the number of false alarms in the SWDP.

Table 2

Effectiveness of the tested methods

	TP	TN	FN	FP
CF	800	946	200	54
TGO	760	956	240	44
NB	715	805	285	195

$$\begin{array}{lll}
 TPR_{CF} = 0,800 & TPR_{TGO} = 0,760 & TPR_{NB} = 0,715 \\
 PPV_{CF} = 0,937 & PPV_{TGO} = 0,945 & PPV_{NB} = 0,786 \\
 ACC_{CF} = 0,873 & ACC_{TGO} = 0,858 & ACC_{NB} = 0,760
 \end{array}$$

Two of the three methods of reducing the number of false alarms in VBFDS, i.e. color filtering and the TGO coefficient, proved to be particularly important in improving the overall performance of the tested algorithm.



Fig. 2. Example of database image



Fig. 3. Figure 2 after color filtering (True Positive)




Fig. 4. The case of False Positive

Figures 2 and 3 show an example of correct detection using the color filtering method. Figure 2 shows an example of an input image from the database used. Figure 3 is the same image as Figure 2, but after color filtering and after analysis by the algorithm. The image shows an applied frame indicating (correctly in this case) the location of the flame. Figure 4 shows a case of False Positive, or false alarm.

The color filtering method proved to be the most effective in raising the overall detection performance of the algorithm. Compared to the basic version, accuracy increased by 11.3%. TGO saw a 9.8% increase, while NB saw a 0.4% decrease. The results of each method are shown in Figure 5.

The color filtering method is the easiest method to implement and requires the least computing power. The TGO method, despite also being efficient, significantly increases the overall required computing power of the algorithm, which, depending on the unit on which the algorithm will be implemented, can make a big difference [16,17].

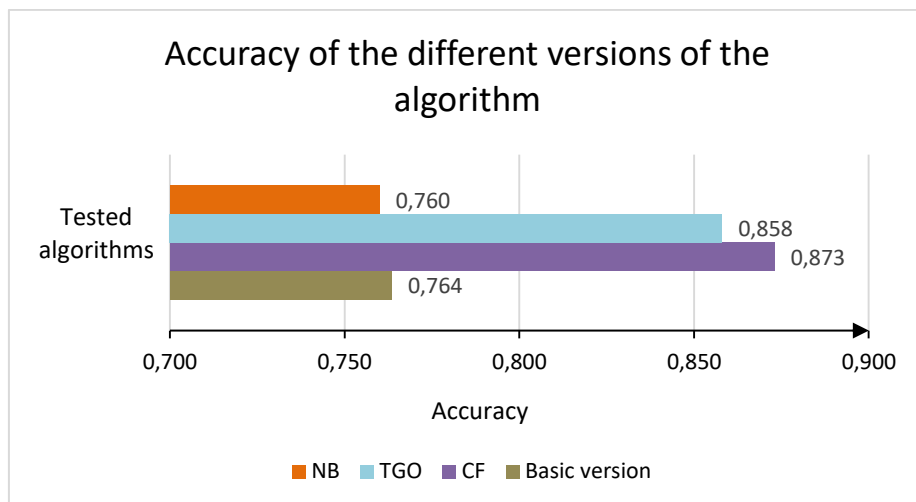


Fig. 5. Accuracy of the basic version of the algorithm and methods used to reduce false alarms

5. Conclusions and summary

The presented test results suggest that it is possible to integrate the developed solution with fire alarm systems. Due to its high sensitivity and susceptibility to false alarms, it is suggested that the VBFDS be implemented in the FAS as an early detection module, during the initial stage of a fire, with a maximum first alarm stage[18,19]. With this procedure, we get the possibility to increase the level of reliability of the innovative integrated fire alarm system by using video-based fire detection as an early warning system while eliminating its biggest drawback[20,21].

By fusing Vbfd with classic FAS, the resultant sensitivity of the FAS will be significantly increased, due to the ability to detect a fire at its very early stage, before combustion products such as smoke or fire-related phenomena such as temperature rise appear and are detected by fire detectors. In addition, depending on the substance being burned, the combustion process may not emit smoke, so that optical smoke detectors (the most common detectors used in FAS), may not detect the threat or detect it with a long delay. Such a situation is unlikely to occur if the FAS is integrated with Vbfd, which detect flame based on optical analysis.



Fig. 6. Example of SWDP implementation in hall monitoring

In addition, if the facility currently has a video surveillance system, it is possible to implement the presented solution in the existing monitoring, without integration into the physical structure of the fire alarm system, by implementing the algorithm at the same station as the monitoring software, as shown in Figure 6.

Fusion of the classic FAS with VBFD is possible and beneficial from the perspective of overall system reliability. In the future, the authors plan further research into the integration of the two systems and the addition of spectrophotometric analysis to the classic FAS.

6. References

1. <https://stat.gov.pl/obszary-tematyczne/zdrowie/zdrowie/dzialalnosc-sluzb-ratowniczych-w-2021-roku,17,5.html>, Główny Urząd Statystyczny, 2021, accessible 08/08/2022.
2. T. Klimczak, J. Paś, S. Duer, A. Rosiński, P. Wetoszka, K. Białek and M. Mazur, „Selected Issues Associated with the Operational and Power Supply Reliability of Fire Alarm Systems”, *Energies* 2022, 15(22), 8409; DOI: 10.3390/en15228409.
3. <http://www.ijsrp.org/research-paper-0813.php?rp=P201579>, Federal Institute of Science and Technology, Angmaly 2020 [Accesed Jun. 10, 2023].
4. Y. Lee, J. Shim, “False Positive Decrement Research for Fire and Smoke Detection in Surveillance Camera using Spatial and Temporal Features Based on Deep Learning”, Andong National University, Andong 2019, DOI: 10.3390/electronics8101167.

5. A. Khalil, S.U. Rahman, F. Alam, I. Khalil, “Fire Detection Using Multi Color Space and Background Modeling”, University of Malakand, Pakistan 2020, DOI: 10.1007/s10694-020-01030-9.
6. X. Zhang, K. Qian, K. Jing, J. Yang, and H. Yu, “Fire Detection based on Convolutional Neural Networks with Channel Attention”, Chinese Automation Congress, China, 2020, DOI: 10.1109/CAC51589.2020.9327309.
7. T. Chen, X. Guo, J. Jia, and F. Xiao, “Frequency and Phase Characteristics of Candle Flame Oscillation”, *Nature*, 2019, DOI: 10.1038/s41598-018-36754-w.
8. J. Paś, T. Klimczak, A. Rosiński, et al. „The analysis of the operational process of a complex fire alarm systems used in transport facilities”, *Build. Simul.* 15, 615-629 (2022). DOI: 10.1007/s12273-021-0790-y.
9. J. Antos, M. Basiak, and D. Kręciwilk, “Influence of false fire alarms on the effectiveness of the fire monitoring system”, Częstochowa 2016, DOI: 10.15199/48.2016.02.48.
10. P. Karasev, I. Kolesov, and A. Tannenbaum, “Optical Flow Estimation for Flame Detection in Videos”, *IEEE Transactions on Image Processing*, 2013, DOI: 10.1109/TIP.2013.2258353.
11. J. Paś, A. Rosiński, M. Wiśnios, and M. Stawowy, “Assessing the Operation System of Fire Alarm Systems for Detection Line and Circuit Devices with Various Damage Intensities”, *Energies* 2022, 15, 3066. DOI: 10.3390/en15093066.
12. P.V. Almeida, T.M. Rezende, A.C. Lisboa, and A.V. Barbosa, “Fire Detection based on Two-Dimensional Convolutional Neural Network and Temporal Analysis”, 7th IEE LA-CCI, Temuco 2021, DOI: 10.1109/LA-CCI48322.2021.9769824.
13. A. Żyłuk, M. Zieja, A. Szelmanowski, J. Tomaszewska, M. Perlińska, and K. Głyda, „Electrical Disturbances in Terms of Methods to Reduce False Activation of Aerial Fire Protection Systems”, *Sensors* 2022, 22(20), 8059, DOI: 10.3390/s22208059.
14. S. Gupta, S. Kanwar, and M. Kashyap, “Performance characteristics and assessment of fire alarm system”. *Mater. Today Proc.* 2022, 57, 2036–2040, DOI: 10.1016/j.matpr.2021.11.184.
15. K. Liu, “An optimization of intelligent fire alarm system for high-rise building based on ANASYS.” In: *Intelligence Computation and Evolutionary Computation*; Du, Z., Ed., Springer: Berlin/Heidelberg, Germany, 2013; pp. 415–421. DOI: https://doi.org/10.1007/978-3-642-31656-2_59.
16. E. Hulida, I. Pasnak, O. Koval, and A. Tryhuba, „Determination of the Critical Time of Fire in the Building and Ensure Successful Evacuation of People.” *Period. Polytech. Civ. Eng.* 2019, 63, 308–316, DOI: 10.3311/PPci.12760.

17. H. Zhao, A. Schwabe, F. Schläfli, T. Thrash, L. Aguilar, R.K. Dubey, J. Karjalainen, C. Hölscher, D. Helbing, V.R. Schinazi, “Fire evacuation supported by centralized and decentralized visual guidance systems.” *Saf. Sci.* 2022, 145, 105451, DOI: 10.1016/j.ssci.2021.105451.
18. E. Shaw, T. Roper, T. Nilsson, G. Lawson, S.V. Cobb, and D. Miller, „The heat is on: Exploring user behaviour in a multisensory virtual environment for fire evacuation.” In Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems, Glasgow, Scotland, 4–9 May 2019; pp. 1–13, DOI: 10.1145/3290605.3300856.
19. M.A. Rahman, S.T. Hasan, and M.A. Kader, „Computer Vision Based Industrial and Forest Fire Detection Using Support Vector Machine (SVM).” In Proceedings of the 2022 International Conference on Innovations in Science, Engineering and Technology (ICISSET), Chittagong, Bangladesh, 26–27 February 2022; pp. 233–238, DOI: 10.1109/ICISSET54810.2022.9775775.
20. J. Valouch, „Integrated alarm systems. In Computer Applications for Software Engineering, Disaster Recovery, and Business Continuity;” Series: Communications in Computer and Information Science XVIII; Springer: Berlin/Heidelberg, Germany, 2012; Volume 340, pp. 369–379, DOI: 10.1007/978-3-642-35267-6_49.
21. S. Duer, K. Zajkowski, M. Harničárová, H. Charun, and D. Bernatowicz, „Examination of Multivalent Diagnoses Developed by a Diagnostic Program with an Artificial Neural Network for Devices in the Electric Hybrid Power Supply System “House on Water”. *Energies* 2021, 14, 2153, DOI: 10.3390/en14082153.

ANALIZA MOŻLIWOŚCI ZWIĘKSZENIA POZIOMU NIEZAWODNOŚCI SYSTEMÓW SYGNALIZACJI POŻARU POPRZEZ INTEGRACJĘ Z SYSTEMEM WIZYJNEJ DETEKCJI PŁOMIENIA

1. Wprowadzenie

Zgodnie z normą PKN-CEN/TS 54-14:2020-09 fałszywe alarmy w Systemach Sygnalizacji Pożaru (SSP) to alarmy wynikające ze zjawisk innych niż pożar. Przykłady takich zjawisk obejmują:

- zjawiska przypominające pożar (np. kurz w pomieszczeniu, mgła),
- wpływ środowiska naturalnego (np. kondensacja deszczu),
- celowe wywołanie pożaru (tzw. sabotaż),
- zainicjowanie alarmu w dobrej wierze poprzez np. błędną interpretację,
- awaria SSP, pętli detekcyjnej lub obwodu monitorującego budynek lub piętro,
- nieprawidłowa obsługa i konserwacja SSP.

Według danych GUS [1], udział fałszywych alarmów związanych z SSP wyniósł 42,7% wszystkich fałszywych alarmów pożarowych w Polsce w 2021 r. GUS udostępnił również dane dotyczące rzeczywistych alarmów pożarowych, tj. zdarzeń wymagających podjęcia działań mających na celu ograniczenie rozprzestrzeniania się pożaru po przybyciu służb ratunkowych na miejsce zdarzenia. W tym przypadku udział alarmów pochodzących z SSP wyniósł zaledwie 1,3% wszystkich rzeczywistych alarmów pożarowych.

Klasyczne SSP charakteryzują się wysokim poziomem fałszywych alarmów w stosunku do liczby potwierdzonych zgłoszeń [2]. Aby zwiększyć poziom niezawodności działania tego typu systemów zaproponowano jego integrację z systemem bazującym na fizycznie odseparowanej metodzie detekcji jednego z symptomów pożaru.

2. Przegląd literatury

Problematyka zwiększenia niezawodności Systemów Wizyjnej Detekcji Płomienia (SWDP) jest popularna i poruszana w wielu artykułach. W artykule [3] autorzy zauważają, że znaczna większość analizowanych algorytmów wizyjnej detekcji pożaru opiera się na klasyfikatorze SVM (ang. Support-Vector Machine). Zaproponowana we

wspominanym artykule metoda zwiększenia niezawodności SWDP opiera się na zmianie popularnego klasyfikatora SVM na klasyfikator NB (ang. Naive-Bayes). Według autorów klasyfikator NB wymaga mniejszej liczby danych uczących, jest szybszy oraz mniej podatny na zjawiska, które nie są związane z pożarem, a mogą spowodować fałszywy alarm w SWDP, takie jak odbicia światła słonecznego przez połyskliwe powierzchnie, źródła światła o barwie z zakresu od żółtego do czerwonego lub ruchome niemiatowe obiekty.

Autorzy w opracowaniu [4] sugerują algorytm, w którym detekcja jest wspierana współczynnikiem TGO (ang. Tracking Growth Object). Innowacja polega na tym, że pożar jest zjawiskiem nieruchomym i nie zmienia swojego położenia, natomiast może się rozprzestrzeniać. Algorytm z tą metodą będzie ignorował obiekty, które zmieniają położenie na obrazie (np. światła samochodów) i będzie priorytetował obiekty lub zjawiska, które nie zmieniają swojego położenia, ale z upływem czasu zajmują coraz więcej miejsca na analizowanym obrazie.

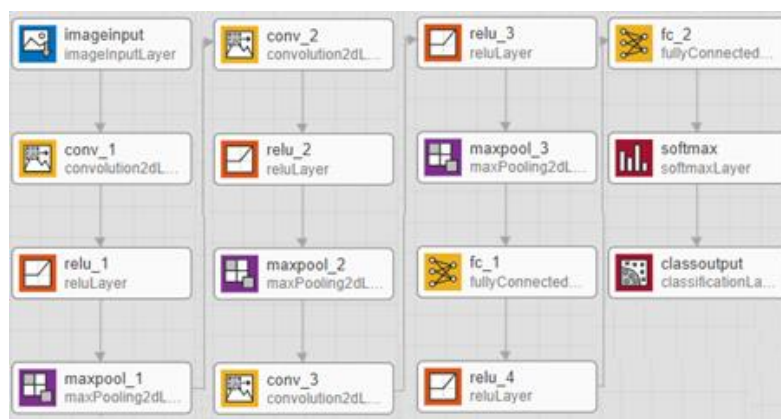
Autorzy artykułu [5] skupili się na analizie barw w celu zwiększenia niezawodności SWDP. Artykuł porusza metodę wstępnej filtracji danych wejściowych algorytmu względem barwy. Polega ona na wstępnej analizie obrazów, pod kątem wartości pikseli, z których się składa. Omawiana metoda pozwala na odrzucenie obrazów, których wartości pikseli nie zawierają się w określonym przedziale. Pozwala to filtrować zjawiska o wysokim natężeniu światła, ale o barwie innej niż barwa płomienia (np. odbicia światła słonecznego).

3. Metodologia

Do badań wykorzystany został algorytm wizyjnej detekcji płomienia, który wykorzystuje techniki głębokiego uczenia do detekcji płomienia na obrazach pochodzących np. z budynkowych kamer monitoringu wizyjnego [6,7]. Algorytm oparty jest na konwolucyjnej sieci neuronowej (ang. Convolutional Neural Network, CNN) CIFAR-10 i nauczony metodą „uczenie przez przeniesienie” (ang. Transfer Learning, TL) [6,7,8]. Dodatkowo przetestowane zostały trzy metody redukcji liczby fałszywych alarmów w SWDP, opisane w literaturze. Pierwszą metodą jest tzw. filtracja kolorów (ang. Color Filtration, CF) [9,10]. Polega ona na wstępnej filtracji danych wejściowych algorytmu pod względem wartości subpikseli. Drugą metodą jest zastosowanie współczynnika TGO (ang. Tracking Growth Object, TGO) do śledzenia obiektów, które potencjalnie mogą być rozwijającym się pożarem [11,12]. Ostatnią metodą jest zastosowanie klasyfikatora NB (ang. Naive Bayes, NB), który w teorii wymaga mniejszej liczby danych uczących oraz jest bardziej precyzyjny przy ekstrakcji cech w porównaniu do zastosowanego domyślnie klasyfikatora SVM (ang. Support-Vector Machine)[13,14].

Test algorytmu został przeprowadzony na bazie danych składającej się z 2000 obrazów, 1000 zawierających sceny reprezentujące pożar, jak i 1000 niezawierających płomienia. Dane wejściowe (2000 obrazów) są analizowane przez algorytm pod względem obecności płomienia. Rysunek 1 przedstawia strukturę wykorzystanej sieci neuronowej. Cechy obrazów są ekstraktowane za pomocą operacji splotu w początkowych warstwach sieci (warstwy conv), następnie do uzyskanej macierzy cech wprowadzana jest nieliniowość (warstwy relu) i ekstrahowane są maksymalne wartości macierzy (warstwy maxpool). Następnie wartościom macierzy nadawane są wagi (warstwy fc) i zostają poddawane klasyfikacji (warstwa softmax i classoutput). Jeśli algorytm wykryje płomień z prawdopodobieństwem 98% lub wyższym, na obraz zostaje naniesiona ramka wskazująca obszar, na którym znajduje się płomień, a cały obraz jest zapisywany w folderze dedykowanym dla obrazów z pozytywną detekcją. Jeśli algorytm nie wykryje płomienia, obraz bez żadnych zmian jest zapisywany w folderze dla detekcji negatywnej. Parametry algorytmu zostały obliczone z wykorzystaniem macierzy błędów.

Stanowisko wykorzystane do badań wyposażone jest w 16 Gb pamięci RAM oraz system operacyjny Windows 10.



Rys. 1. Warstwy sieci neuronowej

4. Wyniki

Finalnie algorytm w przeprowadzonym badaniu osiągnął maksymalną skuteczność na poziomie 87%. Przedstawione rozwiązanie może przyczynić się do zwiększenia niezawodności, jak i skrócenia czasu detekcji w klasycznych Systemach Sygnalizacji Pożaru.

Tabela 1

Wyniki testu

TP	TN	FN	FP
681	846	319	154

$$TPR = \frac{TP}{TP+FN} = \frac{681}{681+319} = 0,681 \quad (1)$$

$$PPV = \frac{TP}{TP+FP} = \frac{681}{681+154} = 0,816 \quad (2)$$

$$ACC = \frac{TP+TN}{TP+FN+FP+TN} = \frac{1527}{2000} = 0,764 \quad (3)$$

Tabela 1 zawiera wyniki testu podstawowej wersji (ang. basic version) sieci, tzn. bez zaimplementowanych metod redukcji fałszywych alarmów. Zdeterminowano takie parametry jak czułość (ang. sensitivity, TPR), precyzja (ang. precision, PPV) i dokładność (ang. accuracy, ACC) [15]. Przypadki detekcji lub jej braku sklasyfikowano następująco:

- TP (ang. True Positive) – na obrazie znajduje się płomień, algorytm poprawnie wykrywa i wskazuje jego położenie,
- TN (ang. True Negative) – brak płomienia na obrazie, algorytm nie sygnalizuje detekcji,
- FN (ang. False Negative) – obraz zawiera płomień, algorytm nie sygnalizuje detekcji,
- FP (ang. False Positive) – obraz nie zawiera płomienia, algorytm sygnalizuje detekcję i wskazuje na obiekt inny niż płomień.

Analogicznie jak w przypadku tabeli 1, tabela 2 przedstawia wyniki testu algorytmu, w tym przypadku z zaimplementowanymi metodami redukcji liczby fałszywych alarmów w SWDP.

Tabela 2

Skuteczność badanych metod

	TP	TN	FN	FP
CF	800	946	200	54
TGO	760	956	240	44
NB	715	805	285	195

$$TPR_{CF} = 0,800 \quad TPR_{TGO} = 0,760 \quad TPR_{NB} = 0,715$$

$$PPV_{CF} = 0,937 \quad PPV_{TGO} = 0,945 \quad PPV_{NB} = 0,786$$

$$ACC_{CF} = 0,873 \quad ACC_{TGO} = 0,858 \quad ACC_{NB} = 0,760$$


Dwie z trzech metod redukcji liczby fałszywych alarmów w SWDP, tzn. filtracja kolorów oraz współczynnik TGO, okazały się szczególnie istotne w ogólnym podniesieniu skuteczności badanego algorytmu.



Rys. 2. Przykładowy obraz z bazy danych



Rys. 3. Zdjęcie z rys. 2 po filtracji kolorów (True Positive)

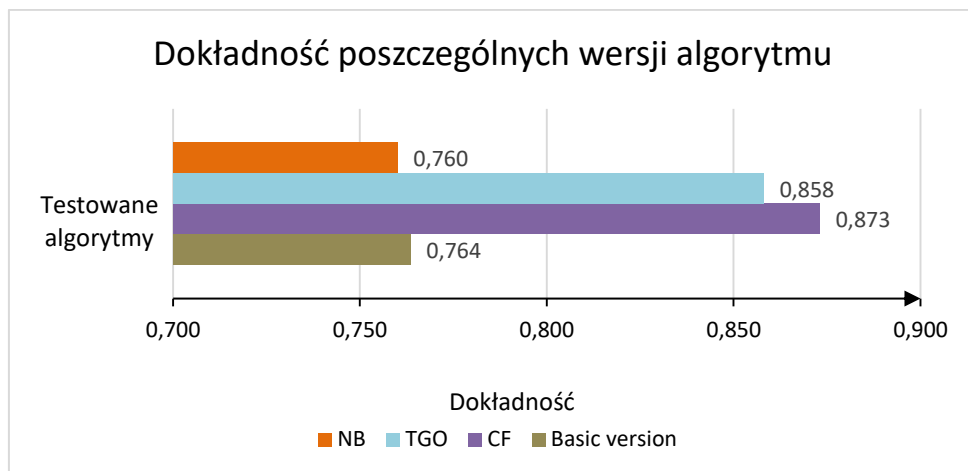


Rys. 4. Przypadek False Positive

Rysunki 2 i 3 przedstawiają przykład poprawnej detekcji z wykorzystaniem metody filtracji kolorów. Rysunek 2 przedstawia przykładowy obraz wejściowy z wykorzystanej bazy danych. Rysunek 3 to ten sam obraz, co na rys. 2, jednak po filtracji kolorów i po analizie przez algorytm. Na obrazie jest widoczna naniesiona ramka wskazująca (w tym przypadku poprawnie) miejsce płomienia. Rysunek 4 pokazuje przypadek False Positive, czyli fałszywy alarm.

Metoda filtracji kolorów okazała się najskuteczniejsza w podnoszeniu ogólnej skuteczności detekcji algorytmu. W porównaniu do podstawowej wersji, dokładność wzrosła o 11,3%. W przypadku TGO obserwujemy wzrost o 9,8%, a w przypadku NB spadek o 0,4%. Wyniki poszczególnych metod zostały przedstawione na rys. 5.

Metoda filtracji kolorów jest metodą najłatwiejszą do implementacji oraz wymaga najmniejszej mocy obliczeniowej. Metoda TGO, mimo że również jest skuteczna, znacznie zwiększa ogólną wymaganą moc obliczeniową algorytmu, co w zależności od jednostki na której implementowany będzie algorytm, może mieć duże znaczenie [16,17].



Rys. 5. Dokładność podstawowej wersji algorytmu oraz metod redukujących liczbę fałszywych alarmów

5. Wnioski i podsumowanie

Przedstawione wyniki badań sugerują, że istnieje możliwość integracji opracowanego rozwiązania z systemami sygnalizacji pożaru. Ze względu na wysoką czułość oraz podatność na fałszywe alarmy, sugeruje się, aby SWDP był implementowany w SSP jako moduł wczesnej detekcji, podczas początkowego stadium pożaru, z maksymalnie pierwszym stopniem alarmowym [18,19]. Dzięki takiemu zabiegowi uzyskujemy możliwość zwiększenia poziomu niezawodności innowacyjnego zintegrowanego systemu sygnalizacji pożaru, dzięki zastosowaniu wizyjnej detekcji pożaru jako systemu wczesnego ostrzegania, jednocześnie eliminując jego największą wadę [20,21].

Poprzez fuzję SWDP z klasycznymi SSP, wypadkowa czułość SSP zostanie znacznie zwiększona, ze względu na możliwość detekcji pożaru na jego bardzo wczesnym etapie, zanim pojawią się produkty spalania takie jak dym lub zjawiska związane z pożarem takie jak wzrost temperatury i zostaną wykryte przez czujki pożarowe. Ponadto w zależności od spalanej substancji, proces spalania może nie emitować dymu, co sprawi, że optyczne czujki dymu (najpopularniejsze czujki wykorzystywane w SSP) mogą nie wykryć zagrożenia lub wykryć je z dużym opóźnieniem. Wystąpienie takiej sytuacji jest mało prawdopodobne, jeśli SSP zostanie zintegrowany z SWDP, które wykrywają płomień na podstawie analizy optycznej.



Rys. 6. Przykład implementacji SWDP w monitoringu sali

Jeśli w obiekcie aktualnie znajduje się system monitoringu wizyjnego, istnieje możliwość implementacji przedstawionego rozwiązania w istniejącym monitoringu, bez integracji w fizyczną strukturę systemu sygnalizacji pożaru, przez wdrożenie algorytmu na tym samym stanowisku co oprogramowanie monitoringu, jak przedstawia to rys. 6.

Fuzja klasycznego SSP z SWDP jest możliwa i korzystna z perspektywy ogólnej niezawodności systemu. W przyszłości autorzy planują dalsze badania nad integracją tych dwóch systemów oraz dodaniem analizy spektrofotometrycznej do klasycznych SSP.

6. Literatura

1. <https://stat.gov.pl/obszary-tematyczne/zdrowie/zdrowie/dzialalnosc-sluzb-ratowniczych-w-2021-roku,17,5.html>, Główny Urząd Statystyczny, 2021, accesible 08/08/2022.
2. T. Klimczak, J. Paś, S. Duer, A. Rosiński, P. Wetoszka, K. Białek and M. Mazur, „Selected Issues Associated with the Operational and Power Supply Reliability of Fire Alarm Systems”, *Energies* 2022, 15(22), 8409; DOI: 10.3390/en15228409.
3. <http://www.ijsrp.org/research-paper-0813.php?rp=P201579>, Federal Institute of Science and Technology, Angmaly 2020 [Accesed Jun. 10, 2023].
4. Y. Lee, J. Shim, “False Positive Decremental Research for Fire and Smoke Detection in Surveillance Camera using Spatial and Temporal Features Based on Deep Learning”, Andong National University, Andong 2019, DOI: 10.3390/electronics8101167.

5. A. Khalil, S.U. Rahman, F. Alam, I. Khalil, “Fire Detection Using Multi Color Space and Background Modeling”, University of Malakand, Pakistan 2020, DOI: 10.1007/s10694-020-01030-9.
6. X. Zhang, K. Qian, K. Jing, J. Yang, and H. Yu, “Fire Detection based on Convolutional Neural Networks with Channel Attention”, Chinese Automation Congress, China, 2020, DOI: 10.1109/CAC51589.2020.9327309.
7. T. Chen, X. Guo, J. Jia, and F. Xiao, “Frequency and Phase Characteristics of Candle Flame Oscillation”, *Nature*, 2019, DOI: 10.1038/s41598-018-36754-w.
8. J. Paś, T. Klimczak, A. Rosiński, et al. „The analysis of the operational process of a complex fire alarm systems used in transport facilities”, *Build. Simul.* 15, 615-629 (2022). DOI: 10.1007/s12273-021-0790-y.
9. J. Antos, M. Basiak, and D. Kręciwilk, “Influence of false fire alarms on the effectiveness of the fire monitoring system”, *Częstochowa* 2016, DOI: 10.15199/48.2016.02.48.
10. P. Karasev, I. Kolesov, and A. Tannenbaum, “Optical Flow Estimation for Flame Detection in Videos”, *IEEE Transactions on Image Processing*, 2013, DOI: 10.1109/TIP.2013.2258353.
11. J. Paś, A. Rosiński, M. Wiśnios, and M. Stawowy, “Assessing the Operation System of Fire Alarm Systems for Detection Line and Circuit Devices with Various Damage Intensities”, *Energies* 2022, 15, 3066. DOI: 10.3390/en15093066.
12. P.V. Almeida, T.M. Rezende, A.C. Lisboa, and A.V. Barbosa, “Fire Detection based on Two-Dimensional Convolutional Neural Network and Temporal Analysis”, 7th IEE LA-CCI, Temuco 2021, DOI: 10.1109/LA-CCI48322.2021.9769824.
13. A. Żyluk, M. Zieja, A. Szelmanowski, J. Tomaszewska, M. Perlińska, and K. Głyda, „Electrical Disturbances in Terms of Methods to Reduce False Activation of Aerial Fire Protection Systems”, *Sensors* 2022, 22(20), 8059, DOI: 10.3390/s22208059.
14. S. Gupta, S. Kanwar, and M. Kashyap, “Performance characteristics and assessment of fire alarm system”. *Mater. Today Proc.* 2022, 57, 2036–2040, DOI: 10.1016/j.matpr.2021.11.184.
15. K. Liu, “An optimization of intelligent fire alarm system for high-rise building based on ANASYS.” In: *Intelligence Computation and Evolutionary Computation*; Du, Z., Ed., Springer: Berlin/Heidelberg, Germany, 2013; pp. 415–421. DOI: https://doi.org/10.1007/978-3-642-31656-2_59.
16. E. Hulida, I. Pasnak, O. Koval, and A. Tryhuba, „Determination of the Critical Time of Fire in the Building and Ensure Successful Evacuation of People.” *Period. Polytech. Civ. Eng.* 2019, 63, 308–316, DOI: 10.3311/PPci.12760.

17. H. Zhao, A. Schwabe, F. Schläfli, T. Thrash, L. Aguilar, R.K. Dubey, J. Karjalainen, C. Hölscher, D. Helbing, V.R. Schinazi, "Fire evacuation supported by centralized and decentralized visual guidance systems." *Saf. Sci.* 2022, 145, 105451, DOI: 10.1016/j.ssci.2021.105451.
18. E. Shaw, T. Roper, T. Nilsson, G. Lawson, S.V. Cobb, and D. Miller, „The heat is on: Exploring user behaviour in a multisensory virtual environment for fire evacuation.” In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, Glasgow, Scotland, 4–9 May 2019; pp. 1–13, DOI: 10.1145/3290605.3300856.
19. M.A. Rahman, S.T. Hasan, and M.A. Kader, „Computer Vision Based Industrial and Forest Fire Detection Using Support Vector Machine (SVM).” In *Proceedings of the 2022 International Conference on Innovations in Science, Engineering and Technology (ICISSET)*, Chittagong, Bangladesh, 26–27 February 2022; pp. 233–238, DOI: 10.1109/ICISSET54810.2022.9775775.
20. J. Valouch, „Integrated alarm systems. In *Computer Applications for Software Engineering, Disaster Recovery, and Business Continuity;*” Series: *Communications in Computer and Information Science XVIII*; Springer: Berlin/Heidelberg, Germany, 2012; Volume 340, pp. 369–379, DOI: 10.1007/978-3-642-35267-6_49.
21. S. Duer, K. Zajkowski, M. Harničárová, H. Charun, and D. Bernatowicz, „Examination of Multivalent Diagnoses Developed by a Diagnostic Program with an Artificial Neural Network for Devices in the Electric Hybrid Power Supply System “House on Water””. *Energies* 2021, 14, 2153, DOI: 10.3390/en14082153.