

# Lokalisierung von Flammen und Glut für das automatisierte Löschen von Bränden

Fabian Stoller<sup>1</sup>, Felix Kümmerlen<sup>2</sup> and Alexander Fay<sup>1</sup>

<sup>1</sup> Helmut-Schmidt-Universität, Institut für Automatisierungstechnik,  
Holstenhofweg 85, 22043 Hamburg

<sup>2</sup> Wehrwissenschaftliches Institut für Schutztechnologien –  
ABC-Schutz (WIS),  
Humboldtstraße 100, 29633 Munster

**Zusammenfassung** Die Zulassung von Feuerlöschern erfordert die Durchführung von Versuchen für den Nachweis der Löschfähigkeit eines Feuerlöschmodells. Damit dieser Versuch unabhängig von den Fähigkeiten menschlicher Löschmeister wird, soll die Durchführung automatisiert werden. Dafür sollen Algorithmen gefunden werden, die mithilfe einer Farb- und einer LWIR-Kamera Flammen und Glutnester lokalisieren können. Diese Informationen sollen genutzt werden, um den Löschversuch effektiv und effizient durchzuführen. Dafür werden in diesem Beitrag sechs Algorithmen zur Lokalisierung von Flammen in Farbbildern und drei Algorithmen zur Lokalisierung von Glut in den Bildern einer Infrarotkamera anhand der Kriterien Sensitivität, Falsch-Positiv-Rate, Intersection over Union und Ausführungsgeschwindigkeit verglichen, um jeweils einen passenden Algorithmus auszuwählen.

**Keywords** Lokalisierungsalgorithmen, Feuerlokalisierung, Glutdetektion

## 1 Einführung

Tragbare Feuerlöscher sind ein zentraler Bestandteil von Brandschutzmaßnahmen an Arbeitsstätten und im öffentlichen Nahverkehr. Die Menge an Feuerlöschern, die bereitzustellen ist, richtet sich

DOI: 10.58895/ksp/1000124383-15 erschienen in:

**Forum Bildverarbeitung 2020**

DOI: 10.5445/KSP/1000124383 | <https://www.ksp.kit.edu/site/books/m/10.58895/ksp/1000124383/>

zum einen nach der jeweiligen Brandgefahr und zum anderen nach den Eigenschaften des Feuerlöschers. In der DIN EN 3-7 [1] sind sowohl die Anforderungen an Feuerlöscher als auch deren Zertifizierung beschrieben. Für die Prüfung der Fähigkeit eines tragbaren Feuerlöschers, Brände der Brandklasse A (Feststoffe, die unter Bildung von Glut brennen [2], z. B. Holz) zu löschen, schreibt die angegebene Norm das Löschen eines Testobjekts mit definiertem Aufbau vor. Aktuell wird diese Prüfung von menschlichen Löschmeistern durchgeführt, die auf Basis langjähriger Erfahrung ihre Vorgehensweise beim Löschen des Testbrandes an die begrenzt verfügbare Menge an Löschmittel in einem Feuerlöscher angepasst haben. Damit sie das Feuer effektiv bekämpfen können, differenzieren sie zwischen Flammen und Glut und wenden verschiedene Löschtechniken an, um diese jeweils zu bekämpfen. Mit dem Ziel, die Vergleichbarkeit der Ergebnisse dieser Prüfung und somit die Qualität der Zertifizierung insgesamt zu verbessern, soll der Löschvorgang zur Zertifizierung von Feuerlöschern automatisiert werden. Dafür müssen Flammen und Glut in einem Brand mit geeigneten Bildverarbeitungs-Algorithmen erkannt werden. Auf Basis der mit diesen Algorithmen gewonnenen Informationen über den Brand werden Ziele und Zielbereiche vorgegeben, in denen das Löschmittel aufzubringen ist. Das Ziel dieser Arbeit ist es, Methoden zur Lokalisierung von Flammen und Glut vergleichend zu evaluieren, um so jeweils einen für das automatisierte Löschen eines Normbrandes geeigneten Algorithmus auszuwählen.

Diese Arbeit präsentiert in Abschnitt 2 den Stand der Forschung auf dem Gebiet der Feuerlokalisierung und der Glutlokalisierung. Anschließend werden anhand der Rahmenbedingungen des Normbrandversuchs relevante Kriterien für die Auswahl geeigneter Algorithmen hergeleitet. In Abschnitt 4 wird dann eine Vorauswahl an Algorithmen anhand der gefundenen Kriterien vergleichend bewertet und jeweils ein Algorithmus für die weitere Entwicklung eines Systems für die automatisierte Durchführung der Normbrandversuche ausgewählt.

## 2 Stand der Forschung

### 2.1 Lokalisierung von Flammen

Einen guten Überblick über die bis 2013 entwickelten Algorithmen zur Detektion von Feuer und Rauch bietet [3]. Die dort aufgeführten Algorithmen basieren auf einer Kombination mehrerer charakteristischer Eigenschaften von Flammen. Besonders relevant in diesem Zusammenhang ist die Farbe einer Flamme, die als häufigstes Kriterium zum Beispiel in [4–6] verwendet wird. Zusätzlich verwenden zum Beispiel die Algorithmen in [7–9] die zeitliche Veränderung der Form von Flammen oder die Unregelmäßigkeit ihrer Bewegung wie etwa in [10]. Diese unterscheidet sie von den meisten anderen beweglichen Objekten, da diese zumeist regelmäßige Bewegungsmuster haben. Für eine Lokalisierung hingegen wird die charakteristische Bewegung der Flamme kaum eingesetzt.

Die Algorithmen zur Lokalisierung von Feuer in Kamerabildern in [8, 11, 12] setzen verschiedene Formen farbbasierter Features ein. In [12] wird jedes Pixel mit einem naiven Bayes Klassifikator entweder der Klasse *Feuer* oder *kein Feuer* zugeordnet. Zusätzlich wird jedes Bild in Superpixel unterteilt, und diese werden anhand ihrer jeweiligen Texturen den genannten Klassen zugeordnet. In [11] werden die Pixel jedes Bildes anhand der Auftrittswahrscheinlichkeiten bestimmter Farbwerte in Flammen der Klasse *Feuer* zugeordnet. Dafür werden anhand von Trainingsdaten diese Auftrittswahrscheinlichkeiten bestimmt. Anschließend wird anhand der Entropie eine weitere Eigenschaft von Flammen überprüft, um die Fehldektionsrate zu verringern. Die in [8] für die Lokalisierung von Deflagrationen vorgestellte Methode setzt neben einem regelbasierten Kriterium für die Farben von Flammen und einem Kriterium für die Ausdehnung der als Flammen segmentierten Bereiche ein Hintergrundmodell ein.

Einige auf CNN basierenden Methoden setzen mit großen Bildsatzen vortrainierte CNNs ein, welche anhand vergleichsweise kleiner Datensätze mit domänenspezifischen Bildern auf die Lokalisierung von Flammen angepasst werden. Diese Vorgehensweise wird als Transferlernen bezeichnet. Ein solcher Ansatz wird zum Beispiel in [13] vorgestellt. Dort wird ein auf SqueezeNet [14] basierendes

CNN mit Hilfe von Bildern von Feuer auf die Flammenerkennung spezialisiert. Für die Lokalisierung wird eine Featuremap aus dem CNN als Maske verwendet. In [15] werden mehrere CNN für die Lokalisierung von Objekten mit Transferlernen auf Feuer spezialisiert. Von den dort vorgestellten Architekturen hat YOLO [16] die besten Resultate hervorgebracht. In [17] wird DeepLabv3 [18], ein CNN für die semantische Segmentierung von Feuer, mittels Transferlernen angepasst. Dieser Ansatz verspricht die Flammen am genauesten zu lokalisieren, ist aber zugleich auch der komplexeste Ansatz.

## 2.2 Lokalisierung von Glut

Die bildverarbeitungsbasierte Lokalisierung von Glut ist bisher kaum als dezidiertes Problem erforscht. Es existieren jedoch verschiedene Ansätze für sehr ähnliche Probleme. Ein Einsatzgebiet ist zum Beispiel die Lokalisierung von schwelenden Torfbränden mit Erdbeobachtungssatelliten. In [19] werden anhand der Daten eines Infrarotspektrometers die Bildbereiche ausgewählt, die Temperaturen im für schwelende Torfbrände typischen Bereich aufweisen. Dieser liegt deutlich unterhalb der Temperaturen von mit Flammen brennenden Bereichen und deutlich oberhalb der Umgebungstemperatur. Der relevante Temperaturbereich für Torfbrände unterscheidet sich von dem für glühendes Holz, die Lokalisierung kann aber auf die gleiche Art durchgeführt werden.

In [20] werden zwar keine Glutnester detektiert, allerdings lässt sich die Methode, die hier zur Detektion von Hotspots auf Photovoltaik-Anlagen eingesetzt wird, ebenso für die Detektion von heißen Stellen in einem gelöschten Brand einsetzen, also zur Identifikation von Glutnestern. Dabei setzen die Autoren auf den Einsatz von k-Means-Clustering, um Bereiche mit von der Umgebung stark abweichenden Temperaturen zu finden. Mit dieser Methode wird der große Temperaturunterschied zwischen Umgebung und dem Bereich von Interesse für eine Lokalisierung genutzt. Dieser Methode fehlt aber eine Berücksichtigung der absoluten Temperatur, sodass zu jedem Zeitpunkt zwei Temperaturcluster gesucht werden. Eine vergleichbare Vorgehensweise findet sich auf Kohlehalde, wo Schwelbrände lokalisiert werden sollen, die bei der Selbsterwärmung der Kohle entstehen können [21].

In [22] werden Brände mit einem Infrarotstereokamerapaar lokalisiert. Für die Identifikation von Pixeln wird ein Schwellwert für die Temperatur von  $T = 300^{\circ}\text{C}$  festgelegt, da Brände eine deutlich höhere Temperatur besitzen als der Hintergrund der Szene. Zusätzlich wurde die Annahme getroffen, dass es sich bei dem Feuer um den größten segmentierten Bereich in den Aufnahmen handelt. Da diese Schwelle jedoch sehr niedrig gewählt ist, werden so nicht nur Flammen, sondern auch Glutnester segmentiert.

### **3 Anforderungen an die Algorithmen zur Lokalisierung von Flammen und Glut**

Beim Normbrandversuch nach DIN EN 3-7 [1] gilt es, mit der vorhandenen Menge an Löschmittel einen möglichst großen Löscheffekt zu erzielen. Dafür muss das Löschmittel so appliziert werden, dass es dort wirkt, wo die Verbrennungsreaktion am intensivsten stattfindet. Diese Stellen sind zum einen die Flammen und zum anderen, sobald die Flammen gelöscht sind, die Glutnester. Eine Lokalisierung von Flammen und Glut soll mittels eines multimodalen Kameraverbands ermöglicht werden. Darin soll eine Farbkamera für die Lokalisierung der Flammen eingesetzt werden und eine Infrarotkamera für die Lokalisierung der Glutnester. Diese Aufteilung ist gewählt, da so die Möglichkeit besteht, beide Merkmale zu lokalisieren und zu unterscheiden. Die Unterscheidung ist erforderlich, um den Einsatz von Löschmittel entsprechend anzupassen und für die weniger heißen Glutnester auch entsprechend weniger Löschmittel einzusetzen.

Eine geeignete Methode lokalisiert die Flammen, bzw. die Glutnester, möglichst genau, um einen genauen Auftrag des Löschmittels auf die lokalisierten Stellen zu ermöglichen. Für die Bewertung dieses Kriteriums wird zum einen die Wahrscheinlichkeit bestimmt, dass der jeweils getestete Algorithmus eine Flamme erkennt. Dafür wird die Kerngröße der Sensitivität verwendet, deren Berechnung in Gleichung 3.1 beschrieben ist. Sie ist der Quotient aus richtig positiven

(RP) Detektionen und der Summe dieser mit den falsch negativen Detektionen (FN).

$$s = \frac{RP}{FN + RP} \quad (3.1)$$

Zum anderen wird für die korrekt erkannten Flammen bestimmt, wie genau die Lokalisierung ist. Dafür werden die Bounding Boxen der lokalisierten Flammen mit den in den Grundwahrheiten hinterlegten Bounding Boxen verglichen. Die Intersection over Union (IOU) ist der in Gleichung 3.2 dargestellte Quotient aus der Schnittfläche  $A_s$  und der vereinigten Fläche  $A_v$  von der Bounding Box der Lokalisierung und der Bounding Box der Grundwahrheiten.

$$IOU = \frac{A_s}{A_v} \quad (3.2)$$

Weiterhin soll die Rate an Fehlalarmen möglichst gering sein, damit möglichst kein Löschmittel für falsche Ziele verschwendet wird. Als Maß für die Fehlalarmrate wird die Falsch-Positiv-Rate (FPR) verwendet, welche sich, wie in Gleichung 3.3 dargestellt, als Quotient der falsch positiven (FP) Detektionen und der Summe der FP mit den richtig negativen (RN) Detektionen berechnet.


$$FPR = \frac{FP}{RN + FP} \quad (3.3)$$

Ein letztes Kriterium ist die Ausführungsgeschwindigkeit der Algorithmen. Diese sollte möglichst hoch sein, um die Steuerung des Löschvorgangs in Echtzeit zu ermöglichen und auf Veränderungen der Situation während des Brandversuchs reagieren zu können. Die Entscheidung für jeweils einen Algorithmus zur Lokalisierung von Flammen und Glut wird anhand der oben beschriebenen Kriterien vorgenommen.


## 4 Auswertung

Für die Auswertung der vorgestellten Methoden zur Flammenlokalisierung werden 65 Videos aus [12] und [23] sowie eigene

Aufnahmen verwendet, die insgesamt aus 4394 einzelnen Frames bestehen. Die Infrarotbilder stammen aus einem eigenen Datensatz, der 86 Aufnahmen enthält, von denen 43 glühendes Holz zeigen. In Abb. 4.1 sind Beispiele der für die Auswertung verwendeten Farbbilder (Abb. 4.1(a)) und IR-Bilder (Abb. 4.1(b)) dargestellt. Die Implementierung und Auswertung der Methoden erfolgte in Matlab auf einem PC mit Intel Core i7-8565U mit 1,8GHz Basistakt und 16GB Arbeitsspeicher.



(a) Beispielbild aus dem Testdatensatz der Farbbilder



(b) Beispielbild aus dem Testdatensatz der Infrarotbilder

**Abbildung 4.1:** Beispielbilder aus einem nach DIN EN 3-7 aufgebauten Brand

#### 4.1 Vergleich der Methoden zur Flammenlokalisierung

Wie bereits in Abschnitt 2.1 dargelegt, gibt es für die Lokalisierung von Flammen in Kamerabildern verschiedene Ansätze. Es werden hierfür die Ansätze aus [8, 11–13, 15, 17] implementiert und anhand der in Abschnitt 3 hergeleiteten Kriterien auf ihre Eignung für den Einsatz beim automatisierten Löschen von Normbränden hin untersucht.

Für das Training von [11] und [12] wird der Datensatz mit Ausschnitten aus Flammenbildern von [12] verwendet. Für das Training der Methoden [13, 15, 17] werden Bilder aus den Datensätzen [12, 23] sowie aus eigenen Aufnahmen verwendet.

In Tabelle 1 sind die Ergebnisse der Auswertung der vorgestellten Algorithmen dargestellt. Auf Basis dieser Ergebnisse lässt sich erkennen, dass die Sensitivität der Erkennung von Flammen bei den Algorithmen [8, 11, 12] am höchsten ist. Eine nur geringfügig niedrigere Sensitivität weisen [13, 15] auf. Der Algorithmus nach [17] weist auf dem Testdatensatz die mit Abstand niedrigste Sensitivität auf. Die Auswertung der IOU zeigt, dass die Lokalisierungen des Algorithmus [12] die höchste Übereinstimmung mit den Grundwahrheiten besitzen und die Algorithmen nach [8, 17] die niedrigsten. Diese beiden Algorithmen weisen zusätzlich jeweils eine hohe FPR auf. Die FPR ist insbesondere deshalb so hoch, da in jedem Testbild beliebig viele Fehler passieren können. Bei [13] führen zum Beispiel fehlerhaft segmentierte Bereiche in Bildern, in denen auch eine korrekte Detektion gefunden wird, zu der hohen FPR. Gute Ergebnisse für dieses Kriterium erreichen besonders die Algorithmen nach [11, 15], die im Vergleich mit den übrigen Algorithmen deutlich niedrigere FPR aufweisen. Die Auswertung der mittleren Ausführungszeit ergibt, dass die Ausführung des auf DeepLab basierenden Algorithmus [17] um ein Vielfaches langsamer ist als die der übrigen Algorithmen. Das liegt wiederum an der hohen Komplexität der verwendeten CNN-Architektur. Am schnellsten ist die Ausführung eines Durchlaufs des Algorithmus nach [8], welcher darauf spezialisiert ist. BOWFire [12] und der auf SqueezeNet basierende Algorithmus [13] sind in etwa gleichauf, genauso wie die noch etwas langsameren Algorithmen nach [11] und [15]. Dabei ist anzumerken, dass die Ausführungszeit der auf CNN basierenden Methoden weniger stark von der Größe



der Eingangsbilder abhängt als die übrigen Algorithmen, da die Eingangsschicht der CNN jeweils eine konstante Dimension besitzt.

**Tabelle 1:** Ergebnisse der Flammenlokalisierungsmethoden auf den Testdaten

Algorithmus	Sensitivität	FPR	IOU	Zeit
[8]	82,12%	93,04%	26,13%	8,24ms
[11]	83,59%	18,63%	53,12%	72,75ms
[12]	81,95%	69,27%	60,08%	30,46ms
[13]	72,53%	69,73%	51,46%	20,71ms
[15]	74,85%	1,86%	45,22%	81,87ms
[17]	43,81%	92,02%	14,78%	583,6ms

Aus der Kombination der Ergebnisse folgt, dass als Algorithmus für das automatisierte Löschen eines Normbrandversuchs nach DIN EN 3-7 [1] die zwei Algorithmen nach [11, 15] in Frage kommen. Dabei weist der Algorithmus nach [11] sowohl eine höhere Sensitivität bei der Erkennung von Flammen als auch eine höhere Genauigkeit in der Lokalisierung sowie eine geringfügig schnellere Ausführungsgeschwindigkeit auf. Der Algorithmus nach [15] hingegen hat hingegen die mit Abstand geringste FPR. Da [11] anhand der Ergebnisse die insgesamt bessere Lokalisierung von Flammen verspricht, wird dieser Algorithmus für den Einsatz im automatisierten Löschen ausgewählt und die etwas höhere FPR akzeptiert.

## 4.2 Vergleich von Methoden zur Glutdetektion

Die Detektion von Glutnestern und heißen Stellen, die zu einer Wiederentzündung des Brandes führen können, basiert ausschließlich auf dem Temperaturunterschied dieser Bereiche im Vergleich zum Hintergrund. Das Beispielbild in Abb. 4.1(b) zeigt, dass sich diese Bereiche deutlich vom Hintergrund abheben. Im Folgenden werden die Methoden auf Basis von [19, 20, 22] vergleichend evaluiert. Dafür werden die bereits für die Flammendetektion beschriebenen Kriterien verwendet. Die Ergebnisse werden mit einem eigenen Datensatz aus 86 IR-Bildern von glühendem Holz sowie IR-Bildern ohne Glut generiert.

In Tabelle 2 sind die Ergebnisse der Anwendung der beschriebenen Methoden auf die Testdaten dargestellt. Es ist ersichtlich, dass

**Tabelle 2:** Ergebnisse der Glutlokalisierungsmethoden auf den Testdaten

Algorithmus	Sensitivität	FPR	IOU	Zeit
[19]	99,15%	41,89%	71,62%	0,1ms
[20]	99,15%	91,76%	64,58%	8,35ms
[22]	99,15%	6,52%	81,04%	0,1ms

alle drei getesteten Algorithmen eine sehr hohe Sensitivität für die Detektion von Glut besitzen. Anhand der mittleren IOU der drei Algorithmen ergibt sich, dass [22] die höchste Übereinstimmung mit den Grundwahrheitswerten aufweist. Die Betrachtung der FPR zeigt jedoch, dass der Algorithmus nach [20] hier am schlechtesten abschneidet, da er aufgrund eines fehlenden Bezugs zu einer absoluten Temperatur eine große Zahl an falsch positiven Detektionen in den Bildern ohne Glut generiert. Der Algorithmus nach [22] besitzt die niedrigste FPR.

Bei der Ausführungsdauer ist die Lokalisierung mit K-Means [20] im Mittel erheblich langsamer als die anderen beiden Methoden. Verglichen mit den Methoden zur Flammenlokalisierung ist diese Methode jedoch sehr schnell, was neben der geringeren Komplexität der Methode auch an den geringeren Auflösungen der Eingangsbilder liegt.

Für die Detektion von Glut ergibt sich der Algorithmus nach [22] als in allen betrachteten Kriterien führend und wird dementsprechend für die Umsetzung des automatisierten Normbrandversuchs eingesetzt, um Glutnester und heiße Stellen nach dem Ablöschen der Flammen in einem Brand zu lokalisieren.

## 5 Zusammenfassung

Die Automatisierung des Normbrandversuchs nach DIN EN 3-7 [1] erfordert Bildverarbeitungsalgorithmen, die es ermöglichen, Flammen und Glut zu lokalisieren, um den Brand möglichst effizient bekämpfen zu können. Mehrere Algorithmen aus dem Stand der Forschung sind anhand ihrer Sensitivität, Falsch-Positiv-Rate, IOU und Ausführungsgeschwindigkeit verglichen worden, um den für diese Aufgabe am besten geeigneten Algorithmus zu bestimmen.

Für die Flammenlokalisierung eignen sich besonders die Algorithmen [11, 15]. Die IOU und die Sensitivität sind bei [11] höher und auch die durchschnittliche Ausführungsgeschwindigkeit ist etwas geringer als bei dem Algorithmus nach [15]. Mit [15] ist die FPR dagegen deutlich geringer als bei [11]. Daraus resultiert zusammengekommen die Auswahl von [11] für die Lokalisierung von Flammen im Kontext des Normbrandversuchs.

Die Detektion von Glut bietet keinen vergleichbar breiten Stand der Forschung, da die Lokalisierung selten als eigenständiges Problem bearbeitet wird. Die getesteten Algorithmen basieren auf der Segmentierung anhand von Temperaturschwellen und sind aufgrund ihrer geringen Komplexität effizient zu berechnen. Für den Einsatz im Normbrandversuch wird entsprechend der Methode in [22] ein einfacher Schwellwert gewählt, um die Glut zu lokalisieren, da diese sowohl bezüglich der IOU als auch in der FPR und der Ausführungszeit die besten Ergebnisse liefert.

Mit diesen beiden Algorithmen ist die Basis für eine Steuerung des Löschvorgangs im Normbrandversuch gelegt. Die Lokalisierungsergebnisse, die die beiden hier ausgewählten Algorithmen produzieren, lassen in einem Brand die für das effiziente Löschen essentiellen Flammen und Glutnester lokalisieren und als Ziele für das Löschmittel festlegen.

## Literatur

1. "Portable fire extinguishers - Part 7: Characteristics, performance requirements and test methods," 2007.
2. Deutsches Institut für Normung and Europäisches Komitee Für Normung, "Brandklassen: Deutsche Fassung EN 2:1992 + A1:2004," 1992.
3. A. E. Çetin, K. Dimitropoulos, B. Gouverneur, N. Grammalidis, O. Günay, Y. H. Habiboğlu, B. U. Töreyn, and S. Verstockt, "Video fire detection – Review," *Digital Signal Processing*, vol. 23, no. 6, pp. 1827–1843, 2013.
4. T. Çelik, H. Özkaramanli, and H. Demirel, "Fire and smoke detection without sensors: Image processing based approach," in *15th European Signal Processing Conference*, IEEE, Ed., 2007, pp. 1794–1798.
5. P. Barmpoutis, K. Dimitropoulos, K. Kaza, and N. Grammalidis, "Fire Detection from Images Using Faster R-CNN and Multidimensional

- Texture Analysis,” in *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 12.05.2019 - 17.05.2019, pp. 8301–8305.
6. Z. Zhong, M. Wang, Y. Shi, and W. Gao, “A convolutional neural network-based flame detection method in video sequence,” *Signal, Image and Video Processing*, vol. 12, no. 8, pp. 1619–1627, 2018.
7. B. U. Töreyn, Y. Dedeoğlu, U. Güdükbay, and A. E. Çetin, “Computer vision based method for real-time fire and flame detection,” *Pattern Recognition Letters*, vol. 27, no. 1, pp. 49–58, 2006.
8. J. Krooß, F. Kümmerlen, and A. Fay, “Schnelle und präzise Segmentierung von beweglichen und morphologisch variablen Objekten am Beispiel der Deflagrationsdetektion,” in *Forum Bildverarbeitung 2018*, F. Puente León, M. Heinzmann, and T. Längle, Eds. Karlsruhe: KIT Scientific Publishing, 2018, pp. 241–252.
9. P. Foggia, A. Saggese, and M. Vento, “Real-Time Fire Detection for Video-Surveillance Applications Using a Combination of Experts Based on Color, Shape, and Motion,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 25, no. 9, pp. 1545–1556, 2015.
10. S. Verstockt, “Multi-modal Video Analysis for Early Fire Detection,” Dissertation, Universiteit Gent, Gent, 14.12.2011.
11. B. M. N. de Souza and J. Facon, “A fire color mapping-based segmentation: Fire pixel segmentation approach,” in *2016 IEEE/ACS 13th International Conference of Computer Systems and Applications (AICCSA)*. IEEE, 29.11.2016 - 02.12.2016, pp. 1–8.
12. D. Y. T. Chino, L. P. S. Avalhais, J. F. Rodrigues, JR., and A. J. M. Traina, “BoWFire: Detection of Fire in Still Images by Integrating Pixel Color and Texture Analysis,” pp. 95–102, 2015.
13. K. Muhammad, J. Ahmad, Z. Lv, P. Bellavista, P. Yang, and S. W. Baik, “Efficient Deep CNN-Based Fire Detection and Localization in Video Surveillance Applications,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 49, no. 7, pp. 1419–1434, 2019.
14. F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, “SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size,” *arXiv preprint arXiv:1602.07360*, 2016.
15. P. Li and W. Zhao, “Image fire detection algorithms based on convolutional neural networks,” *Case Studies in Thermal Engineering*, p. 100625, 2020.
16. J. Redmon and A. Farhadi, “YOLOv3: An Incremental Improvement.”

17. J. Mlích, K. Koplík, M. Hradiš, and P. Zemčík, "Fire Segmentation in Still Images," in *Advanced Concepts for Intelligent Vision Systems*, ser. Lecture Notes in Computer Science, J. Blanc-Talon, P. Delmas, W. Philips, D. Popescu, and P. Scheunders, Eds. Cham, Switzerland: Springer International Publishing, 2020, vol. 12002, pp. 27–37.
18. L.-C. Chen, G. Papandreou, F. Schroff, and H. Adam, "Rethinking Atrous Convolution for Semantic Image Segmentation." [Online]. Available: <http://arxiv.org/pdf/1706.05587v3>
19. C. D. Elvidge, M. Zhizhin, F.-C. Hsu, K. Baugh, M. R. Khomarudin, Y. Ve- trita, P. Sofan, Suwarsono, and D. Hilman, "Long-wave infrared identi- fication of smoldering peat fires in Indonesia with nighttime Landsat data," *Environmental Research Letters*, vol. 10, no. 6, 2015.
20. A. M. Salazar and E. Q. B. Macabebe, "Hotspots Detection in Photovol- taic Modules Using Infrared Thermography," vol. 70, p. 10015, 2016.
21. V. Fierro, J. Miranda, C. Romero, J. Andrés, A. Pierrot, E. Gómez- Landesa, A. Arriaga, and D. Schmal, "Use of infrared thermography for the evaluation of heat losses during coal storage," *Fuel Processing Technology*, vol. 60, no. 3, pp. 213–229, 1999.
22. J. McNeil, "Autonomous Fire Suppression Using Feedback Control for a Firefighting Robot," Dissertation, Virginia Polytechnic Institute and State University, Blacksburg, 14.12.2015.
23. M. T. Cazzolato, L. P. S. Avalhais, D. Y. T. Chino, J. S. Ramos, J. A. de Souza, J. F. Rodrigues-Jr, and A. J. Traina, "Fismo: A compilation of datasets from emergency situations for fire and smoke analysis," *Proc. Satell. events*, 2017.