



ТЕХНИЧЕСКИ УНИВЕРСИТЕТ - СОФИЯ

Факултет по Телекомуникации

Катедра: Радиокомуникации и видеотехнологии

Маг. инж. Мария Цонева Павлова

**ОБРАБОТКА НА ИНФОРМАЦИЯ ОТ БЕЗЖИЧНИ
СЕНЗОРНИ МРЕЖИ С ИЗПОЛЗВАНЕ НА
КОНВОЛЮЦИОННИ МРЕЖИ ЗА ОТКРИВАНЕ НА ПОЖАР**

А В Т О Р Е Ф Е Р А Т

на дисертация за придобиване на образователна и научна степен
"ДОКТОР"

Област: 5. Технически науки

Професионално направление: 5.3. Комуникационна и компютърна
техника

Научна специалност: Телевизионна и видеотехника

Научен ръководител: доц. д-р инж. Лиляна Емилова Дочева

СОФИЯ, 2020 г.

Дисертационният труд е обсъден и насочен за защита от Катедрен съвет на катедра „Радиокомуникации и видеотехнологии“ към Факултет по Телекомуникации при Технически Университет – София на редовно заседание, проведено на 12.10.2020 г. (протокол № 31).

Публичната защита на дисертационния труд ще се състои на 04.03.2021 г. (Четвъртък) от 13.00 часа в Конферентната зала на БИЦ на Технически Университет – Софи на открито заседание на научното жури, определено със заповед ОЖ - 5.3 - 37 от 23.11.2020 г., на Ректора на ТУ – София в състав:

1. Доц. д-р инж. Иво Драганов – председател
2. Доц. д-р инж. Росен Милетиев – научен секретар
3. Проф. д-р инж. Александър Бекярски
4. Проф. д-тн. инж. Румен Кунчев
5. Проф. д-тн. инж. Димитър Радев

Рецензенти:

1. Проф. д-р инж. Александър Бекярски
2. Доц. д-р инж. Иво Драганов

Материалите по защитата са на разположение на интересуващите се във Факултета по Телекомуникации, блок 1, стая 1254 и на интернет страницата на Технически Университет – София.

Дисертантът е задочен докторант към катедра „Радиокомуникации и видеотехнологии“ на Факултета по Телекомуникации. Изследванията по дисертационния труд са направени от автора, като резултатите от тях са публикувани. Част от изследванията са вследствие от работата по научноизследователски проекти.

Автор: маг. инж. Мария Цонева Павлова

Заглавие: „Обработка на информация от безжични сензорни мрежи с използване на конволюционни мрежи за откриване на пожар“

Тираж: 30 броя

Отпечатано в ИПК на Технически Университет - София

I. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

Актуалност на проблема

Пожарите водят до големи екологични и финансови загуби. Тяхното бързо потушаване е пряко свързано с осигуряване на здравословна и комфортна за живот среда. Традиционният метод за откриване на пожари чрез наблюдение на човек, ще става все по-малко ефективен с оглед на това, че съвременният човек все повече и повече разчита на технологиите. Предизвикателството да се открие горски пожар в ранния му етап на развитие е сериозна задача пред учените. Задачата се усложнява от факта, че горските пожари се разрастват бързо, повишават температурата и площта на унищожение. Това поставя пред изследователите въпроса за съхраняването на техническото обезпечаване на малка дистанцията между обекта и техническите средства за наблюдение и откриване на горски пожари. Също така, ако пожарът бъде открит на фаза пушек, щетите биха били значително по-ниски. Всеки проблем, който застрашава човешки живот е актуален проблем и колкото по комплексно сложен е той, толкова предизвикателствата към изследователите нарастват.

Цел на дисертационния труд, основни задачи и методи за изследване

Целта на дисертационния труд е да се разработи нов подход за разпознаване на огън в горски масиви, основан на разпознаване на пушек и пламък с цел повишаване на точността на системите за известяване на възникнал пожар.

Въз основа на направения в първа глава литературен обзор и на проведения анализ, за успешното постигане на целта на дисертацията следва да бъдат решени следните задачи:

1. Да се синтезира архитектура на безжична сензорна мрежа за събиране на данни за наличие огън.
2. Да се реализира архитектура на конволюционна невронна мрежа за откриване на пламък в неподвижни изображения.
3. Да се реализира архитектура на конволюционна невронна мрежа за откриване на пушек в неподвижни изображения.
4. Да се реализира ансамбъл от класификатори, използващи конволюционни невронни мрежи за съвместно откриване на огън и пушек в неподвижни изображения.

Методологията на изследванията в дисертацията включва използването на аналитични, теоретични и практични подходи. Аналитичният и теоретичен подход са използвани при дефиниране на основни параметри на НМ, както и за синтезиране на конкретна архитектура, а чрез практично изпълнение са доказани експериментално направените и предложени модели.

Научна новост

В дисертационния труд са изследвани подходи и методи на съществуващи системи за откриване на пожар. Въз основа на направените анализи са

разработени методи за разпознаване на пламък и пушек чрез конволюционна невронна мрежа. Базирайки се на новостите и възможностите, които позволява конволюционна невронна мрежа са предложени решения, които да подобрят вече съществуващите системи или да бъдат внедрени в нови. Разгледани са и подобрени характеристиките на невронна мрежа чрез нов подход от ансамбъл от две конволюционни невронни мрежи, чрез което да се повиши коефициентът на точност на мрежата, а от там и да се намали времето за откриване на пожар.

Практическа приложимост

Всички методи, алгоритми, архитектури са разработени и внедрени в конволюционна невронна мрежа, разработена и тествана в лабораторни условия. Чрез прилагане на различни модели и параметри е оптимизирана мрежата до такава, която да може да направи разпознаване на образ на пламък и пушек в изображение с висока точност, сравнена с постигнатите в това отношение резултати, публикувани в световните научни форуми.

Апробация

Апробация на предложените архитектури е извършена с реални данни, описани в т. 2.1.4 от глава 2 и т. 3.3.1 от глава 3. Качеството на апробацията се оценява от гледна точка на валидността на получените изходни резултати. Последните са представени таблично в таблица 4.3 и таблица 4.4 от глава четвърта. В дисертацията подробно са представени методите на апробация и тяхната обосновка. Представени са входните данни, избраните методи и изходните резултати. Оценката на апробацията показва, че избраните методи са подходящи за постигането на поставената цел, а самите стойности са представени в таблица 4.2 и 4.5 от глава 4 на настоящия дисертационен труд.

Публикации

Направените анализи и предложените модели и архитектури, предложените и реализирани методи са представени в общо 5 авторски публикации, 3 от които са представени на международни конференции. Две от публикациите са самостоятелни, а три в съавторство.

Структура и обем на дисертационния труд

Дисертационният труд е в обем от 146 страници формат А4, като включва увод, четири глави за решаването на формулираните основни задачи, заключение, списък с основните приноси, списък на публикациите, списък със съкращенията, списък на фигурите, списък на таблиците, приложения и списък на използваната литература. Изложението на дисертационния труд е направено в 4 глави, съдържа 33 фигури, 18 таблици, 3 алгоритъма и 50 математически зависимости. Използвани са 119 литературни източника – 8 на български, 2 на руски и 109 на английски език като за 57 от всички тях има наличен уеб адрес за достъп. Номерата на фигурите и математическите изрази в автореферата съответстват на тези в дисертационния труд.

В глава първа е направен литературен обзор и са разгледани подробно четири основни типа системи за откриване на пожар. Разгледаните системи – сателитно базирани системи, оптични системи, безжични сензорни системи и системи за откриване на пожар в България са анализирани и представени с техните предимства, както и възможностите за оптимизиране. Във втората част на главата са разгледани пет метода за обработка на информацията, получена от системите за ранно откриване на пожар. Първият метод е базиран на сателитни метеорологични данни (RTM подход) към многоспектърния релефен мониторинг на земната повърхност. Вторият метод за обработка на изображения се базира на цветовете пространства. В литературата са представени различни подходи, един от които е преобразуването на изображенията от червено, зелено, синьо (RGB) цветово пространство в трансформирано по координати YCbCr (Y – компонента на интензитета; Cb – синя цветоразликова компонента и Cr – червена цветоразликова компонента) цветово пространство. Третият метод за обработка на информация от различни системи се базира на Support Vector Machine (SVM) класификатор. Машината с поддържащи вектори се използва главно за класификация и нелинейна регресия. Това е основен алгоритъм за обучение на принципа на структурно минимизиране на риска. Четвъртият метод е класификатор на Бейс. Основан на известната теоремата на Бейс, този класификатор определя възможността дадено изображение да принадлежи на даден клас. Петият разгледан метод за обработка на изображения и извличане на информация от тях е чрез невронни мрежи и дълбоки невронни мрежи. Проучените системи и методи за обработка на изображения показваха, че може да бъдат оптимизирани както системите, така и методите на обработка на информация чрез използване на съвременните постижения на технологиите.

В глава втора е предложена архитектура на дълбока невронна мрежа и по-специално конволюционна невронна мрежа (КНМ). Архитектурата на мрежата е проектирана с цел да разпознава пламък в цветни изображения. Предложената архитектура е обоснована и разгледана подробно в нейната цялост. С експериментални данни са доказани твърденията и аналитичните изводи. Експерименталните данни са обобщени и са направени съответните изводи.

В глава трета е предложена архитектура на дълбока невронна мрежа и по-специално конволюционна невронна мрежа (КНМ). Архитектурата на мрежата е проектирана с цел да разпознава пушек в цветни изображения. Експерименталните данни са обобщени и са направени съответните изводи.

В четвърта глава е отделено място за две важни теми. Първата е свързана с предложена архитектура на безжична сензорна мрежа (БСМ) в изпълнение на инфрачервени камери позиционирани на кули за видеонаблюдение и квадрокоптер с камера. Втората част от главата е отделена на разработването на архитектура на нова КНМ. Архитектурата представлява ансамбъл от проектираните в глава 2 и глава 3 архитектури. Всъщност разработените

архитектури за пушек и огън са обединени в една като целта е да се повиши процентът на разпознаваемост на пожар в цифрови изображения.

II. СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

ГЛАВА 1. Системи за откриване на огън в Европа и в Република България

1.1. Анализ на системите за събиране и обработка на информация чрез видеонаблюдение на горски пожари в Европа и на съществуващите в Република България

1.1.1. Сателитно – базирани системи

Използването на спътникова техника е разработено предимно за изследването на биоразнообразието и управлението на екосистеми [1], [2], [5]. Целите, които са поставени, системата постига напълно. Използването на LEO и GEO сателитни системи в помощ за предотвратяването и откриването на пожари е публикувано от някои автори [1], [2], [3].

1.1.4. Сравнителен анализ на оптични сензорни системи

Базирайки се на Mathews, S и колектив, Yanni Li представя интересно проучване – тест за ефективност на трите системи EYEfi, FireWatch, и ForestWatch [13]. Тестът е направен в Австралия съвместно с изследователския център Bushfire Cooperative Research. Целта на изследването е да се сравни работата на трите системи с работата на персонал от наблюдателна кула, таблица 1.1. В докладът са представени резултатите от това проучване, като някои могат да се обобщят по следния начин:

Таблица 1.1 Сравнение между три системи за наблюдение и наблюдение от човек

Наименование на теста	Регистрирани пожари			
	EYEfi	FireWatch	ForestWatch	Персонал от кула
6 пожара, за целите на проучването	0	0	1	6
6 спонтанно възникнали пожара, 2 през нощта	0	3	3	-

В таблица 1.1 са представени резултати от сравнението на три системи и наблюдението на персонал от кула. Докладът от направените опити показва, че камерите откриват пожар 35 мин. по-късно от персонала на кулата и огънят

е 5 пъти по-голям от показаното на камерата. Интересно е да се отбележи, че големи пожари на 70 км. са били регистрирани, а същевременно по-малки и на средно разстояние от 10-20 км. са били пропуснати.

1.1.5. Безжични сензорни мрежи

Подобно предложение имат авторите Liyang Yu, Neng Wang, Xiaoqiao Meng [17], които предлагат система за откриване на горски пожари в реално време чрез използването на невронни БСМ за откриване на горски пожари в реално време. Авторите залагат на алгоритъм на клъстери, който да може да събере данните от пръснатите сензори по терена.

Споменатите мрежи изискват много голяма плътност на разгърнатите възли и много сложна процедура за съхранение на данните и тяхната обработка, чрез НМ. Постигнатите резултати са реализирани и оценени чрез симулации.

1.1.6. Критичен анализ на безжични сензорни мрежи

Може да се отбележи като сериозен недостатък на този тип технология специално за приложения в горски масиви, че сензорите, които се използват по отношение на площта на покритие имат по-ниски технически показатели. За сравнение ако една камера, поставена на кула може да покрие периметър от 10 до 15 км, то един сензор, поставен на естествен носител или изкуствено създаден специално за него има от 5 до 7 пъти по-малък периметър на покритие. Това налага по-голям брой сензори. В дисертационния труд е предложено решение за безжична мрежа с по-малко, но достатъчно на брой сензори за един възел на мрежата и е значително по-надеждна при суровите условия на експлоатация.

1.1.7. Системи за откриване на пожар в Република България

В нашата страна наблюдението и опазването на горските масиви от пожари е прерогатив на Изпълнителна Агенция по Горите към Министерството на земеделието, храните и горите. Горските масиви, за които отговаря ИАГ възлизат на 3 090 010 хектара към 31.12.2018 г., което представлява 72.58% от всичките горски територии на България. [19], [20].

Изнесен център на 112 към ИАГ. Този център функционира от няколко години. Той е пряката връзка между наетите за наблюдение хора и службите за пожарна безопасност.

1.1.8. Критичен анализ на системите за наблюдение и методите на обработка на информация с цел ранно откриване на пожари в България

Системата, изградена в ПП „Врачански Балкан“ е най-съвременната и модерна система на територията на Република България. Дори и в годишния доклад на ИАГ са отчетени по-добри резултати от предходната година, благодарение на работата на системата. Всяка камера е прикачена на кула и

има възможност за завъртане около оста на кулата. Периметърът който може да покрие автоматична наблюдателна станция (АНС) е с радиус най-малко 10 км. и не повече от 15 км. Също така трябва да се отчете факта, че с нарастване на разстоянието точността спада.

1.2. Анализ на методите за обработка на събрана от системите информация

В най-често срещаният случай се касае за обработка на цифрови изображения, снети от камери; обработка на инфрачервени изображения снети от инфрачервени камери или анализ на температурни разлики. Ще бъдат разгледани популярните методи за обработка на цифрови изображения като неразделна част от системите за откриване на пожари.

1.2.2. Обработка на информация чрез метод, базиран на цветовите пространства

Предимство на този метод са малкото и лесни изчисления. Те са дадени във формула (1.1).

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 0.2568 & 0.5041 & 0.0979 \\ -0.1482 & -0.2910 & 0.4392 \\ 0.4392 & -0.3678 & -0.0714 \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} + \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} \quad (1.1)$$

Посоченото преобразуване се използва в етап 2 на предварителната подготовка на изображението. В процеса на извличане на параметри, авторите дават 7 правила, с които проверяват наличието на цветови характеристики.

1.2.4. Обработка на информация чрез Support Vector Machine (SVM) класификатор

Разделянето на пространството чрез линия е важна концепция в SVM. Разглеждат се два случая: 1) тогава, когато данните са линейно разделими и 2) когато данните са линейно неделими. За правилното разбиране на машина с поддържащи вектори е необходимо да се въведат някои основни понятия.

Ъгълът θ е между двата вектора, които умножаваме. Този ъгъл може да се представи като разлика между ъгълът α (ъгълът между абсцисата и вектора x) и β (ъгълът между абсцисата и вектора y).

$$\begin{aligned} x \cdot y &= |x| \cdot |y| \cdot \cos(\beta - \alpha) = |x| \cdot |y| \cdot (\cos \beta \cdot \cos \alpha + \sin \beta \cdot \sin \alpha) = \\ &= |x| \cdot |y| \cdot \left(\frac{x_1 y_1 + x_2 y_2}{|x| \cdot |y|} \right) = x_1 \cdot y_1 + x_2 \cdot y_2 \end{aligned} \quad (1.7)$$

Формула (1.7) приложена за многомерно пространство ще придобие следния вид, изложен във формула (1.8)

$$X \cdot Y = \sum_{i=1}^n X_n \cdot Y_n \quad (1.8)$$

Възможността да се раздели пространството от данни с линия е основна концепция за SVM класификатора. Характерът на данните не винаги позволява да бъдат линейно разделени. Това е причина този вид класификатор

да разглежда в дълбочина и да обръща особено внимание на линейно и нелинейно разделимите данни. По същия начин, за триизмерните данни, казваме, че данните са линейно разделими, ако можем да намерим равнина, която да ги разделя. За двумерното пространство разделението става с права, чието уравнение е дадено във формула (1.9). Ако определим $x = (x_1; x_2)$ и $w = (a; -1)$, то уравнение (1.10) придобива следния вид:

$$x \cdot w + b = 0 \quad (1.11)$$

Последното уравнение се нарича уравнение на хиперравнина [29]. Уравнението на хиперравнина с поддържащ вектор играе ключова роля в разделянето на данните [30]. Хиперравнината освен, че позволява разделяне на пространството може да бъде използвана за да се правят предположения като например в уравнение (1.12) е дадена хипотезата $h(x_1)$ за елемента x_1 по следния начин:

$$h(x_1) = \begin{cases} -1, & w \cdot x + b < 0 \\ 1, & w \cdot x + b \geq 0 \end{cases} \quad (1.12)$$

В литературата [30], [31], се предлагат няколко решения на този проблем и зависят от това дали данните са линейно разделими или не. Един от методите предложен в [31] е да се намерят подходящи стойности за w и b , така че да се намери оптималната хиперравнина е необходимо да се реши оптимизационна задача с ограничението, че геометричното отстояние на всеки елемент трябва да бъде по-голямо или равно на M (геометрична разлика). Оптимизационният проблем на SVM се решава с функция на Лагранж [32]. За решаването на този проблем е необходимо да се намери решение на произведението $x_i x_j$ (има се в предвид във всички изрази, че x и y са вектори). Предлага се функция, която е наречена функция на ядрото и всъщност тя изчислява произведението, но същевременно го изчислява така, че при трансформиране на данните в по-високо размерно пространство резултатът да остане същият. Ако се дефинира $K(x_i x_j) = x_i \cdot x_j$ ще се получи израз от следния вид:

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j K(x_i \cdot x_j) \\ \text{subject to } & \alpha_i \geq 0, \quad i = 1 \dots m, \quad \sum_{i=1}^m \alpha_i y_i = 0 \end{aligned} \quad (1.19)$$

Тази малка на пръв поглед промяна е доста мощен апарат. Възможността да се изчисли произведението в друго пространство позволява да променяме функцията на ядрото и по този начин да се класифицират нелинейно разделими данни. Израз (1.17) представя решение на оптимизационната задача чрез SVM, а израз (1.19) нейното подобрене или представяне в нелинейно разделимото пространство чрез функция на ядрото.

1.2.5. Обработка на данни чрез класификатор на Бейс

Класификационна задача може успешно да се реши и чрез теоремата на Бейс. Това е доста широко застъпен в литературата метод за класифициране на данни, представени чрез вектори.

Ще отбележим с P_i вероятността вектор y да принадлежи на класа 1, с P_j вероятността вектор y да принадлежи на класа 0.

$P_i(y)$ – вероятността елемент y да принадлежи на клас i

$P_j(y)$ – вероятността елемент y да принадлежи на клас j

Вероятността непрекъснатата случайна величина y да принадлежи към клас c_i при условие, че всички характеристики са изпълнени, може да бъде дадена със следното уравнение:

$$P(c_i | y) = P(c_i)P(y | c_i) / P(y) \quad (1.27)$$

Последната формула се нарича формула на Бейс. Тя допуска следната интерпретация: Каква е вероятността елемент от тестовия вектор y да принадлежи към клас 1? $y_1, \dots, y_n$ е вектор от елементи от клас 1 или 0. Направените разсъждения показват, че класификатор на Бейс е метод, който дава добро класифициране и прилагането му не изисква големи ресурси.

1.2.6. Обработка на информация чрез невронни мрежи

Входният вектор е от стойности, които се подават на входа на НМ. Нарича се входен вектор и се отбелязва с $X = (x_1, x_2, \dots, x_n)$. Входният вектор или матрица се умножава в теглови коефициенти (параметри), които образуват вектор или матрица $W = (w_1, w_2, \dots, w_n)$. Произведението се сумира с отклонението b , представени във вектор и резултатът се подава на входа на активационна функция. Изходът на тази функция е изход от един неврон. В уравнение (1.28) е дадено аналитично описание на един неврон.

$$Y = f(\sum_{i=1}^n w_i x_i + b) \quad (1.28)$$

Различните архитектури на мрежите се променят в зависимост от броя слоеве на НМ. Изходът на един неврон $Y = (y_1, y_2, \dots, y_n)$ може да бъде изход на еднослойна мрежа, наречена персептрон, или да е вход на следващ слой на двуслойна или многослойна мрежа.

1.2.7. Обработка на информация чрез дълбоки невронни мрежи

Обучението може да се опише като оценка на параметрите на модела, така че наученият модел да може да изпълни конкретна задача. В ДНМ параметрите са тегловните коефициенти, подредени в тегловни матрици. Този тип мрежи се характеризират с голямо количество параметри – може да достигне до десетки хиляди. От друга страна, моделът се състои от няколко слоя между входния и изходния слой, което позволява присъствието на много етапи на нелинейни единици за обработка на информация с йерархични архитектури.

1.2.8. Критичен анализ на методите за обработка на информация

Всеки един от разгледаните в тази глава методи за обработка на информация има своето място и е доказан от научна и практична гледна точка. Широкото им използване в литературата и доказаните с практиката резултати само потвърждават значимостта и важността на разгледаните методи.

Като вид дълбока невронна мрежа в дисертацията е използвана КНМ, с която и експериментално е показано, че има голям принос в разпознаването на образи в цифрови изображения. Мрежата е сравнена с още един тип мрежа, представител на ДНМ, а именно каскаден класификатор. Последният има своите силни страни в определени области, но експериментално е показано, че в разпознаването на изображения с огън предимство има конволюционната мрежа

Изводи

От изложените по-горе данни може да се направят няколко извода:

- Във всички държави по света така и в България се работи по създаването и усъвършенстването на закони, нормативни документи и правилници за тяхното прилагане с цел опазването на горските масиви и живота на хората. Опазването на горите от изгаряне косвено влияе върху здравето и благосъстоянието на всеки човек на земята. Актуалността и сериозността на проблема се вижда от високата значимост, която му се отдава от страна на най-високо управляващите органи.
- Системите за ранно откриване на горски пожари допринасят за ранното откриване и бързото овладяване на пожарите. Там, където има внедрени такива се отбелязва намаляване на щетите от горски пожари. Намаляване на загубите на дървесен материал, причинени от огнена стихия. Намаляване на атмосферните замърсявания в следствие на големи пожари.
- Системите, които се разработват за опазване на горските масиви не са достатъчно, за да могат да покрият обширните целеви територии.
- В България методът, използващ хора за наблюдаване на горските масиви е все още най-разпространения метод за оповестяване на аварийно положение. Разработеният изнесен център към 112 съвместно с хората, назначени за наблюдаване, са допринесли за скъсяването на времето между пожара и неговото погасяване.
- Развитието на технологиите дава допълнителен тласък за подобряването на съществуващите вече системи. Системите, които работят на територията на РБ са на световно ниво. Те са заимствани от най-добрите постижения в тази област в Европа.
- Анализът на методите за обработка на данни, събрани от съществуващите системи показва, че е слабо застъпен факторът разпознаване на огън чрез НМ. Широко използван е методът за разпознаване на огън чрез

инфрочервено изображение, отчитайки и разлики в температурата от порядъка на десети. Прибавянето на класификатор, към една такава система ще подобри точността от гледна точка намаляване на аларми вдигнати от други топлинни източници, различни от огън и пушек.

- Анализът на някои от методите за класифициране дава ясна насока да бъде избран метод за обработка на изображения с огън и пушек чрез използването на КНМ.

1.3. Научно –приложни приноси към глава 1

Направен е сравнителен анализ на работата на познатите и широко използвани системи в Европа и в България. В сравнителния анализ е взето предвид и най-широко разпространения метод за разпознаване на пожар чрез наблюдение от хора (таблица 1.1.).

Направен е критичен анализ на предимствата и на някои недостатъци на системите, които са работещи и внедрени в отделните държави и в България (т. 1.1.2, 1.1.3, 1.1.4, 1.1.5, 1.1.6, 1.1.7, 1.1.8).

Направен е анализ на популярни методи за разпознаване и класифициране на данни. Направен е критичен анализ на описаните методи, в следствие на който е избран метод за решаване на поставената в дисертационния труд задача (1.2.1, 1.2.2, 1.2.3, 1.2.4, 1.2.5, 1.2.6, 1.2.7).

1.4. Цел и основни задачи на дисертационния труд

1.5.1. Цел на дисертационния труд

Въз основа на направения литературен обзор по темата на дисертацията и критичния анализ на публикации по тази тема се дефинира целта на дисертационния труд:

Да се разработи нов подход за разпознаване на огън в горски масиви, основан на разпознаване на пушек и пламък с цел повишаване на точността на системите за известяване на възникнал пожар.

За постигането на поставената цел в дисертационния труд и въз основа на критичния анализ трябва да се решат следните задачи:

1.4.4. Задачи на дисертационния труд

Да се синтезира архитектура на безжична сензорна мрежа за събиране на данни за наличие огън.

Да се реализира архитектура на конволюционна невронна мрежа за откриване на пламък в неподвижни изображения.

Да се реализира архитектура на конволюционна невронна мрежа за откриване на пушек в неподвижни изображения.

Да се реализира ансамбъл от класификатори, използващи конволюционни невронни мрежи за съвместно откриване на огън и пушек в неподвижни изображения.

ГЛАВА 2. Обработка на изображения за откриване на пламък чрез конволюционна невронна мрежа

2.1. Конволюционни невронни мрежи (КНМ)

Специфичен вид на ДО са КНМ като дълбоки невронни мрежи. Тяхната топология е еднопосочно предаване на данните т.е. входният сигнал се предава от слой на слой в права посока от входен към изходен. Ако има връщане, то е само в границите на слоя. Такива мрежи с еднопосочно предаване се наричат още Многослоен Персептрон, който е ключов в модела на ДО [42], [43].

2.1.1. Архитектура и функционалност на КНМ

Бързият преглед на най-популярните мрежи дава ясен приоритет на архитектурата на КНМ и нейната важност [55], [52], [56]. Доста автори в различни статии правят сравнение между различните архитектури спрямо общи параметри [57] .

2.1.3. Хардуерна конфигурация

Графична карта – Intel® HD Graphics 3000; 12 ядра с честота 650 - 1300 MHz; Pixel Rate - 2.200 GPixel/s; Texture Rate - 13.20 GTexel/s

2.1.4. Реализиране на База данни от изображения с огън

Базата от данни за разпознаване на огън съдържа предимно снимки с огън. Някои от тях са с пушек поради невъзможността да се отдели пушека от самия огън в определени етапи от развитието му. Заснети са различни фази на разгръщане на огъня. В конкретния случай за постигане на поставената задача, а именно да се реализира програма за разпознаване на огън е направена база данни от снимки както следва: изображения с огън - 260, изображения на гористи местности без огън – 865. Събрани дават общо снимките за обучение на мрежата – 844, а за тестване на мрежата – 281 екземпляра. Всички снимки са цветни RGB, с 24 бита наситеност (24 bit depth) т.е. по 8 бита за всеки цветови канал. Изображенията са с размер 100x100 пиксела. Тези размери са избрани, за да се осигури по-голяма бързина и по-малко заемана памет. Така базата е подготвена за да може да бъде използвана от КНМ. Предимството на по-малка база е, че времето за обучение на мрежата е по-малко.

2.2. Реализиране на архитектура на КНМ за разпознаване на огън

Изображението или какъвто и да е друг вид информация се трансформира и съхранява като многомерен масив. Цветното изображение може да се представи като масив от стойности от 0 до 256, като всяко едно от тези числа отговаря на един от пикселите. Следователно ще се получи масив със следните размери:

$$M = [100, 100, 3] \quad (2.1)$$

Масивът има 300 елемента и всеки от тях е число със стойност между 0 и 255.

2.2.1. Параметри на конволюционните слоеве

При конволюционния слой няма смесване между осите при обработката на данните, което означава, че промените по ос y на входния обем ще повлияят само на ос y на изходния обем [69]. Изчислението на параметрите, което всъщност представлява броя на теглата [70], които подлежат на обучение и тези, които не са могли представено в следващите уравнения. Изчисляването на параметрите на входния обем – с размери W (Широчина), H (Височина), C (канали) става чрез уравнение (2.2)

$$P = W \times H \times C \text{ или } P = 100 \times 100 \times 3 = 30\,000 \quad (2.2)$$

В таблица 2.2. са дадени двата слоя, които са обект на изследване и броят обучени и необучени параметри.

Таблица 2.2 Таблица на сравнение на параметрите между двата вида слоеве

	1-ви слой параметри	Общо параметри	Обучени параметри	Необучени параметри
SeparConv2D	275	1210613	1209653	960
Conv2D	4736	1295554	1294594	960

2.2.2. Влияние на размера на представителната извадка на всеки от двата класа.

От гореизложеното ако целта е да се проектира „добър“ класификатор, то тогава е необходимо да бъде изпълнено условие (2.6) [74].

$$n_j \cdot C_j = n_i \cdot C_i \quad (2.6)$$

В посочената формула броят на представителната извадка умножена по коефициента на оценяване C на единият клас i трябва да е равна на броя по коефициента на оценяване на другия клас j . При несиметрични данни в БД, каквито съществуват в конкретния случай без коефициента на корекция ще се получава превес на по-голямата база и резултатите ще се изкривят, както беше отбелязано и по-горе. Представената формула всъщност внася равновесието необходимо за „добър“ класификатор.

2.2.3. Активираща функция

За КНМ, разработена в дисертацията е използвана частично линейна функция ReLU. Изборът на активираща функция влияе върху точността на мрежата, тъй като е част от обучителния процес на модела на НМ. В таблица 2.4 са представени резултатите от сравняването на обучението на КНМ с различни активиращи функции.

Таблица 2.4 Сравнение на 2 мрежи активирани с различни функции

Мрежа	KHM Conv2D			KHM SeparableConv2D		
	загуби, %	точност, %	време 1 пак.	загуби, %	точност, %	време 1 пак.
ReLU	0.314849	90.98	19 s 53 ms	0.144298	94.26	14 s 39 ms
Sigmoid	0.841973	74.59	19 s 51 ms	0.218328	89.34	12 s 33 ms
Softplus	0.200190	93.44	39 s 11 ms	0.377043	90.16	17 s 46 ms
Softsign	0.243442	90.16	36 s 99 ms	0.254811	91.8	28 s 77 ms
tanh	0.707146	77.87	20 s 54 ms	0.296302	90.16	29 s 79 ms
ELU	0.314487	89.34	24 s 65 ms	0.408907	88.52	16 s 44 ms

2.2.5. Необучени параметри на KHM

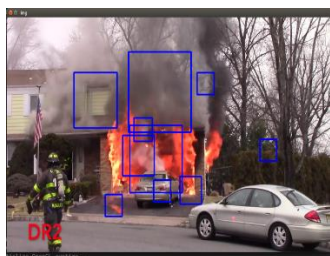
За по-голяма яснота данните са представени в таблица 2.4, където ясно може да се направи сравнение. Последният ред от таблицата има нужда да бъде обяснен. Слой BatchNormalization е една от двете причини да има необучени параметри в мрежата. Втората причина е в процеса на обучение да се получат тегла, които не могат да бъдат определени с точни коефициенти. За създадената конволюционна мрежа отстраняването на слой BatchNormalization води до нулеви необучени параметри. От своя страна това доказва, че тези параметри са породени единствено и само от споменатия слой и в литературата се отбелязват като хиперпараметри [53], [77]. Резултатите са представени в таблица 2.5

Таблица 2.5 Сравнение на големината на филтрите и необучените параметри


KHM SeparableConv2D	с	Брой параметр и първи слой	Общ брой параметр и	Обуче ни параметр и	Необу чени параметр и
Първоначална конфигурация, фиг. 2.14		275	1 210 613	1 209 923	960
Промяна на филтъра Само в конв. слой с размер (5,5), фиг. 2.15		236	1 210 574	1 209 614	960
Промяна на филтрите и в 1,2 конв. слой и в слой BatchNorm, фиг. 2.16		203	551 661	550 765	896
Елиминирание на слой BatchNorm, фиг. 2.17		203	549 869	549	0

2.3. Реализиране на мрежа за разпознаване чрез библиотека OpenCV

Обучението с библиотека OpenCV преминава през 10 етапа или 10 епохи, в които се настройват тегловите коефициенти. Окончателният резултат от обучението е xml файл. Този файл с име `cascade_training_fire.xml` се подава като аргумент на функцията `cv2.CascadeClassifier` [80], с която всъщност се оценяват подадени снимки или видеа на входа на класификатора. Като допълнителна функция в програмата е програмирано разпознатият обект да бъде ограден в син квадрат. Резултатите, които дава този класификатор не са 100% разпознаваемост, което е доста трудно постижимо при поставената задача за разпознаване на огън. Основните две грешки, които први са представени на фиг. 2.19 и 2.20, където са дадени положителни и отрицателни примери.



Фигура 2.19 Положителни примери на работата на НМ с OpenCV



Фигура 2.20 Отрицателни примери на работата на НМ с OpenCV

2.4. Изводи

Последната таблица показва също така, че проектираната, приложена и тествана архитектура на КНМ дава високи резултати при оценяване на мрежата.

Обучена с изображения предимно с огън, приложена е активираща функция “ReLU” за 50 епохи на обучение, мрежа с дълбоко обучение, както и мрежа с учител. Параметрите на тази мрежа дават 93.62% точност. Обобщенията в таблица 2.6 дават ясна представа за предимствата на всяка една от представените архитектури. Трите мрежи не са сравнени по бързина, защото нямат достатъчно обща база, на която може да бъде направено такова сравнение. Например НМ с OpenCV има най-малко епохи, но обучението ѝ отнема часове, докато другите две имат повече, но се обучават в границите на минути.

Таблица 2.6 Резултати от проектираната архитектура за огън

Характеристики	КНМ <i>SeparableConv2D</i>	КНМ <i>Conv2D</i>	НМ OpenCV
Брой образци в извадка	32	32	8
Брой снимки за обучение с огън и без	363	363	1001
Брой снимки за тестване	122	122	50
Размер на изображението	100x100	100x100	32x32
Цвят	RGB	RGB	G
Брой епохи	50	50	10
Кодиране	One hot	One hot	Aglutination
Точност, %	93.62	90.34	75.2
Загуби, %	28.66	38.37	24.8

Ефективността на разработената архитектура се вижда ясно и от сравнението на постигнатите експериментални резултати в други подобни мрежи. Така например К. Muhammad и колектив в статията си: „Efficient Deep CNN-Based Fire Detection and Localization in Video Surveillance Applications“ [81] публикуват постигнати резултати за точност на използваната от тях КНМ за разпознаване на огън в изображения от 89.8% до 94.50% като резултатите варират в зависимост от различните мрежи, които те ползват. Тези проценти, сравнени с резултатът на предложената мрежа 93.62% показват недвусмислено сериозните и положителни резултати, които са постигнати.

Аналитично са представени изчисленията в първи слой и са подкрепени с експериментални резултати. Цялостната архитектура на мрежата е представена в Приложение 2.

2.5. Научно - приложни приноси към глава 2

Предложени са архитектури на КНМ с конволюционен слой Conv2D и слой SeparableConv2D. Разработена е архитектура на НМ с библиотеката OpenCV. Целта на мрежите е да разпознават огън в изображение. Трите мрежи са анализирани и описани (таблица 2.6).

2.6. Приложни приноси към глава 2

Разработена НМ в IDE PycharmProject с библиотека OpenCV. Представени са резултатите от работата и са сравнени с други мрежи за разпознаване на пламък в статични изображения (таблица 2.6).

Разработена е подробна архитектура на КНМ с конволюционен слой SeparableConv2D. Научно и опитно са защитени нейните предимства и различия. Аналитично са изчислени и представени математическите операции в първи слой и са подкрепени с експериментални резултати. Разработена е в среда IDE PycharmProject с библиотеки Keras и Tensor Flow. Изцяло архитектурата е представена в Приложение 2.

Приложно е показана адаптивността и гъвкавостта на КНМ към бързо променящи се среди, което дава големи предимства за използването и като част от БСМ (таблица 2.6).

ГЛАВА 3. Обработка на изображения за откриване на пушек чрез конволюционна невронна мрежа

3.2. Основание за разработването на КНМ за пушек

В настоящата глава ще бъде разгледана КНМ за разпознаване на пушек с идеята двете мрежи да бъдат обединени и да се докаже хипотезата, че такава мрежа ще има по-висок процент на разпознаваемост. В литературата са предложени и други подобни решения като например двуканална дълбока КМ [83], [84], която всъщност е съставена от два подкласа, които отново са КМ. Съществува и варианта няколко паралелни конволюционни слоя [85], [86], [87] или с база данни от сателитни изображения [88]. Всеки от предложените методи си има своите предимства и недостатъци.

3.3. Архитектура на КНМ за разпознаване на пушек

В предходната глава бяха разгледани подробно най-популярните архитектури. В тази глава ще бъдат представени отново двете архитектури и ще бъде направено сравнение между тях, но с променена БД от изображения с пушек. Архитектурата на КНМ мрежа с пушек е дадена в Приложение 2. На фиг. 3.1 е представен моделът на непрекъсната КНМ за пушек, използван за експерименталните резултати.

3.3.1. База данни на КНМ, разпознаваща пушек

Входният поток от изображения с пушек наброява 465 екземпляра, а тези с природа, без пушек са 865. След като двете бази от изображения се смесят, общият им брой става 1330. За целите на обучението входният поток се разпределя по следния начин: 75% от всички изображения за обучение, което представлява 997 екземпляра, а останалите 25% представени от 333 образци са за тестване на точността на мрежата.

3.3.2. Влияние на размера на представителната извадка на всеки от двата класа

След прилагане на корекционния коефициент, се получава корекция в точността на НМ. Сравнителните стойности са представени в таблица 3.1.

Таблица 3.1. Сравнение на два различни слоя в еднакви КНМ след корекция

	Точност, % преди корекция	Загуби, % преди корекция	Точност, % след корекция	Точност, % след корекция
КНМ с SeparableConv2D	93.39	21.89	91.79	14.14
КНМ с Conv2D	92.49	22.83	90.99	22.67

Таблица 3.1. показва сравнението между мрежите, когато се балансира БД. От получените резултати се вижда, че очакваното понижение на стойностите на точност е факт, но това дава възможност да се търсят още оптимизации по отношение на други параметри на КНМ с цел повишаване на нейната точност.

3.3.3. Активираща функция

В архитектурата на КНМ за разпознаване на пушек също е използвана линейната функция “ReLU”. Използването на тази функция осигурява едно важно предимство а именно слага горна граница на стойностите на изходната матрица [84], [90].

3.3.4. Параметри на КНМ за пушек

В настоящата дисертация е направено изследване за влиянието на т. нар. слой „Dropout“. Този слой има спецификата на регулатор с цел предотвратяване на препълването [97]. Всъщност този слой ще установява входните тегла на случаен принцип на нула с честота, която е зададена, като параметър, наречен „rate“. Теглата на входната матрица, които не са установени на нула, се изчисляват по следната формула:

$$K = 1 / (1 - \text{rate}) \quad (3.4),$$

където K – коефициент на теглата на входната матрица, „rate“. Параметърът, установен в настройките на слоя. Този параметър може да приеме стойности от (0;1). Широко в литературата [98], [99], [100] е застъпен коефициент равен на 0.5 като най-оптимален за този слой, но в случая с БД от снимки с пушек, ясно се вижда, че точността на мрежата е по-висока при коефициент равен на 0.2, с който и е настроен мрежата за разпознаване на пушек. Този процес показва, че по-малко неврони е необходимо да отпаднат в конкретната мрежа и това може да се свърже с текстурата на изображенията с пушек, които в някои извадки са близки до образците за обучение.

В таблица 3.4 са показани резултатите в проценти от работата на КНМ с БД от изображения предимно с пушек след фазата на тестване на мрежата.

Таблица 3.4 Сравнение на резултатите на двете архитектури за пушек

Характеристики	КНМ <i>SeparableConv2D</i>	КНМ <i>Conv2D</i>
Брой образци в извадка	16	16
Брой снимки за обучение с пушек и без	997	997
Брой снимки за тестване	333	333
Размер на изображението	100x100	100x100
Цвят	RGB	RGB
Брой епохи	60	60
Кодиране	One hot	One hot
Точност, %	91.79	90.99
Грешка, %	14.14	22.67

3.4. Изводи

Архитектурата на КНМ с изображения на пушек е предложена и разработена. Всички научни изводи са подкрепени с експериментални резултати. Мрежата е с БД от изображения с огън. Дълбока невронна мрежа със един входен слой, един изходен и 13 скрити слоя. Изходният слой има само два неврона, с които взема решение за изображение с пушек и изображение без такова. Приложена е активираща линейна функция „ReLU“ приложима в среда за проектиране „PycharmProjects“ с библиотеки „Keras“ и „TensorFlow“. Обучението на мрежата е реализирано с учител с „one hot“ етиктиране. Настроените параметри на изследваната КНМ дават 91.79% точност при позитивните образци и 14.14 % загуби при негативните образци.

В тази глава на дисертационния труд е показано, че базирайки се на развитието на технологиите в областта на НМ може да се предложи архитектура на КНМ, която да даде определени проценти на разпознаваемост на пушек в неподвижно изображение.

Не по-маловажен извод е и фактът, че след направените изследвания се вижда гъвкавостта и адаптивността на КНМ към бързо променящи се параметри. Промяната на обема на БД, както и текстурата на изображенията наложи промени в КНМ, но въпреки това с значително малък ресурс бяха постигнати резултати, които позволяват на КНМ, разпознаваща пушек да

бъде достатъчно полезна при цялостната оценка на откриването на огън в БСМ.

Обобщенията в таблица 3.4 показват правилен избор на архитектура включително брой скрити слоеве. Обосновано е предимството на всяка от двете архитектури като сравненията са направени при еднакви настройки на параметрите на мрежата. Сериозен принос е подробното и задълбочено изследване на двете архитектури, една изградена на конволюционен слой и архитектура с разпределена конволюция върху цветовите канали. Направено е подробно сравнение на методиката и функционалността на двете архитектури.

Резултатите от тази глава дават предпоставка да се счита, че обединението на резултатите от двете мрежи ще даде по-висока точност в работата на КНМ в система на сензорна мрежа. Това доказва приносът на невронните мрежи като важно оценяващо звено в сензорни мрежи.

3.5. Научно – приложни приноси към глава 3

Разработена е архитектура на КНМ с конволюционен слой Conv2D. Разработената архитектура е с БД от изображения предимно с пушек. Реализирана е в среда IDE PycharmProject с библиотеки Keras и Tensor Flow. Направено е изследване за влиянието на определени параметри от архитектурата върху точността. Цялостната архитектура на мрежата е представена в Приложение 2.

3.6. Приложни приноси към глава 3

Разработена е подробна архитектура на КНМ с конволюционен слой SeparableConv2D, разработена в среда IDE PycharmProject с библиотеки Keras и Tensor Flow. Изцяло архитектурата е представена в Приложение 2.

Приложен принос в тази глава има събирането, обработването и реализирането на БД с изображения то пушек.

Научно е обосновано и експериментално доказано, че КНМ, която има за входни масиви изображения предимно с пушек поради естеството на изображенията и тяхната текстура не може самостоятелно да бъде надеждна за вземането на правилно решение за наличието на огън или не.

ГЛАВА 4. Обработка на информация от БСМ за откриване на пожар чрез конволюционна невронна мрежа


4.1. Предложение за БСМ и БЛА

В тази глава на дисертационния труд е разгледано предложение за Безжична Сензорна Мрежа (БСМ) за събиране и обработка на информация с помощта БЛА, камера и предимствата на кулите за наблюдение.

4.1.1. Апаратна реализация на БСМ и куадкоптер за събиране на данни

На фиг. 4.2 е предложена архитектура на система за контрол на отдалечени обекти. За да може да изпълнява функциите, за които е предназначена


системата трябва да съдържа следните модули: камера за заснемане на обектите; платформа, позволяваща развойна дейност; външна памет, осигуряваща съхраняването на сметата информация; GPS модул, чрез който се предават координати на местоположение; захранване; приемно – предавател, осигуряващ връзката с отдалечен терминал; захранване за модула на управление; модул за управление на полета; приемно-предавател; дистанционно управление.



Фигура 4.2 Архитектура на система за контрол на отдалечени обекти

4.1. Предложение за безжична сензорна мрежа

От предложената БСМ може да се снимат данни за температура, инфрачервено изображение и видеоизображение на определената зона на наблюдение. На фиг. 4.6 е показана блок схема на предложената БСМ.




Фигура 4.6 Блок схема на предложената БСМ

БСМ сменя данните и се изпращат към единен център, където се обработват от невронна мрежа в реално време.

4.2.1. Алгоритъм за обединяване на работата на КНМ с огън и такава с пушек

На фиг. 4.7 е представено схематично обединението на мрежите.



Фигура 4.7 Представяне на съвместна работа на КНМ с огън и такава с пушек

4.2.1. Метод на оценка на КНМ с огън

Оценяването на НМ като цяло е широко разпространено в литературата. Повечето автори се спират на оценяването на точност, прецизност, чувствителност [113], [114], изразени чрез TP (True Positives), TN (True Negatives), FP (False Positives), FN (False Negatives)

$$\text{Чувствителност, \%} = \text{TP}/(\text{TP}+\text{FP}) \times 100 \quad (4.1)$$

$$\text{Специфичност, \%} = \text{TN}/(\text{TN}+\text{FN}) \times 100 \quad (4.2)$$

$$\text{Прецизност, \%} = \text{TP}/(\text{TP}+\text{FN}) \times 100 \quad (4.3)$$

$$\text{Точност, \%} = (\text{TP}+\text{TN})/(\text{TP}+\text{TN}+\text{FP}+\text{FN}) \times 100 \quad (4.4)$$

Има няколко особености, които трябва да бъдат уточнени за тези изображения. Те са набавени от източници, различни от тези, които са използвани за изображенията за обучение и тестване. Също така в тях има две изображения на залез и изгрев, които наподобяват снимки с огън. Значителна разлика има и в текстурата на изображенията. В таблица 4.3 са представени резултати за същите мрежи, но има промяна на БД с изображения от същия фотоапарат, т.е. източникът е един и същ, както и тематиката като гора и огън съвпадат с тези, на които е направено обучението на мрежата.

Таблица 4.3 Резултати от КНМ върху БД с изображения с огън

	КНМ с Conv слой	КНМ SeparableConv слой
РИ	14	16
РН	23	24
НИ	3	1
НН	2	1

Чувствителност, %	82.35	94.12
Специфичност, %	92.00	96.00
Прецизност, %	87.50	94.12
Точност, %	88.90	95.24

Графично функциите на точността и загубите за КНМ за разпознаване на огън са дадени в Приложение 3.

4.2.2. Метод на оценка на КНМ с пушек


В дисертационния труд беше описана КНМ за разпознаване на пушек с БД от изображения, в които има малко или липса на огън. В следващите редове ще бъде представена оценката на работата на мрежата. Ще бъдат използвани аналитичните модели от (4.1) до (4.4) като резултатите ще бъдат представени в таблица 4.5. Разработката на програмата с помощта на библиотеката Керас позволява да се получи оценка на точността на обучената мрежа и на такава след тест. Тези резултати са представени в таб. 4.4.

Таблица 4.5 Оценка на работата на КНМ с пушек

	КНМ с Conv слой	КНМ SeparableConv слой
РИ	11	12
РН	14	13
НИ	2	1
НН	0	1
Чувствителност, %	84.62%	92.31%
Специфичност, %	100%	92.86%
Прецизност, %	84.62%	92.31%
Точност, %	92.59%	92.59%

4.2.3. Оценка на работата на КНМ с огън обединена с КНМ с пушек

Двете мрежи заедно, както беше отбелязано на фиг. 4.7 са реализирани програмно да работят съвместно като на всяка една от тях се подава едно и също изображение. Резултатът от обединението ще е „Има огън“ в случаите, когато от двете мрежи имаме един положителен отговор. Когато и двете мрежи отговорят с „няма огън“, тогава и крайният резултат ще е „няма огън“. Алгоритъм на описаната конюнкция е даден на фиг. 4.10.



Фигура 4.10 Алгоритъм на работа на двете мрежи съвместно

На базата на задълбочен анализ на работа на невронните мрежи поотделно с огън и пламък беше направено предположението, че архитектура от обединението на двете невронни мрежи би допринесло за повишаване точността на разпознаване. Разработването и прилагането на ансамбъл от КНМ за огън и пушек показва, че двете мрежи се допълват и дават по-висока точност при откриването на огън в цифрови изображения. Резултатите представени в таблица 4.6 експериментално потвърждават предложените научни разсъждения.

Таблица 4.6 Оценка на съвместната работа на КНМ с огън и КНМ с пушек

	КНМ с Conv слой	КНМ SeparableConv слой
РИ	27	29
РН	41	43
НИ	3	1
НН	3	1
Чувствителност, %	90.00	95.67
Специфичност, %	91.90	95.73
Прецизност, %	90.00	95.67
Точност, %	91.04	95.30

4.3. Изводи

Използвайки съвременните технологии и подобряване възможностите на камерите може да се изгради възел на БСМ от инфрачервена камера и визуална камера, инсталирана на дрон. Тази мрежа оптимизира типичната сензорна мрежа с намаляване на броя на сензорите, подобряване на цената. Рискът от повреда в сензорите поради обстоятелства на околната среда е сведен до под 3%.

Предложената мрежа е напълно приложима в реални условия. Синтезираната мрежа може да подобри функционалните възможности на вече съществуващи и описани в глава 1 мрежи. Най-значими предимства представени в главата са намаляването на броя на сензорите, представяне на данни (снимки, видео) в реално време. Представената система от БЛА с камера компенсира напълно статичната камера, с възможността да покрие периметри, недостъпни за статичната. По всеобхватното представяне на целевата област като входни параметри на невронна мрежа ще допринесе за постигането на по-високи проценти разпознаваемост на огън сред природата, което е целта на настоящия труд.

Безжичните сензорни мрежи безспорно имат своите предимства и успешното им развитие ще налага тяхната употреба. Една такава мрежа в съчетание с невронна мрежа беше показано в тази глава, че дава добри резултати и база за още разработки в тази насока.

4.4. Научни приноси към глава 4

Синтезирана е архитектура на ансамбъл от КНМ за огън и пламък с цел повишаване на точността на откриване на пожари в открити пространства. Архитектурата дава по-висока точност отколкото при използването на самостоятелна КНМ са за един вид обект.

4.5. Научно – приложни приноси към глава 4

Предложена е архитектура на БСМ с участието на БЛА с цел подобряване на параметрите на вече съществуващи такива мрежи.

Разработена е архитектура, с която върху едно цифрово изображение на открита местност с пожар се прилага разпознаване по два критерия огън и пушек, с което се повишава точността на КНМ и резултатите на разпознаване на огън сред природата са по-високи. Това постига целта, която беше поставена пред дисертационния труд.

НАУЧНИ И НАУЧНО – ПРИЛОЖНИ ПРИНОСИ В ДИСЕРТАЦИОННИЯ ТРУД

Научни приноси

1. Синтезирана е архитектура на ансамбъл от КНМ за огън и пламък с цел повишаване на точността на откриване на пожари в открити пространства. Архитектурата дава по-висока точност отколкото при използването на самостоятелна КНМ са за един вид обект.

Научно – приложни приноси

1. Направен е сравнителен анализ на работата на познатите и широко използвани системи в Европа и в България. В сравнителния анализ е взето предвид и широко разпространения метод за откриване на пожар в България чрез наблюдение от хора (таблица 1.1. и 1.2.).

2. Направен е критичен анализ на предимствата и на някои недостатъци на системите, които са работещи и внедрени в отделните държави и в България (т. 1.1.2, 1.1.3, 1.1.4, 1.1.5, 1.1.6, 1.1.7, 1.1.8).

3. Направен е анализ на популярни методи за разпознаване и класифициране на данни. Направен е критичен анализ на описаните методи, в следствие на който е избран метод за решаване на поставената в дисертационния труд задача (1.2.1, 1.2.2, 1.2.3, 1.2.4, 1.2.5, 1.2.6, 1.2.7).

4. Разработена е архитектура на КНМ с конволюционен слой Conv2D. Сравнена е с предходните две архитектури. С цел откриване на пламък в изображения като тя е сравнена с други две архитектури (таблица 2.6).

5. Разработена е архитектура на КНМ с конволюционен слой Conv2D. Разработената архитектура е с БД от изображения предимно с пушек. Реализирана е в среда IDE PycharmProject с библиотеки Keras и Tensor Flow. Направено е изследване за влиянието на определени параметри от архитектурата върху точността. Цялостната архитектура на мрежата е представена в Приложение 2.

6. Предложена е архитектура на БСМ с участието на БЛА с цел подобряване на параметрите на вече съществуващи такива мрежи.

Разработена е архитектура, с която върху едно цифрово изображение на открита местност с пожар се прилага разпознаване по два критерия огън и пушек, с което се повишава точността на КНМ и резултатите на разпознаване на огън сред природата са по-високи. Това постига целта, която беше поставена пред дисертационния труд.

Приложни приноси

1. Представена и разработена е НМ в IDE PycharmProject с библиотека OpenCV. Представени са резултатите от работата и са сравнени с други мрежи за разпознаване на пламък в статични изображения.

2. Приложно е показана адаптивността и гъвкавостта на КНМ към бързо променящи се среди, което дава големи предимства за използването и като част от БСМ.

3. Приложен принос в дисертацията има събирането, обработването и реализирането на БД с изображения от пламък и пушек.

4. Научно е обосновано и експериментално доказано, че КНМ, която има за входни масиви изображения предимно с пушек поради естеството на изображенията и тяхната текстура не може самостоятелно да бъде надеждна за вземането на правилно решение за наличието на огън или не.

5. Разработена НМ в IDE PycharmProject с библиотека OpenCV. Представени са резултатите от работата и са сравнени с други мрежи за разпознаване на пламък в статични изображения (таблица 2.6).

6. Разработена е подробна архитектура на КНМ с конволюционен слой SeparableConv2D. Научно и опитно са защитени нейните предимства и различия. Аналитично са изчислени и представени математическите операции в първи слой и са подкрепени с експериментални резултати. Разработена е в среда IDE PycharmProject с библиотеки Keras и Tensor Flow. Изцяло архитектурата е представена в Приложение 2.

7. Приложно е показана адаптивността и гъвкавостта на КНМ към бързо променящи се среди, което дава големи предимства за използването и като част от БСМ (таблица 2.6).

СПИСЪК С ПУБЛИКАЦИИТЕ.

A1. Л. Дочева, И. Дочев, М. Павлова, „Софтуерна реализация на система за контрол на отдалечени обекти чрез видеонаблюдение“, Електроника, стр. 35-39, ISSN 1313-3985

A2. Л. Дочева, И. Дочев, М. Павлова, „Апаратна реализация на система за контрол на отдалечени обекти чрез видеонаблюдение“, Електроника, стр. 40-43, ISSN 1313-3985

A3. М. Павлова, „Object Recognition System Operating from Different Type Vehicles Using Raspberry and OpenCV“, World Academy of Science, Engineering and Technology 2018, ISNI 0000000091950263

A4. Л. Дочева, И. Дочев, М. Павлова, „A remote controlled system implementation for object video monitoring“, ELECTROTECHNICA & ELECTRONICA E+E, pp. 310-313, ISSN 0861-4717

A5. М. Павлова, „Using object recognition benefits in a system for fire detection in the nature“, ICEST 2019, ISSN online: 2603-3267, ISSN print: 2603-3259

БИБЛИОГРАФИЯ

[1] “NOAA.”
https://www.avl.class.noaa.gov/saa/products/search?datatype_family=AVHRR
(accessed Jun. 23, 2020).

[2] V. V. Salomonson, “The moderate resolution imaging spectrometer (MODIS),” 28th Aerosp. Sci. Meet. 1990, 1990, doi: 10.2514/6.1990-166.

[3] “MODIS news.” <https://modis.gsfc.nasa.gov/news/> (accessed Jun. 23, 2020).

[4] K. Nakau, M. Fukuda, K. Kushida, H. Hayasaka, K. Kimura, and H. Tani, “Forest fire detection based on MODIS satellite imagery, and Comparison of NOAA satellite imagery with fire fighters’ information,” IARC/JAXA Terr. Team Work., pp. 18–23, 2006.

- [5] К. Р. Любомирова, “Използване на дистанционни методи при провеждане на междинен екологичен мониторинг на природни обекти,” pp. 1–52, 2019.
- [7] A. A. A. Alkhatib, “A review on forest fire detection techniques,” *Int. J. Distrib. Sens. Networks*, vol. 2014, no. 3, p. 597368, Mar. 2014, doi: 10.1155/2014/597368.
- [12] “AlarmEYE AE6000 Forest Fire Video Image Detecting System.” http://www.jgclimited.com/product_classify/dhf-asn-ledchnlian02-fe2/index.php?Product_Site_Classify_SN=21531&PHPSESSID=aqhataua1cnrvkh u6jhd0pcig6&Company_SN=19629&MFC=2 (accessed Jul. 01, 2020).
- [13] Y. X. Li, “Early Bushfire Detection System.”
- [17] L. Yu, N. Wang, and X. Meng, “Real-time Forest Fire Detection with Wireless Sensor Networks.”
- [18] K. H. M. Wajahat KHALID, Asma SATTAR, Muhammad Ali QURESHI, Asjad AMIN, Mobeen Ahmed MALIK, “A smart wireless sensor network node for fire detection,” *Turkish J. Electr. Eng. Comput. Sci.*, vol. 27, pp. 2541–2556, 2019, Accessed: Jul. 15, 2020. [Online]. Available: <http://web.b.ebscohost.com/ehost/pdfviewer/pdfviewer?vid=5&sid=f09b23a5-0d06-4553-8c5b-61ca9b9665b9%40pdc-v-sessmgr03>.
- [19] Министерство на Земеделието Храните и Горите, “Годишен отчетен доклад на ИАГ за 2017 г.,” София, 2017.
- [20] Н. Радева, И. Маринова, and X. Романова, “ПОЖАРИТЕ - ПЪРВОСТЕПЕНЕН РИСК И АНТРОПОГЕННА ОПАСНОСТ ЗА БЪЛГАРИЯ,” *J. Union Sci. - Varna.*, vol. 23, pp. 81–89, 2018, [Online]. Available: <file:///C:/Users/MARIAP~1/AppData/Local/Temp/5586-16142-1-PB.pdf>.
- [25] R. Bennet, *Fire Detection*, First edit. New York: Nova Science Publishers, Inc., 2011.
- [30] B. Scholkopf, R. Williamson, A. Smola, J. Shawe-Taylor, J. Platt, and R. Holloway, “Support Vector Method for Novelty Detection.”
- [31] K. M. Bishop, *Pattern Recognition and Machine Learning*, First edit. New York: Springer Science and Business Media, LLC, 2006.
- [32] Ф. СУ “КлиентОхридски,” “НЕЛИНЕЙНО ОПТИМИЗИРАНЕ.” [Online]. Available: <https://store.fmi.uni-sofia.bg/fmi/or/MO2/NonLinOpt.pdf>.
- [42] Aditya Sharma, “Convolutional Neural Networks in Python - DataCamp.” <https://www.datacamp.com/community/tutorials/convolutional-neural-networks-python> (accessed Aug. 11, 2020).
- [43] Р. Каллан, *Основные концепции Нейронных сетей*, Саутгемпто. Москва: “Вильямс,” 2003.

[52] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Dec. 2016, vol. 2016-Decem, pp. 770–778, doi: 10.1109/CVPR.2016.90.

[53] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” in 32nd International Conference on Machine Learning, ICML 2015, Feb. 2015, vol. 1, pp. 448–456, Accessed: Aug. 14, 2020. [Online]. Available: <https://arxiv.org/abs/1502.03167v3>.

[55] “Torch | Training and investigating Residual Nets.” <http://torch.ch/blog/2016/02/04/resnets.html> (accessed Aug. 17, 2020).

[56] Z. Liu and P. Lou, “DeepFashion: Powering Robust Clothes Recognition and Retrieval with Rich Annotations (Supplementary Material),” Int. Conf. Learn. Represent., pp. 1–14, 2015, doi: 10.1016/j.infsof.2008.09.005.

[57] P. Li and W. Zhao, “Image fire detection algorithms based on convolutional neural networks,” Case Stud. Therm. Eng., vol. 19, p. 100625, Jun. 2020, doi: 10.1016/j.csite.2020.100625.

[69] V. Dumoulin, F. Visin, and G. E. P. Box, “A guide to convolution arithmetic for deep learning,” 2018. [Online]. Available: <http://ethanschoonover.com/solarized>.

[70] “Understanding and Calculating the number of Parameters in Convolution Neural Networks (CNNs) | by Rakshith Vasudev | Towards Data Science.” <https://towardsdatascience.com/understanding-and-calculating-the-number-of-parameters-in-convolution-neural-networks-cnns-fc88790d530d> (accessed Aug. 20, 2020).

[71] “Depthwise separable convolutions for machine learning - Eli Bendersky’s website.” <https://eli.thegreenplace.net/2018/depthwise-separable-convolutions-for-machine-learning/> (accessed Aug. 25, 2020).

[72] “Number of Parameters and Tensor Sizes in a Convolutional Neural Network (CNN) | Learn OpenCV.” <https://www.learnopencv.com/number-of-parameters-and-tensor-sizes-in-convolutional-neural-network/> (accessed Aug. 25, 2020).

[73] G. M. Weiss and F. Provost, “The Effect of Class Distribution on Classifier Learning: An Empirical Study,” Tech. Rep. ML-TR-442, p. 26, Accessed: Oct. 18, 2020. [Online]. Available: https://www.researchgate.net/publication/2364670_The_Effect_of_Class_Distribution_on_Classifier_Learning_An_Empirical_Study.

[74] A. Manolova, “Catégorisation par mesures de dissimilitude et caractérisation d’images en multi échelle,” Université de Grenoble, Français, 2011.

[76] “A guide to receptive field arithmetic for Convolutional Neural Networks | by Dang Ha The Hien | ML Review | Medium.”

<https://medium.com/mlreview/a-guide-to-receptive-field-arithmetic-for-convolutional-neural-networks-e0f514068807> (accessed Aug. 17, 2020).

[77] J. Li, Y. Si, T. Xu, and S. Jiang, “Deep Convolutional Neural Network Based ECG Classification System Using Information Fusion and One-Hot Encoding Techniques,” 2018, doi: 10.1155/2018/7354081.

[80] C.-F. Wang, “What’s the Difference Between Haar-Feature Classifiers and Convolutional Neural Networks? | by Chi-Feng Wang | Towards Data Science,” 2018. <https://towardsdatascience.com/whats-the-difference-between-haar-feature-classifiers-and-convolutional-neural-networks-ce6828343aeb> (accessed Sep. 08, 2020).

[81] 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 Trans. Syst. MAN, Cybern. Syst.*, 2018, [Online]. Available: http://www.ieee.org/publications_standards/publications/rights/index.htm.

[83] K. Gu, Z. Xia, J. Qiao, and W. Lin, “Deep Dual-Channel Neural Network for Image-Based Smoke Detection,” *IEEE Trans. Multimed.*, vol. 22, no. 2, pp. 311–323, Feb. 2020, doi: 10.1109/TMM.2019.2929009.

[84] M. Abo-Tabik, N. Costen, J. Darby, and Y. Benn, “Towards a smart smoking cessation app: A 1D-CNN model predicting smoking events,” *Sensors (Switzerland)*, vol. 20, no. 4, Feb. 2020, doi: 10.3390/s20041099.

[90] Y. Peng and Y. Wang, “Real-time forest smoke detection using hand-designed features and deep learning,” *Comput. Electron. Agric.*, vol. 167, p. 105029, Dec. 2019, doi: 10.1016/j.compag.2019.105029.

[98] J. Brownlee, “A Gentle Introduction to Dropout for Regularizing Deep Neural Networks.” <https://machinelearningmastery.com/dropout-for-regularizing-deep-neural-networks/> (accessed Sep. 18, 2020).

[99] “How ReLU and Dropout Layers Work in CNNs | Baeldung on Computer Science.” <https://www.baeldung.com/cs/ml-relu-dropout-layers> (accessed Sep. 18, 2020).

[100] H. Wu and X. Gu, “Towards Dropout Training for Convolutional Neural Networks.”

[113] K. Patel et al., “A comparative study on polyp classification using convolutional neural networks,” *PLoS One*, vol. 15, no. 7 July, Jul. 2020, doi: 10.1371/journal.pone.0236452.

[114] R. Lagerquist, A. McGovern, C. R. Homeyer, D. J. Gagne, and T. Smith, “Deep learning on three-dimensional multiscale data for next-hour tornado prediction,” *Mon. Weather Rev.*, vol. 148, no. 7, pp. 2837–2861, Jul. 2020, doi: 10.1175/MWR-D-19-0372.1.



Maria Tzoneva Pavlova, M.Sc

**PROCESSING OF DATA, RECEIVED BY WIRELESS SENSOR
NETWORKS, VIA CONVOLUTION NEURAL NETWORK FOR FIRE
RECOGNITION**

ABSTRACT of Ph. D. THESIS

The topic of the dissertation is the development of a new approach in the early fire recognition in forest areas which will improve the already existing systems for early fire recognition. The method is based on Convolution Neural Networks (CNN). The solution proposed could be used with already existing equipment, thus could provide bigger coverage with high accuracy. The global warming and the increase of the average temperatures has caused huge forest fires in Australia, Russia, The USA and many other places due to bigger droughts. The proposed methods could catch the earliest notions of fires and so could prevent huge losses of the so precious lungs of our planet.

The goal of the research is to develop a new approach for fire recognition in forest areas, based on smoke and flame recognition by CNN aiming to increase the precision of the systems for fire alerts.

Using modern technologies and improving camera capabilities, a WNN node can be built from an infrared camera and a visual camera installed on a quadcopter. This network optimizes the typical sensor network by reducing the number of sensors, improving the cost. The risk of sensors damage due to environmental circumstances is diminished to less than 3%. The given UAV system with a camera compensates fully for the static camera, with parameter coverage capabilities not found on the static camera. The images taken by the sensors can be processed by the CNN in real time to allow for fire recognition in the image. As part of the dissertation process, a method of recognizing fire in an image was developed through the CNN. A second CNN has been proposed and subsequently developed to detect smoke in static images. The two networks are combined into an ensemble of CNN, by which means it is aimed to recognize fire with high accuracy. The ensemble from both networks improves their accuracy respectively. One complements the other, thus increasing the accuracy rate relative to the accuracy they are able to achieve in their individual detection work. In this way the goal set in the dissertation work is accomplished. Another achievement is that the accuracy results were compared and are fully competitive to the results of other scientific works on the subject.