

FRI-2G.302-1-CSN-07

**A SOLUTION FOR EARLY FOREST FIRE DETECTION USING
AIRCRAFT PLATFORM AND NEURAL NETWORK COMPUTING
ENGINE ⁷**

Assist. Prof. Diyana Kinaneva, PhD

Department of Telecommunications,
“Angel Kanchev” University of Ruse
Tel.: 082 888 353
E-mail: dkyuchukova@uni-ruse.bg

Eng. Jordan Raychev, PhD Student

Department of Telecommunications,
“Angel Kanchev” University of Ruse
Tel.: 082 888 353
E-mail: jraychev@uni-ruse.bg

Assoc. Prof. Georgi Hristov, PhD

Department of Telecommunications,
“Angel Kanchev” University of Ruse
Tel.: 082 888 663
E-mail: ghristov@uni-ruse.bg

Assoc. Prof. Plamen Zahariev, PhD

Department of Telecommunications,
“Angel Kanchev” University of Ruse
Tel.: 082 888 663
E-mail: pzahariev@uni-ruse.bg

Assist. Prof. Ivanka Tsvetkova, PhD

Department of Telecommunications,
“Angel Kanchev” University of Ruse
Phone: 082 888 836
E-mail: itsvetkova@uni-ruse.bg

***Abstract:** The goal of this paper is to make thorough analysis of the conceptual operating principle of neural networks. The neural networks are the hot topic in today's computing systems because of their ability to “learn” how to perform tasks by considering examples, generally without being programmed or instructed to follow specific rules. The neural networks are inspired by the biological neural networks that constitute human brains. In today's computing systems these networks become widely use in various aspects. The authors of this paper will make a review of how this technology can be implemented in a system for early fire detection. Forest and even urban fires have been and still are serious problem for many countries in the world. Different methods for early fire detection exist and they really help to mitigate fire damages but most of the early fire detection system are implemented inside and they prevent fire damages in close ranges. The planet may also suffer from outside fire damages. In order to decrease the damages from outside (forest or urban) fires we the humans need to implement different techniques. In this paper we present an emerging solution for early fire detection by using an aircraft platform that is capable of taking multiple photos or video of dedicated land fields that are susceptible to fires. All of the captured material are going to be used together with computer vision techniques to predict the existence of fire on the observed lands. Early fire detection could prevent a lot of fire related accidents. In order to implement computer vision technique we first need to train the neural network that we are going to use for making that predictions. Currently, on the market there are available solutions for neural*

network implementation. Such a solution is the Movidius neural stick which is a development kit for ultra-low power embedded deep learning environment developed by Intel..

Keywords: *Aircraft platform, Deep learning, Early fire detection, Neural networks*

ВЪВЕДЕНИЕ

В настоящата статия се представя нов метод за предотвратяване на горски пожари, които силно притесняват жителите на планетата Земя, тъй като те имат огромен и негативен ефект върху околната среда. Горските пожари са причина за унищожението на растителни и животински видове, микроорганизми и други, необходими за нормалното протичане на кръговрата в природата. За да се акцентира върху огромните последици от горските пожари ще се посочи статистика извлечена от доклад на Европейската информационна система за горски пожари [1]. През 2017 година на територията на Европейския съюз в следствие на горски пожари са изгорели над 1,2 милиона хектара природни земи и 127 души, сред които пожарникари и цивилни граждани са станали жертва на тези природни бедствия, въпреки усилията на националните и регионални администрации за горски пожари и подкрепата на европейската комисия за предотвратяване и борба с горските пожари [2].

Системите за ранно откриване на пожари и предотвратяване на големи щети са едни от най-важните компоненти на системите за наблюдение, които се използват за мониторинг на сгради и околна среда. Пожарните инсталации в сградите и закрити помещения разчитат на сензорни системи за откриване на прахови частици във въздуха, които са индикатор за пушек, димящ обект или пожар. Тези системи обаче, често се задействат и при отсъствие на опасност, например при пушач в закрито помещение, което е показател за тяхната неефективност в определени сценарии. Голяма част от системите за ранно предизвестяване от пожари, които са инсталирани на открито за мониторинг на горско площи и околна среда също са неефективни. Тяхната неефективност е скрита зад статичността им и липсата на обхват и мащабност върху наблюдавания обект.

Голяма част от системи за ранно предотвратяване на пожари, възникнали на открити места се позовават на термални камери. Това са свръхчувствителни термовизионни камери, които дават възможност за откриването на огнища на открито на база на топлинния поток, който се извисява над мястото на горене. Недостатък на термалните камери също е статичността и липсата на обхват върху наблюдавания обект. От друга страна, когато възниква пожар, в най-общият случай първото нещо, което сигнализира неговата поява е пушекът. Термалната камера би засякла пламъка, тъй като той е първоизточника на топлинно излъчване. Заради тези недостатъци на съвременните системи за ранно откриване на пожари проучването и търсенето на нови подходи продължава. В настоящата статия се разглежда възможността за изграждане на динамична система посредством безпилотни летателни апарати, които да кръжат над наблюдаваната територия и да извличат снимков или видео материал. С помощта на средствата на компютърното зрение и изкуствения интелект, този снимков материал ще бъде анализиран, ще се търси наличие на дим в кадъра и при откриване на такъв ще се задейства аларма, която ще доведе до последващи действия.

КОНЦЕПТУАЛЕН МОДЕЛ НА ПЛАТФОРМА ЗА РАННО ОТКРИВАНЕ НА ГОРСКИ ПОЖАРИ

Използването на летателни апарати за откриване и предотвратяване на пожари е техника, която широко се използва, но поради пилотното управление на летателните средства този подход се определя като доста рискован в наши дни. Съвременните технологии, свързани с развитието на безпилотните летателни апарати дават възможност много от рисковете да бъдат намалени и тези летателни средства започват да намират различни приложения в направленията за откриване на горски пожари.. Едно такова направление е свързано с изграждане на система за откриване на горски пожари, която е базирана на два типа безпилотни летателни апарати – с фиксирано крило и с ротационно крило. Концептуалния подел на платформата за откриване на горски пожари е представена

на фиг.1. Тази платформа е част от THEASIS система за ранно откриване и наблюдение на горски пожари, която има три основни конфигурации. Изграждането на THEASIS система е една от основните задачи на проект "Forest Monitoring System for Early Fire Detection and Assessment in the Balkan-Med Area" SFEDA (code 2263), в който Русенски университет има активно участие. Водеща организация на проекта е катедрата по Машиностроене и Аеронавтика към университета в Патра (Гърция), а партньори са Децентрализирана администрация на Пелопонес (Западна Гърция и Йония), Горски институт за изследвания към гръцката селскостопанска организация DEMETER, Русенски университет „Ангел Кънчев“ (България), Дирекция природен парк „Русенски лом“ (България), Кипърски технологичен университет (Кипър) и Общински съвет на Пано Платрес (Кипър).



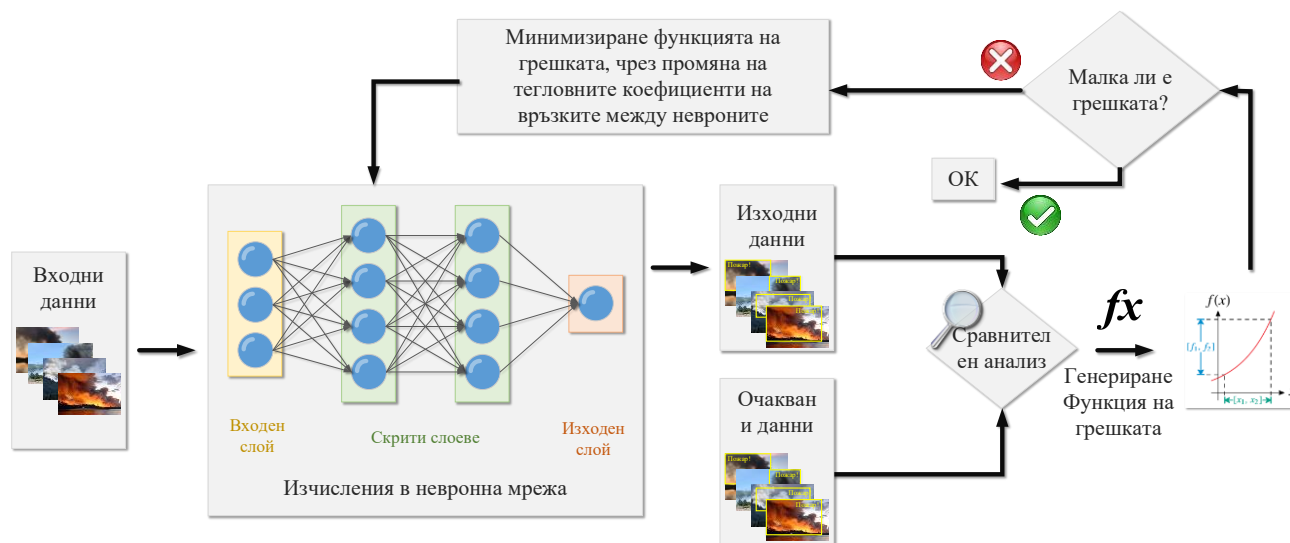
Фиг.1 Концептуален модел на система за ранно откриване на горски пожари реализирана с БЛА с фиксирано крило и БЛА с ротационно крило.

Както се вижда от фиг.1 системата е изградена от няколко основни компонента. За постоянно наблюдение ще се използва БЛА с фиксирано крило с вертикално излитане и кацане. Системата ще бъде изградена над територията на природен парк „Русенски Лом“. Основната задача на този компонент ще бъде постоянно наблюдение на горската част на парка. За реализирането му ще бъде използват ALTi VTOL (vertical take-off and landing) с фиксирано крило. Дронът е снабден с NightHawk 2 EO/IR камера с 20x оптично увеличение и термална резолюция от 640x480. Очевидно ролята на дрона ще бъде да следи термална характеристика на повърхността. В случай, че бъде засечено повишение на температурата в даден участък ще бъде изпратена сигнализация до базовата станция, която освен съобщение за потенциална тревога от пожар ще съдържа и GPS координатите на засеченото потенциално огнище. За да се потвърди наличието на пожар ще се включат други два безпилотни летателни апарата, които летят на ниска надморска височина. За реализиране на този компонент са предвидени БЛА с ротационно крило от серията на DJI – Matrice 600 Pro и Matrice 210 RTK. Предимство на втората серия е, че притежава само балансираща стойка с позиция за две камери, едната от които може да е инфра червена, а другата стандартна оптична камера от серията X5S. Тук в този компонент може да бъде интегрирано компютърно зрение, което с помощта на средствата за изкуствен интелект да открива наличие на пушек в снимките, заснети по време на полет на наблюдаваният обект. Както вече стана ясно, откриването на пушек преди огън би довело до по-ранно откриване на пожар и предотвратяване на по-големи щети.

Ако БЛА с ротационно крило, кръжащо на ниска височина – 10 – 350 метра, потвърди наличието на огнище, веднага се изпраща сигнализация до наземните служби за пожарна отбрана. Докато протича процесът по прекратяване на евентуално възникналия пожар, БЛА с ротационно крило продължава да кръжи над наблюдаваната повърхност и служи като помощно средство по време на отстраняването на възникналото огнище.

ПРИНЦИПИ НА КОМПЮТЪРНОТО ЗРЕНИЕ, ДЪЛБОКОТО ОБУЧЕНИЕ И ИЗКУСТВЕНИЯ ИНТЕЛЕКТ

В настоящата статия се разглежда сценарий на използване на невронни мрежи за компютърно зрение, които се обучават по определен модел да откриват или прогнозираят определени закономерности по зададени входни данни. Изкуствените невронни мрежи са аналог на биологичните невронни мрежи. Те са изградени от прости изчислителни елементи (изкуствени неврони), които са групирани в три различни типа слоеве: входен слой, скрити слоеве и изходен слой. Скритите слоеве могат да съдържат един слой неврони, тогава се говори за просто самообучение или повече слоеве неврони – дълбоко самообучение. Независимо от броя на скритите слоеве, тяхната функция е да изпълняват математически изчисления на база на входните данни. Изходния слой връща изходните данни. Всяка връзка между невроните се асоциира с някаква тежест. Този коефициент на тежестта диктува важността на входната стойност. Първоначалните коефициенти на тежестта се задават на случаен принцип. Всеки неврон има функция на активация, чиято основна задача е да стандартизира изхода на неврона. За да бъде използвана една невронна мрежа за откриване на пушек в снимки например, тя трябва първо да бъде обучена или тренирана. Обучението на невронните мрежи е една от най-трудните задачи, първо защото е необходим голям брой входни данни и второ необходима е голяма изчислителна мощност.



Фиг.2 Принцип на наблюдаваното самообучение

Самото обучение може да бъде наблюдавано (supervised deep learning) или ненаблюдавано (unsupervised deep learning), като има съществена разлика между двата подхода на самообучение. Първият тип дълбоко самообучение включва използването на предварително дефинирани данни, които имат входове и очаквани резултати. Обучението протича на следния принцип: вкарват се дефинираните данни в невронната мрежа, тя извършва необходимите изчисления и връща отговор изходен резултат. Отговорът, който връща системата се сравнява с очакваните резултати. На база на това сравнение се генерира функция, която показва колко неправилни са резултатите на изчисленията на невронната мрежа спрямо реалните резултати (очакваните). Тази функция се нарича функция на грешката. Редуцирането на функцията на грешката е част от самообучението. То се извършва чрез промяна на коефициентите на тежестите между невроните дотогава докато не се получи

ниска стойност на функцията на грешката. Промяната на коефициентите може да се реализира на случаен принцип, но това би било неефективно. Вместо това се използва друга техника, която позволява намирането на минимума на функцията на грешката. Тя работи, като променя коефициентите на малки стъпки след всяка итерация на входните данни и следи в коя посока е минимумът на функцията на грешката. За реализирането на този тип самообучение е необходимо невронната мрежа да изпълнява многократно изчисления върху входните данни (итеративно, многократно) при различни коефициенти на тежестите на връзките между невроните. Този подход е показан на фиг.2.

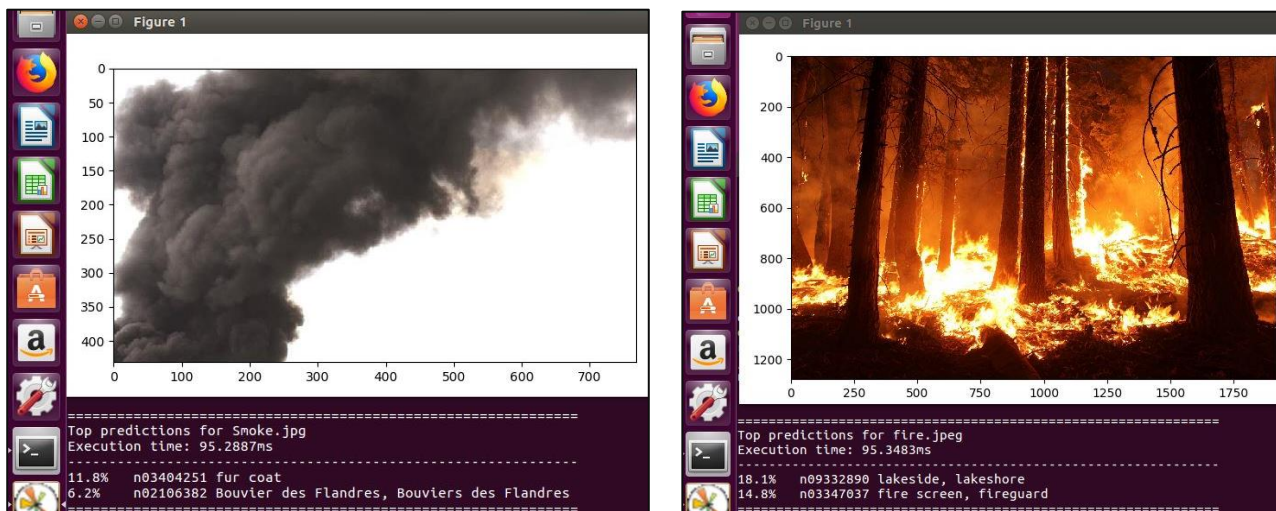
При другият тип самообучение, което е ненаблюдавано се извършват два основни теоретични анализа – корелационен и регресионен анализ. Регресионния анализ е направление в математическата статистика, в което се изучават и оценяват възможните функционални зависимости между две или повече случайни величини. Основни въпроси са дали съществува функционална зависимост между две зависими случайни величини и ако да – да се намери функция, която да я описва достатъчно точно. Задачата на корелационния анализ е да установи степента на влияние на две величини, между които съществува функционална или стохастична зависимост. Когато се тренира невронна мрежа по този подход е необходимо входните данни предварително да бъдат класифицирани. Например ако се използват невронни мрежи за откриване на обекти в снимки при обучението е необходимо входните данни да бъдат класифицирани спрямо обектите, който ще се откриват.

ИЗПОЛЗВАНЕ НА НЕВРОННА МРЕЖА ЗА КОМПЮТЪРНО ЗРЕНИЕ, КОЯТО ДА ОТКРИВА НАЛИЧИЕ НА ПУШЕК В ИЗОБРАЖЕНИЕ

В литературата се срещат доста анализи и методи за ранно откриване на пожари с помощта на съвременните техники за компютърно зрение. Доста от анализите [3, 4, 5, 6] се позовават на методи за откриване на пламък в изображение и видео. В по-новите изследвания се разглеждат методите за откриване на пожар в изображение или видео на база наличие на пушек в картината. Откриването на пушек в изображение, например може да се извърши на два етапа, както е представено в [7]. При първият етап се извличат сивите пиксели от картината, тъй като е известно, че пушекът в най-общия случай покрива нюансите на сивия цвят – от светло сиво до тъмно сиво или дори черно. Очевидно е, че само с този подход би имало доста фалшиви аларми, тъй като сивият цвят се среща и на други места в природата – сгради, скали, дрехи на хора и редица други. За да се намалят грешните предположения за пожар се извършва още една стъпка, която е базирана на динамичната характеристика на пушека. Пушека е дифузионен процес, при който фините прахови частици в състава на пушека се пренасят от област с висока концентрация към област с ниска концентрация. При втората стъпка се прави динамичен анализ на движението на предполагаемия пушек и се потвърждава или не наличието на пушек в картината.

За реализирането на система за ранно откриване на пожар чрез похватите на компютърното зрение и съвременните невронни мрежи в настоящия доклад се използва Intel Movidius Stick. Това е изкуствена невронна мрежа интегрирана в USB стик със следните параметри: Процесор Intel® Movidius™ Myriad™ 2 Vision Processing Unit (VPU), USB 3.0 Type A, минимални системни изисквания: компютър с Ubuntu 16.04 операционна система или Raspberry 3 модел B с Ubuntu 16.04 виртуална машина, 1 GB RAM, 4GB свободно дисково пространство [8]. За обучението на невронните мрежи се използват рамкови платформи TensorFlow [9] или Caffe [10]. TensorFlow е платформа за дълбоко обучение с отворен код разработен от екипа на Google Brain за изпълнение на вътрешни задачи на Google. В последствие става достъпна за външни потребители. Вече има разработени различни модели за обучение на невронната мрежа на Intel. Голяма част от тях са публично достъпни и могат да се използват за доразвиване, тъй като са с отворен код. Пример за модел, с който може да бъде обучена невронната мрежа е image-classifier, който дава възможност различни изображения да бъдат класифицирани по предварително зададени класификатори. Този модел е приложен с цел демонстрация и тестване върху системата за ранно откриване на пожари. За да се тества адекватността на модела и точността му за

откриване на пушек или пожар в изображения са подбрани две изображения от публичното пространство. Тези изображения са подадени на невронната мрежа и тя връща резултат с класификация, която е изчислила. На фиг. 3 е представен обзор от двата теста.



Фиг. 3 Изходни резултати от невронна мрежа обучане да класифицира обекти в изображения

За провеждането на теста са използвани две изображения – едното с наличие на пушек, а другото с горски пожар. Вижда се, че този модел не дава точни резултати и това е съвсем очакван резултат. Класифицирането на изображенията става на база предварително дефинирани категории. Пушекът най-вероятно не попада в нито една категория затова не е разпознат като такъв. От друга страна горският пожар е класифициран като такъв, но вероятността на класификацията да е вярна е едва 14,8 % - твърде недостатъчна за да се приеме системата за точна.

Очевидно невронната мрежа трябва да бъде обучена да разпознава пушек или пожар. Тоест трябва да се използва масив от входни данни, които например могат да бъдат различни изображения на пушек като тези показани на фиг. 4.



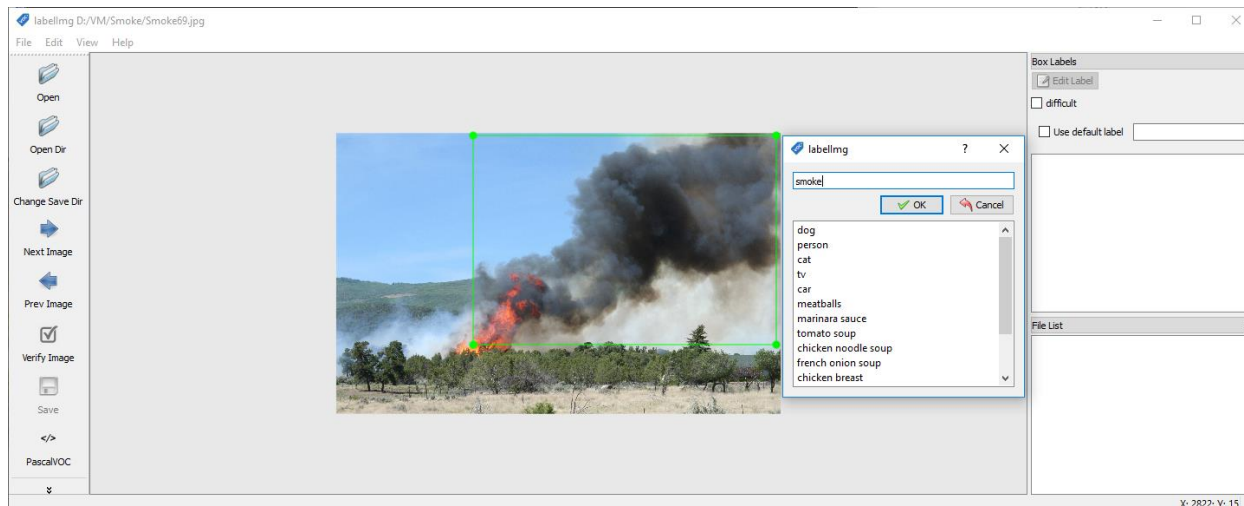
Фиг. 4 Примерни изображения подходящи за входни данни при обучение на невронна мрежа за разпознаване на пушек

Самото обучените протича на три етапа:

- Подготовка на входните данни;
- Трениране;
- Експорт на трениран модел, плюс интеграция към невронна мрежа.

Входните данни, които TensorFlow използва трябва да са структурирани в т. нар. TFRecord файл. Тези файлове съхраняват данните в последователност от двоични стрингове. За да се генерира масива от входни данни (във формат от TFRecord) е необходимо първо да се подберат RGB изображения в jpeg или png формат (колко повече толкова по-добро ще бъде обучението) и второ да се генерира списък с координатите (xmin, ymin, xmax, ymax) на правоъгълник, в който е поместен обекта в изображението и класа на обекта. В разглеждания сценария ще има само един клас – пушек. Списъкът с координати е за всяка снимка е код в .xml формат, който в най-общия случай има десетки редове, а може и да са повече в зависимост от маркираните обекти.

Създаването на .xml анотациите на пръв поглед изглежда доста продължителна и не толкова приятна работа, но за щастие вече има разработени софтуерни продукти, които позволяват оптимизирането на този процес. Пример за такъв софтуерен инструмент е labelImg [11], който дава възможност посредством използването на графичен интерфейс, лесно да се маркира избрания обект в изображението и класифицира като обект. В разглеждания сценарий, обектът представлява пушек. Както е показано на фиг. 6 – маркираната зона е класифицирана като обект пушек (smoke).



Фиг.5 Създаване на анотации – списъци с координати на класифициран обект

След събирането на необходимия брой снимки и създаването на анотации към тях е необходимо от тях да се генерира т.нар. входен масив (dataset) в .TFRecord формат. Отново се намират инструменти, които позволяват оптимизирането на този процес. В най-общия случай тези инструменти представляват програмен код, който позволява генерирането на входни данни в подходящ формат за обучителна платформа, а тя в случая е TensorFlow.

```

diyana@Diyana: ~/Custom-Object-Detection
INFO:tensorflow:Restoring parameters from /home/diyana/Smoke-Object-Detection/model.ckpt
INFO:tensorflow:Running local_init_op.
INFO:tensorflow:Done running local_init_op.
INFO:tensorflow:Starting Session.
INFO:tensorflow:Saving checkpoint to path /home/diyana/Smoke-Object-Detection/train/model.ckpt
INFO:tensorflow:Starting Queues.
INFO:tensorflow:global_step/sec: 0
INFO:tensorflow:Recording summary at step 0.
INFO:tensorflow:global step 1: loss = 5.1097 (68.684 sec/step)
INFO:tensorflow:global step 2: loss = 5.5548 (12.846 sec/step)
INFO:tensorflow:global step 3: loss = 4.7908 (9.923 sec/step)
INFO:tensorflow:global step 4: loss = 4.6132 (10.450 sec/step)
INFO:tensorflow:global step 5: loss = 4.1127 (9.706 sec/step)
INFO:tensorflow:global step 6: loss = 3.6899 (10.493 sec/step)
INFO:tensorflow:global_step/sec: 0.0571981
INFO:tensorflow:Recording summary at step 6.
INFO:tensorflow:global step 7: loss = 2.4001 (11.389 sec/step)
INFO:tensorflow:global step 8: loss = 2.4314 (9.267 sec/step)
INFO:tensorflow:global step 9: loss = 1.8637 (10.613 sec/step)
INFO:tensorflow:global step 10: loss = 3.1020 (10.320 sec/step)
INFO:tensorflow:global step 11: loss = 3.2979 (11.367 sec/step)
    
```

Фиг.6 Обучение на модела

Следващият етап е обучението на модела (фиг.6). Може да се създаде модел и той да бъде обучен от нула, но това изисква много ресурси и изчислителна мощ. Има алтернативен вариант, при който може да се избере готов обучен модел и той да бъде допълнително обучен да разпознава обектите, класифицирани като входни данни. Самото обучение е

итеративно и протича на множество стъпки. Понякога то може да отнеме дни или седмици зависимост от използвания изчислителен ресурс.

След като бъде обучен модел, той се конвертира в подходящ вид за невронната платформа, която ще се използва. В разглеждания сценарий, обученения модел се интегрира в Intel Movidius невронната мрежа и от тук нататък, откриването на пушек в заснети картини е задача, която ще си извършва от невронната мрежа.

ЗАКЛЮЧЕНИЕ

Използването на изкуствен интелект за откриване на пожари е ефективен метод, който дава бързи резултати. Могат да се използват сложни алгоритми за откриване на пожар в картина или видео, които да извършват необходимите изчисления за извличане на пиксели и засичане на движение, но те са свързани с необходимост от много голям изчислителен ресурс. При това тези алгоритми са ефективни при определена видео последователност. Ако е необходимо непрекъснатото следене за наличие на пожар тези алгоритми трябва да изчисляват непрекъснато.

Като алтернатива в настоящия материал се предлага използването на изкуствен интелект, при който огромен изчислителен ресурс ще е необходим само при обучението на модел. След като е наличен обучен модел, той може с прости итерации да прогнозира наличието на пушек в картината, без да е необходимо да изпълнява сложни алгоритми за откриване на зависимост (тези зависимости са вече дефинирани при обучението на модела).

ACKNOWLEDGMENTS

This paper reflects the results received during the implementation of Project "Forest Monitoring System for Early Fire Detection and Assessment in the Balkan-Med Area" (SFEDA), project code 2263, financed under the transnational Cooperation Programme INTERREG V-B "Balkan-Mediterranean 2014-2020", co-funded by the European Union and the National Funds of the participating countries. The study was financially supported by the University of Ruse "Angel Kanchev" contract №BG05M2OP001-2.009-0011-C01, "Support for the development of human resources for research and innovation at the University of Ruse "Angel Kanchev"", which is funded with support from the Operational Program "Science and Education for Smart Growth 2014 - 2020" financed by the European Social Fund of the European Union.

REFERENCES

- [1] Official webpage of the European Forest Fire Information System at: <http://effis.jrc.ec.europa.eu/>
- [2] Jesús San-Miguel-Ayanz, Tracy Durrant, Roberto Boca, Giorgio Libertà, Alfredo Branco, Daniele de Rigo, Davide Ferrari, Pieralberto Maianti, Tomàs Artés Vivancos, Hugo Costa, Fabio Lana, Peter Löffler, Daniel Nuijten, Anders Christofer Ahlgren, Thaïs Leray; Forest Fires in Europe, Middle East and North Africa 2017. EUR 29318 EN, ISBN 978-92-79-92831-4, doi: 10.2760/663443
- [3] Noda, S., and K. Ueda. "Fire detection in tunnels using an image processing method." Vehicle Navigation and Information Systems Conference, 1994. Proceedings., 1994. IEEE, 1994.
- [4] Cappellini, Vito, L. Mattii, and Alessandro Mecocci. "An intelligent system for automatic fire detection in forests." Recent issues in pattern analysis and recognition. Springer, Berlin, Heidelberg, 1989. 351-364.
- [5] Chen, Thou-Ho, Cheng-Liang Kao, and Sju-Mo Chang. "An intelligent real-time fire-detection method based on video processing." Security Technology, 2003. Proceedings. IEEE 37th Annual 2003 International Carnahan Conference on. IEEE, 2003.
- [6] Chen, Thou-Ho, Ping-Hsueh Wu, and Yung-Chuen Chiou. "An early fire-detection method based on image processing." Image Processing, 2004. ICIP'04. 2004 International Conference on. Vol. 3. IEEE, 2004.

[7] Wang, Da-Jinn, Yen-Hui Yin, and Tsong-Yi Chen. "Smoke Detection for Early Fire-Alarm System Based on Video Processing." Journal of Digital Information Management 6.2 (2008).

[8] Intel Movidius Stick Technical Specifications: <https://software.intel.com/en-us/neural-compute-stick>

[9] An open source machine learning framework for everyone: <https://www.tensorflow.org/>

[10] Deep learning framework by BAIR, created by Yangqing Jia, lead developer Evan Shelhamer: <http://caffe.berkeleyvision.org/>

[11] Graphical image annotation tool and label object bounding boxes in images: <https://github.com/tzutalin/labelImg>