

EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY

Evidenčné číslo: 103004/I/2025/36154780123474180

AUTOMATICKÝ SYSTÉM DETEKČIE POŽIARU
S VYUŽITÍM EDGE COMPUTING

Diplomová práca

2025

Bc. Stefan Otto Novak

EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY

AUTOMATICKÝ SYSTÉM DETEKČIE POŽIARU
S VYUŽITÍM EDGE COMPUTING

Diplomová práca

Študijný program: Informačný manažment
Študijný odbor: Ekonómia a manažment
Školiace pracovisko: Katedra aplikovanej informatiky
Vedúci záverečnej práce: Ing. Peter Procházka, PhD.

Bratislava 2025

Bc. Stefan Otto Novak

Pod'akovanie

S úctou ďakujem môjmu vedúcemu práce, pánovi Ing. Petrovi Procházkovi, PhD., za jeho odborné vedenie a neoceniteľné rady, ako aj svojim rodičom a kamarátom za ich trvalú podporu a povzbudenie v priebehu celého štúdia.

ABSTRAKT

NOVAK, Stefan Otto: *Automatický systém detekcie požiaru s využitím Edge Computing*. – Ekonomická univerzita v Bratislave. Fakulta hospodárskej informatiky; Katedra aplikovanej informatiky. – Vedúci záverečnej práce: Ing. Peter Procházka, PhD. Bratislava: FHI, 2025, 54 strán.

Diplomová práca sa zaoberá návrhom automatického systému detekcie požiaru, ktorý spracúva údaje priamo na mieste vzniku využívajúc edge computing. Využíva optimalizované neurónové siete na edge devices, takže dokáže spoľahlivo identifikovať oheň, dym či únik plynu aj bez nepretržitého pripojenia na internet. Práca je členená do troch kapitol, obsahuje 16 obrázkov, 5 grafov a 1 tabuľku, pričom prvá kapitola sa sústreďuje na teoretický prehľad prístupov k detekcii požiaru. V druhej kapitole sa zameriavame na presné definovanie cieľov práce, opis metódy skúmania a metódy práce. Záverečná kapitola prezentuje realizáciu, experimentálne nasadenie a vyhodnotenie funkčného prototypu. Výsledky potvrdzujú výhody spracovania dát na úrovni edge a ukazujú, že uvedené riešenie je perspektívne pre použitie v priemysle, skladoch horľavých materiálov či iných priestoroch s obmedzeným internetovým prístupom.

Kľúčové slová: detekcia požiaru, edge computing, TinyML, neurónová sieť

ABSTRAKT

NOVAK, Stefan Otto: *Automatic Fire Detection System Using Edge Computing*. – University of Economics in Bratislava. Faculty of Economic Informatics; Department of Applied Informatics. – Thesis Supervisor: Ing. Peter Procházka, PhD. Bratislava: FHI, 2025, 54 pages.

This diploma thesis deals with the design of an automatic fire detection system that processes data directly at the source using edge computing. It utilizes optimized neural networks on edge devices, enabling reliable identification of fire, smoke, or gas leaks even without a continuous internet connection. The thesis is divided into three chapters, including 16 images, 5 graphs and 1 table, with the first chapter focusing on a theoretical overview of fire detection approaches. In the second chapter we describe the exact objectives of the work, research methodology and work methodology. The final chapter presents the implementation, experimental deployment, and evaluation of a functional prototype. The results confirm the advantages of data processing at the edge level and show that the presented solution is promising for use in industry, flammable material warehouses, or other areas with limited internet access.

Keywords: fire detection, edge computing, TinyML, neural network

Obsah

Zoznam ilustrácií.....	6
Zoznam skratiek a značiek.....	7
Slovník.....	8
Úvod.....	9
1 Súčasný stav problematiky doma a v zahraničí.....	11
1.1 Prehľad a význam požiarnej ochrany v interiéroch	11
1.1.1 Rizikové faktory v interiéroch	12
1.1.2 Legislatíva a prevencia	13
1.2 Tradičné systémy detekcie požiaru	14
1.3 Moderné technológie a Edge Computing	18
1.4 Využitie Edge Computingu v oblasti detekcie požiarov	19
1.5 Cloud vs. Edge computing.....	21
1.6 Strojové učenie na Edge zariadeniach	22
1.7 MLOps platforma Edge Impulse	24
2 Cieľ práce, metodika práce a metódy skúmania.....	26
3 Výsledky práce.....	27
3.1 Výber a popis hardvéru	27
3.1.1 Arduino Nano 33 BLE	27
3.1.2 Vybavenie snímačov	28
3.1.3 Pripojenie komponentov a elektronický obvod	30
3.2 Scenár simulácie požiaru pre zaznamenávanie údajov	32
3.3 Analýza a spracovanie dát	33
3.4 Neurónová sieť.....	38
3.5 Dosiahnuté výsledky klasifikácie	40
3.5.1 Možnosť pretrénovania.....	41
3.5.2 Vplyv prostredia na výsledky a obmedzenia experimentu	42
3.5.3 Zlyhania a odolnosť systému voči výpadkom senzorov	42
3.6 Implementácia neurónovej siete na platforme Arduino.....	43
3.7 Webová aplikácia a správa dát.....	46
Záver.....	49
Zoznam použitej literatúry.....	51

Zoznam ilustrácií

Obrázok 1: Architektúra rozhodovacieho systému SMOKE	20
Obrázok 2: Dvojstohová alokačná stratégia.....	23
Obrázok 3: Arduino Nano 33 BLE pripojené k univerzálnej doske	28
Obrázok 4: Predná a zadná strana použitých senzorov, usporiadaných zľava doprava: MQ2, MQ135, infračervený senzor 55694	29
Obrázok 5: Technická schéma zapojenia hardvérových komponentov	31
Obrázok 6: Meranie údajov pri plynovom sporáku.....	33
Obrázok 7: Meranie údajov pri ohni a dyme.....	33
Obrázok 8: Graf 5-sek. záznam únik plynu.....	35
Obrázok 9: Gra 5-sek. záznam v blízkosti ohňa.....	35
Obrázok 10: Graf 5-sek. záznam normálneho prostredia.....	35
Obrázok 11: Priemerné hodnoty senzorov	37
Obrázok 12: RMS hodnoty senzorov	38
Obrázok 13: Architektúra neurónovej siete (vrstvy).....	39
Obrázok 14: Matica zmätenia výsledkov	41
Obrázok 15: Snímka obrazovky z webovej stránky.....	47

Zoznam skratiek a značiek

AI – Artificial Intelligence

BLE – Bluetooth Low Energy

DETR – DEtection TRansformer (architektúra v AI)

DSP – Digital Signal Processing

ESP – Espressif Systems (napr. ESP-01 WiFi modul)

HTTP – Hypertext Transfer Protocol

IO – Input/Output

IR – InfraRed

IoT – Internet of Things

ML – Machine Learning

MQ – Typ senzorov (napr. MQ2, MQ135)

NFPA – National Fire Protection Association (USA)

PORT – Komunikačný port

POST – HTTP request

RMS – Root Mean Square

TCP – Transmission Control Protocol

Slovník

Artificial Intelligence – Umelá inteligencia

Dataset – Dátová množina

Edge Computing – Lokálne spracovanie údajov (na zariadení)

Embedded System – Vstavaný systém

Framework – Nástrojový rámec (napr. softvérový)

Internet of Things – Internet vecí

Machine Learning – Strojové učenie

Root Mean Square – Stredná kvadratická hodnota

TinyML – Strojové učenie pre malé zariadenia

Úvod

Automatická detekcia požiarov predstavuje kľúčovú súčasť bezpečnostných opatrení, výrazne ovplyvňujúcu ochranu ľudských životov, materiálnych hodnôt a životného prostredia. Napriek technologickému pokroku požiare stále predstavujú vážnu hrozbu spôsobujúcu ekonomické škody, straty na životoch a rozsiahle environmentálne následky. S rastúcimi požiadavkami na bezpečnosť v rôznych priemyselných a nepriemyselných oblastiach, predovšetkým v skladoch horľavých materiálov a podobných rizikových priestoroch, rastie význam spoľahlivých systémov schopných detegovať a hlásiť požiare v reálnom čase.

Tradičné protipožiarne systémy často využívajú centralizované spracovanie signálov alebo cloudové riešenia, ktoré môžu prinášať viaceré nevýhody, najmä vyššiu odozvu a riziko výpadku v prípade nestabilného internetového pripojenia. Preto sa v posledných rokoch dostáva do popredia koncept Edge Computingu, ktorý umožňuje spracovávať dáta lokálne, priamo na zariadeniach, kde sú údaje snímané. Lokálne spracovanie minimalizuje čas odozvy, čo výrazne prispieva k rýchlejšej reakcii a zvýšenej spoľahlivosti celého systému.

Táto diplomová práca sa zameriava na návrh a implementáciu automatického systému detekcie požiarov, ktorý využíva princípy Edge Computingu a technológie strojového učenia optimalizované pre zariadenia s obmedzenými zdrojmi. Cieľom je vyvinúť robustný a spoľahlivý prototyp schopný okamžitej detekcie a klasifikácie požiaru na základe senzorických údajov.

V rámci teoretickej časti sme podrobne analyzovali súčasný stav poznania a praxe, vrátane prehľadu tradičných aj moderných metód detekcie požiarov. Naša rešerš zahŕňala porovnanie cloudových a edge riešení, pričom sme identifikovali významné výhody Edge Computingu, najmä v oblastiach so slabou konektivitou. Osobitnú pozornosť sme venovali aj nasadeniu neurónových sietí v prostrediach s obmedzenými zdrojmi, čím sme položili teoretické základy pre praktickú realizáciu.

Praktická časť práce zahŕňala návrh a konštrukciu funkčného prototypu založeného na platforme Arduino Nano 33 BLE v kombinácii s plynovými senzormi MQ2 a MQ135 a infračerveným sensorom. Získané údaje zo sensorov boli spracované neurónovou sieťou optimalizovanou na prevádzku priamo na mikrokontroléri, pričom experimentálne testovanie potvrdilo 100 % presnosť klasifikácie požiarov. Tento výsledok poukazuje na

potenciál nami navrhnutého systému pre aplikáciu v rôznych rizikových objektoch, ako sú sklady či priemyselné prevádzky, kde je kritická okamžitá detekcia požiaru.

Prínosom práce je integrácia moderných technológií, ako sú plynové a infračervené senzory spolu s neurónovými sieťami, do kompaktného a efektívneho systému. Tento systém dokáže rýchlo a spoľahlivo identifikovať požiarne riziká, čo prispieva k výraznému zvýšeniu bezpečnosti objektov a minimalizácii potenciálnych škôd spôsobených oneskorenou reakciou na vznik požiaru.

1 Súčasný stav problematiky doma a v zahraničí

Táto kapitola poskytuje prehľad súčasných poznatkov a riešení v oblasti požiarnej ochrany, pričom sa zameriava na technické aj praktické aspekty. Prezentuje postupný vývoj technológií na detekciu požiarov a analyzuje, akým spôsobom tieto riešenia reagujú na rastúce nároky v oblasti bezpečnosti a ochrany. Kapitola tiež poukazuje na významné inovačné trendy, ktoré sa začínajú uplatňovať v praxi.

1.1 Prehľad a význam požiarnej ochrany v interiéroch

Požiare v budovách predstavujú celosvetovo závažný problém z hľadiska strát na životoch aj majetku. Každoročne dochádza k miliónom požiarov v interiéroch, napríklad v Európe sa odhaduje 2,0 – 2,5 milióna požiarov ročne, ktoré spôsobia približne 20 000 – 25 000 úmrtí a státisíce zranení. Zarážajúcim faktom je, že až ~80 % obetí požiarov pripadá na súkromné obydlia (Kobes, 2009). Podobný trend vidno aj inde vo svete, hoci požiare v domácnostiach tvoria menšinu všetkých incidentov, spôsobujú väčšinu úmrtí. V USA napríklad požiare v bytoch a rodinných domoch predstavovali len 25 % hlásených požiarov v roku 2021, no spôsobili až ~75 % všetkých úmrtí pri požiari. Každý rok tak v dôsledku požiarov v interiéroch prichádzajú o život tisíce ľudí a priame ekonomické straty dosahujú miliardy eur. Odhaduje sa, že celosvetové náklady spojené s požiarmi predstavujú približne 1 % globálneho HDP ročne. Popri obetiach na životoch zanechávajú požiare aj mnoho zranených a obrovské materiálne škody, napríklad v USA v roku 2021 evidovali vyše 1,35 milióna požiarov so sumárnou škodou ~15,9 miliardy USD. Tieto štatistiky vyzdvihujú mimoriadny význam protipožiarnych bezpečnostných opatrení v interiéri (Hall & Evarts, 2022; Khan et al., 2022).

Najčastejšie scenáre zahŕňajú požiare v obytných domoch, kde dochádza k tragickým dopadom na rodiny a komunity. Podľa štatistík NFPA takmer tri pätiny všetkých úmrtí pri domácich požiaroch nastávajú v objektoch, kde nie sú nainštalované žiadne alebo funkčné hlásiče požiaru. Včasná detekcia umožňuje rýchlu evakuáciu osôb a včasný zásah, čím sa znižuje počet zranení aj rozsah škôd. Napríklad analýzy NFPA ukázali, že kombinácia automatických hlásičov požiaru a sprinklerového hasenia znižuje mieru úmrtnosti až o 90 % v porovnaní s objektmi bez týchto prvkov. V moderných domácnostiach však neraz chýbajú aktívne hasiace systémy, a preto je včasné odhalenie požiaru jediným mechanizmom, ktorý môže obyvateľov varovať skôr, než sa požiar vymkne spod kontroly (Ahrens, 2019).

1.1.1 Rizikové faktory v interiéroch

Interiéry sú naplnené horľavými materiálmi – nábytok z plastov a penových hmôt, textilie, drevené konštrukcie či elektronika, ktoré môžu ľahko vzplanúť a výrazne urýchliť šírenie ohňa. Moderné syntetické materiály majú tendenciu pri horení produkovať intenzívne teplo a toxické splodiny, výsledkom je rýchle dosiahnutie kritických podmienok a podstatne kratší čas na únik pre obyvateľov. Štúdie poukazujú, že v minulosti mohol čas do náhleho celkového vzplanutia miestnosti trvať 20 a viac minút, no v dnešných domácnostiach môže nastať už za 5–8 minút od vzniku požiaru. Z tohto dôvodu je skorá detekcia a varovanie nevyhnutné. Ak sa požiar odhalí v zárodku, majú obyvatelia väčšiu šancu uniknúť a hasiči možnosť zasiahnuť ešte pred totálnym rozšírením plameňov (Khan et al., 2022; Kobes, 2009).

Okolnosti vzniku požiarov v interiéroch bývajú rôznorodé. Medzi najčastejšie príčiny nehodových požiarov v domácnostiach patrí nedbalosť pri fajčení, poruchy elektroinštalácie alebo spotrebičov, zabudnuté varenie na sporáku, prípadne nepozornosť pri manipulácii s otvoreným ohňom. V mnohých tragických prípadoch požiar vypukne v noci, počas spánku obyvateľov, alebo v miestnosti, kde sa nik nenachádza, oheň tak môže nepozorovane rásť celé minúty. V spálňach a obývačkách plných textilu a čalúnenia môže tlenie prejsť do plameňov a zaplaviť priestor hustým dymom. Dym býva hlavnou príčinou úmrtí pri požiaroch, kvôli uduseniu a intoxikácie, preto včasné odhalenie prítomnosti dymu je kľúčové pre záchranu životov (Modern Building Alliance, 2025).

V prípade skladov horľavých materiálov predstavuje zvýšenú úroveň nebezpečenstva predovšetkým koncentrácia veľkého množstva predmetov a látok náchylných na vznietenie. Medzi najčastejšie rizikové faktory patrí nesprávne skladovanie chemických látok, nedostatočné vetranie či nevhodné teplotné podmienky. Prírodnú hrozbu predstavujú aj potenciálne zdroje iskier alebo tepla, akými sú elektrické inštalácie, mechanické trenie pri manipulácii so strojmi alebo prítomnosť zariadení s možnosťou skratu. Vzhľadom na tieto aspekty je kľúčová rýchla a spoľahlivá detekcia akýchkoľvek zmien, ktoré by mohli indikovať začiatok horenia (Kodur - Kumar - Rafi, 2020).

Z hľadiska protipožiarnej ochrany je nutné dodržiavať viaceré osvedčené postupy, ako je dôsledné oddelenie horľavých a nehorľavých látok, vhodné usporiadanie skladovaných materiálov či priebežné zabezpečenie čistoty priestorov, aby sa minimalizovalo množstvo prachu a iných horľavých častíc. Nevyhnutné je aj dôkladné monitorovanie teploty a vlhkosti, ktoré môžu priamo ovplyvniť riziko vznietenia.

V priestoroch, kde sa manipuluje s horľavými látkami, je zároveň dôležité sledovať aj úniky plynov či tvorbu výbušných zmesí. Praktické uplatnenie základných princípov protipožiarnej ochrany zahŕňa komplexné riešenia, od vhodného konštrukčného návrhu budovy a inštalácie protipožiarnych dverí až po automatické hasiace systémy a sofistikované systémy včasnej detekcie dymu či zvýšenej teploty (Kodur - Kumar - Rafi, 2020).

1.1.2 Legislatíva a prevencia

Vzhľadom na uvedené riziká zavádzajú mnohé krajiny prísne predpisy pre požiaru bezpečnosť v budovách. Všetky moderné stavebné normy vyžadujú určité opatrenia požiarnej ochrany – od použitých materiálov cez požiarne úseky až po detekčné a hasiace systémy. Kľúčovým prvkom aktívnej ochrany sú hlásiče požiaru, ktorých použitie v domácnostiach postupne prechádza z odporúčaní do zákonných povinností. V rámci Európy už viac než desiatka štátov zaviedla legislatívnu povinnosť inštalovať detektory dymu v obytných budovách, napríklad Nórsko, Švédsko, Fínsko, Francúzsko, Veľká Británia, Rakúsko, Belgicko, Nemecko a ďalšie krajiny majú zákonmi nariadené hlásiče v domácnostiach. Tieto opatrenia prinášajú výsledky: v posledných dekádach zaznamenala Európa výrazný pokles obetí požiarov. Počet úmrtí na požiare klesol za 30 rokov o 65 %, čo sa pripisuje práve lepšej prevencii, detekcii a vzdelávaniu v oblasti protipožiarnej bezpečnosti (Modern Building Alliance, 2025). Napriek tomu štatistiky stále odhaľujú rezervy, napríklad podľa European Fire Safety Alliance stále na území Európy zomiera odhadom vyše 5 000 ľudí ročne pri rezidenčných požiaroch (EuroFSA, 2019).

V Slovenskej republike platia pre protipožiaru ochranu stavieb predpisy vychádzajúce z európskych noriem STN EN 54 pre detekčné zariadenia a pod., ako aj zákon o ochrane pred požiarimi, ktorý ukladá povinnosti na zabezpečenie budov hasiacimi prístrojmi a výstražnými zariadeniami. Z pohľadu bežných domácností u nás síce nie priamo nariadené osadiť autonómne hlásiče dymu v každom byte, no ide o odporúčané minimum bezpečnosti a v niektorých prípadoch sa už inštalujú bežne.

Význam včasnej detekcie požiaru v interiéri je zásadný, umožňuje včasné varovanie obyvateľov, aktiváciu záchranných zložiek a nasadenie hasiacich systémov skôr, než požiar prerastie do nekontrolovateľného štádia. Každá minúta v počiatkovej fáze požiaru môže rozhodovať o životoch. Preto sa neustále zdokonaľujú technológie požiarnej detekcie a počítačové systémy sa integrujú priamo na edge zariadenia, aby poskytli ešte

rýchlejšiu a spoľahlivejšiu detekciu. Tieto pokročilé prístupy však stoja na pevných základoch tradičných systémov požiarnej signalizácie, ktorých prehľad je uvedený v nasledujúcej podkapitole.

1.2 Tradičné systémy detekcie požiaru

Tradičné systémy automatickej detekcie požiaru tvoria základ požiarnej bezpečnosti v väčšine budov už niekoľko desaťročí. Ich úlohou je spoľahlivo rozpoznať vznikajúci požiar prostredníctvom fyzikálnych prejavov (dym, teplo, plameň) a iniciovať varovanie – či už lokálne alebo vzdialené. Typický požiarový hlásičový systém pozostáva z viacerých snímačov rozmiestnených v chránenom priestore, prepojených s ústredňou. Ústredňa neustále monitoruje stav detektorov a pri zistení poplachu spustí výstražné zariadenia na varovanie osôb v objekte.

Súčasťou systému bývajú aj ručné hlásiče požiaru (tzv. tlačidlá alebo „break glass“ tlačidlá pri východoch), ktoré umožňujú komukoľvek manuálne vyhlásiť požiar, ak je spozorovaný. Celý systém je napájaný elektricky a navrhnutý tak, aby fungoval aj v nepriaznivých podmienkach počas požiaru. Tradičné systémy požiarnej detekcie možno rozdeliť na konvenčné a adresovateľné:

- **Konvenčný hlásičový systém:** Detektory sú zapojené po skupinách do spoločných okruhov. Ústredňa rozlišuje stav každej zóny (normál, porucha, alarm), avšak neidentifikuje individuálny detektor. Pri požiari teda vyhlási poplach v celej zóne, čo typicky zodpovedá jednej časti budovy (Key Security, 2025). Konvenčné systémy majú jednoduchú architektúru, hlásiče v zóne sú zapojené paralelne na dvojvodičovú slučku, ktorá vedie do ústredne. Nevýhodou je obmedzená informácia o polohe požiaru a tiež to, že ide spravidla o prahové zariadenia bez prenosu meranej hodnoty. Ústredňa zistí len to, že niektorý detektor v zóne prekročil alarmový prah, nevie však napr. intenzitu dymu či teploty. Navyše, prerušenie obvodu môže vyradiť celú zónu z prevádzky. V starších konvenčných systémoch hrozilo, že pri prerušení vedenia ústredňa nezistí ani požiar, ani poruchu na danom okruhu. Konvenčné systémy sa dodnes používajú v menších objektoch vďaka svojej jednoduchosti a nižšej cene; ich obmedzenia v presnosti indikácie sa kompenzujú menším rozsahom objektu (Lee & Lee, 2004).
- **Adresný systém:** Predstavuje modernejšiu generáciu, kde sú všetky detektory, tlačidlá a modulárne zariadenia pripojené na spoločnú komunikačnú linku a každé

zariadenie má pridelenú adresu. Ústredňa komunikuje digitálne so zariadeniami, pravidelne zisťuje ich stav a pri alarme presne identifikuje, ktorý konkrétny detektor alebo tlačidlo bolo aktivované. Adresné ústredne často zobrazujú aj namerané hodnoty a umožňujú pokročilé funkcie, ako je automatické zníženie citlivosti detektorov v určitých hodinách aby sa predišlo falošným poplachom napr. počas varenia. Adresovateľné systémy prinášajú vyššiu spoľahlivosť, v prípade poruchy vedenia vedia často izolovať chybný úsek a zvyšok slučky zostáva funkčný. Vzhľadom na komplexnosť sú adresné systémy využívané najmä vo veľkých a členitých budovách ako kancelárske centrá, nemocnice a obchodné domy, kde detailná informácia a centralizované riadenie je nevyhnutné (Key Security, 2025; Lee & Lee, 2004).

Tradičné hlásiče požiaru fungujú na princípe detekcie rôznych fyzikálnych prejavov ohňa. Medzi najpoužívanejšie patria dymové, teplotné a plamenné detektory, pričom v rámci každej z týchto kategórií existuje viacero konštrukčných vyhotovení.

Dymové hlásiče, či už ionizačné alebo optické, sú určené na čo najskoršiu detekciu aerosólov, viditeľných aj neviditeľných, ktoré vznikajú pri horení. V typických budovách predstavujú primárny prostriedok včasného varovania osôb, pretože väčšina požiarov v interiéri produkuje dym už v počiatočnej fáze. Ionizačné detektory, ktoré využívajú ionizačnú komoru s rádioaktívnym zdrojom Americia-241, sú veľmi citlivé na malé, neviditeľné častice dymu a reagujú veľmi rýchlo pri náhlych plameňoch s jemnými časticami. Ich nevýhodou však je, že pri dusivom tlení s hrubším dymom môžu reagovať pomalšie, niekedy až s desiatkami minútovým oneskorením, a sú náchylnejšie na falošne poplchy z kuchynských výparov. Navyše obsahujú rádioaktívny materiál, čo predstavuje problém pri ich likvidácii a v mnohých krajinách vedie k postupnému vyradeniu z používania (NFPA, 2025). Naopak, optické hlásiče dymu, ktoré detegujú rozptyl svetla na viditeľných časticach dymu pomocou infračerveného zdroja, sú rýchle pri detekcii tlenia a mierne pomalšie pri prudkom plameni, pričom tento rozdiel je rádovo v sekundách. Sú citlivé na pomaly sa rozvíjajúce, dymiace požiare a majú nižšiu mieru falošných poplachov z kuchynských pár. Ich nevýhodou je možná o niečo neskoršia reakcia pri rýchlom plameni a potreba pravidelného čistenia optickej komory (NFPA, 2025).

Teplotné hlásiče reagujú na zvýšenie teploty prostredia, buď dosiahnutím fixnej teploty (typicky 60 °C) alebo prudkým nárastom teploty. Ich reakčný čas je pomalší, aktivujú sa až po rozhorení požiaru, čo ich robí nevhodnými na včasné varovanie. Majú

však vysokú spoľahlivosť a takmer žiadne falošné poplachy, jednoduchú konštrukciu a dlhú životnosť. Využívajú sa skôr na ochranu majetku alebo v prostrediach, kde nie je možné použiť dymové hlásiče, ako sú prašné a vlhké priestory alebo kuchyne s výparmi.

Hlásiče plameňa detegujú ultrafialové a infračervené žiarenie z otvoreného ohňa. Sú veľmi rýchle a dokážu odhaliť prítomnosť plameňa takmer okamžite. Moderné duálne a trojité IR hlásiče dokážu ignorovať rušivé vplyvy a dosahujú detekciu aj na väčšie vzdialenosti. Ich nevýhodou je, že vyžadujú priamu viditeľnosť na zdroj požiaru a neodhalia tlenie bez plameňov. Môžu tiež vznikáť falošné poplachy od UV zdrojov alebo horúcich IR zdrojov, čo si vyžaduje použitie filtračných technológií (Mellon, 2022).

Okrem uvedených základných typov existujú aj špeciálne detekčné systémy. Nasávacie hlásiče dymu aktívne nasávajú vzorky vzduchu z monitorovaného priestoru potrubným rozvodom a vyhodnocujú prítomnosť aj veľmi nízkych koncentrácií dymových častíc. Tieto systémy, často vybavené vysokocitlivými laserovými senzormi, dokážu odhaliť vznik požiaru ešte skôr, než by štandardný hlásič reagoval. Používajú sa v dátových centrách, telekomunikačných ústredniach a podobných objektoch s vysokými nárokmi na včasnú detekciu a kde by bežné hlásiče mohli byť ovplyvnené napr. prúdením vzduchu od klimatizácie. Lineárne hlásiče dymu zase chránia rozsiahle otvorené priestory ako napr. auly a kostoly, pracujú na princípe vysielania infračerveného lúča naprieč miestnosťou a merania jeho zoslabnutia dymom. Výhodou je pokrytie veľkej plochy jedným párom senzora a odrazového prvku, nevýhodou citlivosť na vychýlenie a usadzovanie prachu na optike. Ďalším prvkom môže byť detektor oxidu uhoľnatého ako indikátor požiaru, ten síce primárne slúži na detekciu nebezpečného CO pri kúrení, ale v niektorých viac-senzorových hlásičoch sa využíva na zachytenie skorých štádií tlenia, keďže CO vzniká pri nedokonalom horení (Khan et al., 2022).

Multisenzorové hlásiče kombinujú viacero detekčných princípov, napríklad dymový a teplotný senzor, a využívajú mikroprocesorové vyhodnotenie viacerých signálov. Vďaka tomu dosahujú veľmi rýchlu detekciu rôznych typov požiaru a majú nižší výskyt planých poplachov, pretože poplach sa aktivuje len pri potvrdení viacerými senzormi. Ich nevýhodou je vyššia cena, zložitejšie vyhodnocovanie a náročnejšie testovanie a údržba (Moinuddin - Bruck - Shi, 2017).

Z uvedeného porovnania vyplýva, že ionizačné hlásiče sú síce rýchle pri plamenných požiaroch, ale môžu byť pomalé pri tlení a majú problémy s falošnými

poplachmi a rádioaktívnym materiálom. Optické hlásiče predstavujú vhodnejšiu univerzálnu ochranu s dobrou citlivosťou na tlenie aj plamenné požiare a nižšou mierou falošných poplachov. Odborníci často odporúčajú kombináciu oboch princípov alebo použitie moderných kombinovaných hlásičov. V praxi sa ionizačné hlásiče postupne nahrádzajú fotoelektrickými, a to nielen z dôvodu lepšej detekcie tlenia, ale aj kvôli eliminácii rádioaktívneho materiálu. Autonómne dymové hlásiče sú dnes bežne dostupné pre domácnosti, zatiaľ čo v komplexných budovách sa používajú adresovateľné hlásiče pripojené k ústredni (Moinuddin - Bruck - Shi, 2017).

Tradičné riešenia síce ponúkajú osvedčenú a overenú technológiu, avšak v praxi sa môžu prejavovať nasledovné nedostatky (Liang - Zeng, 2024) :

- **Vysoká latencia:** Kým sa signál dostane z detektora do centrálnej jednotky a prebehne jeho analýza, môže dôjsť k neželanému oneskoreniu. To je obzvlášť rizikové v kritických prostrediach, akými sú sklady horľavých materiálov, kde sa oheň môže rozšíriť vo veľmi krátkom čase.
- **Nutnosť centrálného spracovania:** Pre správnu funkciu musia byť všetky senzory prepojené s ústrednou jednotkou alebo s ďalšou nadstavbou, čo môže vyžadovať rozsiahlu kabeláž alebo stabilné bezdrôtové pripojenie. Ak sa centrálna jednotka pokazí alebo stratí spojenie so senzormi, ochromí to celý systém.
- **Závislosť od internetového alebo lokálneho prepojenia:** V moderných implementáciách býva často potrebný stabilný prístup na internet, aby bolo možné spravovať systémy vzdialene alebo využívať cloudové úložiská pre archiváciu dát. V odľahlých lokalitách či v priestoroch s obmedzenou konektivitou môže byť takáto infraštruktúra nedostupná, čo znižuje spoľahlivosť systému.

Technologický vývoj pokračuje ďalej, požiadavky na rýchlosť a presnosť detekcie rastú, najmä s ohľadom na moderné riziká a smart technológie. Preto sa v súčasnosti pozornosť sústreďuje na inteligentné systémy detekcie, ktoré kombinujú osvedčené princípy tradičných hlásičov s výkonným lokálnym spracovaním dát (Edge computing) a pokročilými algoritmami na rozpoznávanie požiaru v reálnom čase. Tým sa otvárajú nové možnosti, ako ešte účinnejšie chrániť životy a majetok pred ničivými následkami požiarov v interiéroch.

1.3 Moderné technológie a Edge Computing

Moderné technológie zásadne menia prístup k automatickej detekcii požiarov. Kým klasické systémy sa spoliehajú na jednoduché senzory (napr. dymové hlásiče na báze optických komôr či tepelné detektory) a pevne nastavené prahové hodnoty, súčasné smart riešenia integrujú Internet vecí, počítačové videnie a umelú inteligenciu pre rýchlejšie a presnejšie odhalenie vznikajúceho požiaru. Napríklad rozmiestnené bezdrôtové senzorové siete dokážu monitorovať viacero veličín naraz, typicky teplotu, vlhkosť, prítomnosť dymu alebo plynov, a tieto údaje v reálnom čase vyhodnocuje inteligentný systém. Týmto spôsobom je možné odhaliť anomálie v prostredí signalizujúce požiar ešte skôr, než by reagoval tradičný samotný hlásič požiaru. Navyše, prepojenie senzorov cez IoT umožňuje pokryť rozsiahle oblasť s podstatne hustejšou sieťou, než bolo možné v minulosti (Zheng et al., 2022).

Významným trendom je nasadenie počítačového videnia a algoritmov strojového učenia na analýzu obrazu. Bezpečnostné kamery alebo špecializované optické senzory tak nemusia slúžiť len na pasívny záznam. Moderné algoritmy dokážu automaticky rozpoznať prítomnosť plameňa či dymu v zázname. V odbornej literatúre bolo navrhnutých viacero prístupov založených na konvolučných neurónových sieťach trénovaných na detekciu vizuálnych príznakov požiaru. Tieto prístupy dosahujú vysokú presnosť v porovnaní s konvenčnými metódami, najmä pri včasnom zachytení malých ohnísk alebo riedkeho dymu. Hlboké neurónové siete dokážu rozpoznať zložité vizuálne znaky požiaru, čím prekonávajú jednoduché metódy založené na analýze farieb alebo intenzity pixelov. Ich nasadenie je však spojené s vysokými nárokmi na výpočtový výkon a dáta. Tréning rozsiahlych modelov je komplikovaný a časovo náročný proces vyžadujúci veľké množstvo označovaných dát. Navyše, robustné modely pre detekciu požiarov bývajú často objemné a pomalé, čo si vyžaduje výkonný hardvér. Napríklad Li et al. (2022) navrhli model detekcie ohňa a dymu založený na Transformer architektúre DETR, ktorý dosiahol vysokú presnosť, avšak za cenu veľkej výpočtovej náročnosti – model je relatívne pomalý a vyžaduje nasadenie na výkonných grafických procesoroch, čo nie je v praxi vždy realizovateľné na edge zariadeniach. Aj z týchto dôvodov sa výskum uberať smerom k zjednodušovaniu a optimalizácii modelov aby boli vhodné pre nasadenie priamo na zariadenie (Bayegizova et al., 2024; Zheng et al., 2022).

Ďalšou modernou technológiou je využitie autonómnych dronov a satelitov na monitorovanie požiarov z výšky. Drony vybavené kamerami môžu hliadkovať nad lesmi

alebo priemyselnými areálmi a v reálnom čase vyhodnocovať obrazový záznam priamo na palube alebo ho prenášať na blízke edge zariadenie na zemi. V odbornej literatúre sa spomínajú prípady, v ktorých bezpilotné lietadlá vybavené výkonným edge hardvérom dokážu počas letu lokálne detegovať požiar, vďaka čomu nie je potrebné prenášať celý videosignál do riadiaceho centra. Podobne, napr. systém Copernicus poskytuje údaje o lesných požiaroch vo veľkom meradle, hoci s určitým oneskorením. Kombinácia viacerých zdrojov dát, pozemné senzory, kamery, drony aj satelitné dáta predstavuje súčasný trend v protipožiarnych inteligentných systémoch. Kľúčovou výzvou ostáva efektívne spracovanie takto rozsiahlych dátových tokov. Tradičný prístup posielat' všetky dáta do centrálného cloudu naráža na obmedzenia latencie, konektivity a spoľahlivosti. Preto sa v oblasti detekcie požiarov stále viac presadzuje Edge computing, ktorý prináša výpočtový výkon bližšie k zdroju dát (Rostami et al., 2022).

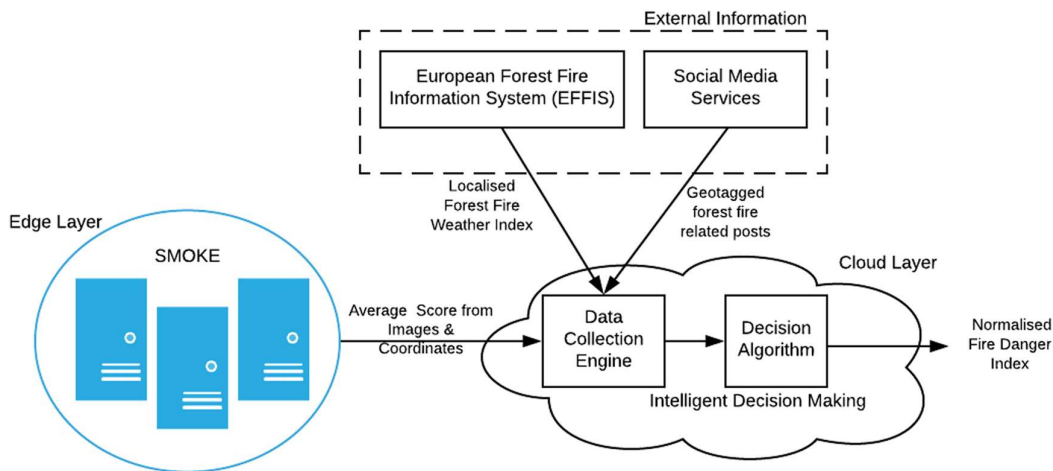
1.4 Využitie Edge Computingu v oblasti detekcie požiarov

Edge Computing predstavuje moderne riešenie výpočtov, pri ktorom sa dáta spracúvajú priamo tam, kde vznikajú, resp. v blízkosti zdroja, namiesto ich posielania do vzdialeného cloudu. V kontexte detekcie požiarov to znamená, že predspracovanie signálov zo sensorov, analýza obrazov z kamier či vyhodnotenie poplachov prebieha na lokálnych zariadení. Až spracované výsledky sa následne posielajú do centrálného systému či cloudu. Tým sa dramaticky znižuje objem prenášaných dát a predovšetkým latencia – čas odozvy celého systému. Vďaka spracovaniu dát priamo na palube odpadá potreba ich zasielania na vzdialené servery, čím sa minimalizuje oneskorenie. Reakcia systému v reálnom čase je pri požiaroch rozhodujúca, pretože každá sekunda meškania môže mať vážne následky (Li et al., 2022).

Lokálne spracovanie na edge sieti prináša viacero konkrétnych výhod. V podmienkach, kde môže nastať výpadok alebo obmedzenie internetového pripojenia, napr. odľahlé lesné oblasti alebo podzemné priestory, edge uzly dokážu fungovať autonómne a vykonávať detekciu aj bez spojenia s cloudom. Zvyšuje sa tak spoľahlivosť systému, požiar môže byť detegovaný a ohlásený lokálne aj v prípade dočasnej straty konektivity. Ďalšou výhodou je zachovanie súkromia a bezpečnosti dát. Videozáznamy a iné citlivé dáta nemusia opúšťať sledovaný objekt, všetko podstatné sa vyhodnotí na mieste. To je dôležité napríklad vo vládných budovách či mestskom kamerovom systéme, kde prenos a ukladanie necenzurovaného videa do verejného cloudu naráža na pravidlá ochrany osobných údajov a spracovanie na edge tieto riziká znižuje (Avgeris et al., 2019).

Bezpečnostné kamery s edge AI tak môžu nonstop analyzovať obraz a do centra posielat' len agregované alarmy, čím sa predíde aj zbytočnému zahlteniu siete neustálym prenosom videozáznamu (Fong, 2018).

Okrem výhod v podobe rýchlej detekcie požiarov a spoľahlivosti v prostrediach s obmedzenou konektivitou sa význam Edge Computingu pri detekcii požiarov prejavuje aj v jeho škálovateľnosti a efektívite spracovania dát. Avgerisov výskum predstavil framework SMOKE, ktorý využíva hierarchickú architektúru na spracovanie obrazových dát z IoT senzorov v reálnom čase. Tento systém umožňuje flexibilné škálovanie výpočtových zdrojov na úrovni edge zariadení a zahŕňa vertikálnu aj horizontálnu alokáciu zdrojov podľa potreby. Okrem toho kombinuje viaceré zdroje informácií vrátane sociálnych médií a environmentálnych senzorov, čím zvyšuje presnosť detekcie požiarov. Experimentálne výsledky ukázali, že takýto model znižuje energetickú náročnosť IoT senzorov a zrýchľuje reakčný čas, čo z neho robí efektívne riešenie pre aplikácie vyžadujúce okamžitú odozvu (Avgeris et al., 2019).



Obrázok 1: Architektúra rozhodovacieho systému kombinujúca Edge systém SMOKE a externé zdroje informácií. Zdroj: (Avgeris et al., 2019)

Významnou vlastnosťou frameworku SMOKE je jeho schopnosť autonómne spracovávať veľké množstvo obrazových dát bez nutnosti nepretržitého pripojenia k cloudu. To znamená, že systém je schopný detegovať požiare aj v oblastiach s obmedzenou internetovou konektivitou. Výpočtovo náročné úlohy, ako napríklad analýza obrazov pomocou algoritmov strojového učenia, sú delegované na Edge servery, ktoré môžu dynamicky prispôbovať svoje výpočtové kapacity podľa aktuálneho zaťaženia.

Tento prístup nielenže optimalizuje využitie výpočtových zdrojov, ale aj minimalizuje oneskorenia v detekcii a reakcii na požiarne incidenty (Avgeris et al., 2019).

Okrem technických výhod je dôležité spomenúť aj externé zdroje dát, ktoré SMOKE integruje do tohto systému. Využívanie sociálnych médií ako zdroja informácií pre detekciu požiarov umožňuje rýchlejšie overovanie a doplnenie údajov z IoT senzorov. Analýza príspevkov na platformách, ako je X, poskytuje dodatočné dáta o možných požiaroch a pomáha predikovať ich rozsah. Kombinácia viacerých zdrojov informácií spolu so škálovateľnou architektúrou Edge Computingu tak predstavuje významný pokrok v oblasti včasnej detekcie požiarov a môže pomôcť minimalizovať škody spôsobené požiarom v rôznych geografických oblastiach (Avgeris et al., 2019).

1.5 Cloud vs. Edge computing

Porovnanie cloudového a edge spracovania pri požiarom incidente ukazuje kľúčové rozdiely. Cloudové riešenie má vyššie oneskorenie detekcie kvôli prenosu dát do cloudu a späť, vyžaduje vysokú dátovú prevádzku pre odosielanie surových dát a je závislé na internetovej konektivitě. Prináša tiež nižšiu ochranu súkromia, keďže citlivé dáta opúšťajú lokalitu.

Naopak, edge computing znižuje oneskorenie spracovaním dát lokálne, minimalizuje dátovú prevádzku prenosom len výsledkov a umožňuje lokálnu autonómiu pri výpadku siete. Zvyšuje ochranu súkromia, keďže dáta ostávajú na mieste. Vyžaduje však výkonnejšie lokálne zariadenia. Edge computing je výhodný pre časovo kritické úlohy, ako je detekcia požiaru, vďaka rýchlejšej odozve a odolnosti. Často sa využíva hybridný model, kde edge zabezpečuje okamžitú analýzu a cloud agreguje dáta a rieši náročnejšie úlohy. Tento kombinovaný prístup spája výhody oboch riešení pre inteligentné protipožiarne systémy (Banbury et al., 2020).

S rozvojom technológií sa čoraz viac presadzuje aj trend nasadzovania algoritmov strojového učenia priamo na edge zariadeniach. Táto možnosť umožňuje ešte efektívnejšie spracovanie dát a rýchlejšie rozhodovanie bez nutnosti odosielania dát do cloudu. Vďaka tomu je možné dosiahnuť vyššiu presnosť detekcie a minimalizovať falošné poplchy, čo je v prostredí požiarnej ochrany kľúčové. V praxi sa často implementuje hybridný model, kde edge vrstva zabezpečuje okamžitú lokálnu analýzu a predbežné upozornenia, zatiaľ čo cloudová vrstva agreguje údaje z viacerých lokalít, uchováva dlhodobé štatistiky a rieši

náročnejšie úlohy. Takáto viacvrstvová architektúra spája výhody oboch prístupov a predstavuje aktuálny smer vývoja inteligentných protipožiarnych systémov.

1.6 Strojové učenie na Edge zariadeniach

Implementácia metód umelej inteligencie priamo na edge zariadeniach, čiže na koncových uzloch s obmedzeným výpočtovým výkonom a pamäťou, si vyžaduje špecifický prístup známy aj ako TinyML. TinyML reprezentuje subdoménu strojového učenia zameranú na minimalizovanie a optimalizovanie modelov a ich beh na mikrokontroléroch a ďalších vstavaných systémoch, ktoré často disponujú len desiatkami či stovkami kilobajtov pamäte a bežia na frekvenciách rádovo desiatok MHz. Cieľom je umožniť, aby aj takéto jednoduché zariadenia dokázali lokálne vyhodnocovať pokročilé úlohy, ako je rozpoznanie obrazových vzorov, zvukových udalostí alebo anomálií v senzorkých dátach, a to v reálnom čase, bez nutnosti pripojenia ku cloudu.

Hlavnými výhodami TinyML sú nízka spotreba energie a schopnosť nepretržitej prevádzky bez výrazného vplyvu na životnosť batérie. Firmy ako Amazon, Apple či Google už využívajú túto technológiu v miliardách zariadení. TinyML funguje vďaka senzorum s nízkou spotrebou, ako sú mikrofóny, akcelerometre, kamery a gyroskopy, čo umožňuje pokročilé analýzy pri minimálnych výpočtových nárokoch (Banbury et al., 2020).

TinyML však čelí výzvam ako obmedzené zdroje, fragmentovaný trh či neustále sa meniace technológie hlbokého učenia. Nedostatok pamäte a výpočtovej kapacity obmedzuje implementáciu bežných softvérových nástrojov, ako sú operačné systémy či súborové systémy. Rôzne zariadenia navyše vykazujú odlišnú spotrebu energie, čo komplikuje udržanie presnosti modelov (Banbury et al., 2020).


Použitie strojového učenia na detekciu anomálií v Edge Computingu predstavuje významný krok k efektívnemu spracovaniu dát priamo na zariadeniach s obmedzenými výpočtovými zdrojmi. Článok autora Huč (2021) analyzuje výkon piatich algoritmov strojového učenia: logistickej regresie, podporných vektorových strojov, rozhodovacích stromov, náhodných lesov a umelých neurónových sietí. Výskum ukázal, že efektívne spracovanie týchto dát je možné aj na nízkonákladových edge zariadeniach, pričom sa minimalizuje potreba posielat veľké objemy dát do cloudu. Táto decentralizácia zvyšuje ochranu súkromia, znižuje latenciu a šetrí šírku pásma, čo je zásadné pri aplikáciách

kritických na čas, ako je kybernetická bezpečnosť alebo priemyselná automatizácia (Huć - Šalej - Trebar, 2021).

Dôležitým aspektom tejto štúdie je analýza metód na vyváženie nevyvážených datasetov, čo je častý problém v oblasti detekcie anomálií. Autori skúmali dva prístupy – prvým bolo náhodné podvzorkovanie najpočetnejšej triedy, druhým bolo použitie klastrovania na výber reprezentatívnych vzoriek. Výsledky ukázali, že redukcia veľkosti datasetu pri zachovaní reprezentatívnych anomálnych vzoriek môže viesť k porovnateľnej presnosti modelov s podstatne väčšou výpočtovou náročnosťou. Tento prístup umožňuje nasadiť algoritmy strojového učenia priamo na edge zariadenia, čím sa otvára cesta k efektívnej detekcii kybernetických útokov, porúch v priemyselných systémoch či analýze senzorických dát v reálnom čase (Huć - Šalej - Trebar, 2021).

Na základe uskutočnených experimentov sa ukázalo, že rozhodovacie stromy a náhodné lesy ponúkajú optimálnu kombináciu výpočtovej efektívnosti a presnosti pri detekcii anomálií. Naopak, umelé neurónové siete a SVM vyžadovali vyššiu výpočtovú kapacitu, čo môže byť problematické v prípade edge zariadení s obmedzenými zdrojmi. Táto štúdia potvrdzuje, že správne optimalizované modely môžu zabezpečiť spoľahlivú detekciu anomálií aj v prostredí s nízkou latenciou, čím sa edge computing stáva ešte vhodnejším riešením pre aplikácie v oblasti bezpečnosti, priemyselného monitorovania a IoT sietí (Huć - Šalej - Trebar, 2021).

Pre vývoj modelov strojového učenia na mikrokontroléroch sa často využíva knižnica TensorFlow a jeho odľahčená verzia TensorFlow LiteRT, ktorá je optimalizovaná pre zariadenia s obmedzenými zdrojmi. LiteRT umožňuje spúšťanie modelov bez potreby operačného systému a dvojstohovú alokačnú stratégiu, čím je ideálny pre nízkoenergetické a výpočtovo nenáročné systémy.



Obrázok 2: Dvojstohová alokačná stratégia. Zdroj: (Avgeris et al., 2019)

Dvojstohová alokačná stratégia je efektívna metóda správy pamäte používaná v rámci TensorFlow LiteRT na optimalizáciu využitia obmedzených zdrojov v zabudovaných systémoch. Ako uvádza David et al. (2021), táto stratégia využíva jedinú

súvislú pamäťovú oblasť, kde sa alokácie riadia dvoma smermi, "Head" stack rastie od najnižších adries smerom nahor a "Tail" stack rastie od najvyšších adries smerom nadol. Táto organizácia umožňuje efektívne spravovať trvalé alokácie v zadnej časti a dočasné alokácie v prednej časti pamäťovej oblasti. Výhodou tejto metódy je minimalizácia fragmentácie pamäte, zabránenie zlyhaniu alokácie v reálnom čase a zvýšenie efektivity výpočtov na mikroprocesoroch s obmedzenou pamäťou. Ak sa však oba zásobníky stretnú, signalizuje to nedostatok dostupnej pamäte a aplikácia vygeneruje chybu. Neustály pokrok v tejto oblasti vyžaduje pravidelné inovácie a aktualizácie frameworkov, aby držali krok s najnovšími výskumnými trendmi (David et al., 2021).

1.7 MLOps platforma Edge Impulse

Edge Impulse je MLOps platforma pre strojové učenie venovaná pre vývoj a nasadenie modelov na edge zapriani, čo je kľúčové pre systémy detekcie požiarov s obmedzenými výpočtovými zdrojmi. Platforma poskytuje ucelený pracovný postup od zberu dát po generovanie implementačného kódu, čo umožňuje efektívne vytvárať modely pre embedded zariadenia. Jej architektúra integruje nástroje na automatizáciu spracovania senzorických dát, ako je spektrálna analýza teplotných trendov alebo detekcia frekvenčných vzorcov dymu pomocou digitálneho spracovania signálu. Tento prístup eliminuje nutnosť manuálnej extrakcie črt, čo zvyšuje rýchlosť vývoja (Hymel et al., 2022).

Optimalizácia pre edge zariadenia sa dosahuje prostredníctvom kompilátora EON, ktorý odstraňuje nadbytočné vrstvy neurónových sietí a redukuje pamäťovú náročnosť modelov až o 40%. To umožňuje nasadenie algoritmov aj na mikrokontroléroch s menej ako 256 kB RAM, čo je kritické pre batériami poháňané požiarne senzory. Platforma zároveň podporuje viac ako 50 hardvérových architektúr vrátane ARM Cortex-M a ESP32, čo zjednodušuje integráciu s bežne dostupnými senzormi teploty, dymu alebo multispektrálnymi kamerami (Hymel et al., 2022).

Lokálne spracovanie dát na senzorových uzloch znižuje latenciu detekcie pod 100 ms a spotrebu energie v porovnaní s riešeniami založenými na prenose dát do cloudu. Táto funkcionálna je dosiahnutá prostredníctvom generovania optimalizovaného C++ kódu, ktorý beží natívne na cieľovom hardvéri bez potreby operačného systému. Platforma tak poskytuje kompromis medzi výkonnosťou a energetickou náročnosťou, čo je pre požiaru detekciu v teréne kľúčové (Hymel et al., 2022).

	Zbierka & Analýza Dát	DSP a Dizajn Modelu	Embedded Nasadenie	AutoML & Aktívne Učenie	IoT Manažment & Monitorovanie
Edge Impulse	✓	✓	✓	✓	~
Amazon SageMaker	✓	~	~	✓	~
Google VertexAI	✓	~	X	✓	~
Azure ML & IoT	✓	~	~	✓	✓
Neuton AI	X	~	✓	~	X
Latent AI	X	✓	✓	X	X
NanoEdge	~	✓	✓	~	X
Imagimob	✓	✓	✓	~	X

Tabuľka 1: Porovnanie podporovaných funkcií platforiem MLOps

✓: Plne podporované, ~: Čiastočne podporované, x: Nepodporované. Zdroj: (Hymel et al., 2022)

V kontexte rozvoja open source komunity, ktorá je veľmi významná pre TinyML, je dôležité pozrieť sa aj na postavenie Edge Impulse v porovnaní s inými MLOps platformami, ako ilustruje Tabuľka 1. Zatiaľ čo Edge Impulse plne podporuje kľúčové kroky vývoja pre embedded ML, od zberu a analýzy dát cez DSP a návrh modelov až po embedded nasadenie a AutoML, niektoré iné platformy vykazujú odlišné zameranie. Napríklad, Amazon SageMaker, Google VertexAI a Azure ML & IoT majú silnú podporu pre cloudové scenáre a AutoML, ale ich podpora pre embedded nasadenie a DSP je často len čiastočná alebo žiadna. Platformy ako Neuton AI, Latent AI a NanoEdge sa viac špecializujú na embedded prostredie a DSP, no môžu mať obmedzenú podporu v oblasti zberu dát, AutoML alebo IoT manažmentu. Imagimob sa podobne zameriava na DSP a embedded nasadenie. Edge Impulse sa tak javí ako komplexné riešenie, ktoré integruje celý pracovný tok špeciálne pre edge computing, čo ho odlišuje od platforiem s širším zameraním na cloudové ML alebo užšie špecializovaných nástrojov pre embedded vývoj. Táto komplexná podpora pre celý cyklus vývoja v edge prostredí, spolu s aktívnou open source komunitou, predstavuje významnú výhodu pre vývoj systémov detekcie požiarov s obmedzenými zdrojmi (Hymel et al., 2022).

2 Cieľ práce, metodika práce a metódy skúmania

Hlavným cieľom tejto diplomovej práce je návrh, vývoj a overenie efektívneho automatického systému na detekciu požiarov využívajúceho princípy Edge Computingu a metódy strojového učenia. Na dosiahnutie tohto cieľa sme definovali nasledujúce čiastkové ciele:

1. Detailná analýza súčasných technológií a prístupov v oblasti automatickej detekcie požiarov.
2. Výber a návrh vhodného hardvéru a softvéru, vrátane výberu konkrétnych senzorov a platformy.
3. Implementácia neurónovej siete na edge zariadenie.
4. Experimentálne overenie spoľahlivosti a presnosti vyvinutého systému.

Naša metodika zahŕňala rozsiahlu rešerš literatúry, ktorá poskytla základné poznatky potrebné pre návrh systému. Po identifikovaní vhodných technológií a prístupov sme navrhli a skonštruovali prototyp, ktorý sme následne podrobili detailnému experimentálnemu testovaniu v špecificky pripravených simulovaných scenároch požiarov. Experimenty zahŕňali rôzne typy situácií vrátane normálneho stavu bez požiaru a rôznych scenárov vzniku požiaru.

Výsledný prototyp je zložený z mikrokontroléra Arduino Nano 33 BLE a troch senzorov: MQ2 (horľavé plyny a dym), MQ135 (toxické a prchavé látky) a IR plameňového senzora 55694. Zostavu sme doplnili o jednoduchú webovú aplikáciu na vizualizáciu nameraných hodnôt.

Dáta sme zaznamenávali v dvoch prostrediach:

- Interiér – kuchyňa (simulácia úniku plynu).
- Exteriér – v prírode (kontrolované horenie).

Na analýzu zozbieraných dát sme využili metódy spracovania signálov a tréning neurónovej siete, pričom sme použili platformu Edge Impulse. Presnosť klasifikácie sme vyhodnocovali pomocou matice zmätenia a ďalších štatistických metód ako presnosť, citlivosť F1-skóre a metrika AUC. Zvláštnu pozornosť sme venovali overeniu prípadného pretrénovania modelu a analyzovali sme vplyv prostredia na výsledky.

3 Výsledky práce

V tejto kapitole sa zameriavame na konkrétne aspekty realizácie hardvérového a softvérového riešenia, pričom prezentujeme postupy použité pri zbere dát, ako aj následnú analýzu presnosti detekcie. Pri návrhu a testovaní systému sme vychádzali z teoretických poznatkov popísaných v prvej kapitole. V našom riešení sme kládli dôraz na kombináciu spoľahlivého hardvéru, vhodne zvolených senzorov a efektívneho softvérového algoritmu, čo umožnilo vytvoriť robustný prototyp detekčného systému pre skladové priestory horľavých materiálov.


3.1 Výber a popis hardvéru

V systéme detekcie požiaru založenom na princípoch Edge Computingu je výber hardvérovej platformy kľúčovým faktorom ovplyvňujúcim spoľahlivosť, presnosť a rýchlosť reakcie. Vhodná hardvérová platforma musí zabezpečovať dostatočný výpočtový výkon na beh základných algoritmov strojového učenia, no zároveň musí byť dostatočne kompaktná a energeticky efektívna pre dlhodobú autonómnu prevádzku v náročných podmienkach. Medzi najčastejšie používaný mikrokontrolér v rámci týchto aplikácií patrí Arduino Nano 33 BLE, ktorý disponuje dostatočným výkonom na prevádzku základných algoritmov strojového učenia priamo na zariadení.

3.1.1 *Arduino Nano 33 BLE*

Arduino Nano 33 BLE predstavuje vhodnú rovnováhu medzi kompaktnými rozmermi, nízkou spotrebou energie a dostatočným výpočtovým výkonom, čo ho robí ideálnym riešením pre použitie v prostrediach so zvýšeným rizikom požiaru, ako sú sklady horľavín, kde je často potrebné inštalovať senzory do stiesnených priestorov alebo na miesta s obmedzeným prístupom k napájaniu.

Arduino Nano 33 BLE je vybavený výkonným mikroprocesorom nRF52840 od spoločnosti Nordic Semiconductor, postaveným na architektúre ARM Cortex-M4F s taktovacou frekvenciou až 64 MHz. Tento čip disponuje 1 MB flash pamäťou a 256 kB RAM, čo poskytuje dostatočnú kapacitu pre nasadenie pokročilých algoritmov strojového učenia v reálnom čase. Prítomnosť akcelerátora s podporou výpočtov s pohyblivou desatinnou čiarkou (FPU) výrazne prispieva k efektívnejšiemu spracovaniu signálu a umožňuje implementáciu modelov TinyML priamo na zariadení bez nutnosti externej výpočtovej podpory (Arduino, 2025).




Obrázok 3: Arduino Nano 33 BLE pripojené k univerzálnej doske a napájacímu káblu. Zdroj: Vlastné spracovanie

Zariadenie je vybavené aj komunikačným rozhraním Bluetooth Low Energy 5.0, ktoré poskytuje možnosť bezdrôtového prenosu dát na krátke vzdialenosti s nízkou energetickou náročnosťou. Táto funkcionálnosť síce nie je kľúčovým prvkom v našom návrhu, no môže nájsť uplatnenie v menších alebo jednoducho členených priestoroch, kde nie sú kladené vysoké nároky na dosah či priepustnosť spojenia (Arduino, 2025). V širšom kontexte použitia, ako napríklad pri návrhu systémov pre veľkokapacitné skladové priestory či priemyselné haly, sa však technológia Bluetooth javí ako nedostatočná – najmä z hľadiska dosahu signálu a spoľahlivosti komunikácie cez viaceré prekážky. Z tohto dôvodu naše zariadenie sme doplnili o Wifi modul ESP-01, ktorý zabezpečuje bezdrôtové pripojenie. Wi-Fi komunikácia sa tak stáva primárnym prenosovým kanálom v systéme, čím sa zabezpečuje vyššia robustnosť, stabilita a flexibilita celého riešenia aj v náročnejších prevádzkových podmienkach.

3.1.2 Vybavenie snímačov

Pri vývoji systému detekcie požiaru pre vnútorné skladovacie priestory horľavých materiálov je dôležité kombinovať rôzne typy senzorov, aby sa zabezpečila presnosť a spoľahlivosť detekcie. Sensory MQ2 a MQ135 umožňujú sledovanie plynov spojených so spaľovaním, zatiaľ čo infračervený senzor 55694 umožňuje priame rozpoznanie plameňa v zornom poli senzora.

Senzor MQ2 je zariadenie schopné detegovať rôzne horľavé plyny a dym, čo ho robí vhodným pre aplikácie detekcie požiaru. Je obzvlášť citlivý na plyny ako LPG, bután, propán, metán, alkohol, vodík a oxid uhoľnatý, pričom jeho rozsah detekcie je od 200 do 10 000 častíc na milión. Senzor funguje meraním zmien odporu jeho vnútorného detekčného materiálu v prítomnosti cieľových plynov. Táto zmena odporu ovplyvňuje výstupné napätie, ktoré môže byť čítané mikrokontrolérom, ako je Arduino, na určenie koncentrácie plynov. MQ2 ponúka analógový aj digitálny výstup, čo umožňuje flexibilnú integráciu do rôznych systémov. Okrem toho obsahuje zabudovaný potenciometer na nastavenie citlivosti, čo umožňuje kalibráciu podľa špecifických podmienok prostredia.



Obrázok 4: Predná a zadná strana použitých senzorov, usporiadaných zľava doprava: MQ2, MQ135, infračervený senzor 55694. Zdroj: Vlastné spracovanie

Senzor MQ135 je navrhnutý na monitorovanie kvality ovzdušia detekciou plynov, ako sú oxid uhličitý (CO_2), amoniak (NH_3), benzén, alkohol a dym. Jeho široké spektrum detekcie ho robí cenným nástrojom na hodnotenie kvality vzduchu a identifikáciu prítomnosti škodlivých plynov, ktoré môžu signalizovať požiar alebo nebezpečné podmienky. Podobne ako MQ2, senzor MQ135 deteguje zmeny odporu jeho detekčného materiálu pri vystavení cieľovému plynu a poskytuje výstup, ktorý môže byť spracovaný Arduinoom pre monitorovanie v reálnom čase. Tento senzor sa často používa v systémoch monitorovania kvality ovzdušia a môže slúžiť ako doplnkové zariadenie v systéme detekcie požiaru alebo na sledovanie hromadenia produktov spaľovania.

Infračervený senzor 55694 je špeciálne navrhnutý na detekciu plameňa v blízkom infračervenom spektre. Funguje na princípe rozpoznávania infračerveného žiarenia, ktoré plamene prirodzene vyžarujú v rozsahu 760 nm až 1100 nm. Tento senzor je schopný detegovať plamene a je vybavený digitálnym aj analógovým výstupom, čo umožňuje jeho jednoduché pripojenie k Arduino. Medzi hlavné vlastnosti patrí:

- Vysoká citlivosť na infračervené spektrum plameňa
- Schopnosť rozlíšiť prirodzené svetlo od plameňa
- Možnosť nastavenia citlivosti potenciometrom


V kombinácii s MQ2 a MQ135 poskytuje tento senzor dodatočnú úroveň ochrany tým, že dokáže detegovať priamu prítomnosť plameňa, zatiaľ čo plynové senzory monitorujú nárast nebezpečných plynov ešte pred vznikom viditeľného ohňa.

Použitie kombinácie senzorov MQ2, MQ135 a infračerveného plameňového senzora 55694 v systéme detekcie požiaru zvyšuje jeho efektivitu a spoľahlivosť. Kým plynové senzory dokážu odhaliť nebezpečenstvo už v skorých fázach vznietenia, infračervený senzor poskytuje priamy dôkaz skutočného požiaru, čo umožňuje rýchlejší zásah a minimalizáciu škôd v skladovacích priestoroch horľavých materiálov. Výsledkom je systém schopný pokryť široké spektrum možných ohnísk a reagovať včas aj na menej nápadné varovné signály. Navyše, tento prístup je škálovateľný. Pri integrácii ďalších snímačov (napr. teplotné senzory, snímače tlaku, kamery) je možné vytvoriť multisenzorovú platformu na vyhodnotenie viacerých ukazovateľov naraz. Každý pridaný snímač zvyšuje robustnosť celého systému a znižuje pravdepodobnosť falošných poplachov, keďže údaje sú overované viacnásobne.

3.1.3 Pripojenie komponentov a elektronický obvod

Hardvérový systém pozostáva z nasledovných komponentov: mikrokontrolér Arduino Nano 33 BLE, univerzálna doska, plynové senzory MQ-2 a MQ-135, infračervený senzor 55694, dva stabilizátory napätia na 3,3 V, WiFi modul ESP-01 a prepojovacie vodiče.

Na technickej schéme (Obrázok 5) sú jednotlivé zapojenia znázornené rôznymi farbami podľa typu signálu. Červené vodiče predstavujú kladné napájanie – napätie 3,3 V sa nachádza prednostne na ľavej strane univerzálnej dosky, zatiaľ čo napätie 5 V je vedené prevažne po pravej strane. Tmavomodré vodiče označujú zem, farebné vodiče potom reprezentujú dátové signály.



Obrázok 5: Technická schéma zapojenia hardvérových komponentov
Zdroj: Vlastné spracovanie

Arduino Nano 33 BLE štandardne pracuje s napätím 3,3V, avšak disponuje aj výstupom pre 5V. Tento výstup však nie je štandardne aktívny – ide o ochranný prvok, ktorý má zabrániť náhodnému spätnému napájaniu 5 V do analógových portov, čo by mohlo viesť k poškodeniu mikrokontroléra. V tomto projekte však bolo potrebné použiť 5V výstup kvôli napájaniu plynových senzorov MQ, a preto bolo nevyhnutné manuálne spájať bezpečnostné PAD-y na spodnej strane dosky Arduino, čím sa aktivoval 5V výstup.

Na pravej strane schémy sú viditeľné dva senzory MQ – konkrétne MQ-2 a MQ-135. Oba senzory pracujú výhradne pri napájaní 5V a ich výstupné napätie by bolo nevhodné priamo pripojiť na analógové porty Arduino, ktoré sú určené na 3,3 V logiku. Z tohto dôvodu sú medzi senzormi a mikrokontrolérom vložené dva nezávislé napäťové regulátory, ktoré znižujú výstupné napätie zo senzorov na bezpečných 3,3 V. Tieto regulátory sú umiestnené v ľavej časti zapojenia.

Infračervený senzor typu 55694 je osadený v ľavom dolnom rohu univerzálnej doky. WiFi modul ESP-01 sa nachádza mimo hlavnej dosky, v dolnej časti schémy. Tento modul je napájaný prostredníctvom dvoch samostatných 3,3V vodičov z externého zdroja, nakoľko samotné Arduino nedokáže poskytnúť dostatočný prúd pre stabilnú prevádzku modulu. Okrem toho je k ESP-01 pripojený jeden vodič GND a dvojica dátových vodičov (RX a TX), ktoré sú privedené k digitálnym portom Arduino.

Všetky komponenty systému s výnimkou senzorov MQ pracujú s napájaním 3,3 V. Výstupy senzorov MQ, ktoré boli upravené pomocou napäťových regulátorov, sú pripojené na analógové vstupy mikrokontroléra – konkrétne porty A0, A1 a A3.

3.2 Scenár simulácie požiaru pre zaznamenávanie údajov

Za účelom získania relevantných údajov pre tréning a testovanie detekčného systému založeného na princípoch Edge Computingu bola navrhnutá a implementovaná experimentálna metodológia simulácie rôznych nebezpečných situácií, ktoré môžu nastať v skladoch horľavých materiálov. Simulácie boli rozdelené do štyroch hlavných tried: aktívny oheň, výskyt iba dymu bez viditeľného plameňa, únik plynu zo zapnutého sporáka bez zapálenia, a bežný stav s čistým vzduchom bez prítomnosti dymu alebo plynu.

Pre simuláciu požiaru a dymu sme vytvorili kontrolované spaľovanie bežne dostupných materiálov – farebných papierov, kartónov a PET fliaš – v bezpečne upravenom vonkajšom priestore v rôznych polohách (viď Obrázok 7). V rámci experimentov sme osobitne merali scenáre s prítomnosťou otvoreného ohňa aj dymu, ako aj situácie, v ktorých sa vyskytoval výhradne dym bez viditeľného plameňa, s cieľom overiť správanie senzorov v rôznych fázach požiaru. Spaľovanie prebiehalo na nehorľavom povrchu s dostatočnou izoláciou okolia, čím sa eliminovalo riziko nekontrolovaného šírenia požiaru. Tieto materiály boli zvolené z dôvodu ich častej prítomnosti v skladových priestoroch a rozdielnej miery tvorby dymu a tepelnej energie. Merania boli realizované v rôznych vzdialenostiach od ohniska, čo umožnilo zaznamenať variabilitu senzorickejých údajov v závislosti od intenzity zdroja a šírenia emisií.



Obrázok 6: Meranie údajov pri plynovom sporáku. Zdroj: Vlastné spracovanie



Obrázok 7: Meranie údajov pri ohni a dyme. Zdroj: Vlastné spracovanie

Pre zaznamenávanie údajov o úniku plynu bol ako zdroj využitý domáci plynový sporák (viď Obrázok 6). Experiment prebiehal v interiéri, kde bol počas merania zapnutý prívod plynu bez jeho zapálenia, čím sa simulovala potenciálne nebezpečná situácia úniku horľavého plynu bez viditeľných sprievodných javov ako sú dym alebo oheň.

Posledný scenár predstavoval kontrolnú skupinu, v ktorej sa experimentálne prostredie nachádzalo v normálnych podmienkach s prítomnosťou čerstvého vzduchu, bez výskytu dymu, ohňa alebo plynu. Tento referenčný stav bol dôležitý pre kalibráciu systému a pre porovnanie s ostatnými simulovanými hrozbami.

3.3 Analýza a spracovanie dát

Na účely zberu dát pre tréning systému na detekciu požiaru sme sa rozhodli využiť platformu MLOps Edge Impulse, ktorej možnosti a výhody sme detailne analyzovali v prvej kapitole.

Dáta boli rozdelené do štyroch tried reprezentujúcich rôzne scenáre, ktoré môžu nastať v skladových podmienkach:

- Oheň
- Dym (bez viditeľného plameňa)
- Únik plynu (bez dymu alebo plameňa)
- Normálny stav (čistý vzduch bez prítomnosti plynu alebo dymu)

Pre každú triedu bolo zaznamenaných 5 minút údajov, pričom boli použité tri rôzne senzory:

- MQ2 – senzor na detekciu dymu, LPG a horľavých plynov
- MQ135 – senzor na detekciu oxidu uhličitého, amoniaku, benzénu a ďalších toxických plynov
- Infračervený senzor plameňa – slúži na priame zachytenie prítomnosti plameňa

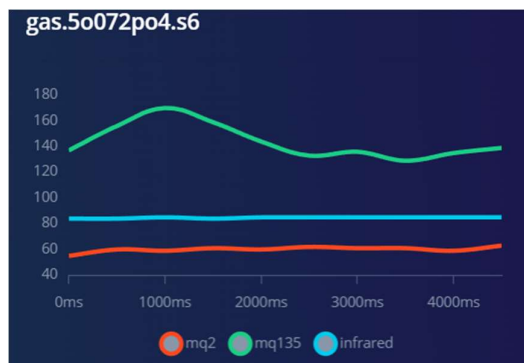
Celkovo bolo teda zaznamenaných 20 minút sensorických údajov, ktoré boli zaznamenané v časových úsekoch po 5 sekundách. Tento krok umožnil získať presne 200 časových sekvencií, z ktorých každá reprezentuje konkrétny úsek správania senzorov

Dáta boli následne náhodne rozdelené na tréningovú a testovaciu sadu podľa často používaného Pareto princípu (80/20) v oblasti umelej inteligencie:

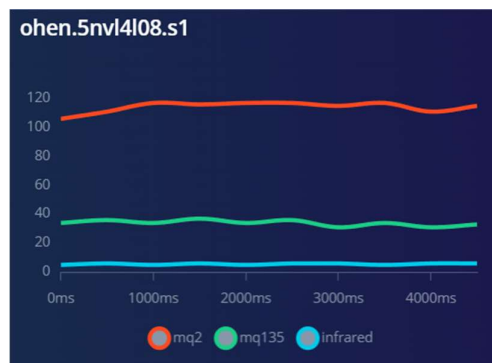
- Tréningová sada: 48 záznamov (5-sekundových) pre každú triedu = 16 minút údajov
- Testovacia sada: 12 záznamov (5-sekundových) pre každú triedu = 4 minúty údajov

Pre lepšiu ilustráciu správania jednotlivých senzorov v rôznych podmienkach boli vytvorené grafické výstupy na základe troch náhodne vybraných záznamov z každej triedy. Tieto grafy poskytujú vizuálny náhľad na charakteristické hodnoty senzorov v rôznych scenároch, ktoré boli súčasťou experimentálneho merania.

Na grafe v obrázku 8 môžeme vidieť typický priebeh sensorických údajov pre prípad úniku plynu. Tento scenár je charakteristický výrazným nárastom výstupnej hodnoty senzora MQ135, ktorá v tomto konkrétnom zázname presahuje hodnotu 120, čo indikuje prítomnosť znečistenia vzduchu plynmi ako je oxid uhličitý, amoniak alebo iné škodlivé výpary. Naopak, hodnota senzora MQ2 zostáva relatívne stabilná v rozmedzí 50 až 60, čo naznačuje, že nedošlo k výskytu výrazného dymu. Hodnota infračerveného senzora sa pohybuje okolo 80, čo je typické pre situáciu bez viditeľného plameňa

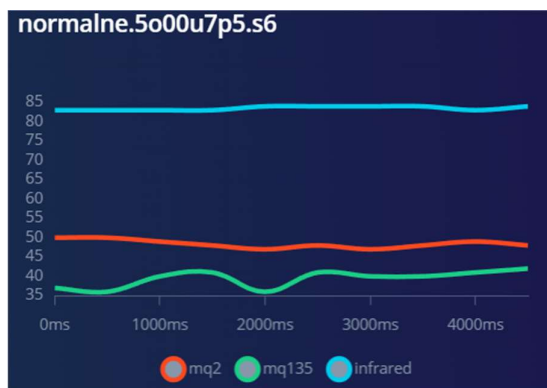


Obrázok 8: Graf 5-sek. záznam únik plynu
Zdroj: Vlastné spracovanie



Obrázok 9: Graf 5-sek. záznam v blízkosti ohňa
Zdroj: Vlastné spracovanie

V prípade grafu na obrázku 9, ktorý reprezentuje situáciu s aktívnym ohňom, je možné pozorovať simultánne správanie všetkých troch senzorov v reakcii na horenie. Výrazný nárast hodnoty senzora MQ2 nad úroveň 100 poukazuje na prítomnosť hustého dymu a horľavých plynov, zatiaľ čo MQ135 zároveň zaznamenáva zvýšené koncentrácie toxických látok vznikajúcich pri horení rôznych materiálov. Zároveň dochádza k poklesu výstupu infračerveného senzora pod hodnotu 10, čo jednoznačne signalizuje prítomnosť plameňa. Tento priebeh zodpovedá očakávanému správaniu senzorov v prípade aktívneho požiaru.



Obrázok 10: Graf 5-sek. záznam normálneho prostredia
Zdroj: Vlastné spracovanie

Napokon, graf na obrázku 10 zobrazuje údaje zo záznamu zaznamenaného počas normálneho stavu, teda bez prítomnosti dymu, plynu alebo ohňa. V tomto prípade sa všetky senzorické hodnoty nachádzajú v štandardných rozsahoch – výstup MQ2 senzora je približne 50, MQ135 sa pohybuje okolo 40 a infračervený senzor osciluje medzi hodnotami 80 a 85. Takéto rozloženie hodnôt reprezentuje typické pozadie, ktoré je dôležité pre tréning modelu na spoľahlivé rozpoznanie bezpečného stavu a minimalizáciu falošných poplachov.

Jednotlivé záznamy sú uložené vo formáte .json, ktorý obsahuje informácie o zariadení, intervaloch merania, použitých senzoroch a nameraných hodnotách. Príklad jednej 5-sekundovej sekvencie dát je uvedený nižšie:

```
{
  "device_name": "laptop",
  "device_type": "DATA_FORWARDER",
  "interval_ms": 500,
  "sensors": [
    {"name": "mq2", "units": "N/A"},
    {"name": "mq135", "units": "N/A"},
    {"name": "infrared", "units": "N/A"}
  ],
  "values": [
    [72, 39, 75],
    [71, 36, 78],
    [68, 39, 72],
    [72, 36, 79],
    [72, 39, 70],
    .....
  ]
}
```

Každá časová rada bola rozdelená na menšie segmenty s využitím kľzavého okna. Kľzavé okno je technika používaná na rozdelenie kontinuálneho toku dát na menšie časové bloky, ktoré môžu byť samostatne analyzované. V našom prípade sme zvolili veľkosť okna 1 000 ms, teda 1 sekundu. Táto hodnota predstavuje dostatočne dlhý časový interval na to, aby sa v ňom mohli prejaviť relevantné zmeny v správaní senzorov pri prechode medzi rôznymi stavmi. Súčasne ide o kompromis medzi rýchlosťou reakcie systému a stabilitou signálu – príliš krátke okno by mohlo byť citlivé na šum, príliš dlhé zas môže znižovať rýchlosť detekcie v reálnom čase.

Krok posunu okna bol nastavený na 500 ms, čo znamená, že sa každú pol sekundu generuje nový dátový segment, pričom segmenty sa čiastočne prekrývajú. Tento prístup zabezpečuje vyššie rozlíšenie v čase a prispieva k zvýšeniu počtu tréningových vzoriek bez potreby ďalšieho merania. Vzorkovacia frekvencia bola nastavená na 2 Hz (2 vzorky za sekundu), čím každé okno obsahuje presne 2 vzorky na každý 500 ms interval. Tieto vzorky reprezentujú zmeny v hodnote plynových a infračervených senzorov počas daného intervalu.


Získané segmenty dát boli následne transformované do vektorov črt, ktoré slúžia ako vstup pre klasifikačný model. Na extrakciu črt sme implementovali jednoduchú, ale efektívnu transformáciu pomocou tzv. flatteningu. Flatten v tomto kontexte znamená pretransformovanie viacrozmerneho časového okna do pevného počtu štatistických črt, ktoré vystihujú správanie senzorov počas daného časového úseku. Tento prístup umožňuje

zachytiť hlavné charakteristiky signálu bez potreby použitia zložitejších modelov na spracovanie časových sekvencií.

V rámci flatteningu sme experimentovali s viacerými štatistickými metrikami. Nakoniec sme vybrali len dve, ktoré sa ukázali ako najinformatívnejšie a zároveň výpočtovo nenáročné:


- Priemer – poskytuje základnú informáciu o celkovej hladine signálu v rámci okna. Je dôležitý pri detekcii pomalých zmien, ako je postupné zvyšovanie koncentrácie plynov.
- RMS (Root Mean Square) – ide o štatistickú metriku vyjadrujúcu efektívnu hodnotu signálu. RMS je obzvlášť vhodný pre situácie, kde je signál nestabilný alebo osciluje, pretože zohľadňuje kvadratickú silu odchýlok od nuly. Pre senzorické aplikácie je RMS výhodný na detekciu energetického obsahu v signáli, napríklad pri výskyte plameňa.

Ostatné metriky ako minimum, maximum, štandardná odchýlka, skewness a kurtosis sme experimentálne vyhodnotili ako menej prínosné pre náš konkrétny dataset. Ich použitie by zbytočne zvýšilo výpočtovú a pamäťovú náročnosť systému, čo je neželané najmä v prípade nasadenia modelu v prostredí s obmedzenými zdrojmi.



Obrázok 11: Priemerné hodnoty senzorov
Zdroj: Vlastné spracovanie

Výsledné RMS a priemerné hodnoty sme použili na vytvorenie 3D vizualizácie (viď grafy v na obrázkoch 11 a 12), kde každá trieda (dym, plyn, normálne, oheň) tvorí samostatný zhluk bodov. Z grafov je zrejmé, že jednotlivé triedy sú dobre separované, čo znamená, že zvolené príznaky majú vysokú rozlišovaciu schopnosť. Napríklad, prípady s plynom majú výrazne vyššie hodnoty MQ135 a pri ohni hodnota z IR senzora dosahuje nízku úroveň. Táto analýza potvrdzuje, že použitie iba metriky RMS a priemeru je v našom prípade dostatočné.



Obrázok 12: RMS hodnoty senzorov
Zdroj: Vlastné spracovanie

Výsledkom spracovania je vektor čírt obsahujúci 6 hodnôt (2 metriky pre každý z 3 senzorov), ktorý je následne klasifikovaný do jednej zo štyroch definovaných tried: oheň, dym, plyn a normálny prostredie. Tento systém umožňuje robustnú klasifikáciu stavov na základe krátkych časových intervalov (1 sekunda), pričom každých 500 ms je k dispozícii nové rozhodnutie. Tým sa zvyšuje rýchlosť reakcie systému pri zachovaní dostatočnej spoľahlivosti detekcie.

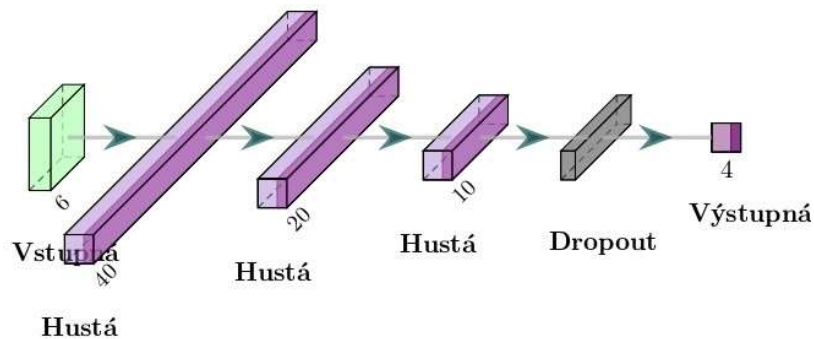
3.4 Neurónová sieť

Navrhnutá neurónová sieť pozostáva z viacerých vrstiev, ktoré zahŕňajú vstupnú vrstvu, skryté vrstvy a výstupnú vrstvu. Táto architektúra bola starostlivo navrhnutá s ohľadom na charakteristiky vstupných dát, hardvérové obmedzenia a požiadavky na čas spracovania.

Vstupná vrstva obsahuje 6 neurónov, ktoré reprezentujú štatistické metriky (priemer a RMS) z troch senzorov: MQ2, MQ135 a infračerveného senzoru. Tieto štatistické metriky boli zvolené preto, že poskytujú dostatočne informatívne zhrnutie senzorických dát, pričom sú výpočtovo nenáročné. Priemer umožňuje detegovať dlhodobé trendy v signáloch, ako je napríklad postupné zvyšovanie koncentrácie plynu, zatiaľ čo RMS odráža celkovú intenzitu signálu a je užitočný pri detekcii dynamických zmien.

Skryté vrstvy pozostávajú z troch hustých vrstiev s 40, 20 a 10 neurónmi. Použitie postupne znižujúceho sa počtu neurónov umožňuje sieti extrahovať a spracovať komplexné vzory z dát, pričom znižuje riziko pretrénovania. Medzi jednotlivými vrstvami bola navyše použitá Dropout vrstva s mierou 0.25, ktorá náhodne vypína časť neurónov

počas tréningu. Tento krok je dôležitý na zvýšenie generalizačných schopností modelu, pretože znižuje pravdepodobnosť, že sa model "naučí naspamäť" trénovacie dáta.



Obrázok 13: Architektúra neurónovej siete (vrstvy)
Zdroj: Vlastné spracovanie

Výstupná vrstva obsahuje 4 neuróny, z ktorých každý reprezentuje jednu z cieľových tried: oheň, dym, únik plynu a normálny stav. Aktivácia týchto neurónov je riadená funkciou softmax, ktorá zaručuje, že výsledky budú interpretovateľné ako pravdepodobnosti.

Pre tréning modelu boli použité nasledujúce hyperparametre:

- **Počet epoch (30):** Tento parameter určuje, koľkokrát model spracuje celú trénovaciu sadu. Hodnota 30 bola zvolená po experimentovaní s rôznymi hodnotami, aby sa dosiahla rovnováha medzi dostatočným učením modelu a minimalizáciou rizika pretrénovania.
- **Learning rate (0.0005):** Učiaci rýchlosť určuje, ako rýchlo sa model prispôbuje počas tréningu. Hodnota 0.0005 bola vybraná ako dostatočne nízka na to, aby sa predišlo veľkým osciláciám v optimalizačnom procese, pričom je dostatočne vysoká na zabezpečenie efektívneho učenia.
- **Batch size (32):** Veľkosť dávky definuje počet vzoriek, ktoré sa spracujú naraz počas jednej iterácie. Hodnota 32 bola zvolená ako kompromis medzi efektívnosťou výpočtov a stabilitou aktualizácií modelu.
- **Validačná sada (20%):** Delenie dát na trénovaciu a validačnú sadu v pomere 80/20 umožňuje monitorovať výkon modelu na dátach, ktoré neboli použité počas tréningu. Tento postup minimalizuje riziko pretrénovania a zaručuje, že model bude dobre generalizovať na nové dáta.

Celý návrh modelu bol implementovaný v programovacom jazyku Python a nasadený cez Edge Impulse. Nasleduje ukážka kódu, ktorý definuje architektúru neurónovej siete v jazyku Python:

```
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout
from tensorflow.keras.optimizers import Adam

EPOCHS = 30
LEARNING_RATE = 0.0005
BATCH_SIZE = args.batch_size or 32

train_dataset = train_dataset.batch(BATCH_SIZE,
drop_remainder=False)
validation_dataset = validation_dataset.batch(BATCH_SIZE,
drop_remainder=False)

model = Sequential()
model.add(Dense(40, activation='relu',
activity_regularizer=tf.keras.regularizers.l1(0.0001)))
model.add(Dense(20, activation='relu',
activity_regularizer=tf.keras.regularizers.l1(0.0001)))
model.add(Dense(10, activation='relu',
activity_regularizer=tf.keras.regularizers.l1(0.0001)))
model.add(Dropout(0.25))
model.add(Dense(y_pred, activation='softmax', name='y_pred'))

opt = Adam(learning_rate=LEARNING_RATE, beta_1=0.9, beta_2=0.999)
callbacks.append(BatchLoggerCallback(BATCH_SIZE,
train_sample_count, epochs=EPOCHS,
ensure_determinism=ENSURE_DETERMINISM))

model.compile(loss='categorical_crossentropy', optimizer=opt,
metrics=['accuracy'])
model.fit(train_dataset, validation_data=validation_dataset, verbose=2, callbacks=callbacks)
```

Tento kód ukazuje, ako bola architektúra neurónovej siete implementovaná pomocou knižnice TensorFlow/Keras. Používa optimalizátor Adam, ktorý je známy svojou efektivitou pri optimalizácii modelov, a stratovú funkciu kategorizálnej krížovej entropie, ktorá je vhodná pre klasifikačné úlohy s viacerými triedami.

3.5 Dosiahnuté výsledky klasifikácie

Na základe testovacej sady, údaje ktoré sme nepoužili v trénovanom procese, sa nám podarilo dosiahnuť výborné výsledky, pričom klasifikátor dosiahol až 100% úspešnosť pri rozpoznávaní jednotlivých tried. Z výstupov analýzy je zrejmé, že neurónová sieť rozlíšila všetky testované vzorky správne, o čom svedčí aj metrika AUC s hodnotou 1.00, ako aj presnosť, citlivosť a F1-skóre, ktoré dosahovali hodnotu 1.00.

	DYM	GAS	NORMALNE	OHEN
DYM	100%	0%	0%	0%
GAS	0%	100%	0%	0%
NORMALNE	0%	0%	100%	0%
OHEN	0%	0%	0%	100%
F1 SCORE	1.00	1.00	1.00	1.00

Obrázok 14: Matica zmätenia výsledkov
Zdroj: Vlastné spracovanie

Ďalšie zistenia potvrdzuje aj matica zmätenia, ktorá pre každý z uvedených stavov vykazuje 100 % klasifikáciu správnej predikcie v príslušných riadkoch a stĺpcoch. Tento fakt naznačuje, že pri poskytnutých testovacích dátach nevznikli žiadne falošné poplchy ani nerozpoznané javy. Vizualnú reprezentáciu presnosti modelu zachytáva konfúzna matica na Obrázku 3.8, kde sú jednotlivé kategórie zobrazené v príslušných riadkoch a stĺpcoch, pričom hodnota 1.0 označuje 100 % úspešnosť.

3.5.1 Možnosť pretrénovania

Na prvý pohľad môže takáto vysoká presnosť vzbudzovať podozrenie na tzv. pretrénovanie - jav, keď model nedokáže generalizovať mimo naučené dáta, pretože sa „naučil naspamäť“ konkrétne vzory zo svojho tréningového súboru. Pretrénovaný model vykazuje extrémne dobré výsledky na tréningových dátach, no zlyháva na nových, mierne odlišných vstupoch.

V našom prípade sa však domnievame, že k pretrénovaniu nedošlo z nasledujúcich dôvodov:

1. Použitie validačnej a testovacej sady: Výsledky boli merané na dátach, ktoré model nevidel počas tréningovania. Tréningové a testovacie dáta boli striktné oddelené, pričom testovacia množina predstavovala 20 % všetkých segmentov.
2. Jednoduchá štruktúra vstupných dát: Vstupné dáta pozostávali z RMS a priemeru signálov zo senzorov MQ2, MQ135 a IR senzora. Ide o relatívne nízkorozmerné a stabilné charakteristiky signálov, ktoré v jednotlivých triedach vykazovali jasne odlišiteľné vzory. To znamená, že triedy neboli navzájom príliš podobné – model tak nemal ťažkosti s rozhodovaním a nebol nútený „hľadať zložité vzory“, ako je to bežné pri obrazoch či prirodzenom jazyku.

3. Použitie dropout vrstvy: Pri tréovaní sme aplikovali dropout regularizáciu (0.25), čo bráni tomu, aby sa model príliš „prilepil“ na konkrétne neuróny a naučil sa redundantné štruktúry.
4. Neexistencia prehnaného počtu parametrov: Architektúra siete bola úmyselne navrhnutá ako jednoduchá – so znižujúcim sa počtom neurónov v skrytých vrstvách (40–20–10). To znižuje riziko pretrénovania pri malom množstve dát.

Zároveň si však uvedomujeme, že takáto perfektná presnosť môže byť čiastočne spôsobená obmedzeniami experimentálneho prostredia, čo popisujeme ďalej.

3.5.2 *Vplyv prostredia na výsledky a obmedzenia experimentu*

Dáta boli získané v Marci v Bratislave, pričom experimenty sa uskutočňovali v domácom prostredí a v prírode. Vonkajšie dáta – konkrétne scenáre "dym" a "oheň" – boli zaznamenávané počas chladného počasia (cca 6–10 °C), s relatívnou vlhkosťou medzi 60–80 %. Tieto podmienky významne ovplyvňujú správanie plynových senzorov – najmä MQ2 a MQ135, ktoré sú citlivé na vlhkosť a teplotné výkyvy. Napriek týmto vonkajším vplyvom však senzory preukázali dostatočnú stabilitu a konzistenciu – ich signály boli opakovateľné a odlišiteľné pre každú triedu.

Napriek tomu by bolo ideálne vykonať merania priamo v reálnom skladovom priestore, ktorý:

- má špecifickú mikroklimu (stála teplota, iné prúdenie vzduchu).
- môže obsahovať rušiacie plyny alebo chemikálie.
- vykazuje inú hlučnosť senzorických údajov (napr. vibrácie, prach, zvýšené emisie VOC).

Práve získanie dát z reálneho skladu by umožnilo model prispôbiť konkrétnym podmienkam daného priestoru. Model by sa tak vedel naučiť špecifické úrovne signálu považované za „normálne“ v danom objekte a odlíšiť ich od výnimočných javov (požiar, únik plynu).

3.5.3 *Zlyhania a odolnosť systému voči výpadkom senzorov*

Počas testovania sme zaznamenali aj dočasné zlyhanie senzora MQ135, ktoré vzniklo pravdepodobne z dôvodu kolísania napájacieho napätia. V dôsledku toho jeho výstup „zamrzol“ a neposkytoval nové hodnoty. Tento stav viedol k tomu, že model prestal detegovať „únik plynu“, hoci bol fyzicky prítomný. Z toho vyplýva, že spoľahlivosť

detekcie je vysoko závislá od zdravia všetkých sensorov. Ak ktorýkoľvek z nich prestane správne fungovať, môže dôjsť buď k úplnému zlyhaniu detekcie, alebo k chybnéj klasifikácii. Navrhujeme preto do budúca tieto opatrenia:

1. Redundancia sensorov – dôležité snímače môžu byť duplicitné. Ak jeden senzor zlyhá, systém môže rozhodovať podľa druhého.
2. Diagnostika sensorov – softvérová vrstva by mala monitorovať „živé správanie“ sensorov. Napríklad ak sa výstup nemení po určitý čas, je vhodné hlásiť chybu senzora.
3. Fallback režim – ak dôjde k výpadku jedného senzora, systém môže dočasne fungovať s upraveným modelom, ktorý ignoruje chýbajúci vstup (napr. trénovaný variant s nižším počtom vstupných parametrov).
4. Využitie sensorovej fúzie – v prípade, že niektoré dáta nie sú dostupné, model by mohol využívať kombinácie sensorických signálov (napr. zvýšená aktivita IR senzora kompenzuje chýbajúce plynové dáta).

Hoci aktuálne výsledky klasifikácie naznačujú, že model je vysoko presný a robustný v testovacom prostredí, uvedomujeme si potrebu jeho ďalšej validácie v reálnych podmienkach. Získanie dát priamo zo skladových priestorov by umožnilo model lepšie prispôbiť špecifickému typu prevádzky. Napriek tomu je vývojový systém plne funkčný a pripravený na rozšírenie – či už vo forme rozšírenia sensorovej siete, pretrénovania modelu na reálne dáta, alebo nasadenia na edge platformách s vyššou výpočtovou kapacitou. Výsledky teda predstavujú solídny základ pre vývoj prakticky nasaditeľného systému včasnej detekcie požiaru, s perspektívou škálovania a prispôbovania rôznym typom objektov.

3.6 Implementácia neurónovej siete na platforme Arduino

V prostredí Edge Impulse bola po úspešnom natrénovaní a validácii exportovaná knižnica C/C++, ktorá obsahuje všetko potrebné na lokálny beh modelu. Táto knižnica bola následne nahraná do projektu v Arduino IDE, čím sa zabezpečila integrácia klasifikátora priamo do firmvéru mikrokontroléra.

V C++ kóde pre Arduino sú hodnoty zo sensorov načítavané prostredníctvom analógových vstupov (A0, A1, A2) a následne uložené do poľa *features[]*.

Toto pole je definované s dĺžkou, ktorá zodpovedá makru `EI_CLASSIFIER_DSP_INPUT_FRAME_SIZE` – preddefinovanej konštante, ktorá zabezpečuje správne zarovnanie dát pre vstup do modelu. Časť C/C++ kódu:

```
void loop() {
  int s1 = analogRead(SENSOR1_PIN);
  int s2 = analogRead(SENSOR2_PIN);
  int s3 = analogRead(SENSOR3_PIN);

  if (NUM_INPUTS == 6) {
    features[0] = (float)s1;
    features[1] = (float)s2;
    features[2] = s3 / 10.0;
    features[3] = (float)s1;
    features[4] = (float)s2;
    features[5] = s3 / 10.0;
  }

  signal_t signal;
  signal.total_length = NUM_INPUTS;
  signal.get_data = [](size_t offset, size_t length, float
*out_ptr) -> int {
    memcpy(out_ptr, features + offset, length * sizeof(float));
    return 0;
  };

  ei_impulse_result_t result = { 0 };
  EI_IMPULSE_ERROR res = run_classifier(&signal, &result, false);
  if (res != EI_IMPULSE_OK) {
    delay(3000);
    return;
  }

  String label = result.classification[0].label;
}
```

Postup transformácie surových dát zahŕňa aj jednoduchú normalizáciu, napríklad delením jednej z hodnôt číslom 10.0, čím sa zabezpečí, že všetky vstupné hodnoty sú v porovnateľnom rozsahu. Následne je vytvorený objekt typu `signal_t`, ktorý obsahuje informácie o celkovej dĺžke dát a implementuje callback funkciu `get_data`. Táto funkcia zabezpečuje správne kopírovanie dát z poľa `features[]` do pamäte, ktorá je ďalej využitá algoritmom inferencie.

Kľúčovou súčasťou implementácie je funkcia `run_classifier`, ktorá vykonáva samotnú inferenciu. Po jej úspešnom vykonaní sa výsledok uloží do premennej `result` a z nej sa získa prvá klasifikácia, ktorá je identifikovaná atribútom `label`. Táto hodnota neskôr slúži nielen na lokálne logovanie, ale aj na ďalšiu komunikáciu s webovým serverom.

Pre zabezpečenie komunikácie s lokálnym serverom využíva sketch sériu AT príkazov na inicializáciu WiFi modulu. V funkcii `setup()` sa najprv inicializuje sériová komunikácia, kde sa používajú AT príkazy na overenie funkčnosti modulu a nastavenie

WiFi pripojenia. Pomocou príkazu AT+CWJAP sa zariadenie pripojí k definovanej WiFi sieti, pričom sú zadávané SSID a heslo. Následne je príkazom *AT+CIPMUX=0* nastavený režim pripojenia tak, aby sa mohla uskutočniť komunikácia cez jeden TCP kanál. Časť C/C++ kódu pre komunikáciu:

```
void sendToServer(const String &label) {
    String message = "POST /send HTTP/1.1\r\n";
    message += "Host: " + String(host) + "\r\n";
    message += "Connection: close\r\n";
    message += "Content-Length: " + String(label.length()) +
"\r\n\r\n";
    message += label;

    String cipstart = String("AT+CIPSTART=\"TCP\", \"") + host +
"\", 3000";
    sendCommand(cipstart, 3000);
    delay(1000);

    String cipsend = String("AT+CIPSEND=") + message.length();
    sendCommand(cipsend, 3000);
    delay(500);

    Serial.print("Sending POST request to ");
    Serial.println(host);
    Serial1.print(host);
    Serial1.print(message);
    unsigned long startTime = millis();
    while (millis() - startTime < 3000) {
        if (Serial1.available()) {
            Serial1.readStringUntil('\n');
        }
    }
}

void sendCommand(const String &cmd, unsigned long timeout) {
    while (Serial1.available()) {
        Serial1.read();
    }
    Serial1.println(cmd);

    unsigned long start = millis();
    while (millis() - start < timeout) {
        if (Serial1.available()) {
            Serial1.readStringUntil('\n');
        }
    }
}
```

V metóde *sendToServer()* sa vytvára HTTP POST požiadavka so správou obsahujúcou klasifikáciu. Táto požiadavka je doplnená o hlavičky potrebné pre správne fungovanie TCP spojenia (napr. Host, Connection a Content-Length). Pomocou funkcie *sendCommand()* sú jednotlivé AT príkazy odosielané a časovo synchronizované, čo zabezpečuje korektný odosielač cyklus a následné čítanie odpovedí z modulu. Tento postup zabezpečuje, že každá klasifikácia je okamžite prenesená do centrálného monitorovacieho systému.

3.7 Webová aplikácia a správa dát

Pre vizualizáciu a správu klasifikácií bol vyvinutý lokálny webový server postavený na Node.js s použitím frameworku Express a knižnice Socket.IO, ktorá umožňuje obojsmernú komunikáciu v reálnom čase. Táto časť implementácie poskytuje používateľovi prehľad o detegovaných udalostiach a upozornenia v prípade vzniku rizikových situácií. Táto webová stránka sa používa len na jednoduchú vizualizáciu klasifikácií, ale v praxi sa tieto údaje môžu posielat' do komplexnej databázy, ktorá môže poskytnúť aj podrobnejšiu analýzu týchto údajov. Hlavnou výhodou týchto edge systémov je, že môžu fungovať bez prístupu na internet, takže v reálnej integrácii môže byť tento systém pripojený priamo k poplachovému systému budovy alebo kontaktovať príslušné authority, pričom nie je nevyhnutne potrebný prístup na internet.

Súbor server.js predstavuje hlavnú súčasť serverovej aplikácie. Na začiatku je vytvorený Express server, ktorý je následne obalený v HTTP serveri. Knižnica Socket.IO je neinicializovaná na tomto serveri, čo umožňuje dynamické šírenie dát medzi serverom a pripojenými klientmi.

JavaScript kód pre vytvorenie Express servera:

```
const express = require('express');
const http = require('http');
const socketIo = require('socket.io');

const app = express();
const server = http.createServer(app);
const io = socketIo(server);

app.use(express.text({ type: '*/*' }));
app.use(express.static('public'));

app.post('/send', (req, res) => {
  const classification = req.body.trim();
  console.log('Received classification:', classification);
  io.emit('classification', classification);
  res.sendStatus(200);
});

const PORT = process.env.PORT || 3000;
server.listen(PORT, () => {
  console.log(`Server listening on port ${PORT}`);
});
```

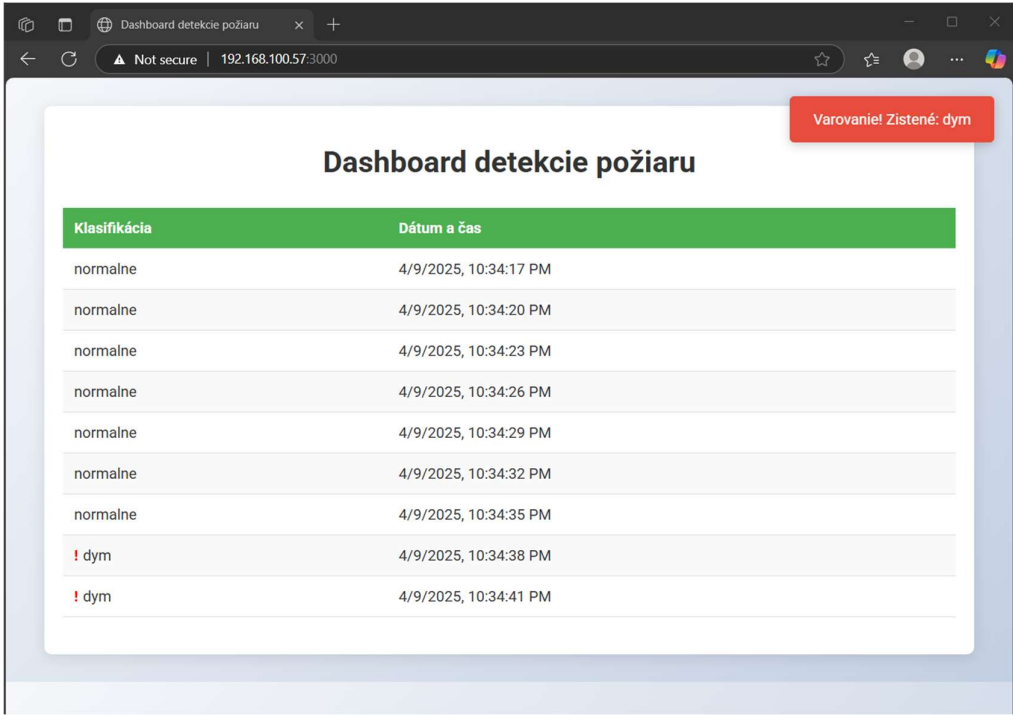
Aplikácia spracováva prijatý POST request na ceste `/send`, kde sú príjmom spracované klasifikované dáta. V tejto časti sa údaje najprv očistia, potom sa zaznamenajú do logov a zároveň sú vysielané všetkým pripojeným klientom prostredníctvom udalosti `classification`. Takýmto spôsobom je zabezpečená okamžitá aktualizácia zobrazenia na klientských zariadeniach.

Konfigurácia súboru package.json definuje názov projektu, verziu, hlavný spúšťač súbor a zoznam závislostí. Medzi hlavné závislosti patria Express (verzia 4.18.2) a Socket.IO (verzia 4.5.4), ktoré sú esenciálne pre beh servera a obojsmernú komunikáciu. Po nainštalovaní balíkov je aplikáciu možné spustiť príkazom `npm start`, čo spustí server na definovanom porte (štandardne port 3000).

Json súbor použitých balíkov:

```
{
  "name": "my-fire-dashboard",
  "version": "1.0.0",
  "main": "server.js",
  "scripts": {
    "start": "node server.js"
  },
  "dependencies": {
    "express": "^4.18.2",
    "socket.io": "^4.5.4"
  }
}
```

V hlavnej časti webstránky je umiestnená tabuľka, ktorá slúži na zobrazenie záznamov o prijatých klasifikáciách spolu s aktuálnym dátumom a časom. Každý nový záznam sa dynamicky pridáva do tabuľky a stránka sa automaticky posúva nadol, aby bol vždy viditeľný najnovší záznam.



Klasifikácia	Dátum a čas
normalne	4/9/2025, 10:34:17 PM
normalne	4/9/2025, 10:34:20 PM
normalne	4/9/2025, 10:34:23 PM
normalne	4/9/2025, 10:34:26 PM
normalne	4/9/2025, 10:34:29 PM
normalne	4/9/2025, 10:34:32 PM
normalne	4/9/2025, 10:34:35 PM
! dym	4/9/2025, 10:34:38 PM
! dym	4/9/2025, 10:34:41 PM

Obrázok 15: Snímka obrazovky z webovej stránky
Zdroj: Vlastné spracovanie

Jednoduchý notifikačný mechanizmus implementovaný cez JavaScriptový kód zobrazuje upozornenie v pravom hornom rohu stránky (Obrázok 15). Ak prijatá klasifikácia spadá medzi rizikové stavy, vykreslí sa výrazné červené upozornenie, čím sa zabezpečí okamžitá vizuálna signalizácia nebezpečia. Tabuľka a tento vizuálny prvok sú na obrázku 15.

Ďalej je súčasťou indexu aj implementácia Socket.IO klienta, ktorý sa po pripojení na server dynamicky pripája na udalosť *classification*. Každá prijatá správa je následne spracovaná – aktualizuje sa tabuľka a vykoná sa kontrola, či daná klasifikácia patrí medzi nebezpečné stavy, čo vyvolá zobrazenie notifikácie. Týmto spôsobom je zabezpečená plynulá a robustná interakcia medzi hardvérom, serverom a koncovým používateľom.

Celková architektúra systému demonštruje komplexný prístup k detekcii požiaru kombináciou edge computing a real-time webového monitoringu. Integrácia neurónovej siete do platformy Arduino, následne prepojená so serverovou aplikáciou pomocou HTTP a Socket.IO, čím prispieva k rýchlej a efektívnej reakcii v prostredí s možným nebezpečenstvom požiaru.

Záver

Diplomová práca úspešne splnila všetky stanovené ciele. Zaoberali sme sa detailnou analýzou súčasných systémov detekcie požiarov a identifikovali sme výhody nasadenia Edge Computingu pre lokálnu detekciu požiarov. Praktická realizácia našej práce viedla k zostrojeniu prototypu automatického systému detekcie požiaru využívajúceho Arduino Nano 33 BLE a senzory MQ2, MQ135 a infračervený senzor.

V rámci našej práce sme úspešne implementovali neurónovú sieť špeciálne optimalizovanú pre použitie na mikrokontroléroch, ktoré majú obmedzené výpočtové zdroje. Napriek týmto obmedzeniam sa nám podarilo dosiahnuť 100 % presnosť pri rozlišovaní štyroch rôznych stavov prostredia. Tento výsledok jasne poukazuje na potenciál kombinácie jednoduchšej, cenovo dostupnej technológie a správne navrhutej umelej inteligencie. Konkrétne sme využili iba tri základné, lacné senzory, ktoré však v spojení s efektívne optimalizovanou neurónovou sieťou dokážu s vysokou spoľahlivosťou detegovať prípadné požiare – a to aj bez potreby nepretržitého pripojenia ku cloudovým službám.

Vysoká presnosť modelu vyplýva zo starostlivo zozbieraných dát a z vhodne navrhutej architektúry neurónovej siete. Skontrolovali sme aj možnosť pretrénovania a vzhľadom na použitie rozsiahleho a diverzifikovaného datasetu sme problém pretrénovania eliminovali. Pre ďalšie zlepšenie presnosti a spoľahlivosti modelu odporúčame neustále rozširovať sadu tréningových dát.

Experimenty boli realizované v kontrolovanom prostredí simulujúcom reálne podmienky skladových priestorov. Avšak odporúčame budúce experimenty vykonať aj v rôznorodejších prostrediach pre lepšie výsledky.

Vyvinuli sme aj webovú aplikáciu pre monitorovanie v reálnom čase, ktorá umožňuje okamžitú analýzu údajov a jednoduchšiu správu systému. Tento systém môže byť efektívne využitý v priemysle, skladových objektoch a iných rizikových lokalitách na rýchlu a spoľahlivú detekciu požiarov, čím prispieva k zvýšeniu bezpečnosti a ochrany životov a majetku.

Na záver môžeme konštatovať, že predložený prototyp potvrdil praktickú uskutočniteľnosť konceptu edge computing v požiarnej signalizácii a súčasne naznačil perspektívu jeho priemyselnej adopcie. Prepojili sme teoretické východiská

moderného TinyML s konkrétnym hardvérom. Preukázali sme výhody lokálneho spracovania dát voči tradičným centralizovaným riešeniam a identifikovali sme kľúčové oblasti, v ktorých sa ďalším výskumom a inžinierskym zdokonaľovaním dá posunúť požiarna bezpečnosť na novú úroveň.

Zoznam použitej literatúry

- Ahrens, M. (2019). *Smoke alarms in US home fires*. National Fire Protection Association. Fire Analysis and Research Division. Dostupné na: <https://www.chelmsfordma.gov/DocumentCenter/View/10843/NFPA-smoke-alarm-study>
- ARDUINO. *Arduino Nano 33 BLE*. Dostupné na: https://store.arduino.cc/en-sk/products/arduino-nano-33-ble?srsId=AfmBOornEFwUBIOu4EHHyaEu9qgnRH5JNJeE_X4M8OKHR-sbc4sUyMy
- Avgeris, Marios et al. (2019). *Where there is fire there is smoke: A scalable edge computing framework for early fire detection*. Sensors. MDPI. Dostupné na: <https://www.mdpi.com/1424-8220/19/3/639>
- Banbury, Colby R. et al. (2020). *Benchmarking TinyML Systems: Challenges and Direction*. Dostupné na: https://www.researchgate.net/publication/339841311_Benchmarking_TinyML_Systems_Challenges_and_Direction
- Bayegizova, Aigulim et al. (2024). *Fire detection using deep learning methods*. International Journal of Electrical & Computer Engineering. Dostupné na: <https://core.ac.uk/download/pdf/591354125.pdf>
- OpenAI. (2023). ChatGPT (Mar 14 version) [Large language model]. <https://chat.openai.com/chat>
- Conventional vs Addressable Fire Alarm System. *Key Security*. Dostupné na: <https://www.keysecurity.com.tw/conventional-vs-addressable-fire-alarm.html#:~:text=To%20indicate%20fire%20in%20a,detectors%20and%20call%20points>
- David, Robert et al. (2021). *TensorFlow Lite Micro: Embedded Machine Learning on TinyML Systems*. arXiv. Dostupné na: <http://arxiv.org/abs/2010.08678>
- EU Fire Safety Guide - Modern Building Alliance. (2025). *Modern Building Alliance*. Dostupné na: <https://www.modernbuildingalliance.eu/EU-fire-safety-guide>

- EU-Wide data on residential fires. (2019). *EuroFSA*. Dostupné na: <https://www.europeanfiresafetyalliance.org/action-plan/statistics/#:~:text=EU,but%20not%20on%20residential%20fires%E2%80%99>
- Fong, J. (2018, July 24). *How the Edge Computing Layer Helps with Latency*. IEEE Innovation at Work. Dostupné na: <https://innovationatwork.ieee.org/how-the-edge-computing-layer-helps-with-latency/#:~:text=,preventive%20measures>
- Hall, S., & Evarts, B. (2022). *Fire loss in the United States during 2021*. National Fire Protection Association (NFPA). Dostupné na: <https://www.darley.com/wp-content/uploads/2022/11/NFPA-2021-Report-and-Tables.pdf>
- Huć, Aleks - Šalej, Jakob - Trebar, Mira. (2021). *Analysis of machine learning algorithms for anomaly detection on edge devices*. Sensors. MDPI. Dostupné na: <https://www.mdpi.com/1424-8220/21/14/4946>
- Hymel, Shawn et al. (2022). *Edge impulse: An MLOps platform for tiny machine learning*. arXiv. Dostupné na: <https://arxiv.org/pdf/2212.03332#page=12&zoom=100,0,0>
- Installing and maintaining smoke alarms - NFPA. *NFPA*. Dostupné na: <https://www.nfpa.org/education-and-research/home-fire-safety/smoke-alarms/installing-and-maintaining-smoke-alarms>
- Khan, F., Xu, Z., Sun, J., Khan, F. M., Ahmed, A., & Zhao, Y. (2022). *Recent advances in sensors for fire detection*. Sensors. Dostupné na: <https://www.mdpi.com/1424-8220/22/9/3310>
- Kobes, M. (2009). *Consumer fire safety: European statistics and potential*. Netherlands Institute for Safety: Arnhem, The Netherlands. Dostupné na: https://www.modernbuildingalliance.eu/assets/uploads/2018/05/09-06-24_rapport_consumer_fire_safety_pdf1.pdf
- Kodur, Venkatesh - Kumar, Puneet - Rafi, Muhammad Masood. (2020). *Fire hazard in buildings: review, assessment and strategies for improving fire safety*. PSU research review. Emerald Publishing Limited. Dostupné na: <https://www.emerald.com/insight/content/doi/10.1108/prr-12-2018-0033/full/html>
- Lee, K. C., & Lee, H. H. (2004). *Network-based fire-detection system via controller area network for smart home automation*. IEEE Transactions on Consumer Electronics. Dostupné na: <https://ieeexplore.ieee.org/abstract/document/1362504>

- Li, Yang - Su, Yanmang - Zeng, Xiangye - Wang, Jingyi. (2022). *Research on multi-sensor fusion indoor fire perception algorithm based on improved TCN*. Sensors. MDPI. Dostupné na: <https://www.mdpi.com/1424-8220/22/12/4550>
- Liang, Tianyu - Zeng, Guigen. (2024). *FSH-DETR: An Efficient End-to-End Fire Smoke and Human Detection Based on a Deformable DETection TRansformer (DETR)*. Sensors. Dostupné na: <https://www.mdpi.com/1424-8220/24/13/4077>
- Mellon, M. (2022). *4 Common types of flame detectors*. Vanguard. Dostupné na: <https://vanguard-fire.com/common-types-of-flame-detectors/#:~:text=1>
- Moinuddin, Khalid AM - Bruck, Dorothy - Shi, Long. (2017). *An experimental study on timely activation of smoke alarms and their effective notification in typical residential buildings*. Fire safety journal. Elsevier. Dostupné na: <https://www.sciencedirect.com/science/article/abs/pii/S0379711217305210>
- PerplexityAI. (2023). Perplexity [Large language model]. <https://www.perplexity.ai>
- Rostami, A., Shah-Hosseini, R., Asgari, S., Zarei, A., Aghdami-Nia, M., & Homayouni, S. (2022). *Active fire detection from landsat-8 imagery using deep multiple kernel learning*. Remote Sensing. Dostupné na: <https://www.mdpi.com/2072-4292/14/4/992>
- Zheng, S., Gao, P., Zou, X., & Wang, W. (2022). *Forest fire monitoring via uncrewed aerial vehicle image processing based on a modified machine learning algorithm*. Frontiers in Plant Science. Dostupné na: <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2022.954757/full>