

# DETECTION OF COLLAPSE BY ANDROID SMARTPHONE

**Tomáš Repčík**

Bachelor Degree Programme (3), FEEC BUT

E-mail: xrepci01@vutbr.cz

Supervised by: Denisa Maděránková

E-mail: maderankova@feec.vutbr.cz

**Abstract:** The bachelor's study is focused to design and build an Android application for the detection of collapse, which is enhanced by new techniques coming from a sphere of the artificial intelligence modified for smartphones. The application uses accelerometer outputs which are in suspicious moments analysed by the neural network. The artificial intelligence is based on simulated events of collapse and events which resemble a fall of a person. The study describes data collected from 20 people. To provide the best results of training, the most convenient and useful features were selected by multiple approaches. Total accuracy of the collapse detection reached 93 %, with 9 % and 13 % of false positive and false negative detections, respectively.

**Keywords:** collapse, Android smartphone, fall detection, machine learning, neural network, Python, Java, Tensorflow lite, Keras

## 1 ÚVOD

Podľa štatistík, pád človeka je druhá najčastejšia príčina neúmyselnej smrti, čo činí takmer celosvetovo 700 000 úmrtí ročne. Za rok sa udeje 40 000 000 pádov, ktoré si vyžadujú zdravotnú starostlivosť, pričom najrizikovejšia skupina ľudí sú seniori nad 65 rokov [1]. V dnešnej dobe ale väčšina ľudí vlastní Android smartphon, ktoré už sú schopné pracovať aj s optimalizovanými modelmi umelej inteligencie. S nástupom Android 8, Oreo, systém obsahuje natívnu podporu neurónových sietí, čím sa dosahuje vysokej miery optimalizácie. Tento modul v systéme je schopná využiť knižnica Tensorflow, konkrétne formát modelu Tensorflow lite, ktorý je v aktuálnom vývoji a ponúka malú veľkosť a vysokú mieru optimalizácie. Tento modul obsahuje aj spätnú kompatibilitu a zároveň aplikácia je kompatibilná so zariadeniami od Androidu 4.4.4 KitKat a vyššie.

## 2 ZBER A SPRACOVANIE DÁT

Pád môžeme rozdeliť na dve fázy, na fázu padania a fázu dopadu [2]. Fáza padania je význačná dočasným poklesom akcelerácie, ktorý je spôsobený zemskou gravitáciou. Následne dochádza k drastickému spomaleniu pri náraze, čo sa prejaví akceleráciou zvyčajne nad 3 g. Tieto 2 fázy sa teda stávajú hlavným oporným bodom pri spracovaní týchto priebehov, pretože existuje veľa situácií podobných pádu, napr. keď si človek prudšie sadne, ľahne, potkne, behá a atď.


Výskumu v rámci bakalárskej práce sa zatiaľ zúčastnilo 20 dobrovoľníkov, ktorý vykonávali rôzne pohyby podobné pádu a samotný simulovaný pád, ktorý pravdepodobne bude menšie vo svojej amplitúde, ale bude mať rovnaký priebeh ako v prípade pádu skutočného. Táto vzorka obsahuje 12 mladých ľudí vo veku 20 až 30 rokov, 7 vo veku 40 až 50 a aj jednu osobu nad 70 rokov.

Na meranie bola využitá aplikácia vlastnej tvorby SensorBox dostupná na Google Play, ktorá je usposobená na zápis výstupu všetkých senzorov v mobile do csv súborov, pričom údaje nepodliehajú žiadnemu skresleniu. Aplikácia umožňuje merať priebehy v zadaných intervaloch v sekundách až hodinách. Vo vytvorenej databáze majú všetky merania dĺžku 10 s, v ktorých sa vyskytuje len samotný priebeh daného pohybu. Väčšina meraní sú snímané smartphonom umiestneným vo vrecku v nohaviciach, tričku alebo bunde. Je nutné podotknúť, že budúca implementácia nemusí byť funkčná, pokiaľ mobil bude umiestnený v kabelke alebo batohu, pretože ich pohyb nemusí byť

konzistentný s pohybom človeka. Zároveň pri meraní boli použité rôzne smartphony, hlavne Huawei P9 a Sony Xperia Z5. Je nutné brať ohľad na odlišné druhy mobilov, keďže nainštalované senzory môžu disponovať odlišnými parametrami a systém ich môže obmedzovať podľa vytťaženia.

Celkovo bolo vyzbieraných 1774 meraní. Tieto dáta boli vyfiltrované pomocou istých pravidiel. Je nutné, aby priebeh akcelerácie obsahoval magnitúdu nad 3 g. Zároveň meranie musí mať dĺžku medzi 9 až 11 sekúnd, pričom nemôže byť oneskorenie medzi vzorkami vyššie ako 200 milisekúnd. Takto bolo označených 94 meraní ako neplatných, pričom ostalo 1680 meraní, z čoho je 414 pádov, 329 pohybov podobných potknutiu, chôdzi, skoku alebo behu, 622 sadov a 315 ľahov, pri ktorých boli využité rôzne druhy povrchov a výšky uloženia mobilu. Maximalizácia autenticity je zabezpečená variabilitou dobrovoľníkov a rôznymi prevedeniami simulovaného pádu.

Výpočet parametrov bol prevedený okolo najvyššieho piky, kde došlo k hľadaniu fáze pádu maximálne 0,3 s a poslednej hodnoty nad 1,5 g od vzorky vzdalenej 0,7 s od piky. Týmto oknom eliminujeme vyšší vplyv rušení pred pádom, odlišné uloženie mobilu a zameriame detekciu analýzu samotného dopadu, ktorý sa líši v jednotlivých pohyboch. Z týchto priebehov bolo vypočítaných celkovo 43 parametrov z akcelerácie, uhlovej rýchlosti a jej zrýchlenia [3]. Za zmienku stojí napríklad zmena uhlu, označená v obrázku 1 ako CA alebo odchýlka zmeny uhlu označená ako AD, ktorých hlavnou úlohou sa stalo odlišenie stojaceho človeka a ležiaceho človeka [4]. Ostatné parametre sa zvyčajne odlišujú len svojou veľkosťou. Parametre boli vypočítané aj z údajov z gyroskopu, ktoré ale neboli použité z dôvodu podobnosti s akcelerometrom. Vynechaním gyroskopu znížime aj spotrebu batérie. V budúcnosti ale tieto údaje môžu byť použité na zlepšenie detekcie inou metódou. Parametre nemajú normálne rozdelenie, preto pre potlačenie odchýlok bolo zvolené široké interkvartilné rozpätie, podľa ktorého boli identifikované odľahlé hodnoty. Tieto hodnoty boli spriemerované podľa najbližších hodnôt pre zachovanie variability.



**Obrázok 1:** Štandardizované hodnoty jednotlivých vypočítaných parametrov u akcelerácie

### 3 VÝBER PARAMETROV A TVORBA NEURÓNOVEJ SIETE

Pre výber parametrov boli použité metódy ako analýza hlavných komponent, analýza nezávislých komponent alebo nie negatívna maticná faktorizácia. Taktiež vizuálne boli preverené distribúcie parametrov pre jednotlivé pohyby. Podľa komponent boli tiež zistené parametre, ktoré sa najviac podieľajú na ich samotnej tvorbe, pričom boli preverené rôzne kombinácie parametrov podľa ich distribúcií. Podľa tohto postupu bolo zistené, že najviac sa na oddelení jednotlivých pohybov podieľajú tieto parametre magnitúdy akcelerácie: Crestov faktor, zmena uhlu s výpočtom kosínusu, zmena uhlu bez kosínusu, odchýlka zmeny uhlu, rozdiel minima a maxima, pomer počtu vzoriek nad 3 g ku ostatným vo vybranom úseku, šikmosť a špicatosť. Problémom prahového riešenia by

nastal v určení samotných prahov, keďže hranice medzi jednotlivými distribúciami pohybov sú odlišné, nejasné a dochádzalo by ku značným konfliktom. Na to bolo zvolené pružnejšie riešenie v podobe neurónovej siete, ktorá svojimi prahmi a váhami dokáže lepšie určiť ideálne nastavenie.

Tieto parametre boli využité pre tvorbu umelej doprednej neurónovej siete pomocou knižnice Keras, ktorá je nadstavba nad knižnicou Tensorflow. Sieť bola testovaná vo veľkom počte konfigurácií. Boli otestované rôzne konfigurácie od jednej vstupnej vrstvy s jedným výstupným neurónom až po sieť s tromi skrytými so 120 neurónmi. Pre neuróny boli aplikované sigmoidy ako aktivačné funkcie. Rovnako boli implementované rôzne optimalizačné algoritmy ako odhad adaptačného momentu, adam alebo stochastický gradientný zostup, SGD, s rôznymi rýchlosťami učenia. Boli taktiež implementované metódy na priebežne ukladanie najlepšieho modelu podľa chyby s úspešnosťou validácie siete. Pre validáciu siete bolo zvolených náhodne 50 pádov a 50 iných pohybov. Rovnako bolo otestovaných množstvo nastavení epoch pre získanie optimálnej úspešnosti.

Počet neurónov v sieti nemal dopad na jej úspešnosť vzhľadom na to, že nejde až o tak zložitý úkon. Preto pre hlbšie testovanie bola zvolená sieť len so vstupnou vrstvou a jedným výstupným neurónom. SGD nebolo schopné tak rýchlo konvergovať k riešeniu, preto pre počiatok učenia bol využitý adam. Po dosiahnutí pomerne optimálneho výsledku bol ešte nasadený SGD s menšou rýchlosťou učenia pre spresnenie siete. Pri učení nedochádzalo k preučeniu siete, ale ku konvergencii váh k istému riešeniu, ktoré viedli k dosiahnutiu siete s 93 % úspešnosťou pri validácii. Pri chôdzi a behu sieť zaznamenala úspešnosť až 99%, čo vylučuje ich interferenciu pri detekcii. Za určenia hranice na 0,5 na výstupnom neuróne ako hranici k určeniu pádu, by 9 % databáze bolo určené ako falošne pozitívne a 13 % ako falošne negatívne. Treba zobrať do úvahy, že niektoré vykonané merania šli až do extrémnych prípadov, preto je možné očakávať vyššiu úspešnosť.

#### 4 IMPLEMENTÁCIA DO ANDROID SMARTPHONU

Hlavnou súčasťou aplikácie je služba, ktorá sa vytvorí ako proces na pozadí. Táto služba, i po zrušení aplikácie, je stále prítomná a je reprezentovaná notifikáciou, pričom jej systém dáva najvyššiu prioritu pre zachovanie. Podmienkou pre aplikáciu je, aby mobil obsahoval GPS a akcelerometer.

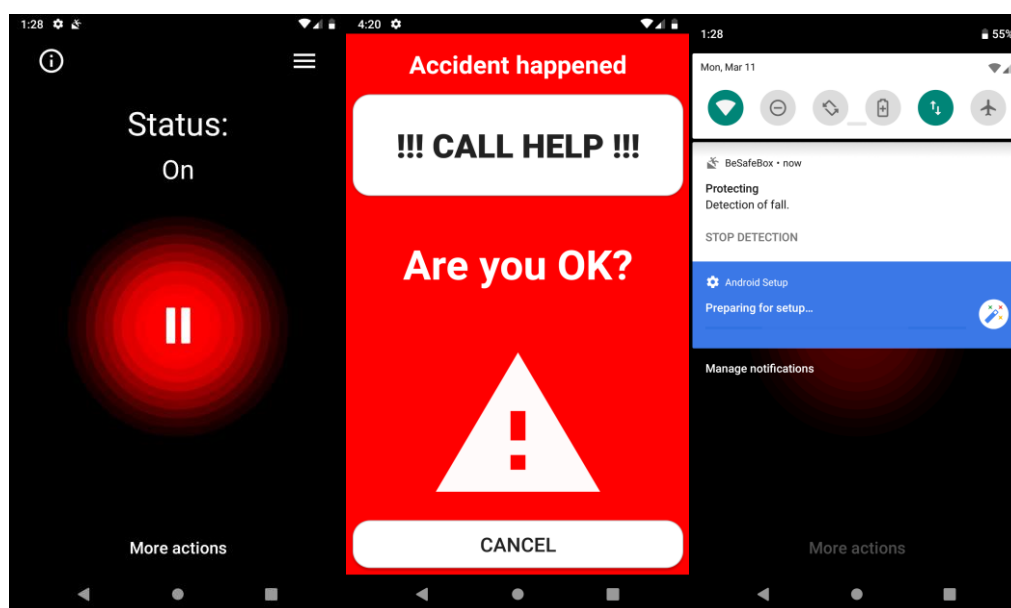
Jednotlivé merania z akcelerometru sú dočasne ukladané v úložisku aplikácie, ktoré môžu byť neskôr využité pre klasifikáciu pádu. Android od verzie 6, Marshmallow, obsahuje v sebe Doze režim, ktorý sa aplikuje pri vypnutí obrazovky. V tomto režime sú pozastavené aplikácie a procesor prechádza do spiacieho režimu ak je to možné, pričom nie je možné vykonať žiadny proces a niekedy ani výstupy z akcelerometra nie sú prítomné. Preto aplikácia si musí vytvoriť nárok na procesor na to, aby mohla fungovať neustále. Nanešťastie procesor je druhý najväčší spotrebiteľ energie, preto tento čas, ktorý je procesor aktívny, je nutné limitovať.

Do aplikácie boli vložené 2 šetriace metódy. Jedna z nich využíva senzor vzdialenosti, ktorý určí kedy sa smartphone nachádza vo vrecku. Teda služba je aktívna len počas aktívneho nosenia smartphonu. Akonáhle je ale mobil vybratý do voľného prostredia, aplikácia umožní systému ju uspať a naopak. Druhá metóda využíva rozpoznanie aktivity človeka, ktorá sa nachádza v systéme. Pomocou tejto funkcie sme schopný určiť, kedy človek zmení svoj pohybový stav. Keď sa začne hýbať, dochádza k aktivácii služby, pokiaľ nečinne sedí, aplikácia je uspatá a šetrí batériu. Toto riešenie ale prináša jednu nevýhodu a to v zmysle, že aplikácia sa môže aktivovať až po 10 sekundách od počiatku pohybu, teda nemusí detekovať pád, ktorý nastal hneď na začiatku. Tieto nastavenia je možné upraviť v nastaveniach, pričom dokážu znížiť spotrebu aj niekoľko násobne.

Aplikácia hľadá piky magnitúdy akcelerácie nad 3 g. Pokiaľ sa taký objaví, dochádza k 1 sekunde pasívneho nahrávania. Následne ak sa v ďalších 4 sekundách objaví pik nad 3 g alebo priemerná akcelerácia presahuje nad  $10,5 \text{ m/s}^2$ , dochádza k potlačeniu detekcie. Táto priemerná aktivita bola zistená z meraní, pretože človek po danom pohybe bol vyzvaný, aby sa prestal hýbať. Tento filter je pomerne efektívny k zrušeniu detekcii pri chôdzi, behu a pod. Ak sa aktivita nepotvrdí, dochádza k overeniu, či to náhodou nebol pád samotného mobilu. Pád mobilu je symbolický poklesom hodnoty zrýchlenia pod  $2,5 \text{ m/s}^2$ , preto keď sa také zrýchlenie je obsiahnuté v meraní, tak je detekcia

zamietnutá. Najmenšia hodnota zrýchlenia bola v databáze 5,63 m/s<sup>2</sup>. Ak nie je potvrdený pád mobilu, dochádza k prepočtu parametrov v meraní a parametre sú následne posunuté neurónovej sieti. Pokiaľ dôjde k detekcii pádu, je vyvolaný alarm. Priebežné testy aplikácie ukazujú, že za vyvolaní 30 volaní na neurónovú sieť počas 1 h neustáleho behu je schopná vyčerpať 10 – 20 mAh v závislosti od spotreby akcelerometru, čo v kombinácii so spomenutými optimalizáciami nepredstavuje vysokú mieru narušenia denného využitia mobilu ani v zmysle výkonovej kapacity mobilu, pričom v priemere zaberá 20 MB v dočasnej pamäti.

Plný alarm je sprevádzaný s vibráciami, prepisu hlasitosti na maximum a zapnutím svetla. Po 60 s sú odoslané súradnice človeka pridanému kontaktu cez SMS a mail. Dnešné mobily sú vyrábane už dostatočne pevné, preto podmienky za pádu človeka vyústia maximálne v ojedinelých prípadoch v rozbitý displej, ale vnútro ostáva funkčné a schopné reagovať. Pre overenie správnej funkcionality je ešte nutné aplikáciu podrobiť testovaniu. Toho dosiahneme budúcou distribúciou cez Google Play programom pre interné testovanie, ktoré zabezpečí spätnú väzbu.



**Obrázok 2:** Ukážka aplikácie - naľavo hlavné menu, v strede alarm, napravo notifikácia služby na pozadí

## REFERENCIE

- [1] WHO. *Falls* [online]. 2018 [vid. 2018-09-25]. Dostupné z: <http://www.who.int/news-room/fact-sheets/detail/falls>
- [2] KIM, Tai-hoon, Akingbehin KIUMI a Haeng-kon KIM. *Evaluating AAL Systems Through Competitive Benchmarking - Indoor Localization and Tracking* [online]. 2011. ISBN 978-3-642-17640-1. Dostupné z: doi:10.1007/978-3-642-17641-8
- [3] JACOB, Jerene, Tam NGUYEN, Donald Y.C. LIE, Steven ZUPANCIC, J. BISHARA, Andrew DENTINO a Ron E. BANISTER. A fall detection study on the sensors placement location and a rule-based multi-thresholds algorithm using both accelerometer and gyroscopes. *IEEE International Conference on Fuzzy Systems* [online]. 2011, 666–671. Dostupné z: doi:10.1109/FUZZY.2011.6007744
- [4] FIGUEIREDO, Isabel N., Carlos LEAL, Luís PINTO, Jason BOLITO a André LEMOS. Exploring smartphone sensors for fall detection. *mUX: The Journal of Mobile User Experience* [online]. 2016, 5(1), 2. Dostupné z: doi:10.1186/s13678-016-0004-1