

Akustický detektor rozbití skla

Bc. Jaroslav Čmejla
doc. Ing. Zbyněk Koldovský, Ph.D.

Ústav informačních technologií a elektroniky

Abstract

This work deals with the recognition of acoustic events, namely, breaking of glass. The main outcome is a glass breaking detection algorithm. The proposed detection algorithm combines MFCC features and neural networks trained on simulated recordings. Several options and parameter settings and their impact on the detection capabilities were considered. Results achieved after various training strategies are compared. The final detection method is demonstrated.

Úvod

Úlohy rozpoznávání zvukových jevů výpočetními systémy jsou velice oblíbené a žádané. Pro jejich rozmanitost ale málokdy mají jednoduché a přímočaré řešení. Úspěšné řešení těchto úloh je předmětem dlouhodobého testování, hledání všemožných nástrojů a nových i starých metod.

Firma Jablotron Alarms a.s. se zabývá vývojem a prodejem zabezpečovací techniky. Jedním z jejich artiklů jsou akustické detektory rozbití skla. Firma již dodává funkční detektory rozbití skla, ale ty mírají problémy s detekováním speciálních skel (fóliované apod.). Bylo proto sestaveno zadání práce, jejímž výsledkem by měl být nový způsob rozpoznávání zvukových událostí. Od našeho návrhu byla očekávána vyšší variabilita při rozpoznávání různých druhů skel.

Při zpracování byla čerpána inspirace z již vyřešených úloh rozpoznávání řeči [1]. V našem návrhu bylo využito technologie umělých neuronových sítí [3, 4] a MFCC příznaků [1, 2].

Cíle práce

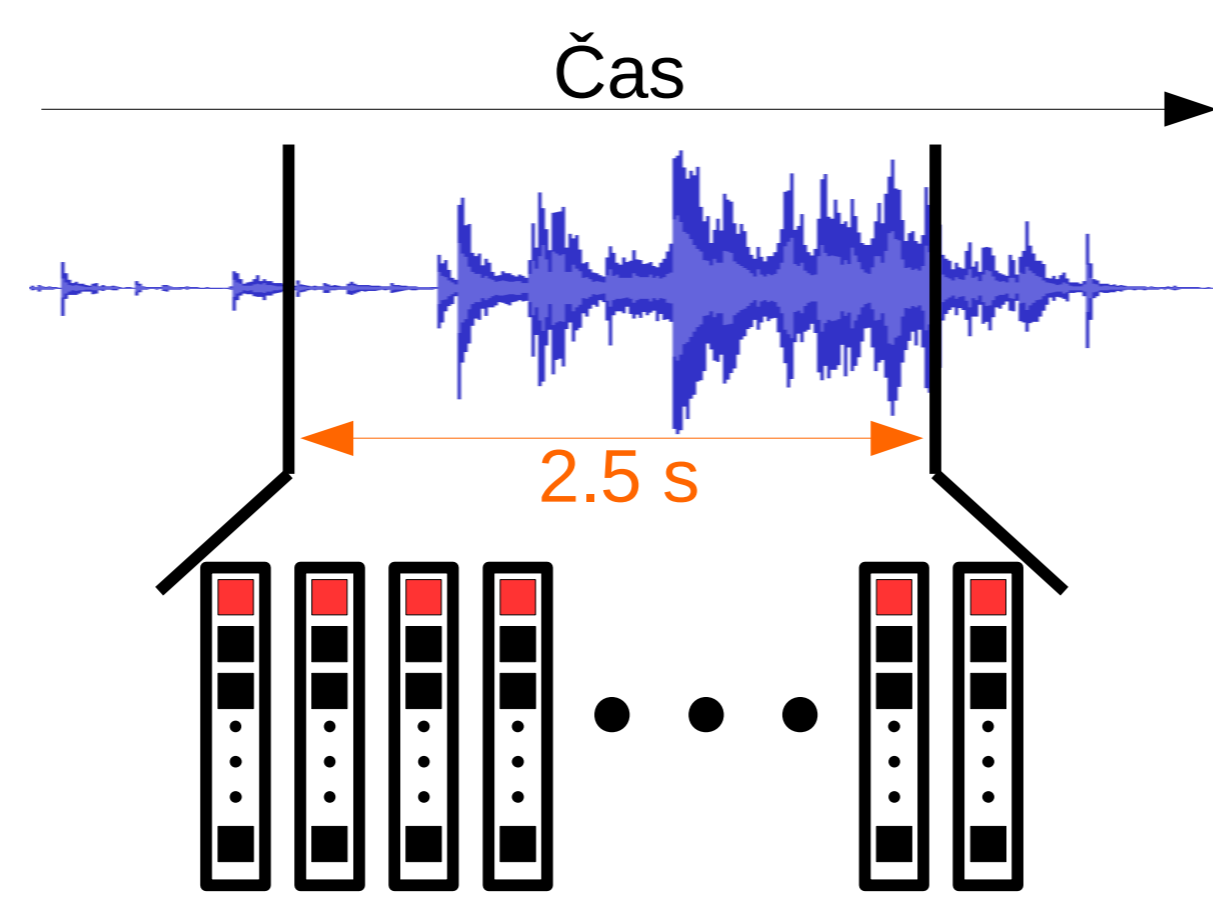
1. Provést analýzu záznamů zvuků rozbití skla. Použít vzorky poskytnuté firmou Jablotron Alarms a.s. a vzorky, které lze získat z internetových zdrojů. Pokusit se získat vlastní záznamy.
2. Navrhnout a optimalizovat způsob detekce zvukových událostí, které odpovídají rozbití určitého druhu skla. Rozhodnout, jaký druh příznakových vektorů použít a jaký použít model pro detekci.
3. Navrženou metodu otestovat na reálných datech. Vyhodnotit úspěšnost metody a její výpočetní náročnost.

Návrh detektoru

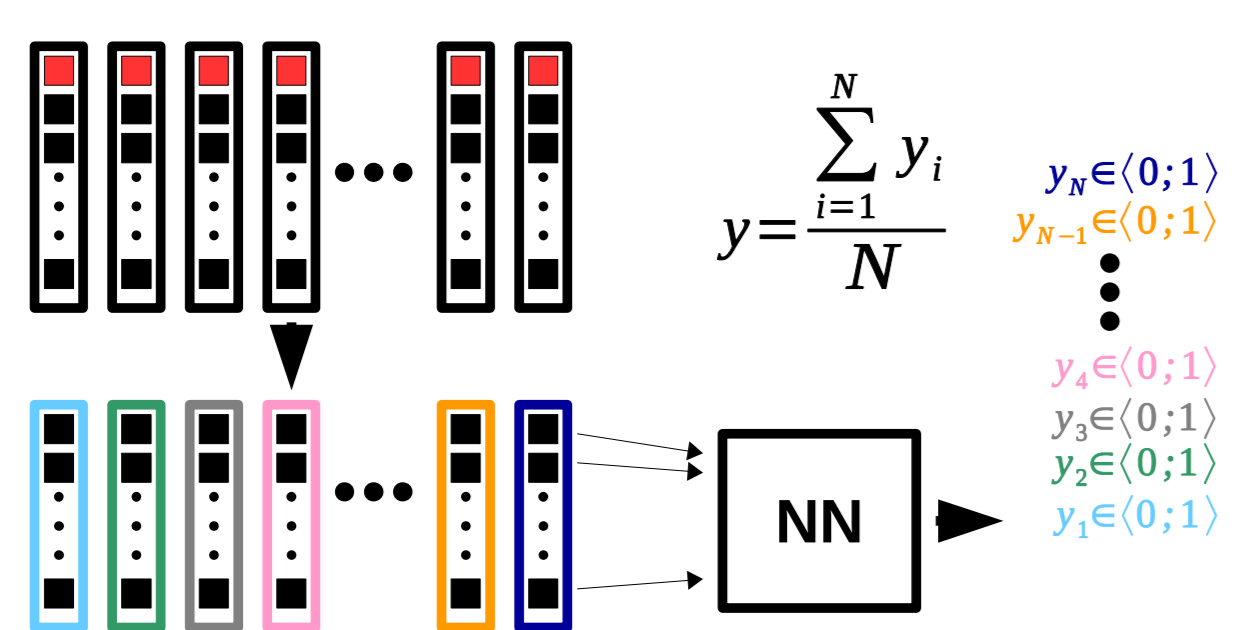
Pro zpracování bylo potřeba zajistit nahrávky zvuků rozbití skel. Nahrávky analyzovat a nalézt jejich typické vlastnosti. Autentičnost nalezených nahrávek byla ověřena porovnáním s vlastními záznamy.

Výsledný detektor rozpoznává signál ve 2,5 vteřinovém okně. Signál v rámci okna je segmentován po 800 vzorcích, detektor snímá 16kHz vzorkovací frekvencí. Z každého segmentu jsou extrahovány příznakové vektory (viz obrázek 1). Ty jsou dále upraveny a slouží jako vstup do klasifikátoru.

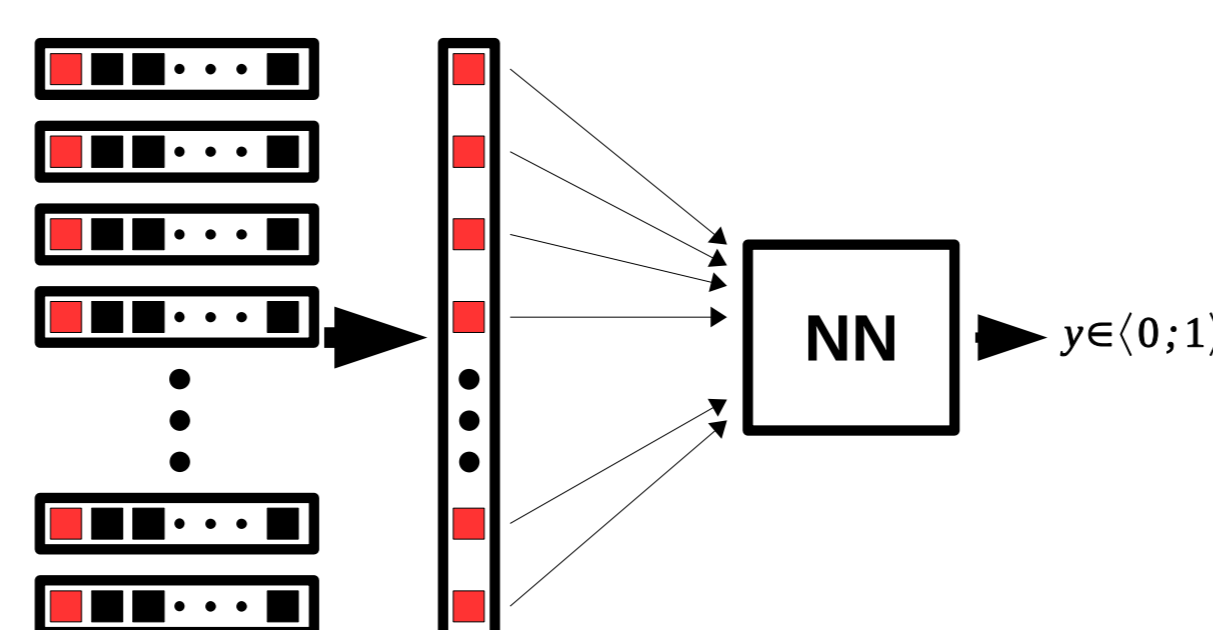
Detektor se skládá ze 2 klasifikátorů. První klasifikuje na základě vývoje energie v čase (viz obrázek 3). Druhý na základě spektrálního rozložení jednotlivých segmentů (viz obrázek 2). Výstupem z obou klasifikátorů je hodnota (v diagramech – y), která je určena pravděpodobností, s jakou dané charakteristiky odpovídají zvukům rozbití skla. V případě, že výstupy z obou částí nejednou splňují definovaná kritéria, tak detektor zareaguje spuštěním „alarmu“.



Obrázek 1: Extrakce příznakových vektorů z okna detektoru. Červeně jsou znázorněny příznaky odpovídající energii segmentu.



Obrázek 2: Klasifikátor spektrálního rozložení

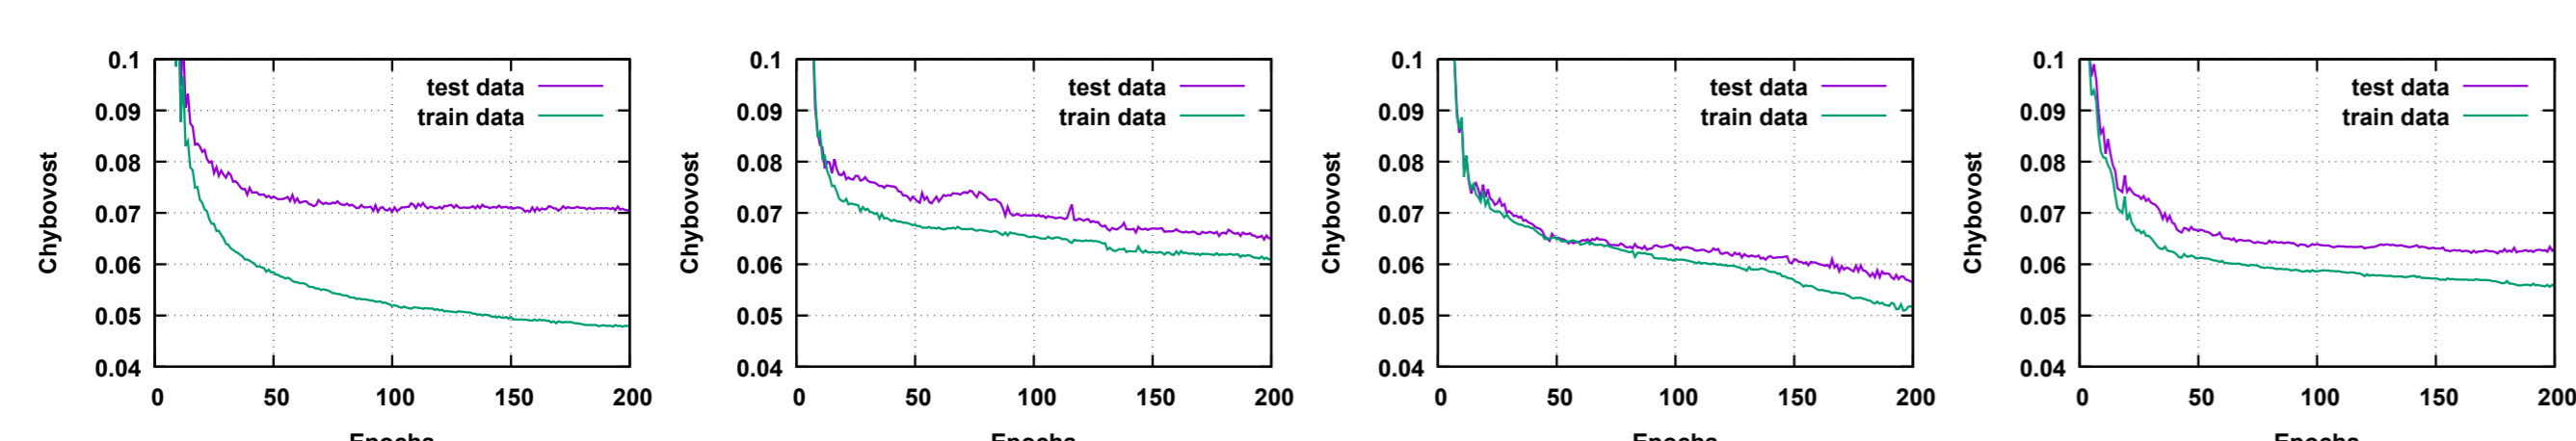


Obrázek 3: Klasifikátor dynamiky energie

Oba klasifikátory jsou tvořeny neuronovými sítěmi (v diagramech – NN). Neuronová síť pro klasifikaci dynamiky energie má 50 vstupních neuronů. Klasifikátor rozložení spektrálního rozložení má 11 vstupních neuronů. Výstupní vrstva má v obou případech 2 neurony (klasifikace: rozbití skla, ruchy).

Výsledky měření – trénování

Následující grafy (obrázek 4) ukazují výsledky trénování klasifikátoru spektrálního rozložení. Měření bylo prováděno pro různé struktury neuronových sítí a pro různá nastavení generátoru příznakových vektorů. Ve všech případech byla použita aktivační funkce \tanh . Trénovací data měla celkem 57m a 17s. Testovací data měla celkem 14m a 52s.




a: (64+64), melovské b: (8+4), melovské c: (8+4), lineární d: (8+4), kvadratické

Obrázek 4: Grafy a, b, c, d ukazují výsledky učení. V závorce je vždy uveden počet neuronů ve skrytých vrstvách. Informace za závorkou znázorňuje zvolené rozdělení banky filtrů. Příznakové vektory: MFCC, 11 koef., 20 filtrů.

Výsledky měření – testování

Práce detektoru je prezentována úspěšnou detekcí testovacího signálu (viz obrázek 5). Detektor snímá běžné zvuky z místnosti a v náhodných intervalech byly ručně spuštěny nahrávky zvuků rozbití skla. Tyto nahrávky nebyly součástí množiny dat, která sloužila k natrénování sítí.



Obrázek 5: Ukázka rozpoznávání testovacího zvukového signálu. Signál je znázorněn modrou spojnicí. Zelené sloupce v horní polovině grafu značí, kde se v signálu nacházejí zvuky rozbití skla. Červené sloupce v dolní polovině grafu značí, kde detektor rozpoznal zvuk rozbití skla. Nastavení kritérií: rozložení spektra – 0,85 (8+4 neuronů, lineární), vývoj energie – 0,80 (128 neuronů).

Během testovacího nahrávání bylo spuštěno deset nahrávek rozbití skla. Ve všech deseti případech detektor zareagoval spuštěním upozornění.

Výsledek dlouhodobého testování je znázorněn tabulkami 1 a 2. Testování probíhalo obdobně jako v případě testu, který je znázorněn obrázkem 5. Celkem bylo přehráno 30 nahrávek zvuků rozbití skla, 30 nahrávek ruchů (kavárna, rušná pozemní komunikace, vlaková stanice, bílé šumy). Zvuky ticha (běžné zvuky v místnosti) mezi nahrávkami byly považovány za ruchy.

Výsledek rozpoznávání	Positivní	Negativní	Výsledek rozpoznávání	Positivní	Negativní
Rozbití skla	22	8	Rozbití skla	29	1
Ruchy	5	85	Ruchy	8	82

Tabulka 1: Nastavení kritérií: rozložení spektra – 0,85 (8+4 neuronů, lineární), vývoj energie – 0,80 (128 neuronů).

Tabulka 2: Nastavení kritérií: rozložení spektra – 0,70 (8+4 neuronů, lineární), vývoj energie – 0,90 (128 neuronů). Nižší hodnota kritéria pro klasifikaci spektra simuluje zkrácení okna detektoru.

Závěr

Hlavním výstupem práce je funkční návrh detektoru rozbití skla. Spolu s návrhem jsou v práci uvedeny výsledky měření pro trénování jednotlivých částí detektoru a jejich srovnání včetně uvedených komentářů. Byly nalezeny vyhovující příznakové vektory a byla provedena jejich optimalizace.

Vedlejším výstupem práce je naprogramovaný software, který má ilustrovat použití námi vytvořeného návrhu v praxi.

Některé dílčí části, hlavně tedy ukázka funkčního detektoru, byly prezentovány ve firmě Jablotron Alarms a.s.

Návrhy vylepšení

Během práce na detektoru byla objevena řada možností, které se již nestihly realizovat. Jednou z nich je využití neuronových sítí s učení bez učitele. Neuronová síť se při tomto učení snaží najít závislosti ve vstupních vzorech a podle toho je třídí do shluků. Tyto shluky poté tvoří klasifikační skupiny a je podle nich definován výstup. Mohlo by se ukázat, že se zvuk rozbití skla dá rozdělit na více sobě jdoucích částí, které by bylo možné detekovat postupně. Na tomto základě by mohl být vytvořen konečný automat, který by po postupné detekci všech částí skončil v koncovém stavu a byl by spuštěn alarm. Na podobném principu pracují systémy zpracování řeči (použití HMM) [1].

Další zvýšení úspěšnosti by se mohlo odvíjet s využitím vyšší vzorkovací frekvence (nebylo provedeno pro nedostatečné množství dat).

Reference

- [1] NOUZA, Jan, Zbyněk KOLDOVSKÝ a Robert VÍCH (eds.). *Řeč a počítač: principy hlasové komunikace, úlohy, metody a aplikace: sborník článků*. Liberec: Technická univerzita v Liberci, 2009. ISBN 978-80-7372-548-8.
- [2] HUANG, Xuedong, Alex ACERO a Hsiao-Wuen HON. *Spoken language processing: a guide to theory, algorithm and system development*. Upper Saddle River: Prentice Hall, 2001. ISBN 0-13-022616-5.
- [3] TUČKOVÁ, Jana. *Vybrané aplikace umělých neuronových sítí při zpracování signálů*. Vyd. 1. Praha: České vysoké učení technické v Praze, 2009. ISBN 978-80-01-04229-8.
- [4] HAYKIN, Simon S. *Neural networks and learning machines*. 3rd ed. New York: Prentice Hall, c2009. ISBN 0131471392.

Kontakty

Bc. Jaroslav Čmejla – jaroslav.cmejla@tul.cz
doc. Ing. Zbyněk Koldovský, Ph.D. – zbynek.koldovsky@tul.cz

Tato práce byla podpořena firmou Jablotron Alarms a.s.
Tato práce byla podpořena z projektu Studentské grantové soutěže (SGS) na Technické univerzitě v Liberci v roce 2016.