

**ČESKÉ VYSOKÉ
UČENÍ TECHNICKÉ
V PRAZE**

FAKULTA ELEKTROTECHNICKÁ



**ZÁVĚREČNÁ
PRÁCE**

2021

**JAKUB
ŠPAŇÁR**

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Špaňár** Jméno: **Jakub** Osobní číslo: **474522**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra teorie obvodů**
Studijní program: **Lékařská elektronika a bioinformatika**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

On-line aplikace hodnocení vývojové dysfázie

Název bakalářské práce anglicky:

Online assessment of developmental dysphasia

Pokyny pro vypracování:

Seznamte se s problematikou vývojové dysfázie u dětí a na základě experimentů popsaných v [1] navrhnete a realizujete systém pro hodnocení vývojové dysfázie v reálném čase.
Pro vyhodnocení možností systému a jeho klinického využití použijte již dříve vytvořených databází dětských promluv v [1].

Seznam doporučené literatury:

- [1] Ovčáří-Nejepsová, M.: Analýza promluv dětí s vývojovou dysfázií. Dizertační práce, ČVUT, FEL, 2016.
[2] Psutka, J. Komunikace s počítačem mluvenou řečí. Academia. 1995.

Jméno a pracoviště vedoucí(ho) bakalářské práce:

prof. Ing. Roman Čmejla, CSc., katedra teorie obvodů FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **11.02.2021**

Termín odevzdání bakalářské práce: **21.05.2021**

Platnost zadání bakalářské práce: **30.09.2022**

prof. Ing. Roman Čmejla, CSc.
podpis vedoucí(ho) práce

doc. Ing. Radoslav Bortel, Ph.D.
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Student bere na vědomí, že je povinen vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací.
Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studenta

Čestné prohlášení

Prohlašuji, že jsem zadanou bakalářskou práci vypracoval samostatně, a že jsem uvedl veškeré použité informační zdroje v souladu s metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze, dne 20. května 2021

Jakub Špaňár

Poděkování

Mé upřímné a velké poděkování patří prof. Ing. Romanu Čmejlovi a Ing. Janu Vimrovi za odborné rady, ochotu a vstřícný přístup během vypracování této práce.

Abstrakt

Tato práce se zabývá tvorbou online aplikace pro hodnocení vývojové dysfázie. Vývojová dysfázie je současné době nejrozšířenější porucha řeči u dětí. Diagnostikovat vývojovou dysfázii mohou jen zkušení odborníci. S funkční online aplikací by se proces diagnostiky dětí s vývojovou dysfázií urychlil a zefektivnil.

Hlavním cílem bylo proto vytvoření aplikace, která by byla schopna rozlišovat zdravé nahrávky od nezdravých nahrávek s dostatečně velkou přesností. Cílem bylo otestovat možnosti zpracování nahrávek, způsob jejich porovnání a navržení úspěšného rozhodovacího systému pro nahrávky. Následně byly nejúspěšnější metody použity v samostatně spustitelné aplikaci.

Jako rozhodné parametry byly použity tyto: energie, délka signálu a také hodnoty z metod MFCC a LPC. Tyto hodnoty pro MFCC a LPC byly získány pomocnou metodou DTW. Největší přesnosti se dosahuje při použití všech čtyř parametrů pro binární SVM klasifikaci. Přesnost klasifikace se pohybuje od 84 % do 97 % v závislosti na druhu promluvy. S touto přesností byla vytvořena aplikace pro klasifikaci promluv.

Klíčová slova: DTW, MFCC, LPC, vývojová dysfázie

Vedoucí práce: Roman Čmejla

Abstract

This work deals with the creation of an online application for the evaluation of developmental dysphasia. Developmental dysphasia is currently the most common speech disorder in children. Developmental dysphasia can only be diagnosed by experienced professionals. With a functional online application, the process of diagnosing children with developmental dysphasia would be speeded up and made more efficient.

The main goal was therefore to create an application that would be able to distinguish healthy recordings from unhealthy recordings with sufficient accuracy. The aim was to test the possibilities of processing recordings, how to compare them and to design a successful decision system for recordings. Subsequently, the most successful methods were used in a stand-alone executable application.

The following were used as decisive parameters: energy, signal length as well as values from the MFCC and LPC methods. These values for MFCC and LPC were obtained using the DTW auxiliary method. The highest accuracy is achieved using all four parameters for binary SVM classification. The accuracy of the classification ranges from 84 % to 97 % depending on the type of speech. An application for speech classification was created with this accuracy.

Key words: DTW, MFCC, LPC, developmental dysphasia

Supervisor: Roman Čmejla

Title: Online assessment of developmental dysphasia

1	ÚVOD	9
2	ŘEČ	10
2.1	VÝVOJ ŘEČI	10
2.2	PATOLOGIE ŘEČI	10
2.3	VÝVOJOVÁ DYSFÁZIE	11
2.3.1	Vznik	11
2.3.2	Terapie	11
2.4	ZDROJ DAT: DATABÁZE PROMLUV	11
3	ZPRACOVÁNÍ	13
3.1	PARAMETRIZACE	13
3.1.1	Délka	13
3.1.2	Energie	13
3.1.3	LPC	14
3.1.3.1	Výpočet parametru LPC	15
3.1.4	MFCC	15
3.1.4.1	Cepstrum	15
3.1.4.2	Banka filtrů	16
3.1.4.3	Výpočet parametru MFCC	17
3.2	POROVNÁNÍ KOEFICIENTŮ	17
3.2.1	DTW	17
3.2.1.1	Implementace DTW algoritmu	17
4	KLASIFIKÁTORY	19
4.1	BAYESOVSKÁ KLASIFIKACE	19
4.1.1	MLE	19
4.1.2	Implementace Bayes klasifikátoru	20
4.2	SVM KLASIFIKÁTOR	20
4.2.1	SVM klasifikátor s jádrem	21
4.2.2	Jádro RBF	21
4.2.3	Implementace SVM klasifikátoru	21
5	PŘESNOST KLASIFIKACE	23
5.1	VÝBĚR REFERENČNÍHO PROMLUVY/VZORKU ŘEČI	23
5.2	JEDNODIMENZIONÁLNÍ KLASIFIKACE	23
5.2.1	Výsledky jednodimenzionální klasifikace	27
5.3	VÍCEDIMENZIONÁLNÍ KLASIFIKACE	28
5.3.1	Výsledky vícedimenzionální klasifikace	29
5.4	ZHODNOCENÍ	29
6	APLIKACE	31
6.1	VÝBĚR PROGRAMOVACÍHO JAZYKA	31
6.1.1	C#	31
6.1.2	Matlab	31
6.1.3	Python	31
6.2	IMPLEMENTACE APLIKACE	32
6.2.1	Popis	32
6.2.2	Algoritmus	33
6.2.3	Uživatelské rozhraní	34
6.2.4	Výsledky	35
6.2.5	Závislosti	37
7	ZÁVĚR	38
8	LITERATURA	39
9	PŘÍLOHY	41

1 Úvod

Vývojová dysfázie je porucha řeči, která se začíná projevovat už v dětském věku. Je to porucha, kterou trpí především chlapci, a je jedna z nejrozšířenějších v dnešní době. Děti s danou poruchou mají problém s mluvením, s gramatikou a se slovní zásobou. Mezi symptomy patří nesprávné určování časových posloupností, problémy s prostorovou orientací, narušení krátkodobé paměti či porucha motorických funkcí. Pro úspěšnou léčbu je důležité, aby detekce vývojové dysfázie proběhla co nejdříve.

Diagnostika této poruchy je závislá na subjektivním hodnocení odborníků. Diagnostikovaný jedinec musí projít řadou dalších testů jako EEG či vyšetření pomocí CT. Z nedostatku standardizovaných testů je zde riziko záměny poruchy za jinou.

Špatná diagnostika může zavinit zanedbání poruchy, což vede ke zhoršujícím se příznakům. Proto je důležité poruchu diagnostikovat včas a začít správnou léčbu. Správná léčba dětí postižených touto poruchou vede posléze ke zlepšení stavu. I přes rozšířenou incidenci poruchy se touto problematikou zabývá málo odborných prací.

2 Řeč

Jelikož je komunikace základním pilířem naší civilizace vede vývojová dysfázie k závažným psychosociálním následkům. Narušení vývoje řeči zkoumá určitá část logopedie. (Smolík, 2009)

2.1 Vývoj řeči

Jako narušený vývoj řeči se definuje strukturální a systémové narušení jedné, několika, případně i všech oblastí vývoje řeči vzhledem k chronologickému věku dítěte. Při vývoji řeči každé dítě je jinak schopné a zároveň je ovlivněno mnoha faktory, proto může docházet k retardaci či akceleraci vývoje. Mezi hlavní faktory vývoje řeči patří intelekt, adekvátní sociální prostředí, fyziologické možnosti dítěte jako sluch, zrak, artikulační a fonační ústrojí a pod. (Ovčáří, 2016)

Do prvního roku je dítě ve stavu fyziologické nemluvnosti. Jedná se o naprosto přirozený stav, během něhož dítě prochází přípravnými stádii vývoje řeči a osvojuje si návyky důležité pro vlastní vývoj řeči. V tomto období se dítě postupně naučí křičet, broukat, žvatlat a porozumět řeči v závislosti na melodii, mimiky a barvy hlasu. Poté nastává období, ve kterém se dítě postupně začíná učit mluvit. V případě, že dítě nemá žádnou poruchu řeči, mělo by mezi druhým a třetím rokem být schopno napodobovat promluvu, používat přídavná jména a slovesa, odpovídat na otázky ano a ne a mluvit ve větách. V případě, že dítě je zdravé, nemá postiženou motoriku či řečové orgány, slyší, jeho duševní vývoj je normální a dítě reaguje na stimulované podněty, a přesto nemluví v dostatečném měřítku, nastává prodloužená fyziologická nemluvnost. Opožděný vývoj řeči diagnostikujeme, když dítě nemluví nebo mluví méně než ostatní děti stejného věku i po třetím roce života. Po čtvrtém roce by promluva neměla obsahovat dysgramatismus. Nemluvnosti ani po čtvrtém roce života je obvykle příznakem patologického narušení, což také může zahrnovat vývojovou dysfázii. (Mlynářová, 2007, Ovčáří, 2016)

Ukončení vývoje řeči u zdravého dítěte je obvykle mezi pátým a šestým rokem. Dítě je poté schopné souvislého vypravování děje a používat souvětí. Následně nastává intelektualizace řeči neboli rozšiřování slovní zásoby, rozlišování abstraktních a konkrétních pojmů, zpřesňování významů slov a pod. (Ovčáří, 2016)

2.2 Patologie řeči

Mezi příčiny opožděného vývoje řeči patří vrozený syndrom, sluchová či mluvící vada a vývojová dysfázie. Muže nastat např.: narušení plynulosti řeči (například koktavost a breptavost), narušení článkování řeči (například patlavost) a symptomatické poruchy řeči. Poruchy, které ovlivňují nejen řeč, jsou především organické poruchy. Mezi ty patří afázie či syndrom demence. V případě ztráty řeči bez fyziologického poškození, mluvíme o získané psychogenní nemluvnosti. Jedná se o poruchu způsobenou psychotickým onemocněním či určitým závažným zážitkem. (Ovčáří, 2016)

2.3 Vývojová dysfázie

Vývojová dysfázie je porucha zasahující hlavně jazykovou oblast. Vývojová dysfázie často vede nejen ke zhoršení schopnosti komunikovat, ale má souvislost i s problémy s učením, chováním a způsobuje emoční i sociální problémy. K tomu se někdy přidávají i mírné nedostatky kognitivních funkcí jako například špatná pozornost, nedostatečná rychlost zpracování informace, nedostatky v pracovní paměti. (Matiasovitsová, 2019)

V dnešní době chápeme pojem vývojová dysfázie jako specifickou poruchu při vývoji řeči se sníženou schopností se naučit verbální komunikaci i přes příznivé podmínky pro rozvoj řeči. Vývojová dysfázie se řadí do skupiny centrálních poruch komunikačních schopností. Vývojová dysfázie je vrozená či je poruchou kvůli nepříznivému zásahu do vývoje řeči. Vývojová dysfázie je diagnostikována tehdy, pokud má nonverbální inteligenci, sluchovou a orální motoriku v pořádku, bez vážné neurologické poruchy. A není zde vliv některých promlův autistického spektra. (Matiasovitsová, 2019, Ovčář, 2016)

2.3.1 Vznik

Vznik vývojové dysfázie není zcela jasný. Jde o poruchu centrálního zpracování řečového signálu. Výzkum této poruchy se zaměřuje na genetický původ této nemoci a využívá studia dvojčat. Výsledky naznačují vliv dědičnosti hlavně u mužských potomků, přičemž vývojová dysfázie se vyskytuje u chlapců čtyřikrát více než u dívek. (Matiasovitsová, 2019, Ovčář, 2016)

2.3.2 Terapie

Léčba či raději více používané slovo terapie se zaměřuje na překonání, zmírnění či odstranění symptomů a zmírnění následků postižení. Na terapii dítěte by se měla podílet skupina odborníků. Především se jedná o spolupráci klinického logopeda a klinického psychologa. (Rybáčková, 2013)

Úspěšná terapie se také neobejde bez spolupráce rodiny. Rodina či blízcí jsou ti, kteří by si měli dané poruchy včas všimnout a následně vyhledat odbornou pomoc. Včasným rozpoznáním vývojové dysfázie lze zmírnit či úplně odstranit projevy poruchy. Zároveň hlavním faktorem terapie je řádné plnění a procvičování cviků stanovených odborníkem. Je též nutný dobrý řečový vzor. Terapie není účinná po pár sezeních, proto je trpělivost pacienta i jeho rodiny nezbytná. Terapie je dlouhodobý proces. Jde o rozvoj vlastní řečové tvorby slov, slovní zásoby, obsahové i formální stránky řeči, ale také i motoriky, sluchového a zrakového vnímání, paměti, myšlení apod. (Rybáčková, 2013, Ovčář, 2016)

2.4 Zdroj dat: databáze promlův

Práce se věnuje zpracování vzorků řeči dětí. A to jak zdravých, tak i trpících vývojovou dysfázií. Tyto vzorky/promlůvy dětí byly pořízeny Ph.D. M. Ovčář, a jsou částí její disertační práce (Ovčář, 2016). Databáze promlův obsahuje vzorky od více než 200 dětí. Sto dětí patří do zdravé skupiny a zbylé dětí do skupiny nezdravé. Nezdravá skupina se dále dělila do tří kategorií podle vážnosti postižení. Promlůvy obsahovaly různé vzorky slov. Byly to slova: babička, čokoláda, fotbalista, hamburger, ježek, košile, máma, popelnice, Rákosníček,

ředkvička, silnice, sluníčko, ucho a velryba. Každá nahrávka byla předem zařazena do zdravé či nezdravé skupiny. Informace o stupni postižení nezdravé promluvy byla také k dispozici.

3 Zpracování

Cílem práce bylo vytvořit program, který bude schopen rozlišit zdravé a nezdravé vzorky řeči. Byly porovnány mezi sebou vždy dva vzorky řeči. Jeden byl určen jako referenční, podle kterého byl druhý vzorek posuzován je-li zdravý. Tato kapitola je věnována způsobům a metodám, které byly použity.

3.1 Parametrizace

Důležité bylo znát míru rozdílu vzorků. Vzorky (chcete-li nahrávky) jsou zvukový signál, na které bylo nahlíženo jako na jednodimenzionální řadu. Prověřování každého prvku s jiným je nejen časově náročné ale i nepraktické. Proto byla použita parametrizace signálu. Parametrizace nepopisuje signál jako takový ale jen jeden z jeho parametrů. Parametrů signálu je mnoho jako např.: amplituda, frekvence, tvar atd. (Weik and SpringerLink, 2006). V práci byly použity různé parametrizace signálů. Následně byly vybrány ty nejefektivnější parametry.

Nakonec byly využity následující čtyři parametrů - délka signálu, komutativní vzdálenost mezi energiemi, LPC koeficienty a MFC koeficienty referenční a testované promluvy. Koeficienty LPC a MFC jsou nejčastěji používané techniky extrakce pro identifikaci mluvčího (A and Dhonde, 2015).

3.1.1 Délka

Na rozdíl od ostatních metod parametrizace použitých v této práci, délka signálu je funkční parametr a není potřeba ho porovnávat s referenční nahrávkou. Jako parametr délky byl použit počet diskretních hodnot signálu.

3.1.2 Energie

Energie signálu je definovaná jako suma kvadrátů absolutních hodnot signálu. Při zpracovávání signálu bylo zacházeno se signálem v diskretním čase. Vzorec pro výpočet energie je poté definován podle rovnice (3.1).

$$E = \sum_{i=0}^{n-1} x[i]^2 \quad (3.1)$$

E – energie signálu

n – počet diskretních hodnot

x – signál v diskretním čase

Pomocí vzorce (3.1) se vypočítá energie celého signálu. Tato hodnota je užitečná, ale nikoliv pro porovnání signálů.

Vzorec (3.1) byl upraven do formy (3.2), pro počítání energii po segmentech.

$$E_j = \sum_{i=(j-1)*d}^{\min(j*d; n-1)} x[i]^2 \quad (3.2)$$

E_j – energie segmentu signálu
 j – počet segmentů v signálu
 d – délka jednoho segmentu

Použitím vzorce (3.2) bylo vytvořené pole energií segmentů. Pole energie referenční a konkrétní testované promluvy byly poté porovnány metodou DTW. Tímto způsobem byla vypočtena jedna hodnota, která dále byla použita jako parametr pro klasifikaci.

3.1.3 LPC

Linear predictive coding (LPC) je metoda pro časovou kompresi signálu. Používá se pro syntézu a rozpoznávání řeči. LPC patří do třídy kodéru hlasu, který se ale nesnaží vytvořit nový signál podobný originálnímu, ale místo toho se snaží vytvořit syntetický hlas se správnými spektrálními vlastnostmi. Obecně LPC analyzuje signál promluvy odhadem původní frekvence. (Gray, 2009, Yap et al.)

Termín „linear predictive“ v názvu metody odkazuje na mechanismus používání lineární kombinaci minulých časových vzorků k aproximaci či predikci nastávajícího vzorku. Pro lineární kombinaci je každý vzorek vynásoben skalárem tak zvaným LPC koeficientem. Tento druh predikce je považován za operaci v diskretním čase transformací lineárního systému. (2003)

Nový prvek v signálu použitím LPC koeficientů je definován v rovnici (3.3).

$$x_n = \sum_{i=1}^p a_i x_{n-i} \quad (3.3)$$

p – počet LPC koeficientů
 a_i – LPC koeficient
 x – signál vytvořen LPC koeficienty

Chyba pro daný vzorek (3.4).

$$e_n = x'_n - x_n \quad (3.4)$$

x' - původní signál

Součet kvadrátů chyb (3.5)

$$E = \sum_{i=1}^N e_i^2 \quad (3.5)$$

E – součet kvadrátů chyb

N – počet diskretních vzorků

3.1.3.1 Výpočet parametru LPC

Metoda výpočtu LPC je založena na lineárním programování. Jedná se o optimalizaci problému maximalizací či minimalizací proměnné na soustavách lineárních nerovnic. V tomto případě se snažíme minimalizovat sumu čtvercových rozdílů mezi skutečnými prvky signálu a lineárně předpovídanými prvky.

Podobně jako pro parametr energie je výpočet LPC koeficientů použit na segmenty signálu. Pro každý segment byl vypočten stejný počet koeficientů. Získané dvoudimenzionální pole s délkou určenou počtem segmentů mělo v každém prvku stejný počet LPC koeficientů. Pole testovaného vzorku a referenčního vzorku bylo porovnáno metodou DTW. Výsledek byl použit jako parametr.

Přesnost a časová náročnost počítání LPC koeficientů je závislá počtu koeficientů. Obvykle se používá 8 nebo 13 koeficientů. Předem nebylo zřejmé, který počet vyhovuje více, a proto byly otestovány obě možnosti a ověřeny jejich přesnosti. Výhodnější počet koeficientů byl poté použit v aplikaci.

3.1.4 MFCC


Mel frequency cepstrum coefficient (MFCC) je výpočetní technika, která se stala standardem v systému rozpoznávání hlasu. Jedná se o vysoce účinnou metodu při rozpoznávání zvuků a pro modifikaci intenzity a frekvenci obsahu zvukového signálu. MFCC je populární také díky efektivním výpočetním schémátům a jeho robustnosti v přítomnosti různých šumů. (Sahidullah and Saha, 2012)

3.1.4.1 Cepstrum

V metodě se používá cepstrální reprezentace zvukového signálu. Cepstrum vzniká jako výkonové spektrum logaritmu výkonového spektra. Původní použití cepstra bylo zaměřeno na analýzu seismických signálů, kde se ukázalo, že je výrazně lepší než autokorelační funkce. Techniky cepstra jsou výhodné pro analýzu dat, jenž obsahují ozvěny či dozvuky. Obvykle se cepstrum využívá k určení časového příchodu hlavní vlny s její ozvěnou a relativní amplitudou. Zpracování cepstra může určit vlnovou křivku. (Childers et al., 1977, Randall, 2017)


3.1.4.2 Banka filtrů

Pro přesnější napodobení vnímání lidského ucha se v metodě využívaná Mel stupnice. Při modelu vnímání řeči bylo zjištěno, že lidské vnímání řeči je nelineární v normální stupnici ale lineární v Mel stupnici. Tím, že reprezentace je v lineárním měřítku, je výhodné pro algoritmy při zpracování řeči. (Arun Sankar and Sathidevi, 2020)



Obr. 1: Porovnání Mel a frekvenční stupnice

Při počítání MFCC je zapotřebí spektrum řádně filtrovat. Filtrování proběhne pomocí banky filtrů. Filtry jsou trojúhelníkového tvaru a jsou rozloženy lineárně pomocí Mel stupnice. (Zheng et al., 2001)



Obr. 2: Lineárně rozmístěné trojúhelníkové filtry podle mel stupnice na lineární frekvenční stupnici

3.1.4.3 Výpočet parametru MFCC

Výpočetní technika MFCC probíhá v několika krocích. Nejprve se použije Fourierovu transformaci na část signálu za použití váhovacího Hammingového okna. Výkonové spektrum vzniklé po Fourierově transformaci je filtrováno trojúhelníkovými filtry rozdělenými pomocí Mel stupnice. Výstup pro každý filtr byl zlogaritmován a transformován pomocí cosínovy transformace. Výsledné koeficienty jsou poté amplitudy výsledného cepstra. (Sahidullah and Saha, 2012, A and Dhonde, 2015)

Stejně jako v předešlých způsobech parametrizace byly opět MFC koeficienty vypočteny pro segmenty signálu nikoli pro celý signál. Výsledkem počítání MFCC bylo podobně jako v LPC vícedimenzionální pole o délce podle počtu segmentů. Každý prvek měl daný počet koeficientů. Parametr MFCC byl vypočítán DTW rozdílem polí vzorku testovacího a referenčního.

Počet MFC koeficientů je variantně 8 a 13. Opět byly vypočítány výsledky pro obě varianty.

3.2 Porovnání koeficientů

Pro získání parametrů LPC, MFCC a energie je za potřebí najít metodu, která porovná vypočtené koeficienty mezi dvěma poli a nějakým způsobem kvantuje jejich rozdíl. V případě LPC a MFCC se počet koeficientů testuje pro 8 a 13. Na energii se dá nahlížet jako na jeden koeficient. Hledaná metoda měla být schopna vypočítat absolutní rozdíl mezi segmenty s jakýmkoli počtem koeficientů. Za tímto účelem byl použit DTW algoritmus.

3.2.1 DTW

Dynamic time warping (DTW) je známý algoritmus pro rozpoznávání znaků. Metoda původně vycházela z rozpoznávání řeči a její aplikaci na chromatografii jako metodu chromatografického porovnávání špiček. DTW umožňuje rozhodnout o míře podobnosti i pro signály o různých délkách. Vzdálenost DTW dosahuje optimální nelineární zarovnání párů z jednoho a druhého signálu pomocí minimalizace cen daných párů. (Stasiak et al., 2019, Vial et al., 2009)

3.2.1.1 Implementace DTW algoritmu

Algoritmus DTW je jednoduchý ale časově náročnější. Při porovnávání dvou polí o délce M a N je časová náročnost $O(M*N)$. Algoritmus počítá matici o velikosti M a N . Následně mezi každým prvkem z jednoho pole a každým prvkem z druhého pole se spočítá Euklidova vzdálenost v prostoru koeficientů. Prvek pole reprezentuje jeden segment signálu pomocí 1, 8 či 13 koeficientů. Vypočítaná vzdálenost se zapíše do tabulky do odpovídající pozice. Tato vzdálenost byla využita jako cena mezi danými prvky. Po sestavení kompletní matice se nachází optimální cesta s nejmenší cenou od počátku matice $[1, 1]$ do jejího konce $[M, N]$. Výsledná minimální cena je kumulovaná vzdálenost polí. (Stasiak et al., 2019, Ovčáří, 2016)

V této práci byla implementace hledání optimální cesty a tvorba matice zkombinována. Nejprve byla porovnána vzdálenost prvních segmentů obou signálů a vynesena do tabulky na pozici $[1, 1]$. Poté byla postupně porovnávána vzdálenost prvního segmentu jednoho signálu se

všemi segmenty druhého signálu a opačně. Pro každý odpovídající bod $[1, i]$; $i = 1, 2, \dots, N$ (či $[j, 1]$; $j = 1, 2, \dots, M$) bylo do tabulky zapsáno součet vypočítané vzdálenosti a bodu $[1, i-1]$ (či $[j-1, 1]$). Aby byla tabulka dokončena pro všechny body $[j, i]$; $i = 2, 3, \dots, N$; $j = 2, 3, \dots, M$; byl použit stejný způsob ale místo předem určitého bodu se ke vzdálenosti přičítalo minimum z bodů $[j, i-1]$, $[j-1, i-1]$, $[j-1, i]$. Tímto způsobem byla nejmenší kumulovaná vzdálenost od počátku k jakémukoli bodu dána. Bod $[M, N]$ udává celkovou nejmenší komutativní vzdálenost pro dané pole.

4 Klasifikátory

Pro fungující program bylo nutno najít efektivní klasifikátory.

4.1 Bayesovská klasifikace

Naive Bayes algorithm neboli Bayesovská klasifikace je proces, který odhaduje pravděpodobnost nového pozorování do předem definované kategorie podle modelu pravděpodobnosti definované podle Bayesovské teorie. Způsob rozhodování hodnotí pravděpodobnost ze všech kategorií. V případě, že všechny proměnné, které popisují tréninková data jsou nezávislá a každá z nich přispívá stejným dílem ke klasifikaci, byla vyvinuta jednoduchá metoda Bayesovské klasifikace známé jako naive Bayes algorithm. V rámci každé třídy jsou pravděpodobnosti rozděleny pomocí normálního rozdělení pravděpodobností. (Tsangaratos and Ilia, 2016)

Ze začátku práce nebylo zřejmé, jestli Bayes klasifikátor bude použit i pro více dimenzionální data. Proto byl použit vzorec pro více dimenzionální normálové rozdělení (4.1). Normálové rozdělení se chová ve vyšších dimenzích stejně. Hodnoty pravděpodobnosti jsou všude nezáporné a integrál přes celý prostor je roven 1.

Funkce hustoty pravděpodobnosti pro více dimenze je dána rovnicí (4.1)(Prince, 2012):

$$f(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^2 |\Sigma|}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x}-\boldsymbol{\mu})} \quad (4.1)$$

\mathbf{x} – reálný vektor

Σ – rozptyl

$\boldsymbol{\mu}$ – střední hodnota rozdělení

4.1.1 MLE

V případě, že normálové rozdělení není známé, je nejprve nutné dané rozdělení specifikovat. Podle vzorce (4.1) je pro normálové rozdělení zapotřebí dvou parametrů $\boldsymbol{\mu}$ a Σ . Pro tento účel je metoda maximum likelihood estimation (MLE) neboli metoda maximální věrohodnosti, která dokáže parametry $\boldsymbol{\mu}$ a Σ vypočítat.

Už podle jména lze předpokládat, že metoda se snaží najít takové parametry, kde by byly pravděpodobnosti dostupných dat co největší. Za předpokladu, že všechny vzorky z dat jsou na sobě nezávislé, je pak celková funkce pro věrohodnost určena jako součin pravděpodobností každého bodu. (Prince, 2012)

Po použití MLE na rovnici (4.1) vzniknou rovnice (4.2) a (4.3) pro μ a Σ :

$$\boldsymbol{\mu} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (4.2)$$

$$\boldsymbol{\Sigma} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T \quad (4.3)$$

4.1.2 Implementace Bayes klasifikátoru

Bayes klasifikátor je jednoduchý klasifikátor. Tedy jeho naimplementování nebylo problematické. Nejdříve byla data rozdělena do předem určených tříd. Pomocí metody MLE byly spočítány parametry střední hodnoty a rozptylu pro každou ze tříd. Tímto způsobem byly získány normální distribuce pravděpodobnosti tříd.

Pro klasifikaci bodu byly pravděpodobnosti všech tříd porovnány. Bod je klasifikován do třídy, kde má největší pravděpodobnost být.

4.2 SVM klasifikátor

Support vector machine (SVM) neboli metoda podpůrných vektorů je algoritmus řešící binární klasifikace. Dovoluje volně vybírat modelové parametry při řešení více dimenzionálních a nelineárně separovatelných problémů. Tedy metoda má unikátní výhody jako je dobrá generalizace a robustnost. (He et al., 2020)

SVM je moderní metoda zavedena V. Vapnikem a jeho kolegy. Jedná se o velmi účinnou metodu pro rozpoznávání vzorů. Cílem metody je najít nadrovinu - lineární rozhodovací plochu. Na rozdíl od ostatních klasifikátorů metoda SVM maximalizuje odstup (maximal margin) od binárních tříd. Je zřejmé, že nadrovina, která zvětšuje vzdálenost od obou tříd, rozděluje největší potenciální počet bodů, které více patří ke třídě na stejné straně. (Nasser and Dogru, Ayat et al., 2005)

Rozhodovací funkce je dána rovnicí (4.4)

$$f(\mathbf{x}) = \text{sgn}(\mathbf{w}^T \mathbf{x} - b) \quad (4.4)$$

\mathbf{w} – normálový vektor nadroviny

b – offset nadroviny od počátku

sgn – sign funkce

Nadrovinou vzniklou rovnicí (4.4) lze rozdělit prostor, v němž se nadrovina nachází, na dva separované poloprostory. Klasifikace testovaného bodu je určena jeho pozicí v jedné z oblastí. Kvůli sign funkci jsou možné jen dva výsledky, což reprezentuje použité třídy.

4.2.1 SVM klasifikátor s jádrem

Vzhledem k možnému překrývání dat dvou tříd, díky nimž jsou data lineárně neoddělitelné, byl do metody přidán kernel neboli jádro. Hlavní myšlenka použití jádra je namapovat trénující data do nového prostoru (feature space) pomocí nelineární jádrové funkce a poté sestavit rozhodovací funkci v daném prostoru. Nová dimenze dat je obecně vysoká a může dojít i k nekonečné dimenzi. Nově vzniklý klasifikátor bude v původním prostoru nelineární. (Amari and Wu, 1999, Feng et al., 2019)

Po zavedení jádra do rovnice (4.4)

$$f(\mathbf{x}) = \text{sgn}(\mathbf{w}^T \mathbf{x} - b) = \text{sgn} \sum_{i=1}^n w_i y_i k(\mathbf{x}_i, \mathbf{x}') \quad (4.5)$$

n – počet tréninkových dat

w_i – váha tréninkových dat, $w_i \in \mathbb{R}$, $0 < w_i < C$, $i = 1, \dots, n$

C – parametr nastavený pro trénování, $C \in \mathbb{R}$

y_i - klasifikace tréninkových dat $y_i \in [-1, +1]$, $i = 1, \dots, n$

$k: \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$, kernel funkce měřící podobnost mezi body $\mathbf{x}, \mathbf{x}' \in \mathcal{X}$

\mathbf{x}_i - tréninková data $i = 1, \dots, n$

\mathbf{x}' - testovací bod

4.2.2 Jádro RBF

Radial basis function (RBF) byla vybrána jako jádro pro tuto práci. RBF byl použit pro mapování dat do vyšších dimenzí, které převedou data do lineárně separovatelného tvaru. Pro jádro RBF byla Gaussova funkce použita pro mapování prvků do prostoru vyšší dimenze, tak že jsou binární vlastnosti tříd oddělitelné. (He et al., 2020)

$$k(\mathbf{x}, \mathbf{x}') = e^{-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\sigma^2}} \quad (4.6)$$

σ – parametr nastavený pro trénování, $\sigma \in \mathbb{R}$

Přesnost RBF-SVM klasifikátoru je závislá na různých hodnotách parametru C a σ z rovnic (4.5) a (4.6) ($C, \sigma \in \mathbb{R}$). Parametr C je trestní parametr, který udává maximální váhu špatně zařazeného testovacího bodu. Nesprávným výběrem parametru C dochází k overfitting nebo underfitting. Parametr σ je součástí jádrové funkce, který implicitně určuje distribuci dat po mapování do nového prostoru. (Feng et al., 2019, He et al., 2020)

4.2.3 Implementace SVM klasifikátoru

Klasifikátor SVM byl implementován pomocí Python knihovny *sklearn*. Výhodou využití knihovny pro SVM klasifikátor je nalezení optimálních hodnot C a σ . Zároveň knihovna *sklearn* umožňuje klasifikátor více tříd transformací výsledku klasifikátoru „jeden proti jednomu“ na „jeden proti zbytku“.

Nejprve bylo definováno jádro klasifikátoru, což byl RBF. Pomocí funkce *fit()* se do modelu nahrály data s označením třídy. Tímto způsobem vznikl funkční model SVM klasifikátoru s RBF jádrem. Klasifikace nového bodu proběhla pomocí funkce *predict()*, která vrací třídu bodu.

5 Přesnost klasifikace

Parametrizací signálu byly vypočítané čtyři parametry v závislosti na referenční vzorcích řeči (viz kapitola 3). Tato kapitola se věnuje přesnosti klasifikace jednotlivých parametrů i použití více parametrů pro vícedimenzionální klasifikátor (viz kapitola 4).

5.1 Výběr referenčního promluvy/vzorku řeči

Přesnost klasifikátoru je proměnlivá v závislosti na výběru referenční promluvy, podle které se bude testovaná nahrávka posuzovat a podle které budou vypočítané parametry jako LPC, MFCC a energie. Jako potenciální referenční vzorky byly vzaty ty, co byly určeny jako zdravé. Ovšem to, že promluva je označena za zdravou, nemusí znamenat, že je ideální pro porovnávání. Mohlo dojít ke špatnému označení, či může být na hranici zdravé a nezdravé. Pro vybrání nejlepší referenční promluvy byly klasifikátory sestaveny pro všechny potenciální referenční promluvy a podle jejich přesnosti se vybrala nejlepší referenční promluva.

Možnost použití nezdravého referenčního vzorku byla zvážena a odmítnuta. Z důvodu mnoha možných vad v promluvě nebylo možné vybrat jednu nahrávku, která by dokázala reprezentovat všechny vady.

5.2 Jednodimenzionální klasifikace

Jako jednodimenzionální klasifikace se v práci uvádí použití pouze jednoho parametru pro klasifikaci promluv. Zároveň byla testována přesnost použití jiného počtu koeficientů pro LPC a MFCC.

Klasifikátory SVM a Bayes byly použity dvakrát. Vzorky řeči se rozdělovaly do 4 tříd: zdravé, nezdravé kategorie 1, nezdravé kategorie 2 a nezdravé kategorie 3. Byly otestovány přesnosti binární klasifikace zdravý/nezdravý a klasifikace o 4 třídách.

Testování přesností klasifikace proběhlo pro všechny typy promluv. V této kapitole budou zobrazovány výsledky pro promluvy: babička, máma, velryba. Výsledky ostatních typů promluvy jsou k náhledu v příloze.

Spolu s celkovou přesností se do tabulky vypisuje i přesnost jednotlivých tříd. Z důvodu většího počtu nezdravých nahrávek může klasifikátor rozhodnout o zařazení všech promluv do třídy nezdravých a tím docílit větší přesnosti.

Popis tabulek

Parametr – jméno použitého parametru

LPC8 – DTW vzdálenost LPC 8 parametrů

LPC13 – DTW vzdálenost LPC 13 parametrů

MFCC8 – DTW vzdálenost MFCC 8 parametrů

MFCC13 – DTW vzdálenost MFCC 13 parametrů

Energie – DTW vzdálenost Energii

Délka – délka signálu

Jména – jméno promluvy s nejlepší přesností pro daný parametr

Celek – celková přesnost klasifikátoru

Z – přesnost na zdravých promluvách

N – přesnost na nezdravých promluvách

N1 – přesnost na nezdravých promluvách kategorie 1

N2 – přesnost na nezdravých promluvách kategorie 2

N3 – přesnost na nezdravých promluvách kategorie 3

Tab. I: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova babička, máma, velryba

Babička				
Parametr	Jména	Celek	Z	N
LPC8	babicka_Z_0081_1	67 %	87 %	59 %
LPC13	babicka_Z_0081_1	65 %	90 %	56 %
MFCC8	babicka_Z_0084_1	81 %	94 %	75 %
MFCC13	babicka_Z_0084_1	81 %	94 %	76 %
Energie	babicka_Z_0018_1	65 %	74 %	61 %
Délka		51 %	85 %	37 %
Máma				
Parametr	Jména	Celek	Z	N
LPC8	mama_Z_0065_1	66 %	92 %	56 %
LPC13	mama_Z_0027_1	63 %	92 %	52 %
MFCC8	mama_Z_0011_1	92 %	95 %	91 %
MFCC13	mama_Z_0011_1	93 %	95 %	92 %
Energie	mama_Z_0088_1	79 %	89 %	75 %
Délka		72 %	60 %	76 %
Velryba				
Parametr	Jména	Celek	Z	N
LPC8	velryba_Z_0100_1	58 %	91 %	43 %
LPC13	velryba_Z_0050_1	60 %	92 %	46 %
MFCC8	velryba_Z_0061_1	70 %	85 %	63 %
MFCC13	velryba_Z_0061_1	71 %	87 %	63 %
Energie	velryba_Z_0038_1	61 %	89 %	48 %
Délka		57 %	88 %	43 %

Tab. II: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý/kategorie 1/ nezdravý/kategorie 2/ nezdravý/kategorie 3 pro slova babička, máma, velryba

Babička						
Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	babicka_Z_0084_1	41 %	89 %	44 %	0 %	0 %
LPC13	babicka_Z_0038_1	40 %	90 %	39 %	0 %	0 %
MFCC8	babicka_Z_0081_1	52 %	90 %	11 %	56 %	56 %
MFCC13	babicka_Z_0016_1	51 %	93 %	8 %	54 %	54 %
Energie	babicka_Z_0084_1	38 %	80 %	23 %	23 %	23 %
Délka		34 %	83 %	0 %	24 %	24 %
Máma						
Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	mama_Z_0065_1	42 %	89 %	6 %	39 %	39 %
LPC13	mama_Z_0020_1	43 %	86 %	5 %	48 %	48 %
MFCC8	mama_Z_0003_1	54 %	88 %	30 %	57 %	57 %
MFCC13	mama_Z_0059_1	54 %	83 %	1 %	73 %	73 %
Energie	mama_Z_0002_1	46 %	89 %	49 %	26 %	26 %
Délka		42 %	54 %	8 %	71 %	71 %
Velryba						
Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	velryba_Z_0079_1	42 %	92 %	48 %	0 %	0 %
LPC13	velryba_Z_0039_1	42 %	92 %	49 %	3 %	3 %
MFCC8	velryba_Z_0039_1	43 %	86 %	6 %	34 %	34 %
MFCC13	velryba_Z_0060_1	43 %	87 %	19 %	24 %	24 %
Energie	velryba_Z_0038_1	43 %	82 %	19 %	32 %	32 %
Délka		39 %	83 %	33 %	14 %	14 %

Tab. III: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova babička, máma, velryba

Babička				
Parametr	Jména	Celek	Z	N
LPC8	babicka_Z_0031_1	81 %	45 %	96 %
LPC13	babicka_Z_0088_1	80 %	46 %	94 %
MFCC8	babicka_Z_0048_1	87 %	79 %	91 %
MFCC13	babicka_Z_0084_1	87 %	76 %	92 %
Energie	babicka_Z_0049_1	75 %	18 %	98 %
Délka		72 %	0 %	100 %
Máma				
Parametr	Jména	Celek	Z	N
LPC8	mama_Z_0027_1	81 %	42 %	95 %
LPC13	mama_Z_0027_1	82 %	48 %	95 %
MFCC8	mama_Z_0011_1	94 %	92 %	94 %
MFCC13	mama_Z_0020_1	95 %	89 %	98 %
Energie	mama_Z_0002_1	88 %	69 %	95 %
Délka		73 %	7 %	98 %
Velryba				
Parametr	Jména	Celek	Z	N
LPC8	velryba_Z_0041_1	73 %	26 %	95 %
LPC13	velryba_Z_0088_1	73 %	22 %	96 %
MFCC8	velryba_Z_0060_1	82 %	55 %	94 %
MFCC13	velryba_Z_0060_1	83 %	59 %	95 %
Energie	velryba_Z_0046_1	75 %	29 %	96 %
Délka		69 %	0 %	100 %

Tab. IV: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slova babička, máma, velryba

Babička						
Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	babicka_Z_0081_1	50 %	79 %	0 %	78 %	0 %
LPC13	babicka_Z_0032_1	50 %	76 %	2 %	74 %	18 %
MFCC8	babicka_Z_0084_1	55 %	89 %	0 %	83 %	11 %
MFCC13	babicka_Z_0016_1	56 %	89 %	0 %	83 %	18 %
Energie	babicka_Z_0033_1	45 %	49 %	0 %	82 %	23 %
Délka		39 %	65 %	0 %	59 %	2 %
Máma						
Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	mama_Z_0027_1	47 %	73 %	1 %	75 %	9 %
LPC13	mama_Z_0020_1	48 %	71 %	3 %	81 %	5 %
MFCC8	mama_Z_0011_1	61 %	93 %	17 %	93 %	4 %
MFCC13	mama_Z_0020_1	61 %	92 %	18 %	91 %	7 %
Energie	mama_Z_0056_1	53 %	79 %	0 %	87 %	11 %
Délka		46 %	76 %	0 %	74 %	0 %
Velryba						
Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	velryba_Z_0050_1	47 %	80 %	39 %	38 %	0 %
LPC13	velryba_Z_0088_1	46 %	78 %	23 %	50 %	0 %
MFCC8	velryba_Z_0064_1	52 %	73 %	33 %	64 %	0 %
MFCC13	velryba_Z_0047_1	52 %	69 %	20 %	79 %	0 %
Energie	velryba_Z_0084_1	48 %	61 %	17 %	76 %	3 %
Délka		42 %	72 %	0 %	61 %	0 %

5.2.1 Výsledky jednodimenzionální klasifikace

Podle tabulek I, II, III, IV je zřejmé, že různé parametry preferují různé referenční promluvy. Docházelo k několika shodám a není pravidlem, že pokud promluva funguje dobře k jednomu klasifikátoru, tak že bude fungovat dobře i k jinému.

Porovnáváním klasifikátorů Z/N oproti klasifikátoru Z/N1/N2/N3 je zřejmé, že jednotlivé kategorie je skoro nemožné od sebe navzájem odlišit. Z tohoto důvodu se nadále bude pracovat pouze s binárním klasifikátorem pro zaručení větší přesnosti.

Počet koeficientů použitých pro počítání LPC a MFCC nehraje velkou roli. Při MFCC se obecně přesnost s 13 koeficienty zvyšovala a časová náročnost při počítání 8 či 13 koeficientů není závažně rozdílná. Z tohoto důvodu bylo použito MFCC s 13 koeficienty. V případě LPC koeficientů se přesnost zvyšovala spíše pro 8 koeficientů. Na rozdíl od MFCC je časová náročnost pro LPC 13 koeficientů pozorovatelná. V práci bylo použito LPC s 8 koeficienty.

Přesnost klasifikace závisela i na použitém klasifikátoru. Ukázalo se, že přesnost SVM klasifikátoru je větší než Bayes. Tento výsledek se dal čekat, neboť SVM je obecně přesnější a více používaný klasifikátor než Bayes.

Při porovnávání jednotlivých druhů parametrů je pozorovatelná nejlepší přesnost pro MFCC parametr. Parametry LPC a energie jsou horší než MFCC, avšak stále dávají relativně dobrý výsledek. Parametr délka se ukázal, že není ideálním způsobem při klasifikaci slov. I přesto, že jsou přesnosti pro parametry různé, byla otestována jejich společná přesnost při klasifikaci.

5.3 Vícedimenzionální klasifikace

Výsledky z jednodimenzionální klasifikace byly použity pro vícedimenzionální klasifikaci. Za prvé bylo určeno, že rozdělovat promluvy i do nezdravých kategorií není možné, a proto klasifikátor bude řadit pouze binární třídy, tedy pouze zdravé a nezdravé. Dále bylo vypořádáno větší přesnost SVM klasifikátoru. Z porovnávání počtu koeficientů bylo rozhodnuto o použití LPC s 8 koeficienty a o MFCC s 13. Každý z parametrů se projevil schopný klasifikace.

Bylo nutno určit, zda při použití více parametrů se přesnost zhorší či nikoliv.

Popis tabulky

Metoda – jména použitých parametrů

L8 – DTW vzdálenost LPC 8 parametrů

M13 – DTW vzdálenost MFCC 13 parametrů

E – DTW vzdálenost Energii

D – délka signálu

Jména – jméno promluvy s nejlepší přesností pro daný parametr

Celek – celková přesnost klasifikátoru

Z – přesnost na zdravých promluvách

N – přesnost na nezdravých promluvách

Tab. V: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova babička, máma, velryba

Babička				
Metoda	Jména	Celek	Z	N
L8+M13	babicka_Z_0084_1	89 %	78 %	93 %
L8+M13+E	babicka_Z_0084_1	88 %	73 %	95 %
L8+M13+D	babicka_Z_0084_1	90 %	79 %	94 %
L8+M13+E+D	babicka_Z_0084_1	90 %	78 %	94 %
Máma				
Metoda	Jména	Celek	Z	N
L8+M13	mama_Z_0020_1	96 %	91 %	98 %
L8+M13+E	mama_Z_0020_1	95 %	87 %	98 %
L8+M13+D	mama_Z_0059_1	96 %	89 %	99 %
L8+M13+E+D	mama_Z_0069_1	97 %	91 %	99 %
Velryba				
Metoda	Jména	Celek	Z	N
L8+M13	velryba_Z_0060_1	83 %	60 %	94 %
L8+M13+E	velryba_Z_0047_1	83 %	60 %	94 %
L8+M13+D	velryba_Z_0050_1	84 %	61 %	94 %
L8+M13+E+D	velryba_Z_0044_1	84 %	63 %	94 %

5.3.1 Výsledky vícedimenzionální klasifikace

Tab. V jasně ukazuje přesnosti při použití kolika a jakých parametrů. Výsledky byly nejednoznačné. V některých případech použití energie zhoršilo či zlepšilo přesnost. To samé se dá říct o parametru délka.

Pro práci byly nakonec použity všechny parametry. Důvodem byla úplně nejlepší klasifikace, a to klasifikace slova „Máma“ při použití všech parametrů.

5.4 Zhodnocení

Z výsledků o přesnosti jednodimenzionální klasifikace a vícedimenzionální klasifikace bylo určeno, že výsledky klasifikátor bude vícedimenzionální binární klasifikátor SVM používající všechny 4 druhy parametrů.

Použití všech parametrů pro klasifikace všech druhů promluv dostáváme danou přesnost.

Tab. VI: Největší přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro všechny druhy promluv

Druh promluvy	Jméno	Celek	Z	N
Babička	babicka_Z_0084_1	90 %	78 %	94 %
Čokoláda	cokolada_Z_0053_1	89 %	76 %	94 %
Fotbalista	fotbalista_Z_0033_1	89 %	83 %	93 %
Hamburger	hamburger_Z_0028_1	91 %	83 %	94 %
Ježek	jezek_Z_0032_1	89 %	74 %	94 %
Košile	kosile_Z_0056_1	87 %	70 %	94 %
Máma	mama_Z_0069_1	97 %	91 %	99 %
Popelnice	popelnice_Z_0033_1	94 %	88 %	97 %
Rákosníček	rakosnicek_Z_0007_1	91 %	84 %	94 %
Ředkvička	redkvicka_Z_0022_1	89 %	79 %	93 %
Silnice	silnice_Z_0059_1	89 %	80 %	93 %
Sluníčko	slunicko_Z_0031_1	88 %	72 %	94 %
Ucho	ucho_Z_0033_1	84 %	63 %	92 %
Velryba	velryba_Z_0044_1	84 %	63 %	94 %

Celková přesnost u klasifikace promluv je okolo 90 %. Bylo dosaženo lepších výsledků při použití více parametrů. Výsledkem této práce je aplikace, která dokáže rozpoznat vývojovou dysfázii. Pozoruhodné je že slovo máma je nejspolehlivějším slovem pro porovnání.

6 Aplikace

V této kapitole je popsán návrh, provedení a finální funkčnost aplikace.

6.1 Výběr programovacího jazyka

Před začátkem psaní aplikace bylo nutno určit jazyk pro aplikaci. Každý možný jazyk byl pro práci otestován jak ve funkčnosti programu a rychlosti, tak ve velikosti finální složky. Testované programovací jazyky byly C#, Matlab, Python. Z důvodů níže uvedených byl vybrán Python.

6.1.1 C#

Jako první volba pro programovací jazyk aplikace byl C#. Specificky bylo využito visual studio pro tvorbu windows form application. Jednalo se o pochopitelné rozhraní. Výhodou byla design okno, ve kterém bylo možno navrhnout rozpoložení nástrojů jako tlačítka, textových polí a podobně.

Výhodou byla rychlost, se kterou se ostatní testované jazyky v této práci nemohli srovnávat. Nevýhodou však byl velice chudý způsob debugování, a především neschopnost řešení LP problémů pro výpočet LPC koeficientů. Kvůli těmto nedostatkům nebyla ani aplikace v C# dokončena.

6.1.2 Matlab

Matlab na rozdíl od C# je už předem navržen na pracování s maticemi a obecně se signály. Matlab je jednodušší jazyk oproti C#, proto implementace aplikace byla vytvořena snadno a rychle v Matlab app designer. Podobně jako v C# je zde možnost upravovat pozice nástrojů.

Kvůli predispozicím jazyka pracovat se signály, vypočítání LPC a MFC koeficientů nebylo problematické. Podobně naučení klasifikátoru proběhlo bez problémů. Velkou nevýhodou aplikace vytvořené v Matlabu bylo rychlost a úložný prostor. Aplikace vytvořené v Matlabu nejsou schopny fungovat na počítačích bez programu Matlab či Matlab runtime. V této práci je hlavním cílem vytvořit samostatnou aplikaci pro rozpoznávání vývojové dysfázie, proto není akceptovatelné, aby si uživatel aplikace musel pořizovat Matlab.

Druhou možností byl Matlab runtime. Matlab runtime je bezplatný software obsahující samostatnou řadu sdílených knihoven, které umožňují spuštění aplikace i bez Matlab programu. Matlab runtime se dá zabalit přímo do aplikace a při instalaci do uživatelského počítače se spolu s aplikací nainstaluje i Matlab runtime. I přes to, že aplikace je schopna fungovat s Matlab runtime, je velikost složky nadbytečná v porovnání s jejími funkcemi. Při testování velikosti složky bylo zjištěno, že velikost přesahuje 1 GB, což není praktické ani uživatelsky přívětivé.

6.1.3 Python

Poslední jazyk, který byl vyzkoušen byl Python. Přesto že Python vzhledově i funkčně dost připomíná C#, nenastaly zde žádné komplikace při implementaci. Získání LPC a MFC koeficientů bylo provedeno pomocí knihovny *librosa*. Ostatní funkce pro normování či počítání DTW bylo zjednodušeno knihovnou *numpy*.

Výhodou Pythonu byly využití knihoven pro potřebné funkce a jednoduché zpracování do exe tvaru o malé velikosti. Kód byl psán v PyCharmu a pomocí pyinstalleru byl kód převeden do samostatné spustitelné aplikace se závislostmi. Nevýhodou tvoření aplikace v Pythonu byla absence designového okna pro nastavování geometrie nástrojů a proces byl více časově náročný. Zároveň spuštění aplikace zabere cca 30 vteřin. Jakmile program je spuštěn, aplikace funguje dobře. I přes lehké zpoždění při spuštění, aplikace naimplementovaná v pythonu funguje nejlépe.

6.2 Implementace aplikace

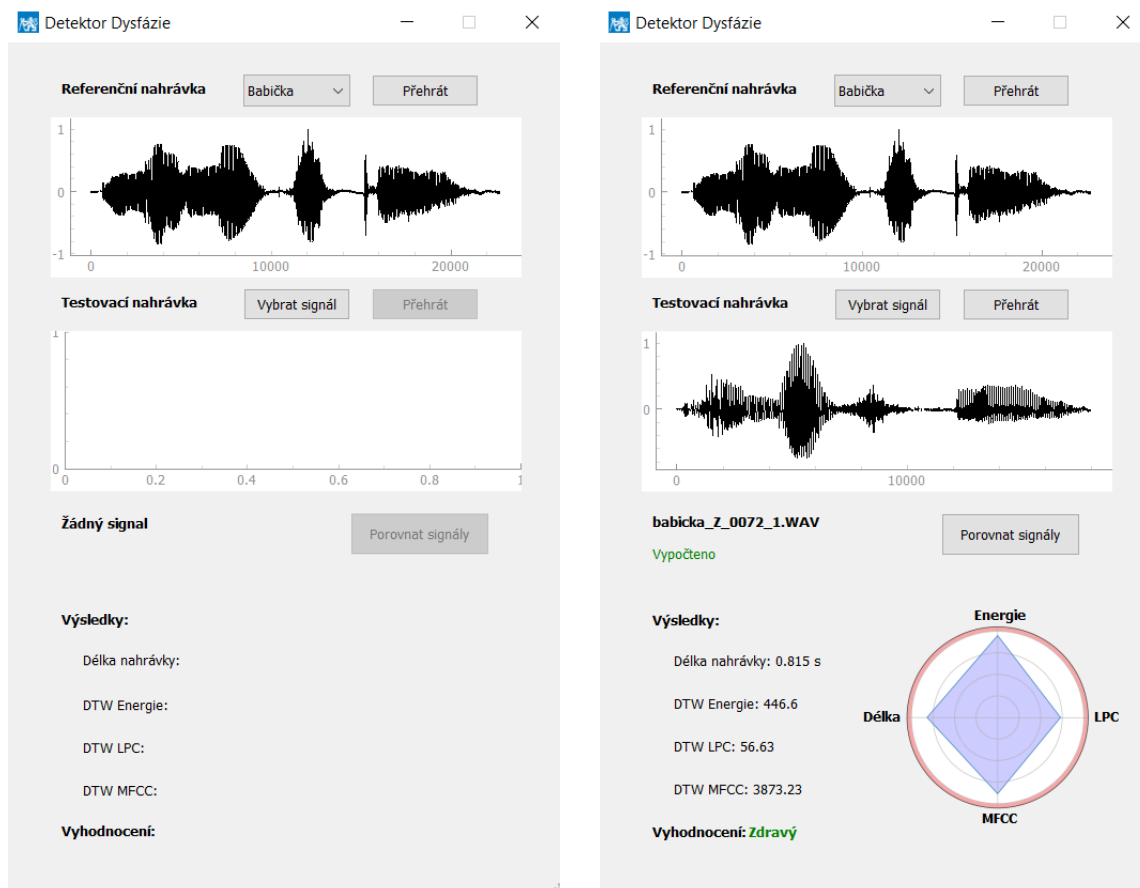
Hlavním cílem pro tvorbu aplikace bylo jednoduché, snadno pochopitelné prostředí a uživatelsky přívětivý systém. Aplikace byla navržena tak, aby si uživatel vybral svoji nahrávku, kterou chce otestovat. Po vybrání testovací nahrávky byla potřeba zpětná vazba od aplikace pro ověření či zkontrolování testovací nahrávky. Jakmile je testovaný signál úspěšně nahrán, bude moci aplikace otestovat správnost řeči na základě předem určené referenční nahrávky a vypíše výsledky. Vypis výsledků a dalších užitečných informací by měl být co nejvíce intuitivní.

Jako jméno aplikace bylo zvoleno „Detektor dysfázie“.

6.2.1 Popis

Samotná aplikace nezabírá tolik prostoru na ploše a reaguje na jakékoli změny. Uživatel má na výběr ze čtyř funkčních tlačítek a jednoho rozbalovacího seznamu. Všechny interaktivní tlačítka jsou řádně popsáné.

- Rozbalovací seznam – na obrázku 3 je zobrazen vedle nápisu referenční nahrávky a slouží k vybrání druhu testování. Jako možné zdroje byly použity všechny druhy poskytnutých nahrávek. Tj. Babička, Čokoláda, Fotbalista atd.
- „Vybrat signál“ – tímto tlačítkem se spustí dialogové okno, kterým uživatel vybere svou testovací nahrávku.
- „Přehrát“ – tlačítka zobrazená vedle nápisů referenční nahrávka a testovací nahrávka přehrají zvukový záznam (pokud je k dispozici).
- „Porovnat signál“ – použití tohoto tlačítka se spustí program pro vypočítání správnosti testovací nahrávky

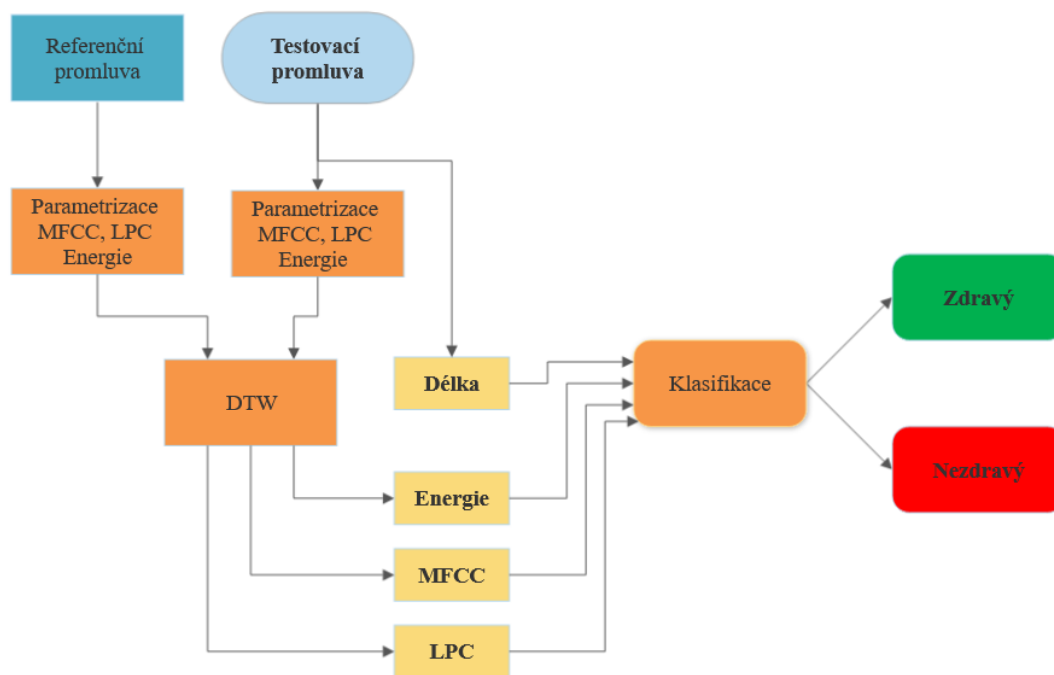


Obr. 3: Aplikace před vybráním testované promluvy (vlevo),
Aplikace po porovnání signálu (vpravo)

6.2.2 Algoritmus

Cílem testování testované nahrávky byla přesnost rozřazení do kategorie zdravé či nezdravé. Pro klasifikování referenční nahrávky byly vypočítané její LPC a MFCC koeficienty spolu s energií po segmentech. Tyto výsledky byly porovnány metodou DTW. Vznikly tak tři parametry. K těmto třem parametrům se přidala délka testované nahrávky. Tímto způsobem byl vytvořen čtyřdimenzionální bod hodný pro klasifikaci.

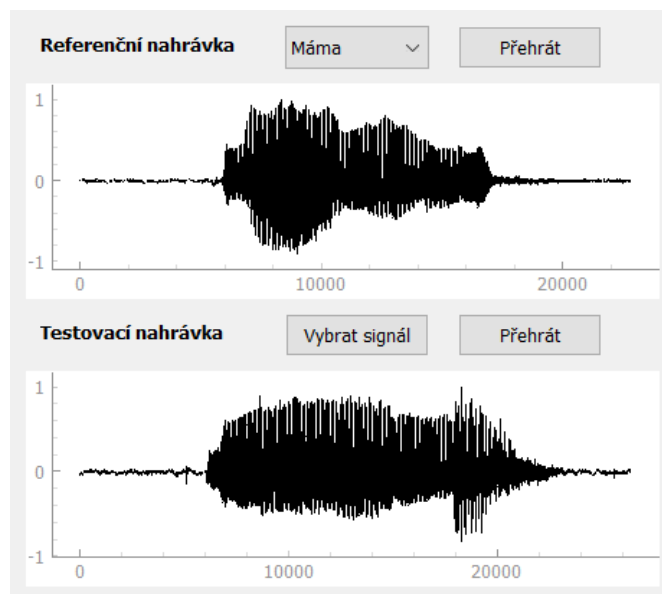
Výběr klasifikátoru a pro něj referenční nahrávku bylo provedeno způsobem popsaným v kapitole 5. Jedná se o klasifikátor binární klasifikátor SVM.



Obr. 4: Blokové schéma algoritmu v aplikaci

6.2.3 Uživatelské rozhraní

Komunikace s uživatelem je důležitá pro úspěšné pochopení a používání aplikace. Za tímto účelem bylo do aplikace přidána akustická a vizuální zpětná vazba. Vizuální zpětná vazba je ve formě grafického zobrazení signálu a akustická v možnosti přehrání nahrávky pro její zkontrolování.



Obr. 5: Vizuální zobrazení referenčního a testovaného signálu

Grafická okna aplikace se aktualizují po změně referenční či testované nahrávky. Stejně tak funguje tlačítko „Přehrát“, které přehraje nahrávky.

Další důležitou informací pro uživatele je špatný výběr nahrávky. I v tomto případě musí uživatel jasně vidět, že došlo k chybě.

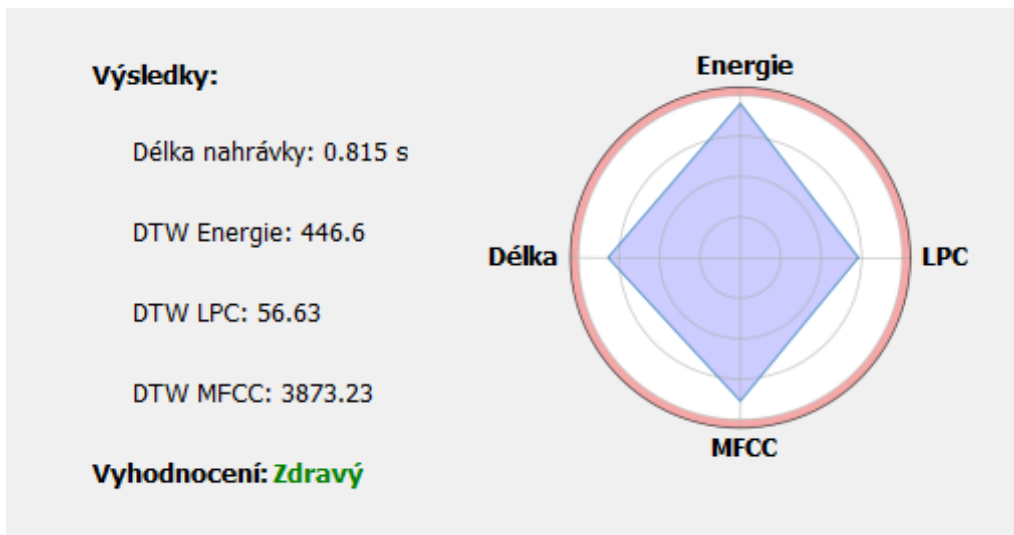


Obr. 6: Informace o úspěšném (nahore) či neúspěšném (dole) nahrání testovací promluvy

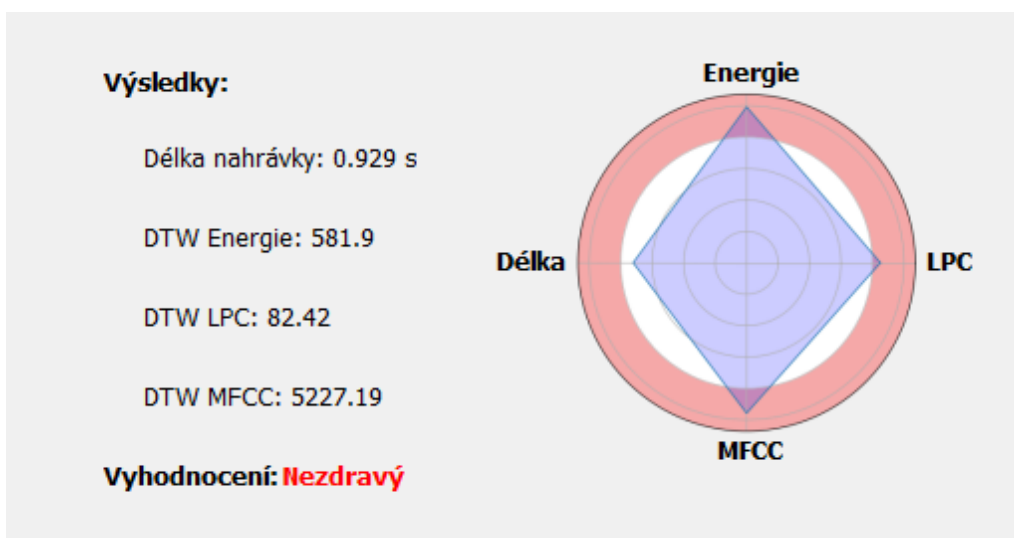
Při selhání nalezení signálu je tlačítko „porovnat signály“ nestisknutelné a je napsáno uživateli, že signál nebyl vybrán. V opačném případě se možnost porovnat signály zpřístupní a jméno signálu je napsáno pro další ověření.

6.2.4 Výsledky

Výsledky byly navrženy tak, aby byly pro uživatele jednoduše pochopitelné. Za tímto účelem byla v aplikaci navržena část na zobrazování výsledků. Mezi zobrazené hodnoty patří všechny použité parametry pro klasifikaci. Tato informace je pro odborníky v této oblasti, pro případ dalšího použití naměřených výsledků. Hlavním výsledkem aplikace je „Vyhodnocení“. To ukazuje zdravý či nezdravý v závislosti na výsledku klasifikace.



Obr. 7 : Zobrazení výsledků spolu s grafem pro zdravý signál



Obr. 8 : Zobrazení výsledků spolu s grafem pro nezdravý signál

Přidán byl i radarový graf. Radarový graf ukazuje relativní správnost všech parametrů. Pomocí metody MLE byla nalezena jednodimenzionální normální distribuce pro parametry zdravých a nezdravých promluv. Následně byl vypočítán práh normovaných normálních distribucí. Tímto prahem se poté znormovaly hodnoty vypočítaných parametrů. Práh je na obrázku znázorněn prahem dvou barev. U zdravého výsledku se bude většina či všechny vrcholy grafu nacházet v bílé (zdravé) oblasti. V opačném případě může jeden či více parametrů zasahovat do červené (nezdravé) oblasti. Tímto způsobem lze jednoduše rozpoznat v jakých parametrech nahrávka nevyhovuje a o kolik.

6.2.5 Závislosti

Závislost pro počítačovou aplikaci bereme jako soubor jakéhokoli druhu, který je potřebný pro běh aplikace. Složka se všemi potřebnými závislosti byla zabalena spolu s aplikací, aby uživatel nemusel stahovat žádné dodatečné soubory.

V aplikaci „Detektor dysfázie“ je nutno mít velké množství závislostí. Především je v aplikaci potřeba referenčních nahrávek. Pro všechny druhy promluv bylo potřeba referenční nahrávka. Referenční nahrávky jsou uloženy ve WAV tvaru.

Dále bylo potřeba mít hodnoty z kterých aplikace dokáže vytvořit funkční model klasifikátoru. Pro model byly předem vytvořeny 4 txt soubory pro každý druh promluvy. Do txt souborů byly zapsány parametry jako délka, DTW energie, DTW LPC koeficientů a DTW MFCC. V aplikaci je uvedena funkce, která dané txt soubory umí přečíst a vytvořit z nich funkční klasifikátor.

7 Závěr

Téma této práce bylo navržení a implementace aplikace pro hodnocení vývojové dysfázie. Byly navrženy a vyzkoušeny možnosti pro parametrizaci promluv. Byly použity čtyři parametry získané z porovnávání testované a referenční promluvy a ze samotné testovací promluvy. Tyto parametry byly využity pro testování klasifikátorů. Jako hlavní klasifikátor byl určen SVM.

Funkční samostatně stojící aplikace byla úspěšně vytvořena v jazyce Python. Jde o aplikaci malého rozsahu, která je schopna s dostatečně velkou přesností rozlišovat zdravé promluvy od nezdravých. V aplikaci se objevuje graf pro jednodušší porozumění. Tento graf využil MLE pro normování.

Přesnost aplikace se pohybuje okolo 90 % v závislosti na druhu promluvy. Nejedná se o aplikaci, která by byla schopna nahradit vystudované odborníky. Aplikace může být využita lidmi, kteří si nejsou jisti onemocněním jejich dítěte. Může poskytnout potřebnou informaci, která povede k návštěvě odborníka.

Práce rozhodně má prostor pro další rozvoj. Použití více parametrů docílit větší přesnosti při klasifikování. Stejně tak by pomohlo i více vzorků jak od zdravých, tak od nemocných dětí. V případě mnohem většího počtu vzorků bychom uvažovali o použití neuronových sítí, eventuelně s kombinací klasifikátorů, používaných touto prací. Dále se práce může rozšířit na více druhů promluv.

8 Literatura

2003. Speech processing; a dynamic and optimization-oriented approach. *Scitech Book News*. Portland: Ringgold Inc.
- A, A. & DHONDE, S. B. 2015. Effect of Varying MFCC Filters for Speaker Recognition. *International journal of computer applications*, 128, 7-9.
- AMARI, S. & WU, S. 1999. Improving support vector machine classifiers by modifying kernel functions. *Neural networks*, 12, 783-789.
- ARUN SANKAR, M. S. & SATHIDEVI, P. S. 2020. Design of MELPe-Based Variable-Bit-Rate Speech Coding with Mel Scale Approach Using Low-Order Linear Prediction Filter and Representing Excitation Signal Using Glottal Closure Instants. *Arabian Journal for Science and Engineering*, 45, 1785-1801.
- AYAT, N. E., CHERIET, M. & SUEN, C. Y. 2005. Automatic model selection for the optimization of SVM kernels. *Pattern recognition*, 38, 1733-1745.
- FENG, X., LING, X., ZHENG, H., CHEN, Z. & XU, Y. 2019. Adaptive Multi-Kernel SVM With Spatial-Temporal Correlation for Short-Term Traffic Flow Prediction. *IEEE transactions on intelligent transportation systems*, 20, 2001-2013.
- GRAY, R. M. 2009. *Linear Predictive Coding and the Internet Protocol*, Hanover, UNITED STATES, Now Publishers.
- HE, Y., TSANG, K. F., KONG, R. Y.-C. & CHOW, Y.-T. 2020. Indication of Electromagnetic Field Exposure via RBF-SVM Using Time-Series Features of Zebrafish Locomotion. *Sensors (Basel, Switzerland)*, 20, 4818.
- CHILDERS, D. G., SKINNER, D. P. & KEMERAIT, R. C. 1977. The cepstrum: A guide to processing. *Proceedings of the IEEE*, 65, 1428-1443.
- MATIASOVITSOVÁ, K. 2019. *Vývojová dysfázie u česky mluvících dětí předškolního věku*.
- MLYNÁŘOVÁ, M. 2007. *Diagnostika vývojové dysfázie ve Speciálně pedagogickém centru*. Masarykova univerzita, Pedagogická fakulta Brno.
- NASSER, A. T. & DOGRU, N. Signature recognition by using SIFT and SURF with SVM basic on RBF for voting online. 2017. IEEE, 1-5.
- OVČAŘÍ, M. 2016. *ANALÝZA PROMLUV DĚTÍ S VÝVOJOVOU DYSFÁZIÍ*. DISERTAČNÍ PRÁCE, České vysoké učení technické v Praze.
- PRINCE, S. J. 2012. *Computer vision: models, learning, and inference*, Cambridge University Press.
- RANDALL, R. B. 2017. A history of cepstrum analysis and its application to mechanical problems. *Mechanical Systems and Signal Processing*, 97, 3-19.

- RYBÁČKOVÁ, P. 2013. *Způsoby terapie při vývojové dysfázii*.
- SAHIDULLAH, M. & SAHA, G. 2012. Design, analysis and experimental evaluation of block based transformation in MFCC computation for speaker recognition. *Speech Communication*, 54, 543-565.
- SMOLÍK, F. 2009. VYVOJOVA DYSFAZIE A STRUKTURA RANYCH JAZYKOVYCH SCHOPNOSTI. *Ceskoslovenska Psychologie*, 53, 40-54.
- STASIAK, B., SKIBA, M. & NIEDZIELSKI, A. 2019. FlatDTW – Dynamic Time Warping optimization for piecewise constant templates. *Digital Signal Processing*, 85, 86-98.
- TSANGARATOS, P. & ILIA, I. 2016. Comparison of a logistic regression and Naïve Bayes classifier in landslide susceptibility assessments: The influence of models complexity and training dataset size. *Catena (Giessen)*, 145, 164-179.
- VIAL, J., NOÇAIRI, H., SASSIAT, P., MALLIPATU, S., COGNON, G., THIÉBAUT, D., TEILLET, B. & RUTLEDGE, D. N. 2009. Combination of dynamic time warping and multivariate analysis for the comparison of comprehensive two-dimensional gas chromatograms: Application to plant extracts. *Journal of Chromatography A*, 1216, 2866-2872.
- WEIK, M. & SPRINGERLINK 2006. *Computer Science and Communications Dictionary*, New York, NY, Springer.
- YAP, X., KHONG, A. W. H. & GAN, W.-S. Localization of acoustic source on solids: A linear predictive coding based algorithm for location template matching. 2010. IEEE, 2490-2493.
- ZHENG, F., ZHANG, G. & SONG, Z. 2001. Comparison of different implementations of MFCC. *Journal of Computer Science and Technology*, 16, 582-589.

9 Přílohy

Příložené soubory:

Aplikace – kód a závislosti aplikace

Kódy – kódy využití pro parametrizaci a klasifikaci

Tab. VII: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo čokoláda

Parametr	Jména	Celek	Z	N
LPC8	cokolada_Z_0062_1	59 %	89 %	47 %
LPC13	cokolada_Z_0088_1	62 %	93 %	49 %
MFCC8	cokolada_Z_0060_1	78 %	92 %	73 %
MFCC13	cokolada_Z_0060_1	78 %	93 %	72 %
Energie	cokolada_Z_0085_1	66 %	81 %	60 %
Délka		56 %	87 %	44 %

Tab. VIII: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo fotbalista

Parametr	Jména	Celek	Z	N
LPC8	fotbalista_Z_0027_1	76 %	95 %	66 %
LPC13	fotbalista_Z_0079_1	74 %	93 %	65 %
MFCC8	fotbalista_Z_0033_1	82 %	90 %	77 %
MFCC13	fotbalista_Z_0033_1	81 %	92 %	75 %
Energie	fotbalista_Z_0061_1	67 %	78 %	62 %
Délka		59 %	89 %	44 %

Tab. IX: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo hamburger

Parametr	Jména	Celek	Z	N
LPC8	hamburger_Z_0054_1	62 %	71 %	58 %
LPC13	hamburger_Z_0027_1	60 %	92 %	46 %
MFCC8	hamburger_Z_0030_1	79 %	90 %	74 %
MFCC13	hamburger_Z_0031_1	80 %	91 %	75 %
Energie	hamburger_Z_0096_1	69 %	67 %	70 %
Délka		63 %	70 %	60 %

Tab. X: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo ježek

Parametr	Jména	Celek	Z	N
LPC8	jezek_Z_0040_1	63 %	80 %	57 %
LPC13	jezek_Z_0040_1	60 %	85 %	50 %
MFCC8	jezek_Z_0072_1	81 %	92 %	76 %
MFCC13	jezek_Z_0072_1	81 %	91 %	77 %
Energie	jezek_Z_0088_1	66 %	64 %	66 %
Délka		56 %	87 %	45 %

Tab. XI: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo košile

Parametr	Jména	Celek	Z	N
LPC8	kosile_Z_0057_1	62 %	89 %	51 %
LPC13	kosile_Z_0061_1	63 %	91 %	52 %
MFCC8	kosile_Z_0047_1	74 %	93 %	67 %
MFCC13	kosile_Z_0060_1	74 %	94 %	66 %
Energie	kosile_Z_0090_1	64 %	72 %	61 %
Délka		53 %	86 %	39 %

Tab. XII: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo popelnice

Parametr	Jména	Celek	Z	N
LPC8	popelnice_Z_0025_1	69 %	88 %	61 %
LPC13	popelnice_Z_0007_1	67 %	96 %	56 %
MFCC8	popelnice_Z_0041_1	85 %	91 %	82 %
MFCC13	popelnice_Z_0035_1	85 %	88 %	84 %
Energie	popelnice_Z_0083_1	74 %	82 %	71 %
Délka		54 %	87 %	41 %

Tab. XIII: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo Rákosníček

Parametr	Jména	Celek	Z	N
LPC8	rakosnicek_Z_0040_1	71 %	93 %	61 %
LPC13	rakosnicek_Z_0047_1	68 %	91 %	57 %
MFCC8	rakosnicek_Z_0005_1	85 %	97 %	80 %
MFCC13	rakosnicek_Z_0005_1	85 %	97 %	80 %
Energie	rakosnicek_Z_0057_1	65 %	71 %	62 %
Délka		58 %	86 %	46 %

Tab. XIV: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo ředkvička

Parametr	Jména	Celek	Z	N
LPC8	redkvicka_Z_0078_1	70 %	78 %	66 %
LPC13	redkvicka_Z_0054_1	67 %	72 %	66 %
MFCC8	redkvicka_Z_0004_1	80 %	92 %	74 %
MFCC13	redkvicka_Z_0004_1	79 %	92 %	73 %
Energie	redkvicka_Z_0014_1	67 %	66 %	67 %
Délka		58 %	78 %	49 %

Tab. XV: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo silnice

Parametr	Jména	Celek	Z	N
LPC8	silnice_Z_0020_1	65 %	91 %	54 %
LPC13	silnice_Z_0059_1	65 %	91 %	55 %
MFCC8	silnice_Z_0059_1	80 %	90 %	75 %
MFCC13	silnice_Z_0059_1	80 %	90 %	76 %
Energie	silnice_Z_0047_1	54 %	88 %	41 %
Délka		53 %	84 %	41 %

Tab. XVI: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo sluníčko

Parametr	Jména	Celek	Z	N
LPC8	slunicko_Z_0059_1	63 %	91 %	51 %
LPC13	slunicko_Z_0059_1	63 %	91 %	51 %
MFCC8	slunicko_Z_0010_1	77 %	89 %	72 %
MFCC13	slunicko_Z_0031_1	76 %	88 %	71 %
Energie	slunicko_Z_0031_1	65 %	62 %	66 %
Délka		53 %	86 %	40 %

Tab. XVII: Přesnost jednodimenzionálního Bayes klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo ucho

Parametr	Jména	Celek	Z	N
LPC8	ucho_Z_0062_1	56 %	88 %	44 %
LPC13	ucho_Z_0062_1	59 %	92 %	47 %
MFCC8	ucho_Z_0045_1	72 %	97 %	63 %
MFCC13	ucho_Z_0045_1	72 %	96 %	63 %
Energie	ucho_Z_0045_1	61 %	74 %	56 %
Délka		59 %	90 %	46 %

Tab. XVIII: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo čokoláda

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	cokolada_Z_0057_1	37 %	89 %	21 %	10 %	10 %
LPC13	cokolada_Z_0034_1	38 %	91 %	0 %	27 %	27 %
MFCC8	cokolada_Z_0053_1	48 %	86 %	36 %	21 %	21 %
MFCC13	cokolada_Z_0053_1	47 %	88 %	34 %	20 %	20 %
Energie	cokolada_Z_0020_1	41 %	65 %	0 %	53 %	53 %
Délka		39 %	84 %	14 %	23 %	23 %

Tab. XIX: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo fotbalista

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	fotbalista_Z_0027_1	44 %	91 %	18 %	11 %	11 %
LPC13	fotbalista_Z_0089_1	44 %	89 %	0 %	29 %	29 %
MFCC8	fotbalista_Z_0033_1	50 %	90 %	30 %	19 %	19 %
MFCC13	fotbalista_Z_0033_1	48 %	90 %	24 %	18 %	18 %
Energie	fotbalista_Z_0083_1	50 %	81 %	39 %	34 %	34 %
Délka		40 %	84 %	0 %	32 %	32 %

Tab. XX: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo hamburger

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	hamburger_Z_0017_1	42 %	91 %	0 %	33 %	33 %
LPC13	hamburger_Z_0020_1	42 %	92 %	0 %	31 %	31 %
MFCC8	hamburger_Z_0030_1	53 %	86 %	0 %	74 %	74 %
MFCC13	hamburger_Z_0030_1	52 %	88 %	0 %	69 %	69 %
Energie	hamburger_Z_0073_1	44 %	72 %	0 %	56 %	56 %
Délka		33 %	55 %	9 %	34 %	34 %

Tab. XXI: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo jezek

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	jezek_Z_0031_1	39 %	57 %	39 %	30 %	30 %
LPC13	jezek_Z_0025_1	37 %	72 %	48 %	4 %	4 %
MFCC8	jezek_Z_0072_1	47 %	85 %	54 %	14 %	14 %
MFCC13	jezek_Z_0007_1	47 %	86 %	41 %	18 %	18 %
Energie	jezek_Z_0047_1	39 %	82 %	0 %	39 %	39 %
Délka		31 %	85 %	20 %	0 %	0 %

Tab. XXII: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo košile

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	kosile_Z_0062_1	37 %	88 %	31 %	8 %	8 %
LPC13	kosile_Z_0060_1	38 %	90 %	20 %	15 %	15 %
MFCC8	kosile_Z_0002_1	48 %	90 %	37 %	25 %	25 %
MFCC13	kosile_Z_0002_1	47 %	90 %	38 %	24 %	24 %
Energie	kosile_Z_0062_1	41 %	66 %	0 %	52 %	52 %
Délka		32 %	84 %	18 %	3 %	3 %

Tab. XXIII: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo popelnice

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	popelnice_Z_0062_1	40 %	91 %	25 %	16 %	16 %
LPC13	popelnice_Z_0062_1	42 %	92 %	33 %	17 %	17 %
MFCC8	popelnice_Z_0083_1	48 %	88 %	66 %	1 %	1 %
MFCC13	popelnice_Z_0039_1	48 %	90 %	54 %	6 %	6 %
Energie	popelnice_Z_0031_1	48 %	86 %	0 %	56 %	56 %
Délka		36 %	82 %	12 %	17 %	17 %

Tab. XXIV: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo Rákosníček

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	rakosnicek_Z_0027_1	43 %	91 %	43 %	6 %	6 %
LPC13	rakosnicek_Z_0094_1	40 %	89 %	2 %	32 %	32 %
MFCC8	rakosnicek_Z_0083_1	54 %	94 %	25 %	41 %	41 %
MFCC13	rakosnicek_Z_0083_1	54 %	94 %	24 %	45 %	45 %
Energie	rakosnicek_Z_0096_1	46 %	59 %	63 %	30 %	30 %
Délka		42 %	85 %	0 %	45 %	45 %

Tab. XXV: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo ředkvička

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	redkvicka_Z_0016_1	44 %	77 %	25 %	40 %	40 %
LPC13	redkvicka_Z_0099_1	38 %	83 %	21 %	17 %	17 %
MFCC8	redkvicka_Z_0004_1	44 %	92 %	6 %	23 %	23 %
MFCC13	redkvicka_Z_0004_1	46 %	92 %	6 %	29 %	29 %
Energie	redkvicka_Z_0030_1	39 %	65 %	14 %	36 %	36 %
Délka		32 %	61 %	25 %	7 %	7 %

Tab. XXVI: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo silnice

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	silnice_Z_0036_1	39 %	84 %	23 %	13 %	13 %
LPC13	silnice_Z_0073_1	40 %	88 %	0 %	18 %	18 %
MFCC8	silnice_Z_0083_1	46 %	89 %	15 %	25 %	25 %
MFCC13	silnice_Z_0020_1	47 %	88 %	28 %	20 %	20 %
Energie	silnice_Z_0047_1	42 %	83 %	25 %	26 %	26 %
Délka		37 %	81 %	2 %	37 %	37 %

Tab. XXVII: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo sluníčko

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	slunicko_Z_0022_1	35 %	91 %	15 %	2 %	2 %
LPC13	slunicko_Z_0036_1	36 %	91 %	22 %	2 %	2 %
MFCC8	slunicko_Z_0079_1	43 %	85 %	26 %	16 %	16 %
MFCC13	slunicko_Z_0079_1	42 %	88 %	21 %	16 %	16 %
Energie	slunicko_Z_0063_1	41 %	64 %	25 %	42 %	42 %
Délka		36 %	81 %	29 %	14 %	14 %

Tab. XXVIII: Přesnost jednodimenzionálního Bayes klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo ucho

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	ucho_Z_0002_1	38 %	92 %	29 %	1 %	1 %
LPC13	ucho_Z_0020_1	39 %	86 %	24 %	3 %	3 %
MFCC8	ucho_Z_0005_1	44 %	90 %	29 %	11 %	11 %
MFCC13	ucho_Z_0020_1	45 %	84 %	40 %	17 %	17 %
Energie	ucho_Z_0035_1	41 %	69 %	45 %	20 %	20 %
Délka		35 %	83 %	20 %	2 %	2 %

Tab. XXIX: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova čokoláda

parametr	Jména	Celek	Z	N
LPC8	cokolada_Z_0040_1	77 %	30 %	95 %
LPC13	cokolada_Z_0007_1	78 %	41 %	92 %
MFCC8	cokolada_Z_0053_1	86 %	68 %	94 %
MFCC13	cokolada_Z_0060_1	87 %	71 %	93 %
Energie	cokolada_Z_0086_1	77 %	26 %	96 %
Délka		72 %	0 %	100 %

Tab. XXXI: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova fotbalista

Parametr	Jména	Celek	Z	N
LPC8	fotbalista_Z_0084_1	83 %	63 %	93 %
LPC13	fotbalista_Z_0031_1	85 %	78 %	88 %
MFCC8	fotbalista_Z_0021_1	88 %	81 %	92 %
MFCC13	fotbalista_Z_0033_1	88 %	78 %	93 %
Energie	fotbalista_Z_0005_1	79 %	41 %	98 %
Délka		69 %	21 %	93 %

Tab. XXXII: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova hamburger

Parametr	Jména	Celek	Z	N
LPC8	hamburger_Z_0040_1	74 %	25 %	95 %
LPC13	hamburger_Z_0027_1	74 %	35 %	91 %
MFCC8	hamburger_Z_0028_1	89 %	80 %	92 %
MFCC13	hamburger_Z_0028_1	89 %	79 %	93 %
Energie	hamburger_Z_0021_1	77 %	45 %	91 %
Délka		70 %	1 %	100 %

Tab. XXXIII: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova jezek

Parametr	Jména	Celek	Z	N
LPC8	jezek_Z_0040_1	80 %	38 %	97 %
LPC13	jezek_Z_0041_1	79 %	35 %	96 %
MFCC8	jezek_Z_0042_1	87 %	76 %	91 %
MFCC13	jezek_Z_0042_1	87 %	78 %	91 %
Energie	jezek_Z_0005_1	75 %	25 %	95 %
Délka		72 %	0 %	100 %

Tab. XXXIV: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova košile

Parametr	Jména	Celek	Z	N
LPC8	kosile_Z_0023_1	78 %	48 %	90 %
LPC13	kosile_Z_0085_1	80 %	46 %	94 %
MFCC8	kosile_Z_0084_1	87 %	72 %	93 %
MFCC13	kosile_Z_0083_1	87 %	69 %	94 %
Energie	kosile_Z_0040_1	76 %	19 %	99 %
Délka		71 %	0 %	100 %

Tab. XXXV: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova popelnice

Parametr	Jména	Celek	Z	N
LPC8	popelnice_Z_0033_1	82 %	55 %	93 %
LPC13	popelnice_Z_0041_1	81 %	57 %	91 %
MFCC8	popelnice_Z_0007_1	92 %	77 %	98 %
MFCC13	popelnice_Z_0039_1	91 %	82 %	95 %
Energie	popelnice_Z_0058_1	84 %	59 %	95 %
Délka		71 %	0 %	100 %

Tab. XXXVI: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova Rákosníček

Parametr	Jména	Celek	Z	N
LPC8	rakosnicek_Z_0088_1	83 %	60 %	93 %
LPC13	rakosnicek_Z_0007_1	82 %	62 %	91 %
MFCC8	rakosnicek_Z_0005_1	89 %	85 %	91 %
MFCC13	rakosnicek_Z_0005_1	89 %	86 %	91 %
Energie	rakosnicek_Z_0041_1	78 %	35 %	97 %
Délka		70 %	0 %	100 %

Tab. XXXVII: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova ředkvička

Parametr	Jména	Celek	Z	N
LPC8	redkvicka_Z_0082_1	78 %	44 %	93 %
LPC13	redkvicka_Z_0077_1	80 %	51 %	93 %
MFCC8	redkvicka_Z_0004_1	88 %	76 %	93 %
MFCC13	redkvicka_Z_0004_1	88 %	76 %	93 %
Energie	redkvicka_Z_0015_1	75 %	32 %	94 %
Délka		71 %	4 %	100 %

Tab. XXXVIII: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova silnice

Parametr	Jména	Celek	Z	N
LPC8	silnice_Z_0023_1	81 %	49 %	93 %
LPC13	silnice_Z_0023_1	82 %	52 %	93 %
MFCC8	silnice_Z_0059_1	87 %	73 %	93 %
MFCC13	silnice_Z_0059_1	88 %	78 %	92 %
Energie	silnice_Z_0057_1	77 %	25 %	98 %
Délka		72 %	0 %	100 %

Tab. XXXIX: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova sluníčko

Parametr	Jména	Celek	Z	N
LPC8	slunicko_Z_0018_1	79 %	42 %	94 %
LPC13	slunicko_Z_0002_1	80 %	42 %	95 %
MFCC8	slunicko_Z_0010_1	85 %	65 %	94 %
MFCC13	slunicko_Z_0010_1	86 %	65 %	94 %
Energie	slunicko_Z_0057_1	76 %	27 %	96 %
Délka		71 %	0 %	100 %

Tab. XL: Přesnost jednodimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova ucho

Parametr	Jména	Celek	Z	N
LPC8	ucho_Z_0084_1	80 %	39 %	96 %
LPC13	ucho_Z_0023_1	81 %	41 %	97 %
MFCC8	ucho_Z_0033_1	82 %	56 %	92 %
MFCC13	ucho_Z_0033_1	82 %	58 %	91 %
Energie	ucho_Z_0056_1	77 %	25 %	97 %
Délka		72 %	0 %	100 %

Tab. XLI: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo čokoláda

parametr	Jména	Celek	Z	N1	N2	N3
LPC8	cokolada_Z_0023_1	47 %	71 %	0 %	79 %	0 %
LPC13	cokolada_Z_0007_1	48 %	76 %	1 %	76 %	0 %
MFCC8	cokolada_Z_0053_1	56 %	79 %	11 %	89 %	4 %
MFCC13	cokolada_Z_0053_1	56 %	80 %	7 %	89 %	4 %
Energie	cokolada_Z_0085_1	44 %	66 %	0 %	64 %	29 %
Délka		44 %	71 %	10 %	61 %	0 %

Tab. XLII: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo fotbalista

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	fotbalista_Z_0036_1	56 %	81 %	18 %	74 %	0 %
LPC13	fotbalista_Z_0037_1	56 %	84 %	27 %	65 %	0 %
MFCC8	fotbalista_Z_0063_1	62 %	85 %	27 %	83 %	0 %
MFCC13	fotbalista_Z_0028_1	62 %	85 %	42 %	68 %	0 %
Energie	fotbalista_Z_0056_1	53 %	73 %	53 %	44 %	0 %
Délka		48 %	90 %	0 %	55 %	0 %

Tab. XLIII: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo hamburger

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	hamburger_Z_0049_1	45 %	77 %	16 %	55 %	0 %
LPC13	hamburger_Z_0020_1	47 %	79 %	13 %	60 %	0 %
MFCC8	hamburger_Z_0028_1	57 %	88 %	8 %	87 %	0 %
MFCC13	hamburger_Z_0028_1	57 %	84 %	12 %	87 %	0 %
Energie	hamburger_Z_0004_1	47 %	67 %	9 %	74 %	5 %
Délka		41 %	76 %	5 %	53 %	0 %

Tab. XLIV: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo jezek

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	jezek_Z_0040_1	47 %	65 %	0 %	85 %	0 %
LPC13	jezek_Z_0040_1	47 %	68 %	0 %	81 %	2 %
MFCC8	jezek_Z_0077_1	55 %	90 %	0 %	86 %	0 %
MFCC13	jezek_Z_0072_1	56 %	88 %	0 %	84 %	19 %
Energie	jezek_Z_0072_1	45 %	64 %	2 %	73 %	10 %
Délka		44 %	80 %	1 %	60 %	4 %

Tab. XLV: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo košile

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	kosile_Z_0095_1	49 %	76 %	0 %	76 %	0 %
LPC13	kosile_Z_0085_1	50 %	76 %	0 %	81 %	0 %
MFCC8	kosile_Z_0003_1	56 %	82 %	0 %	90 %	11 %
MFCC13	kosile_Z_0003_1	56 %	79 %	0 %	90 %	11 %
Energie	kosile_Z_0094_1	46 %	50 %	0 %	85 %	11 %
Délka		39 %	72 %	0 %	52 %	0 %

Tab. XLVI: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo popelnice

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	popelnice_Z_0032_1	51 %	77 %	8 %	75 %	0 %
LPC13	popelnice_Z_0072_1	52 %	85 %	0 %	77 %	0 %
MFCC8	popelnice_Z_0035_1	60 %	84 %	23 %	87 %	0 %
MFCC13	popelnice_Z_0083_1	61 %	86 %	14 %	93 %	0 %
Energie	popelnice_Z_0042_1	53 %	77 %	1 %	85 %	7 %
Délka		41 %	72 %	0 %	56 %	0 %

Tab. XLVII: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo Rákosníček

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	rakosnicek_Z_0098_1	54 %	86 %	0 %	82 %	0 %
LPC13	rakosnicek_Z_0085_1	53 %	76 %	18 %	75 %	0 %
MFCC8	rakosnicek_Z_0083_1	65 %	88 %	36 %	85 %	0 %
MFCC13	rakosnicek_Z_0083_1	64 %	86 %	35 %	83 %	0 %
Energie	rakosnicek_Z_0052_1	50 %	64 %	10 %	80 %	6 %
Délka		45 %	86 %	0 %	55 %	0 %

Tab. XLVIII: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo ředkvička

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	redkvicka_Z_0039_1	50 %	58 %	11 %	86 %	0 %
LPC13	redkvicka_Z_0095_1	49 %	60 %	8 %	83 %	0 %
MFCC8	redkvicka_Z_0022_1	59 %	86 %	31 %	72 %	0 %
MFCC13	redkvicka_Z_0004_1	59 %	84 %	22 %	81 %	0 %
Energie	redkvicka_Z_0015_1	45 %	55 %	0 %	83 %	0 %
Délka		42 %	85 %	9 %	39 %	0 %

Tab. XLIX: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo silnice

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	silnice_Z_0072_1	50 %	75 %	0 %	81 %	0 %
LPC13	silnice_Z_0059_1	52 %	83 %	10 %	74 %	0 %
MFCC8	silnice_Z_0084_1	58 %	76 %	23 %	87 %	0 %
MFCC13	silnice_Z_0015_1	59 %	86 %	17 %	86 %	0 %
Energie	silnice_Z_0047_1	47 %	69 %	0 %	76 %	3 %
Délka		40 %	75 %	0 %	53 %	0 %

Tab. L: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo sluníčko

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	slunicko_Z_0013_1	50 %	73 %	5 %	78 %	0 %
LPC13	slunicko_Z_0031_1	49 %	75 %	7 %	72 %	0 %
MFCC8	slunicko_Z_0033_1	55 %	80 %	5 %	88 %	0 %
MFCC13	slunicko_Z_0012_1	55 %	86 %	8 %	80 %	0 %
Energie	slunicko_Z_0083_1	47 %	71 %	0 %	75 %	3 %
Délka		42 %	68 %	2 %	63 %	0 %

Tab. LI: Přesnost jednodimenzionálního SVM klasifikátoru pro klasifikaci více tříd zdravý/nezdravý kategorie 1/ nezdravý kategorie 2/ nezdravý kategorie 3 pro slovo ucho

Parametr	Jména	Celek	Z	N1	N2	N3
LPC8	ucho_Z_0032_1	48 %	69 %	5 %	75 %	15 %
LPC13	ucho_Z_0061_1	48 %	68 %	1 %	81 %	2 %
MFCC8	ucho_Z_0075_1	56 %	75 %	42 %	63 %	23 %
MFCC13	ucho_Z_0075_1	55 %	77 %	38 %	63 %	21 %
Energie	ucho_Z_0084_1	45 %	65 %	0 %	74 %	6 %
Délka		40 %	82 %	0 %	47 %	4 %

Tab. LII: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova čokoláda

Metoda	Jména	Celek	Z	N
L8+M13	cokolada_Z_0053_1	87 %	72 %	93 %
L8+M13+E	cokolada_Z_0053_1	88 %	73 %	93 %
L8+M13+D	cokolada_Z_0060_1	88 %	73 %	94 %
L8+M13+E+D	cokolada_Z_0053_1	89 %	76 %	94 %

Tab. LIII: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova fotbalista

Metoda	Jména	Celek	Z	N
L8+M13	fotbalista_Z_0033_1	89 %	84 %	91 %
L8+M13+E	fotbalista_Z_0010_1	88 %	84 %	91 %
L8+M13+D	fotbalista_Z_0033_1	90 %	84 %	93 %
L8+M13+E+D	fotbalista_Z_0033_1	89 %	83 %	93 %

Tab. LIV: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova hamburger

Metoda	Jména	Celek	Z	N
L8+M13	hamburger_Z_0048_1	89 %	75 %	95 %
L8+M13+E	hamburger_Z_0017_1	89 %	76 %	94 %
L8+M13+D	hamburger_Z_0043_1	90 %	78 %	95 %
L8+M13+E+D	hamburger_Z_0028_1	91 %	83 %	94 %

Tab. LV: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova ježek

Metoda	Jména	Celek	Z	N
L8+M13	jezek_Z_0042_1	87 %	78 %	91 %
L8+M13+E	jezek_Z_0028_1	87 %	76 %	91 %
L8+M13+D	jezek_Z_0056_1	89 %	78 %	93 %
L8+M13+E+D	jezek_Z_0032_1	89 %	74 %	94 %

Tab. LVI: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova košile

Metoda	Jména	Celek	Z	N
L8+M13	kosile_Z_0084_1	87 %	67 %	94 %
L8+M13+E	kosile_Z_0083_1	87 %	71 %	94 %
L8+M13+D	kosile_Z_0056_1	88 %	70 %	95 %
L8+M13+E+D	kosile_Z_0056_1	87 %	70 %	94 %

Tab. LVII: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova popelnice

Metoda	Jména	Celek	Z	N
L8+M13	popelnice_Z_0083_1	92 %	81 %	96 %
L8+M13+E	popelnice_Z_0039_1	92 %	83 %	96 %
L8+M13+D	popelnice_Z_0033_1	93 %	87 %	96 %
L8+M13+E+D	popelnice_Z_0033_1	94 %	88 %	97 %

Tab. LVIII: Přesnost vícedimenzionálního SVM Klasifikátoru pro binární klasifikaci Zdravý/ Nezdravý pro slova Rákosníček

Metoda	Jména	Celek	Z	N
L8+M13	rakosnicek_Z_0007_1	90 %	81 %	94 %
L8+M13+E	rakosnicek_Z_0007_1	90 %	81 %	94 %
L8+M13+D	rakosnicek_Z_0005_1	91 %	89 %	92 %
L8+M13+E+D	rakosnicek_Z_0007_1	91 %	84 %	94 %

Tab. LVIII: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo ředkvička

Metoda	Jména	Celek	Z	N
L8+M13	redkvička_Z_0004_1	88 %	82 %	91 %
L8+M13+E	redkvička_Z_0004_1	88 %	82 %	91 %
L8+M13+D	redkvička_Z_0022_1	89 %	82 %	92 %
L8+M13+E+D	redkvička_Z_0022_1	89 %	79 %	93 %

Tab. LIX: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo silnice

Metoda	Jména	Celek	Z	N
L8+M13	silnice_Z_0059_1	88 %	77 %	92 %
L8+M13+E	silnice_Z_0059_1	88 %	77 %	93 %
L8+M13+D	silnice_Z_0047_1	89 %	74 %	94 %
L8+M13+E+D	silnice_Z_0059_1	89 %	80 %	93 %

Tab. LX: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slovo sluníčko

Metoda	Jména	Celek	Z	N
L8+M13	slunicko_Z_0059_1	85 %	72 %	91 %
L8+M13+E	slunicko_Z_0031_1	87 %	70 %	94 %
L8+M13+D	slunicko_Z_0010_1	87 %	71 %	94 %
L8+M13+E+D	slunicko_Z_0031_1	88 %	72 %	94 %

Tab. LXI: Přesnost vícedimenzionálního SVM klasifikátoru pro binární klasifikaci zdravý/ nezdravý pro slova ucho

Metoda	Jména	Celek	Z	N
L8+M13	ucho_Z_0033_1	84 %	64 %	92 %
L8+M13+E	ucho_Z_0088_1	84 %	58 %	95 %
L8+M13+D	ucho_Z_0033_1	83 %	64 %	91 %
L8+M13+E+D	ucho_Z_0033_1	84 %	63 %	92 %