
**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**
**BRNO UNIVERSITY OF TECHNOLOGY**

**FAKULTA INFORMAČNÍCH TECHNOLOGIÍ**
**FACULTY OF INFORMATION TECHNOLOGY**

**ÚSTAV INTELIGENTNÍCH SYSTÉMŮ**
**DEPARTMENT OF INTELLIGENT SYSTEMS**


# NÁSTROJ PRO PODPORU CVIČENÍ KLAVÍRNÍCH SKLADEB

**TOOL FOR PIANO PRACTICING**

**DIPLOMOVÁ PRÁCE**
**MASTER'S THESIS**


**AUTOR PRÁCE** **Bc. NIKITA USTINOV**
**AUTHOR**

**VEDOUCÍ PRÁCE** **Dr. Ing. FRANTIŠEK ZBOŘIL, Ph.D.**
**SUPERVISOR**



**BRNO 2020**

**Vysoké učení technické v Brně**
Fakulta informačních technologií

Ústav inteligentních systémů (UITS) Akademický rok 2019/2020

# Zadání diplomové práce


Student: **Ustinov Nikita, Bc.**
Program: Informační technologie Obor: Inteligentní systémy
Název: **Nástroj pro podporu cvičení klavírních skladeb**
**Tool for Piano Practising**
Kategorie: Umělá inteligence
Zadání:

1. Seznamte se s nástroji, které umožňují převádět zachycený zvuk při hře na piano do notového zápisu. Zvolte takovou implementaci systému, která umožňuje své začlenění do externích aplikací.
2. Navrhněte systém, který by pro zvolené klavírní cvičení v notovém zápise umožnil tento zápis digitálně zpracovat a následně kontrolovat, zdali přehrávání tohoto cvičení odpovídá zápisu.
3. Realizujte vámi navržený systém jako mobilní nebo desktopovou aplikaci.
4. Testujte vhodnost vámi vytvořené aplikace na několika lidech, kteří jsou ve hře na piano různě pokročilí a zpracujte jejich hodnocení této aplikace.

Literatura:

- Beauchamp, J. W.: Analysis, synthesis, and perception of musical sounds. Springer. 2007
- Russel, S., Norvig, P.: Artificial Intelligence, A Modern Approach, Pearson, 2009

Při obhajobě semestrální části projektu je požadováno:

- První dva body zadání

Podrobné závazné pokyny pro vypracování práce viz https://www.fit.vut.cz/study/theses/
Vedoucí práce: **Zbořil František, doc. Ing., Ph.D.**
Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.
Datum zadání: 1. listopadu 2019
Datum odevzdání: 31. července 2020
Datum schválení: 31. října 2019

# Abstrakt

Účelem této práce je navrhnout a implementovat aplikaci pro cvičení hry na klavíru. Hlavní nevýhodou již existujících aplikací je omezený výběr skladeb, které lze cvičit, protože tyto skladby jsou pevně zapsané v paměti. Aplikace která je výsledkem této práci vyřeší daný problém - uživatel bude moct nahrát do aplikace libovolnou klavírní nahrávku kterou chce cvičit a aplikace se postará o vytvoření procesu cvičení. Proces cvičení se spočívá v ukázce uživatelů určitým způsobem upravených not, a současná kontrola, pomocí mikrofonu, co hraje uživatel. Největším výzvou dané diplomové práce bylo najít způsob jak přesně a rychle klasifikovat audio signál z mikrofonů. Daná úloha byla vyřešena pomocí dvou nezávislých neuronových sítí s různou architekturou, které byli trénovány na různých datových sadech. Za účelem odůvodnění zvoleného řešení budou uvedeny všechny potřebné teoretické muzikální a vědecké pojmy a metody, které mají k tomu přímý vztah. Výsledná aplikace bude testována z třech hledisek: přesnosti, rychlosti, uživatelské použitelnosti.



# Abstract

The purpose of this work is to design and implement an application for piano practice. The main disadvantage of existing applications is the limited selection of songs that can be practiced. The application, which is the result of this work, will solve the problem - the user will be able to upload to the application any piano record he wants to practice, and the application will take care of creating a training process. The training process consists of showing the user a certain way of editing notes and simultaneously controlling what the user is playing with a microphone. The biggest challenge of the diploma thesis was to find a way to accurately and quickly classify the audio signal from the microphone. This problem was solved using two independent neural networks with different architectures, which were trained on different data sets. To justify the chosen solution, all the necessary theoretical musical and scientific concepts and methods that are directly related to it will be presented. The resulting application will be tested in three respects: accuracy, speed, the usability of the user.



# Klíčová slova

strojové učení, neuronové sítě, automatizovaná transkripce hudby

# Keywords

machine learning, neural networks, automatic music transcription


# Citace

USTINOV, Nikita. *Nástroj pro podporu cvičení klavírních skladeb*. Brno, 2020. Diplomová práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Dr. Ing. František Zbořil, Ph.D.

# Nástroj pro podporu cvičení klavírních skladeb

## Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana Dr. Ing. Zbořila, Ph.D. Uvedl jsem všechny literární prameny, publikace a další zdroje, ze kterých jsem čerpal.

.....
Nikita Ustinov
31. července 2020


## Poděkování

Děkuji vedoucímu práce Dr. Ing. Františeku Zbořilu, Ph. D. za metodickou a odbornou pomoc při zpracování této diplomové práce.

Výpočtové prostředky byly poskytnuty v rámci projektu „e-Infrastruktura CZ“ (e-INFRA LM2018140) poskytovaného v rámci programu Projekty velkých infrastruktur výzkumu, vývoje a inovací.

# Obsah

# Kapitola 1

# Úvod

V dnešní době existuje velké množství aplikací pro cvičení hry téměř pro jakýkoliv nástroj, včetně klavíru. Hlavní nevýhodou takových aplikací je omezený výběr skladeb, které lze cvičit, protože tyto skladby jsou pevně zapsané v paměti a zpravidla je nelze přidat zvnějšku. Účelem této práce je navrhnout a implementovat aplikaci pro cvičení hry na klavíru, kde uživatel může cvičit jakoukoliv skladbu, k níž má nahrávku. Bodové shrnutí procesu cvičení je následující:

- Uživatel nahraje do aplikace audio záznam klavírní hudby.
- Aplikace převede daný záznam do MIDI (nebo jiného vnitřního) formátu.
- Aplikace bude postupně dělat dvě věci: ukazovat uživateli noty které jsou reprezentovaný barevnými obdélníky a na základě poslouchaní mikrofonem kontrolovat co uživatel hraje na klavíru. Obdélníky postupně padají na klávesy v GUI. Když se obdélník dotkne klávesy, program zastaví padající klávesy a bude čekat pokud uživatel nezmáčkne příslušnou klávesu na klavíru. Po zmáčknutí padání bude pokračovat. Obr. 1.1 demonstruje možné GUI.

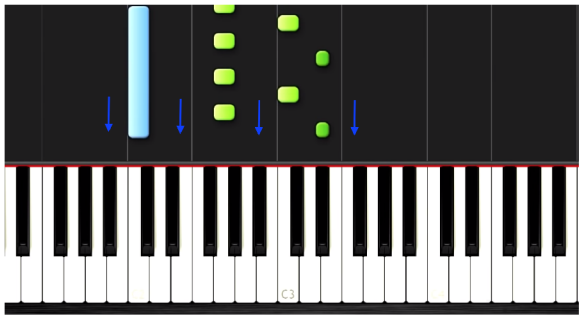


Obrázek 1.1: Možný UI TODO [?]

Takový cvičící proces může být velmi užitečný pro uživatele, který nezná muzikální teorie, noty a notový zápisu. Grafická reprezentace not ve tvaru padajících obdélníků může uživatele naučit kdy a jakou klávesy musí zmáčknout, aby zazněla správná melodie.

Zjednodušením od standardní úlohy automatizované transkripci hudby (automatic music transcription, AMT [1]) je skutečnost, že v dané aplikace nebudeme brat v úvahu polifonickou hudbu tj. hudbu která se skládá z více zdrojů (hlas, kytara, klavír): nadále budeme

předpokládat, že na vstupu bude nahrávka obsahující pouze klavír. Návrh takové aplikace představuje netriviální úlohu, zejména kvůli následujícím dvěma problémům. První vyzvou je přesný překlad zvukového záznamu uživatele do vnitřní reprezentace, na základe které pak bude uživatel cvičen. Druhým problém je pořízení zvuku z mikrofonu a kontrola v reálném čase zda to, co uživatel hraje, odpovídá originální nahrávce, aby aplikace včas zastavila padání not. Hlavním rozdílem mezi prvním a druhým problémem je nárok na přesnost a rychlost. V prvním případě je důležitá přesnost transkripce hudby do not, zatímco rychlost zpracování kritická není. Oproti tomu ve druhém případě, při real-time kontrole uživatele, je doba zpracování jednoho zvukového fragmentu na prvním místě. Oba dva problémy lze redukovat na problém klasifikace přehrávaných not podle fragmentu zvukového záznamu. Nejběžnějším způsobem klasifikace zvuku v těchto dnech jsou neuronové sítěTODO cite, skryte Markovske retezceTODO cite nebo techniky zpracování signálu (např. autokoreleaceTODO cite).

Naše řešeni je založené na použiti dvou různé velkých neuronových síti (každá pro jednotlivé části programu) s různými architekturami. První neuronová síť bude zaměřena na přesnou transkripci nahrávky do notového zápisu. Taková síť se všemi kladenými na ní požadavky jíž existuje a byla zveřejněna v prací (6). Danou síť jednoduše integrujeme do výsledné aplikaci. Druhá síť bude vytvořená vlastními síly a použita za účelem průběžné kontroly zvuku z mikrofonu, během cvičícího procesu. Velka část dané práci se bude zabývat pravě vytvořením vlastní real-time neuronové sítě: výběru architektury, formátu vstupních dat, přípravou datasetu a samotnému trénování.

Celkové řešení bude testováno zda odpovídá časovým požadavkům na real-time a zda je použitelné pro konečného uživatele.

# Kapitola 2

# Teoretický základ

Na začátek je potřeba formalizovat předmět našeho zájmu. Tato kapitola vymezuje všechny pojmy a principy, znalost kterých je nezbytná pro pochopeni dané práce.

## 2.1 Zvuk a reprezentace zvuku

Zvuk [**?**] je fyzický fenomén, který se šíří ve formě elastických vln mechanických vibrací v prostoru. Stejně jako libovolná vlna zvuk se dá popsat amplitudou a frekvenci. Člověk dokáže vnímat zvuku s frekvenci od 16—20 Hz do 15—20 kHz. Klavír produkuje zvuk od 27.5-4186 Hz (odpovídá notám A0 až C8, víz dal)[2, 3].

### 2.1.1 Ton, nota

Ton je stálý zvuk s určitou frekvenci[1]. Z kombinace tónů se skládá hudba. Notou nazýváme grafickou reprezentaci tonu, víz. Obr 3.1 (Hudební zápis not). Pro pojmenovaní not používáme následující symboly: C, D, E, F, G, A, B. Když frekvenční poměr dvou zvuku je stupněm dvojky, potom tyto zvuky vnímáme jako podobné a značíme stejným symbolem. Interval mezi těmito zvuky se nazývá oktáva. Každá oktáva se dále dělí na 12 intervalů které se nazývá půltóny. Pro rozlišení mezi stejnými noty různých oktáv se používají číslice, např. C1, D4 atd.[1,2] Síla tonu udává jeho hlasitost.

### 2.1.2 Formáty audio

**WAV.** Chceme-li zvuk zapsat nebo přehrát na nějakém elektronickém zařízení, je potřeba použít vhodný zvukový formát, který moderní zařízení dokážou pochopit. Základním formátem kterému rozumí všechny počítače s operačním systémem Windows je WAV formát. Ve své podstatě WAV představuje kontejner (obálka) nad určitým audio formátem, typicky nad formátem PCM (Pulse Code Modulation). PCM je docela starý formát, ale v něm se dá zapsat velmi kvalitny zvuk. PCM soubor obsahuje sekvenci vzorků v čase, kde každý vzorek udává amplitudu (sílu) signálu v určitý okamžik (víz Obr. 2.1). Nevýhodou daného formátu je jeho příliš velký rozměr. Právě tento problém se snažili vyřešit pozdější formáty jako například MP3.

**MIDI.** Musical Instrument Digital Interface (MIDI) je jedním z nejvýznamnějších formátů přenosu hudby. Převážně se používá pro ukládání kompozici produkovaných různými

[1] V literatuře se často říká že tón je stálý zvuk s určitou výškou. Vyšku ale se dá odvodit jednoduchými výpočty z frekvenci. Proto v textu jsme odvozujeme výšku od frekvenci.

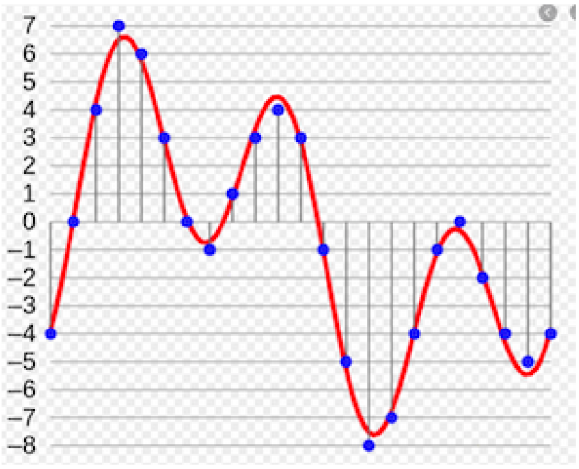


Obrázek 2.1: PCM ukázka

hudebními nástroji. Na rozdíl od WAV, MIDI se nesnaží uložit každý vzorek v každý okamžik, ale ukládá pouze noty (klávesy, struny apod.) které byli spuštěny v daný okamžik, čímž dokáže silně redukovat velikost cílového souboru. Na Obr. 2.2 je vidět standardní MIDI soubor.

```
<message note_on channel=0 note=52 velocity=40 time=1521>
<message note_on channel=0 note=64 velocity=42 time=0>
<message note_on channel=0 note=59 velocity=43 time=211>
<message note_on channel=0 note=64 velocity=0 time=141>
<message note_on channel=0 note=64 velocity=44 time=0>
<message note_on channel=0 note=55 velocity=45 time=14>
<message note_on channel=0 note=59 velocity=0 time=126>
<message note_on channel=0 note=59 velocity=46 time=0>
<message note_on channel=0 note=52 velocity=0 time=141>
```

Obrázek 2.2: MIDI soubor je strukturován jako seznam událostí. Každá událost obsahuje značku , kód klávesy (notě), čas (time) a rychlost (velocity). Kód klávesy je to speciální MIDI kód který jednoznačně odkazuje na klávesu na hudebním nástroji. Čas události říká kolik časových jednotek uplynulo od předchozí události. Rychlost udává s jakou silou byla zmáčknutá klávesa. Pokud rychlost se rovná nule, tato událost odkazuje na skutečnost že klávesa byla uvolněna.

### 2.1.3 Frekvenční reprezentace zvuku

Těžko se dá analyzovat zvuk pouze na základě amplitud roztažených v čase. Většinou chceme vědět jaké frekvence obsahuje zvuková nahrávka. Proto budeme potřebovat transformovat amplitudy (PCM vzorky) do frekvencí které tento zvuk obsahuje, jinými slovy budeme potřebovat spektrum vstupního signálu. Za tím účelem můžeme použít Diskrétní Fourierovou Transformací (DFT). Nechť $\{x_n\}_{0 \leq n \leq N}$ je vzorkovaný audio signál. $k$-ta složka jeho frekvenčního spektra, $X_k$, se počítá podle následujícího vzorce:

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{i2\pi}{N}kn}.$$

DFT vezme na vstup vzorkovaný signál a na výstupu budeme mít obrazek signál rozloženy ve frekvenční doméně. V praxi se ale používá jeho zrychlená podoba FFT (Fast Fourier Transformation), která má časovou složitost $\mathcal{O}(N \log N)$ oproti $\mathcal{O}(N^2)$ u DFT. Ukázka transformaci zvukového signálu do spectra pomoci DFT je na Obr. 2.3.

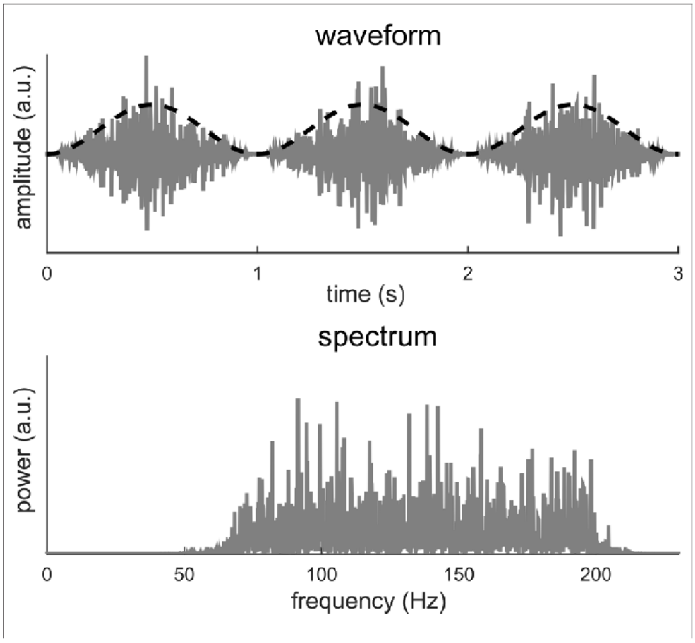


Obrázek 2.3: Příklad transformaci pomoci DFT

DFT (FFT) má ale jednu nepříjemnou vlastnost: když ji provedeme ztratíme informaci o čase. Například při transformaci hudební skladby pomocí FFT budeme vidět frekvencí a amplitudy z dané skladby, ale vůbec nebudeme tušit v jakém okamžiku tyto frekvence se objevili. Proto když chceme signál(zvuk) analyzovat v čase potřebujeme trochu jinou reprezentaci, kterou je spektrogram. Spektrogram dostaneme tím způsobem, že vstupní signál nasekáme na rámce (vynásobením signál posuvným oknem) a v každém rámci spočítáme FFT. Příklad spektrogramu je vidět na Obr. 2.4[**?**]

Tady je problém v tom, že přesnost v časové doméně a ve frekvenční jsou navzájem vylučující. Když zvyšujeme rozlišení v čase (např. při použití malého okna), ztratíme přesnost frekvenčního rozlišení a naopak. Zvuková reprezentace pomocí lineárně uspořádaných frekvenci neodpovídá přesně tomu jak zvuk vnímá člověk, proto v praxi klasický spéct (spektrogram) není moc populární.

Jednou z možných alternativ je Mel-spektogram. Daný způsob vytváření spektra je inspirován přírodou — způsobem jak člověk dokáže vnímat různé frekvence.[2] Mel-spektrogram je klasický spektrogram, který je komprimován ve frekvenční ose, a proto může být efektivnější ve své velikosti při zachování nejdůležitějších informací.[**?**] Mel transformaci se dá popsat teto formuli:

[2]Člověk lepe rozlišuje nízké frekvence. Se zvýšením frekvenci schopnost člověka jích rozlišit logaritmický klesá.

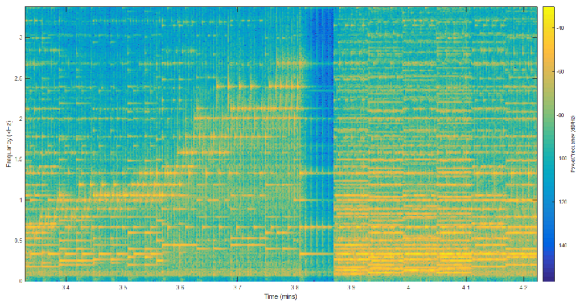

Obrázek 2.4: Spektrogram klavírní skladby [**?**]

$$m = 2595 \log_{10}\left(1 + \frac{f}{700}\right),$$

kde f je právě transformovaná frekvence. [**?**] Ukázka Měl transformace je na Obr. **??**

Jinou možnou alternativou je Constant-Q (CQT) spektrogram. CQT spektrum poskytuje 2D reprezentací s logaritmickými měřítky středních frekvencí, což je dobře sladěno s frekvenčním rozložením tónu, proto se CQT používá převážně tam, kde by základní frekvence not měly být přesně identifikovány, například pro rozpoznávání akordů nebo transkripci not. Je ale nutné zdůraznit, že výpočet CQT je o něco náročnější než výpočet klasického spektrogramu nebo Mel-spektrogramu. Transformací klasického spektrogramu do CQT spektrogramu popisuje vzorek

$$f_c(k_{lf}) = f_{min} \times 2^{\frac{k_{lf}}{\beta}}, \tag{2.1}$$

kde $f_{min}$ je to minimální analyzovaná frekvence, $k_{lf}$ - index filtru, $\beta$ - počet bínů v oktávě.

Další reprezentaci zvuku je tzv. cepstrum [**?**]. Jedná se o výsledek inverzní Fourierova Transformace. Podobně jako u spektrogramů, existuje také varianta Mel-transformace cepstra – Mel-cepstrum.

## 2.2 Modely pro transkripci zvuku

Pro účely klasifikace nebo rozpoznávání not se používají různé matematické modely. Mezi nejvýznamnější modely pro automatizovanou transkripci hudby patří skryté Markovské řetězce (hidden Markov chain, HMM [3]) a neuronové sítě [**?**]. Nejprve v rychlosti popíšeme HMM.

**Definice 1.** Nechť $X_n$ a $Y_n$ jsou stochastické procesy v diskrétním čase a $n \geq 1$. Potom dvojice $(X_n, Y_n)$ je Skrytý Markovův Model pokud platí:

- $X_n$ je Markov proces a není přímo pozorovatelný (skrytý)
- $\boldsymbol{P}\left(Y_n \in A \mid X_1 = x_1, \ldots, X_n = x_n\right) = \boldsymbol{P}\left(Y_n \in A \mid X_n = x_n\right)$, pro každé $n \geq 1, x1, \ldots, x_n$, a měřitelnou množinu $A$.

Jinými slovy HMM je statistický model, který simuluje činnost procesů podobného Markovovu procesu s neznámými parametry. Při učení je potřeba najít neznámé parametry na

základě pozorovatelných. Získané parametry mohou být použity v další analýze, například pro rozpoznávání vzorů. Například existuje nějaký klasifikační úkol pouze s jednou třídou, potom HMM může vypadat následovně:

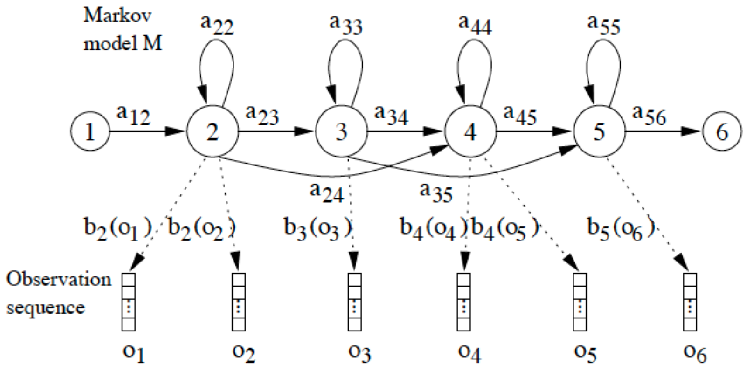


Obrázek 2.5: Skrytý Markovův model který dokáže říct, zda nějaký vzorek patří pouze do jedné konkrétní třídy [**?**].

Jak je vidět, HMM se skládá z několika skrytých stavů. Každý stav po trénování má uvnitř Gaussovou funkcí. Přechod mezi stavy se provádí s určitou pravděpodobností (na obrázku $a_{ij}$). Na vstup (do stavu 1) se podává nějaká sekvence. Výstupem potom bude míra podobnosti vstupní sekvencí a sekvence které HMM se naučil. Tato míra podobnosti se určuje tak, že každý stav podle nauče Gaussové funkcí se počítá pravděpodobnost že i-ty element vstupní sekvence je shodný s j-tým elementem naučených sekvencí. Na základě těchto dílčích pravděpodobností výstupní stav se potom spočítá celkovou pravděpodobnost že vstupní sekvence je shodná se naučenými sekvencemi. Při výpočtu může nastat problém když vstupní sekvence má jiný počet elementů než počet stavů HMM(I <> J). Tento problém se dá řešit sestavením různých cest pomocí Dynamic Time Warping metodu (popsáno dál). Když je potřeba rozpoznávat více tříd (což je typické) potom k tomuto modelu se přidává stejné modely (které ale se snaží naučit jiné vzorky). Vstupní vzorek je potom vzorkem třídy jejíž model má na výstupu nejvyšší pravděpodobnost.

I když HMM je velmi dobrý model pro klasifikaci audio nahrávek, pro porovnání s neuronovými sítí prohrává. Proto moje řešení bude založeno převážně na neuronových sítích. Jimž bude věnovat zbytek této sekce.

Umělá neuronová síť (dal prostě neuronová síť) je matematický model a jeho softwarová nebo hardwarová implementace postavená na principu organizace a fungování biologických neuronových sítí - sítí nervových buněk živého organismu. Tato koncepce vznikla ve studiu procesů probíhajících v mozku a ve snaze simulovat tyto procesy.[**?**] Neuronové sítě se skládají z neuronů které jsou navzájem propojeny do určité architektury. Architektury se typický rozděluje na několik vrstev: vstupní, skrytá a výstupní. Když skrytá vrstva skládá se z několika vrstev tato neuronová síť se nazývá hluboká.

### 2.2.1 Neuron

Umělý neuron je umělý neuronový síťový uzel, což je zjednodušený model přírodního neuronu. Matematicky je umělý neuron obvykle představován jako nelineární funkce jediného argumentu - lineární kombinace všech vstupních signálů. Tato funkce obvyklé se nazývá *aktivační funkce*. Jinými slovy se na začatek spočítá $u$ (vzorek 2.2). Potom se přdává na

vstup určite aktivační funkci $f()$.

$$u = \sum_{i=0}^{n} w_i x_i, \tag{2.2}$$

kde $n$ je počet neuronů, ke výstupem kterých se připojen daný neuron. Výsledek je odeslán na jeden výstup. Takové umělé neurony jsou kombinovány v sítích - spojují výstupy některých neuronů se vstupy ostatních Na Obr. 2.6 je vidět model umělého neuronu – Preceptron TODO cite. Jedna se ale o nejjednodušší verzi umělého neuronu. V praxi se občas používají i složitější modely.

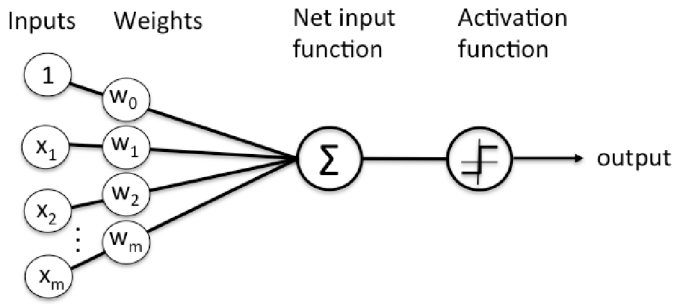


Obrázek 2.6: Model umělého neuronu [**?**]

Funkce aktivace neuronové sítě jsou klíčovou součástí hlubokého učení, které se vyvinulo paralelně s architekturou neuronové sítě. Aktivační funkce určují výstup modelu hlubokého učení, jeho přesnost a také výpočetní efektivitu trénování modelu. Aktivační funkce mají také hlavní vliv na schopnost neuronové sítě konvergovat a rychlost konvergence[3], nebo v některých případech mohou aktivační funkce zabránit neuronovým sítím v konvergování.[**?**]

Aktivační funkce mohou být:

- Skokové (binární):

$$y = \begin{cases} 0 & \text{pro u} < \theta, \\ 1 & \text{pro u} \geq \theta. \end{cases}$$

- Lineární: $y = ku$
- Nelineární: Např. $y = tanh(u)$

Grafický průběh různých typu aktivačních funkci je znázorněn na Obr. 2.7.

V současnosti se převážně používá nelineární funkce, protože umožňují vytvářet komplexní mapování mezi vstupy a výstupy sítě, které jsou nezbytné pro učení a modelování komplexních dat, jako jsou obrázky, video, audio a datové soubory, které jsou nelineární a zároveň mají vysokou dimenzi[**?**]

V současné době existuje velké množství různých aktivačních funkcí. Některé z nich jsou univerzální a mohou být použity na všech vrstvách sítě. Některé funkce jsou specifické a používají se pouze za určitých podmínek. Dál budou popsaný nejdůležitější aktivační funkce které se používají v klasifikačních úlohách.

[3]Konvergenci se tadý rozumí přibližování ke spravnému řešení

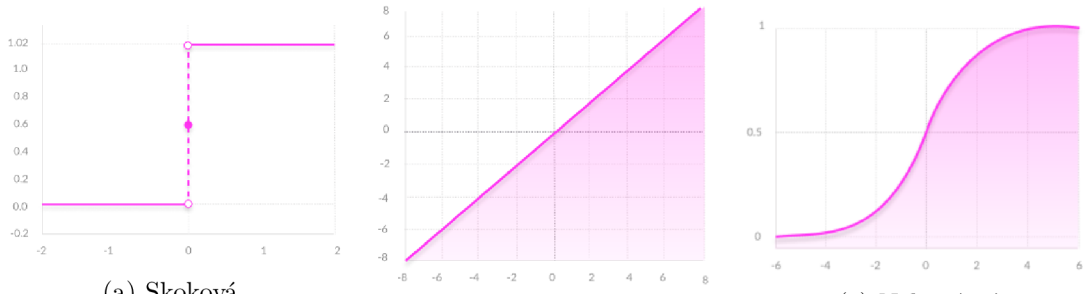

(a) Skoková

(b) Lineární

(c) Nelineární

Obrázek 2.7: Průběh různych aktivačních funkcí [**?**].

Sigmoida (obrázek vpravo 2.7) je klasickou aktivační funkci která byla dříve moc populární a je vhodná pro všechny vrstvy. Má rozsah hodnot od (0, 1) a centrum v 0.5. Matematický je popsaná vzorkem 2.3.

$$y = \frac{1}{1 + e^{-z}}, \tag{2.3}$$

Hyperbolický tangens (dal tanh) je další populární v minulosti aktivační funkci. Má rozsah hodnot od (-1, 1) a centrum v 0. Kvůli tomu má o něco lepší rychlost konvergenci než sigmoida. Matematický je popsaná vzorkem 2.4.

$$y = \frac{e^{z} - e^{-z}}{e^{z} + e^{-z}}, \tag{2.4}$$

Nevýhodou tanh a sigmoidy je poměr — (výpočetní složitost/přínos). Sami o sobě tyto funkce velmi užitečné, ale teď existujou více efektivní alternativy. Navíc tyto funkce jsou velmi citlivé na problém mizejícího gradientu[4].

Průlomem stal vynález funkce ReLU (Rectified Linear Unit). Matematický tato funkce je popsaná vzorkem 2.5.

$$y = max(0, u). \tag{2.5}$$

Kvůli své jednoduchosti, učení neuronu kteří mají uvnitř ReLU je několikrát rychlejší než učení tanh nebo sigmoidy. Ale ReLU neurony mají problém když na vstupu mají 0. V tomto případě klasický ReLU neuron 'zemře' (jeho výstupem od tohoto okamžiku vždycky bude 0). Což způsobí sníženi rozlišovací schopnosti sítě. To se dá řešit pomoci drobných modifikaci jako například Leaky ReLU.

Leaky ReLU — je modifikaci ReLu funkci, která je popsaná následující formuli.

$$y = \begin{cases} u & \text{pro } \geq 0, \\ \alpha & \text{pro } < 0, \text{ kde } \alpha << 1. \end{cases}$$

Když Leaky ReLU dostane na vstup zápornou nebo nulovou hodnotu, na rozdíl od Klasického ReLU vrátí malou zápornou hodnotu. A pravě tímto zabraní 'zemření'.

[4]Vanishing gradient problém — velmi důležitý problém při učení neuronových sítí. Při zvětšení počtu skrytých vrstev schopnost prvních vrstev se učit rychlé stoupa dolu. To je dáno specifikou učení neuronových sítí a konkretně BGD (Backpropagation Gradient Descent) algoritmem (https://towardsdatascience.com/the-vanishing-gradient-problem-69bf08b15484).

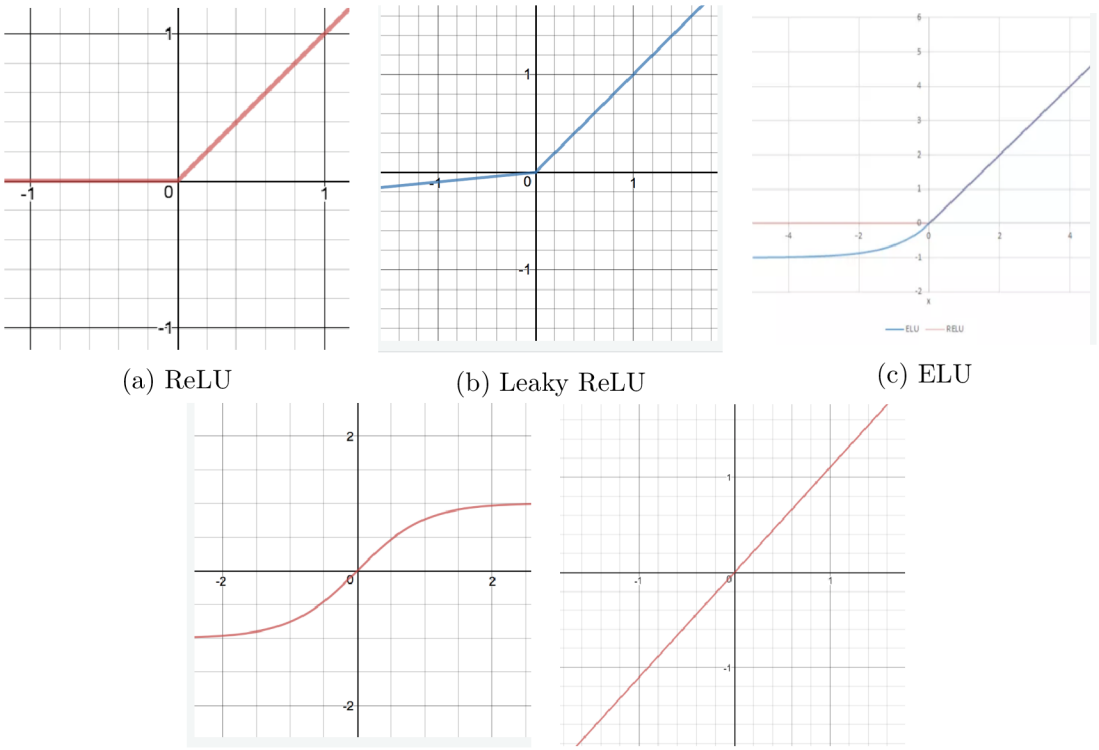


(a) ReLU (b) Leaky ReLU (c) ELU

(d) Tanh (e) Linear

Obrázek 2.8: Průběh aktivačních funkcí.

ELU (Exponential Linear Unit) — je silnou alternativou Leaky ReLU. ELU se dá popsat následujícím vzorkem.

$$y = \begin{cases} u & \text{pro } u \geq 0, \\ \alpha(e^u - 1) & \text{pro } z \leq 0, \end{cases}$$

kde $\alpha$ je předem stanovena konstanta. Dana aktivační funkce také umí produkovat záporné hodnoty. Nevýhodou je ale pro vstupní hodnoty $> 0$ může ¨vybuchnout¨ (dat na výstup příliš velké hodnoty).

Softmax — jedna se o specifickou aktivační funkci která přímo určena pro výstupní vrstvu. Má rozsah výstupních hodnot (0, 1) , přitom suma výstupních hodnot všech výstupních neuronů se rovna 1. To znamená že síť která na výstupu má Softmax aktivační funkci může specifikovat na kolik procent je jista že na vstupu vidí určitou třídu. Pravě proto teď Softmax je standardem pro klasifikační úlohy. Dole je matematicky popsán vystup neuronu s indexem $j$.

$$y_j = \frac{e^{u_j}}{\sum_{k=1}^{m} e^{u_k}},$$

kde $m$ je počet výstupních neuronu. Graficky znázorněni průběhu aktivacích funkci je vidět na Obr. 2.8.

### 2.2.2 Učeni neuronových síti

Učením neuronových síti se označuje proces během kterého se určuji váhy (typický) každého neuronu při procházení trénovací sady. Na začátku učení jsou váhy inicializovaný malými

čísly kolem 0. Při zpracování každého vzorku se váhy sítě trochu mění. Epochou se rozumí počet iteraci trénování pokud neuronová síť zpracovává každý vstup z datové sady právě jednou. Trénovací proces typický konči když přesnost neuronové sítí dosáhne předem nastavené konstanty anebo přesnost přestane se zlepšovat určitý počet epoch. Můžeme rozlišit několik přístupů k učeni neuronových síti.

**Učeni s učitelem.** Je to druh učeni, který je typický pro problémy jako regrese a klasifikace. Zde trénovací sada obsahuje dvojici $(x, y)$ kde $x$ je vstup pro neuronovou síť a $y$ je požadovaný výstup neuronové síti. Dostav na vstup $x$, síť produkuje vlastní výstup $y\prime$. Při porovnání $y\prime$ a $y$ trénovací proces dostává informaci v jekem směru musí upravovat váhy každého neuronu. Porovnání $y\prime$ a $y$ a extrakce informaci o směru a velikosti chyb se provádí pomoci funkci ztrát (víc dál).

**Učeni bez učitele** Učeni bez učitele používá se obvyklé pro úlohy klasterizaci, když nevíme přesný počet tříd. Na rozdíl od učení s učitelem datová sada pro daný druh úlohy neobsahuje složku $y$. To znamená že síť nebude dostávat ke každému vstupu správnou odpověď. Učení potom spočívá v nalezení zákonnosti (souvislosti) mezi vstupními vzorky a seskupeni dat do různých skupin.

**Učeni s podpořením** Daný typ učení se používá když existuje model který rozhoduje o akcí v situovaném prostředí na zakldě neuronové sítí. Problém je v tom, že model nemá žádné znalosti o systému. Model ale může provádět experimenty — nějakým způsobem ovlivňovat prostředí a sbírat odezvy[5] od prostředí. Pravě na základě těchto dat neuronová sít se snaží naučit dělat správnou předpověď - volit nejlepší následující akci tak, aby v dlouhodobé perspektivě model dosáhl předem stanovenou cíle(stavu v systému). Tento typ učení obvyklé se používá pro naučení správně strategie umělého agenda(robota, hráče ve hrách atd.).

**Transfer learning** Jedna se o metodu kterou se nedá zařídit do výše uvedených kategorii. Tato metoda může byt aplikovaná ke každé z nich. Tato technika učení používá se když nemáme dostatečné množství dat nebo výpočetních zdrojů na trénování vlastní neuronové síti. Daná metoda spočívá v použití jíž naučené neuronové síti na jiných datech. Z teto síti odstraníme poslední vrstvy, a začneme tuto síť trénovat na vlastní datové sadě. Kdýž sít byla pečlivě naučena na nějaké velké datové sadě, potom ona obsahuje uvnitř všechně potřebně nízko úrovňové paterny, které je potřeba extrahovat ze vstupu. Nám zbývá jenom naučit poslední vrstvy tak, aby síť byla schopna použit tyto paterny pro náš specifický úkol.

### 2.2.3 Ztrátová funkce

Funkce ztrát je srdcem algoritmů strojového učení. Používají se pro extrakci informaci o chybě výstupu neuronové síti. Na základě teto chyby optimalizační algoritmus pak dokáže změnit váhy tak, aby síť se o něco zlepšila. Existuje hodně druhu ztrátových funkci které jsou účinné pouze pro malý seznam úloh. Proto výběr ztrátové funkcí je velmi důležitý.

Obecně jích se dá rozdělit na dvě skupiny podle druhu úloh na kterých se uplatňuje model(neuronová sít):

- Regresní

[5] Odezvou se tady rozumi novy stav prostredi

- Klasifikační

Dana diplomová práce se zaměřená na klasifikaci vstupní nahrávky. Tady je těžko použit modely které jsou primo zaměřeny na regresní úlohy. Proto za účelem dodržení rozměru diplomové práce dál budou popsaný pouze aktivační funkci které jsou důležité pro klasifikační úlohy.

Mean Square Error (MSE) je klasickou funkcí ztrát ve strojovém učení. Dole můžete vidět matematický vzorec.

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y})^2,$$

kde $n$ je počet výstupních neuronů.

Nevýhodou MSE je to, že druha mocnina v $(y_i - \hat{y})^2$ silněji penalizuje velké odchylky, což zhoršuje rychlost konvergence. MSE se původně používalo pro všechny typy úloh, ale s časem bylo zjištěno, že pro klasifikační úlohy existuji lepší alternativy. Nyní MSE a ostatní podobné ztrátové funkce (Mean Bias Error, Mean Absolute Error) se používají v regresních úlohách.

Binary Cross Entropy (BCE) je možnou alternativou k MSE. Obvykle se používá pro úlohy binární klasifikaci. Dá se popsat následujícím vzorcem.

$$H_p(q) = -\frac{1}{N}\sum_{i=1}^{N} y_i \times \log(p(y_i)) + (1 - y_i) \times \log(1 - p(y_i)).$$

BCE se snaží přiblížit rozložení hodnot výstupních neuronů penalizaci za chybový a za příliš pochybující výstup. Používá se v klasifikačních úlohách, kde vstupní vektor se dá zařídit pouze do jedné třídy.

Co když nějaký vstupní vektor je potřeba zařadit do více tříd? Potom se jedna o multi-label klasifikační úlohu. V takovém případě se používá Categorical Cross Entropy. Dana ztrátová funkce je popsaná následujícím vzorcem.

$$L(X_i, Y_i) = -\sum_{j=1}^{N} y_{ij} \times log(p_{ij}),$$

kde $Y_i$ je one-hot vektor[6] $p_{ij}$ je pravděpodobnost že vzorek $i$ patří do třídy $j$.

### 2.2.4 Vrstvy neuronových sítí

Jak bylo uvedeno dříve vrstvy představuji skupinu podobných neuronů. Některé vrstvy jsou univerzální - dá se jich použit skoro v každé architektuře, některé jsou specifické - používají se pouze v specifických architekturách. Dana sekce bude popisovat nejčastější vrstvy neuronových sítí, které se používají v architekturách důležitých pro klasifikační úlohy.

**Dense (plně propojená) vrstva** Klasická vrstva kde každý neuron propojen s každým výstupním neuronem předchozí vrstvy. Typický jsou to poslední vrstvy neuronových sítí. Tato vrstva silně zvětšuje počet trénovacích vah (větší trénovací doba) ale je velmi užitečná pro sumarizaci dílčích příznaku předchozích vrstev.

[6]One-hot vektor, je vektor čísel 0,1. Délka vektoru se rovna počtu tříd a každé číslo říká zda příslušný vzorek patři do určité třídy

**Konvoluční vrstva.** Konvoluční vrstva představuje množinu neuronů které jsou odlišné od klasického chápani neuronu. Na rozdíl od Dense vrstvy neuron v konvoluční vrstvě připojen (¨vidí¨) pouze k malému lokálnímu poli z předchozí vrstvy a během vypočtu prochází svým lokálním oknem celou předchozí vrstvu. Konvoluční neuron reprezentován konvolučním jádrem (matici). Při učení síť se právě snaží naučit správné hodnoty teto matici. Pro získání výstupu neuronu, jeho konvoluční jádro se pohybuje nad vstupním obrázkem (nebo nad výstupem předchozí vrstvy) a vypočítá lineární kombinaci hodnot pod jádrem, kde jako koeficienty lineární kombinaci používá hodnoty v jádře. Na obrázku 2.9 můžete vidět ukázku procházení konvolučního jádra.

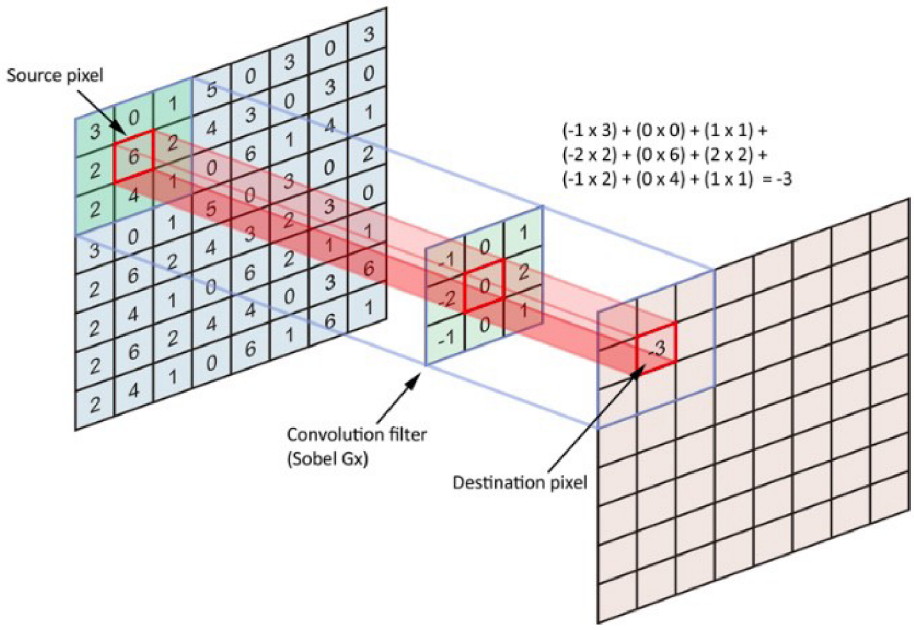


Obrázek 2.9: Výpočet výstupu konvolučního neuronu pro jednu polohu [**?**].

Tento typ vrstvy zpravidla reaguje na nějakou předem naučenou vlastnost: caru, hranu, kolo. Na základě nasbíraných vlastnosti plně propojené vrstvy potom dokážou velice snadno klasifikovat obrázek.

**Sdružující vrstva** Takže známa jako pooling vrstva je nelineární komprese mapy rysů. Skupina pixelů (obvykle ve velikosti 2 × 2) je zkomprimovaná na jeden pixel a podléhá nelineární transformaci. Nejčastěji se používá funkce max(). Transformace ovlivňují nesouvislé obdélníky nebo čtverce, z nichž každý je stlačen do jednoho pixelu a je vybrán pixel s maximální hodnotou. Operace sdružování výrazně snižuje prostorový objem obrazu. Shromáždění se interpretuje následovně: pokud již byly některé známky zjištěny v předchozí operaci konvoluce, pak takový podrobný obrázek již není zapotřebí pro další zpracování a je zkomprimován do méně podrobného. Kromě toho filtrování již nepotřebných částí pomáhá zabránit přeučeni neuronové sítě. Sdružující vrstva se obvykle vkládá za konvoluční vrstvu před další konvoluční vrstvu. Na obrázku 2.10 je vidět vypočet pooling vrstvy pro jeden vstup.

Kromě sdružování s maximální funkcí můžete použít i další funkce - například průměrnou hodnotu nebo nějakou normalizaci.

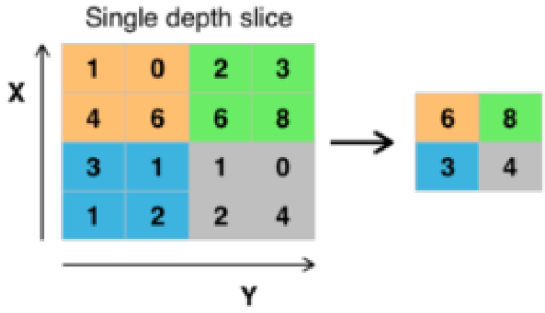


Obrázek 2.10: Komprimace 16 výstupu předchozí vrstvy do 4, [**?**].

**LSTM** LSTM vrstva je vrstva, která se skádá z LSTM modulů. Modul LSTM je modul pro cyklické sítě, který může ukládat hodnoty jak pro krátkou, tak pro dlouhou dobu. Na vstup bere vzorky které uspořádané v čase v jednom směru (t1, t2, t3 ...). Závazné je, že modul LSTM nepoužívá aktivační funkci uvnitř svých rekurzivních komponent. A tímto způsobem Rekurentní neuronové sítě(víc dal) používající LSTM jednotky částečně řeší problém mizejícího gradientu, protože LSTM jednotky umožňují gradientu průtok beze změny. Sítě LSTM však stále mohou trpět explodujícím gradientem problému.[26]

**BiLSTM** BiLSTM je podobná LSTM s tím rozdílem, že BiLSTM při generaci výstupu (odpovědi) bude brát v potaz vzorky uspořádání ve dvou směrech v čase (t1, t2, t3 a zároveň t3, t2, t1). [27]

Schematické zobrazení LSTM a BiLSTM sítí je vidět na obrázku 2.11.

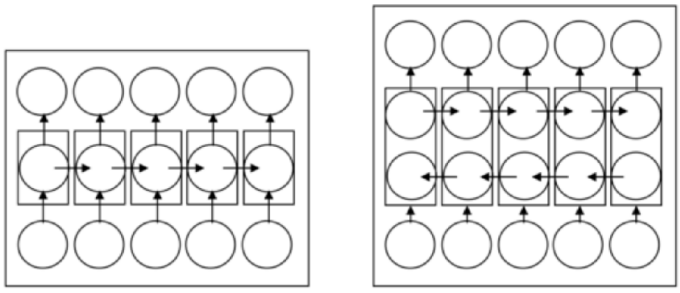

Obrázek 2.11: Schematické znázornění architektury LSTM (vlevo) a BiLSTM (vpravo) vrstev [**?**].

### 2.2.5 Architektury neuronových síti

Existuje řada architektur které jsou zaměřeny pro různé účely. Následující sekce bude popisovat nejdůležitější architektury neuronových síti vztažených ke klasifikaci signálu (včetně audia).

**Konvoluční neuronové sítě** To je speciální architektura umělých neuronových sítí, navržená Janem Lekunem v roce 1988 a zaměřená na efektivní rozpoznávání vzorů. V roce 2012 tento typ sítě zvítězil v soutěži o klasifikaci obrázků s velkým rozdílem oproti konkurenci. A od té doby to byl standard v klasifikaci obrázků. Myšlenka konvolučních neurono-

vých sítí je tedy střídat konvoluční vrstvy a sdružující vrstvy. Struktura sítě je jednosměrná (bez zpětné vazby). Klasickou strukturu neuronové sítě můžete vidět na Obr. **??**.

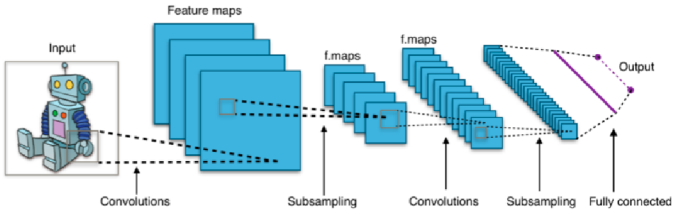


Obrázek 2.12: Typická architektura konvoluční neuronové sítě [**?**]

**Důležité reprezentanty** V tomto segmentu budou popsaný důležité reprezentanty konvolučních neuronových sítí. To jsou nejmenší a nejrychlejší neuronové sítě mezi konvolučními neuronovými síti. Přesnost uvedených dále sítí je stále dobrá a pravě proto ony začleněný do dané prací.

**VGG16** VGG16 je konvoluční neuronová síť navržená K. Simonyanem et. al. (TODO VGG16odkaz), což je vylepšená verze AlexNet[7]. Na rozdíl od AlexNet VGG16 nahrazuje velké konvoluce (velikosti 11 a 5 v první a druhé konvoluční vrstvě) několika malými konvolucemi o velikosti 3x3, jedna po druhé. Počet trénovacích parametru ale se zvýšil na 138 milionu. Při testování na ImageNet[8] VGG16 dosahuje přesnosti 92,7 procenta[9]. Architekturu VGG16 můžete vidět na Obr. 2.13.

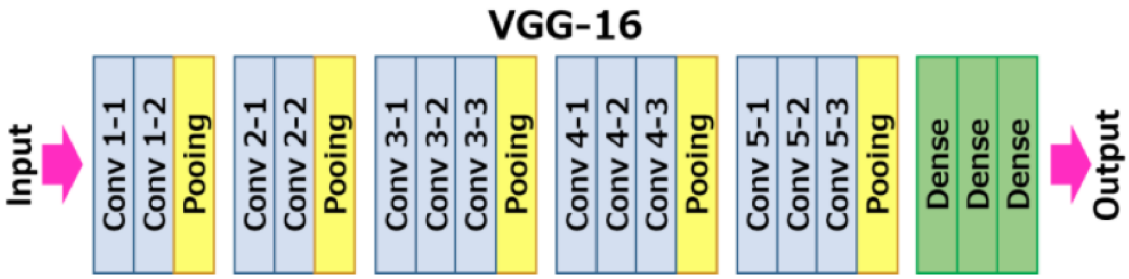


Obrázek 2.13: Architektura VGG16 kde:
Conv - konvoluční vrstva, Pooling - Sdružující vrstva a Dense - plně propojena vrstva.

**MobileNetV2** MobileNetV2 je to konvoluční neuronová síť od Google, která je náhradou MobileNetV1. Tyto sítě mají malou vypocetni složitost(pouze 3.4 milionu trénovacích parametru) a proto primárně se používají na mobilních zařízeních. Architekturu dané sítě můžete vidět na Obr. 2.14

[7]AlexNet je konvoluční neuronová síť. Byla představena na konkurzu po rozpoznávaní objektů v obraze v roku 2012. Od tohoto momentů konvoluční sítě se považují jako standart v klasifikaci obrazů.

[8]ImageNet je dataset v úloze rozpoznávání objektů v obraze. ImageNet se skládá z více než 14 milionů obrázků patřících do 1 000 tříd.

[9]Síť VGG16 byla trénovaná několik týdnů pomocí grafických karet NVIDIA TITAN BLACK. Přitom měření přesnosti na ImageNet děla takovým způsobem, že výsledek je počítán jako správný, pokud neuronová síť zařadí správnou odpověď mezi 5ti nejpravděpodobnějšími objekty na obrázku.

| Type / Stride | Filter Shape | Input Size |
|---|---|---|
| Conv / s2 | $3 \times 3 \times 3 \times 32$ | $224 \times 224 \times 3$ |
| Conv dw / s1 | $3 \times 3 \times 32$ dw | $112 \times 112 \times 32$ |
| Conv / s1 | $1 \times 1 \times 32 \times 64$ | $112 \times 112 \times 32$ |
| Conv dw / s2 | $3 \times 3 \times 64$ dw | $112 \times 112 \times 64$ |
| Conv / s1 | $1 \times 1 \times 64 \times 128$ | $56 \times 56 \times 64$ |
| Conv dw / s1 | $3 \times 3 \times 128$ dw | $56 \times 56 \times 128$ |
| Conv / s1 | $1 \times 1 \times 128 \times 128$ | $56 \times 56 \times 128$ |
| Conv dw / s2 | $3 \times 3 \times 128$ dw | $56 \times 56 \times 128$ |
| Conv / s1 | $1 \times 1 \times 128 \times 256$ | $28 \times 28 \times 128$ |
| Conv dw / s1 | $3 \times 3 \times 256$ dw | $28 \times 28 \times 256$ |
| Conv / s1 | $1 \times 1 \times 256 \times 256$ | $28 \times 28 \times 256$ |
| Conv dw / s2 | $3 \times 3 \times 256$ dw | $28 \times 28 \times 256$ |
| Conv / s1 | $1 \times 1 \times 256 \times 512$ | $14 \times 14 \times 256$ |
| $5\times$ Conv dw / s1 | $3 \times 3 \times 512$ dw | $14 \times 14 \times 512$ |
| $5\times$ Conv / s1 | $1 \times 1 \times 512 \times 512$ | $14 \times 14 \times 512$ |
| Conv dw / s2 | $3 \times 3 \times 512$ dw | $14 \times 14 \times 512$ |
| Conv / s1 | $1 \times 1 \times 512 \times 1024$ | $7 \times 7 \times 512$ |
| Conv dw / s2 | $3 \times 3 \times 1024$ dw | $7 \times 7 \times 1024$ |
| Conv / s1 | $1 \times 1 \times 1024 \times 1024$ | $7 \times 7 \times 1024$ |
| Avg Pool / s1 | Pool $7 \times 7$ | $7 \times 7 \times 1024$ |
| FC / s1 | $1024 \times 1000$ | $1 \times 1 \times 1024$ |
| Softmax / s1 | Classifier | $1 \times 1 \times 1000$ |

Obrázek 2.14: Architektura MobilenetV2 kde:
Conv - konvoluční vrstva, Conv dw - Hloubkově oddělitelná konvoluce, Avg Pooling - Sdružující vrstva která redukuje na základě funkci *average*(), Dense - plně propojena vrstva.

V MobileNetV2 se používá nové typy vrstev, a to jsou:

- Relu6
- Hloubkově oddělitelná konvoluce

**Relu6** je drobnou modifikaci klasické ReLu funkce. Jediným odlišením je to že maximální výstupní hodnota Relu6 může byt 6. Nový matematický zápis teto funkce je dole.

$$f = min(max(0, u), 6)$$

Relu6 pomáhá zachovat robustnost sítě při využiti vypočtu s nízkou přesnosti.

**Hloubkově oddělitelná konvoluce**(Depthwise Separable Convolution) je nova (relativně komplikovaná) modifikace konvoluční vrstvy. Hlavni myšlenkou teto vrstvy je:

- Odděleni vypočtu pro různé kanály vstupního obrázku.
- Výpočet hlubokých (s zachováním všech kanálů určitého pixelu) map příznaků.
- Sumarizace příznaku pro všechny pixely.

Použiti teto vrstvy dokáže zmenšit počet vypočtu které je potřeba provést pro inference[10] neuronové sítě. Zmenšeni poctu vypočtu záleží na parametrech sítě a typicky výpočtů o 8-9 krát méně. Přesnost při tom klesá pouze trochu.

**Rekurentní neuronové sítě** Rekurentní neuronové sítě (RNS, RNN) je typ neuronových sítí kteří primárně určeny k prací s časově závislými sekvencemi (řeč, písmo, hudba). Na rozdíl od vícevrstvých acyklických neuronových sítí RNN mohou používat svou vnitřní paměť ke zpracování sekvencí libovolné délky. Pro rekurentní sítě od jednoduchých po komplexní bylo navrženo mnoho různých architektonických řešení. V poslední době nejrozšířenější síť s dlouhodobou a krátkodobou pamětí (LSTM).[**?**, **?**]
Obecně rekurentní sítě se dá rozdělit na:

- One to one - používá se pro predikci a extrapolaci.
- One to many - často se navazuje na konvoluční síť a používá se pro automatický popis obrázku.
- Many to one - je vhodná pro klasifikaci sentimentů.
- Many to many (bez posuvu) - používá se pro strojový překlad
- Many to many (s posuvem) - dá se aplikovat pro klasifikaci videa na úrovní snímků.

Na obrázku 2.15 je přehled druhů rekurentních neuronových sítí.

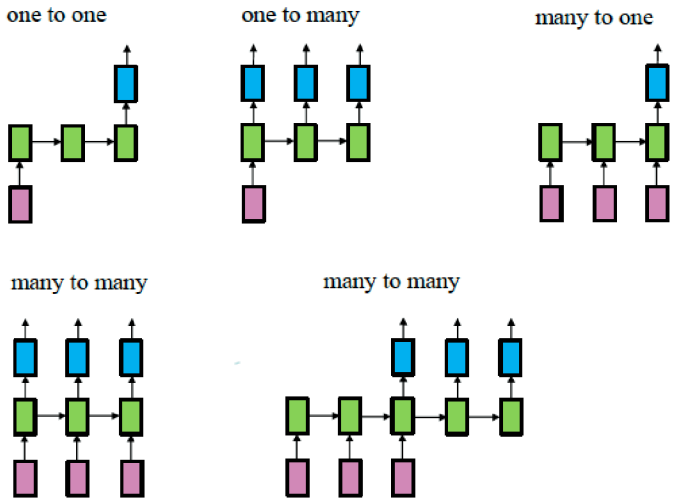


Obrázek 2.15: Schematické rozdělení RNN

[**?**]
Klasická RNN ale má určité problémy. Teoreticky, ony mohou sledovat libovolné dlouhodobé závislosti ve vstupních sekvencích. Potom problém je v tom, že když trénujete klasickou RNN pomocí zpětného šíření chyby, gradienty, které se šíří zpět, se mohou ¨zmizět¨ (mohou konvergovat k nule) nebo „explodovat“ (konvergovat k nekonečnu).[26]

[10]Inferencem neuronové síti se tady rozumí proces, ve kterém neuronová síť ze vstupu vypočítá vlastní výstup **??**

### 2.2.6 Příprava trénovací sady

Modely strojového učeni typicky jsou velmi závisle na velikosti a kvalitě trénovací sady (dal datasetu). Od velikosti závisí jak dobře model bude rozumět reálným datum. Od kvality datasetu závisí jak rychle model a trénovací algoritmus dokážou extrahovat užitečné znalosti z dat a převést jich do parametru modelu.

I presto ze pořízení velikého datasetu je problém není moc triviální. V rámci diplomové práce tento problém je těžko ovlivnitelný. Od nás ale úplně závisí kvalita dat, kterými budeme krmit model(například neuronové síti). Pravě proto následující sekce bude věnovaná zlepšeni kvality datasetu.

V případě že se jedna o učeni s učitelem(víc 2.2.2) je potřeba aby každému vstupu odpovídál správný výstup. V případě práci se zvukem (dataset ma tvar dvojic - audio,MIDI) je potřeba mit dobře zarovnany dataset: kousek audia musi obsahovat pouze noty, které uvědené v seznamu MIDI. Zarovnání se dá provest pomoci DTW (vic dal).

Je nezbytné mít v datech určitý úroveň šumu, aby model mohl po trénování porozumět skutečným datům. Ale úroveň šumu nesmí byt matoucí pro model.

Pokud víme nějakou empirickou znalost o datech, tak je občas je dobrým řešením převést data do jiné representaci, která zachovávala tuto znalost. A tím docilme velkého redukovaní času, který je potřeba věnovat trénovaní modelu. Protože model už nebude nucen naučit již zmíněnou znalost. V případe ze se jedna o audio nahrávku, a chceme tuto audio nahrávku klasifikovat, nemusíme model krmit PCM vzorky (víz 2.1). Model mnohem jednoduše dokáže klasifikovat nahrávku, pokud dostane na vstup místo PCM vzorků nějakou frekvenční reprezentaci teto nahrávky. Taky algoritmy strojového učeni jsou velmi závisle na rozsahu hodnot vstupních dat. Proto je potřeba v datasetu předem změnit měřítko (normalizovat). Rozsah hodnot a nova škala je závislá na typu použitého modelu(typu aktivační funkci v případe neuronových síti). Například pro SVM klasifikátor nejlépe vyhovuje rozsah vstupních hodnot [-1,1] a směrodatnou odchylku 0.5 s centrem v 0.

**Dynamic Time Warping (DTW)** To je algoritmus pro nalezení míry podoby mezi dvěma sekvencemi s různou délkou. Hlavní problém s porovnáním takových sekvenci je to že jejich porovnaní Eukleidovskou vzdálenosti často selhává. To je dáno tím, že Eukleidovská vzdálenost se vypočítá postupným porovnáním prvků se stejnými indexy. Potom v situaci, když budou porovnaný dvě skoro stejné sekvence (vektory), ale jeden z ních bude posunout o jeden prvek, Eukleidovská vzdálenost muže považovat tyto vektory za úplně odlišné. Na rozdíl od Eukleidovské vzdálenosti DTW se snaží co nejlépe namapovat prvky(indexy) jednoho vektoru na druhy. Potom nejlepší mapování se považuje za délku (rozdíl) mezi vektory. Rozdíl mezi eukleidovskou metrikou a DTW je na obrázku 2.16.
Nechť máme 2 vektory r a t s délkami k a n, potom zarovnání probíhá následujícím způsobem [**?**]:

1. Sestavena matice M kde každý prvek M(i, j) je dan výpočtem distance mezi vektory r(i) i t(j).
2. Probíhá výpočet cesty mezi prvkem M(0, 0) a M(k, n).
3. Buňky matice které jsou patří k určité cestě se sčítají. A tím dostáváme kumulovanou vzdálenost dvou vektorů.
4. Tato kumulovaná vzdálenost potom může být normalizovaná.
5. Nejmenší vzdálenost potom považována za distanci mezi vektory r a t.

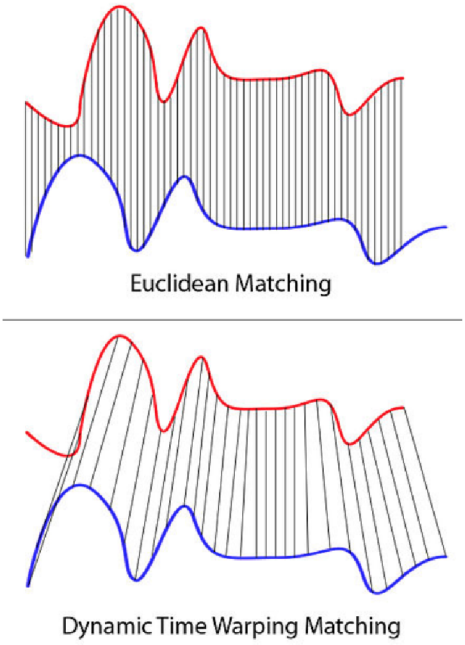


Obrázek 2.16: Rozdíl při porovnaní pomoci euklidovské metriky (nahoře) a DTW (dole) [**?**]

6. Průběh výpočtu můžete vidět na obrázku dole.

Grafické znázornění porovnaní dvou sekvenci pomoci DTW je na obrázku 2.17.

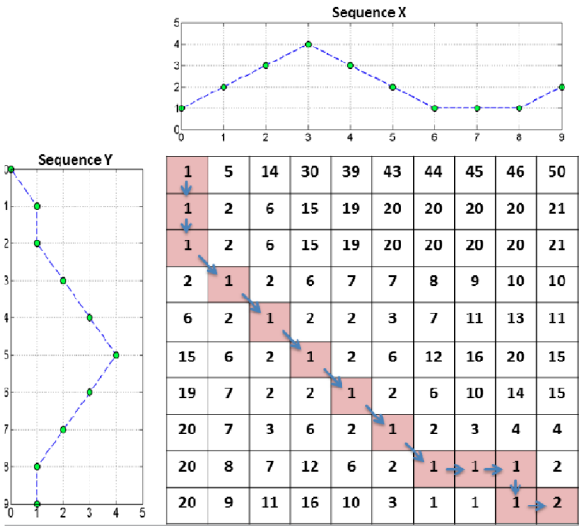


Obrázek 2.17: Výpočet DTW [**?**].)

### 2.2.7 Metriky trénování

K tomu abýchom pochopilii zda nějaká neuronová síť se zlepšuje či ne, musíme zavest určité metriky, které nam budou tuto informaci poskytovat. Takových metrik existuje cela řada. Neda se zvolit pouze jednu, protože různé metriky poskytujou různe vlastnosti kva-

lity neuronové sítě. V dalším textu budou popsany nejdůležitější metriky pro trénování neuronových síti.

Předtím, než vysvětlovat různé metriky je potřeba zavést pojem *chybové matici*. Chybová matice je to specifická tabulka, která umožňuje vizualizovat výkon algoritmu (typický se jedná o učení s učitelem). Každý řádek matice představuje instance v predikované třídě, zatímco každý sloupec představuje instance v reálné třídě (nebo naopak). Příklad chybové matici pro dvě třídy můžete vidět v tabulce 2.1.

| | y = 1 | y = 0 |
|---|---|---|
| y'= 1 | True Positive | False Positive |
| y'= 0 | False Negative | True Negative |

Tabulka 2.1: Chybová matice pro dvě třídy, kde: y' - je predikce modelu, y - je skutečna hodnota reálného světa.

Z ní dostavamé 4 důležité hodnoty: True Positive (TP), True Negative (TN), False Positive (FP), False Negative (FN). Tyto hodnoty budou použity pro výpočet potřebných metrik.

Nejpopulárnější metrika je *accuracy*. Jedná se o poměr spravných odpovědi vůčí celkovému počtu odpovědi. Vypočíta se podle vzorce 2.6:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{2.6}$$

Tato metrika je standardem, ale skoro neužítečna při existencí nvyváženosti v trénovácích datech. Je to dano tím, že accuracy je sílně závislá na poměru počtu prvků v každé třídě.

Na rozdíl od accuracy, *precision* a *recall* není závilsé na poměru počtu prvků v třídach a proto jejích se dá použit i pro nevyvážena trénovácí data. Dá se jich počítat podle vzorků 2.7 a 2.8

$$precision = \frac{TP}{TP + FP}, \tag{2.7}$$

$$recall = \frac{TP}{TP + FN}. \tag{2.8}$$

Občas je potřeba popsat kvalitu neuronové sítě jednou hodnotou. K tomu se používa metrika *f1*. Jedna se o harmonický průměr precision a recall. Výpočet teto metriky je popsan vzorcem 2.9.

$$f1 = (1 + \beta^2) \times \frac{precision \times recall}{(\beta^2 \times precision) + recall}, \tag{2.9}$$

kde $\beta$ - váha důležitosti precision a recall. Tato metrika bude se rovnat jedničce, pokud precision a recall budou se rovnat jedničce. f1 bude blízko nule, pokud precision nebo recall je blízko nule.

Taký často se sleduje metrika *Loss*. Jedná se o hodnotu ztrátové funkci, která byla určěna pro danou neuronovou síť (víc 2.2.3.).

## 2.3 Existujici přístupy pro transkripci zvuku

Než se začneme navrhovat vlastní aplikaci je potřeba dobře prozkoumat již existující řešení. To nám umožni odhalit slepé uličky a přímo se pustit posouvat správnou technologii

dopředu. V této kapitole budou probraný různé způsoby klasifikací audio vzorků klavírní hudby, což je klíčovým krokem k transkripci audiosignálu do not.

Autoři [4] zároveň analyzovali log-scaled spektrum a cepstrum za účelem lepšího výběru kandidátních not v určitém kusu kompozice. Obr. 2.18.

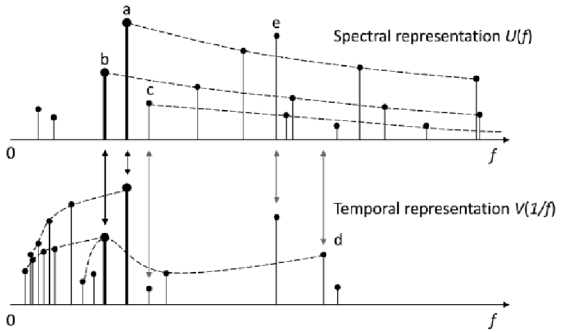


Obrázek 2.18: Log-scaled spektrum a cepstrum [**?**].

Potom na to se uplatňovali klasické metody zpracování signálu. Jako výsledek - daný přístup ukazuje lepší hodnoty přesnosti pouze na jednom datasetu z sedmi. Ale stále je to byl dobry alternativní pokus bez použiti neuronových sítí.

V [] autoři použili HMM (víz 1) pro klasifikaci audio vzorku za účelem odhaleni plagiátu v nové vymyšlených kompozicích. Navrženy model dosahuje průměrné přesnosti skrz všechny typy datasetu 67 procent, což je relativně málo. Natolik mala přesnost podle mě způsobena příliš malým datasetem kterým disponovali autoři.

Práce [5] používá neuronové sítě a založena na myšlence že některé rámce jsou důležitější než ostatní. Tyto rámce jsou rámce s začátkem noty (protože hned po začátku znění energie noty se začne klesat). A pravě v těchto rámech máme co nejvíc informaci pro klasifikací vzorků. Za účelem nalezení těchto rámců byl natrénován zvláštní detektor začátku noty založený na konvolučních a rekurentních vrstvách. Vstupem pro tento detektor je Mel-spektrogram. Jehož výstupem je 88 (klavír má pravě 88 kláves) pravděpodobnosti že určitá nota se právě zazněla v tomto rámci. Tento výstup je přímo použít jako doplňkový vstup pro samotný detektor not. Celková architektura síti je zobrazen níž na Obr. 2.19.

Metoda navařená v [6] je založena na metodě představené v [5]. Neuronová síť (model) byl převzat pouze z drobnými úpravami, které se týkali pouze zvýšení počtu neuronů ve vrstvách. Závazným rozdílem [**?**] od [**?**] je ale to , že autoři v (6) použili pro trénování modelu jiný dataset, čím dosáhly obrovského přírůstku přesnosti. Vznikly dataset se jmenuje MAESTRO v1. Byl sestaven pomoci nahrávek vytvořených během 9-ti let pianových konkurzu. Obsahuje synchronizované na 3 ms (audio - MIDI) dvojice. Tak přesná synchronizace byla dosažená minimalizaci distanci mezi CQT ramcem z audia a vygenerovaným audiem na základě příslušného MIDI. Minimalizace distanci bylo provedeno pomoci technologie DTW. V Tab. 2.2 můžete vidět porovnání různých datasetů s MAESTRO v1.

Je vidět, ze MAESTRO v1 má skoro 10 krát větší počet not oproti MAPS datasetu (na němž byl trénován model z prací [5]).

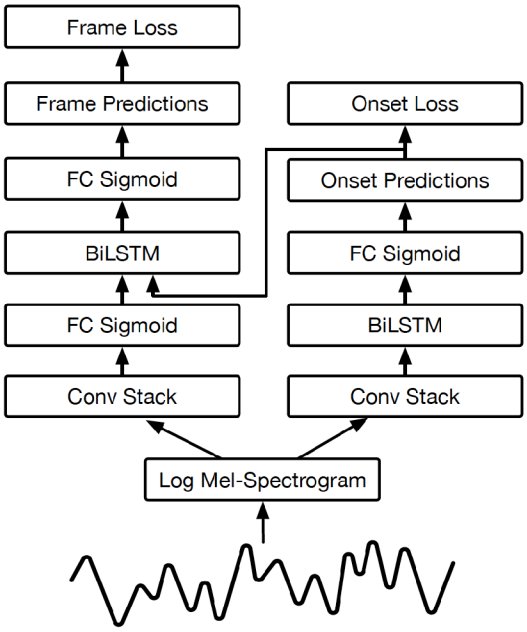


Obrázek 2.19: Architektura sítě [**?**]

| Dataset | Počet skladeb | Celková delka | Počet not(millin) |
|---|---|---|---|
| SMD | 50 | 4.7 | 0.15 |
| MusicNet | 60 | 15.3 | 0.58 |
| MAPS | 208 | 17.9 | 0.62 |
| MAESTRO v1 | 1184 | 172.3 | 6.18 |
| MAESTRO v2 | 1282 | 201.2 | 7.13 |

Tabulka 2.2: Porovnání datasetů [**?**].

# Kapitola 3

# Navrh systému

Cílem teto práce je navrhnout a implementovat systém, který by umožňoval uživateli cvičit libovolnou pianovou kompozici k niž má nahrávku. Systém má dvě klíčové funkce:

1. Převod nahravký do note batches reprezentaci (víz dál).
2. Během cvičícího procesu kontrolovat v reálném čase co přesně hraje uživatel.

První bod — transformace nahrávky do note batches — se dá implementovat za použití neuronovou síti z prací [6]. Přesnost jejích modelu je těžko dosažitelna v rámci diplomové prací a proto tento model (dál velká neuronová síť) bude skoro bez změn zahrnut do mého systému. Nedostatkem modelu z (6) je mala rychlost, typický zpracovaní vzorků délkou $x$ sekund trvá $x \times 2$ sekund. Což neumožní použití tohoto modelu ve druhem bodě. Proto jsem použil jinou neuronovou síť (dal real-time neuronová síť) jejž cílem je rychle poskytnutí klasifikaci vstupních audio vzorků z mikrofonu.

## 3.1 Notova reprezentace — note batches

V průběhu cvičícího procesu je potřeba rychlé, bez zbytečných vypočtu generovat seznam not, které mají být vykreslený na obrazovku v následující okamžik. Z již existujících formátu zaměřených na notový zápis, MIDI vypadá jako nejvhodnější. Při použití MIDI je ale potřeba projit fajl v několika cyklech:

1. Extrakce začátku a konce not.
2. Diskretizace času.

Proto byla navržena jiná metoda zápisu not obsazených v kompozice — note batches. Note batches představuje 2D seznam, kde první dimenze je tvořena časovou diskretizaci: jsou to indexy které představuji časové kroky. Druha dimenze představuje seznam not které mají znít v tento časově diskretizovaný okamžik. Každá nota je reprezentovaná MIDI kódem, s tou vyjmkou, že pokud kód je větší než 100, to znamená že nota s kódem MIDI = (kód $-100$) má začátek v daný okamžik. Porovnání note batches, MIDI a notového zápisu můžete vidět na Obr. 3.1.

Tato notová reprezentace umožňuje rychle kreslit poznámky na obrazovce. Vše, co musíte udělat, je načíst další řádek.

| | |
|---|---|
| 0 | [132] |
| 1 | [32, 152] |
| 2 | [32, 52] |
| 3 | [32, 52] |
| 4 | [32, 52] |
| 5 | [] |

Note batches

```
<message note_on channel=0 note=52 velocity=40 time=1521>
<message note_on channel=0 note=64 velocity=42 time=0>
<message note_on channel=0 note=59 velocity=43 time=211>
<message note_on channel=0 note=64 velocity=0 time=141>
<message note_on channel=0 note=64 velocity=44 time=0>
<message note_on channel=0 note=55 velocity=45 time=14>
<message note_on channel=0 note=59 velocity=0 time=126>
<message note_on channel=0 note=59 velocity=46 time=0>
<message note_on channel=0 note=52 velocity=0 time=141>
```

MIDI soubor

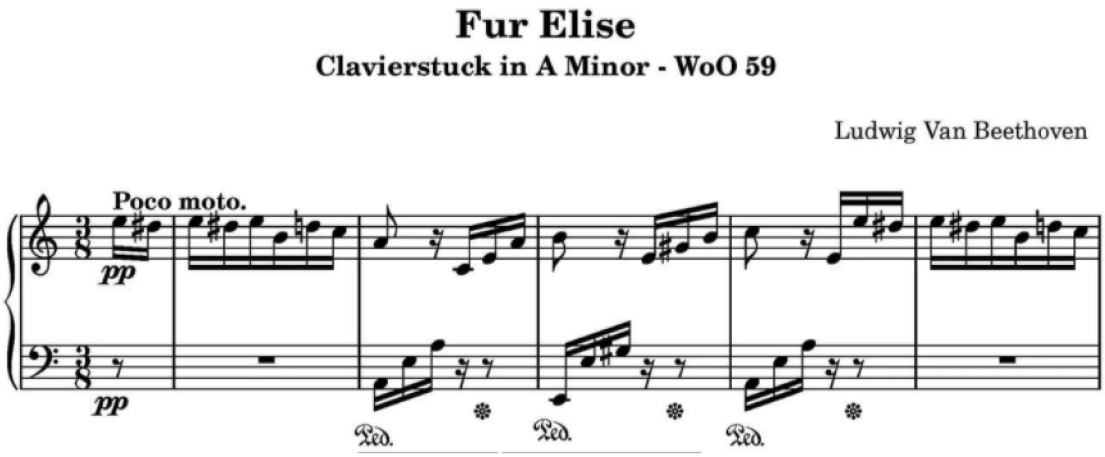


Hudebni zapis not

Obrázek 3.1: Ukázka různých způsobu reprezentaci not.

## 3.2 Cvičicí proces

Cvičící proces obsahuje tři sub-procesy: řídicí proces, proces poslouchání a rozpoznávání. Každý sub-proces má cyklus který vykonává určitou hlavní činnost. Tyto činnosti budou popsaný niž.

paragraphŘídicí proces

Z reprezentaci note batches aplikace bude postupně vykreslovat nahoru obrazovky noty, kde každá nota bude reprezentovaná obdélníkem. Během času aplikace bude postupně posouvat noty dolu dokud nějaká nota(obdélník) se nedotkne klávesy v dolní častí obrazovky. Když nota se dotkla klávesy proces přestane posouvat noty dolu. Proces prodlouží posouvat noty dolu až zjistí že všechny potřebné klávesy byli zmáčknuty. Klávesy které byli zmáčknuty v tento okamžik proces dostane ze seznamu - $list_{prediction}$.

**Proces poslouchaní** Tento proces pravidelně sbírá audio signal z mikrofonu, uplatňuje na tento signal filtr pro redukujicí šumu (víz dal), a ukladá výsledný signal do seznamu - $list_{listening}$.

**Proces rozpoznávaní** Tento procs bude spuštěn zároveň s předchozími procesy. Daný proces bude v cyklu:

1. Načítat audio vzorky ze seznamu - $list_{listening}$.
2. Převádět tyto audio vzorky na vstup do real-time neuronové síti.
3. Zapisovat výstup real-time neuronové sítě do seznamu $list_{prediction}$.

## 3.3 Real-time neural network

Cílem real-time neuronové sítě - poskytovat rychlou klasifikaci vstupních audio vzorků. K tomu aby aplikace vůbec byla funkční je potřeba kromě rychlosti dosáhnout navíc přijatelnou pro uživatele přesnost. V teto kapitole bude probrán postup pro vytváření a trénovaní neuronové sítě, která by dokázala splnit tyto protichůdné požadavky.

### 3.3.1 Architektura neuronové sítě

Od výběru vhodně architektury závisí rychlost výsledné neuronové síti a taky schopnost budoucí neuronové sítí zobecnit data, která ta uvidí v datasetu. Od vyberu vhodné velikosti závisí schopnost neuronové sítě dosáhnout požadované přesnosti. Proto je tady důležité zvolit správnou architekturu a zváženou velikost. Ale s rostoucí velkosti model se těžší trénuje. Kvůli tomu nejjednodušším řešením by bylo použit jíž trénovanou neuronovou síť na jiných datech a pomoci Transfer learningu (víz 2.2.2) přizpůsobit tuto síť k náš aplikace. Jako kandidáty byli zvolený VGG16 a MobileNetV2. Důvody proč pravě tyto modely jsou následující:

- VGG16 je jednou z nejmenších konvolučních neuronovou síti, ale přesto přesnost této sítě jenom o trochu hůř než u větších analogu.
- MobileNetV2 je konvoluční neuronová sít která primárně určena k běhu na mobilních zařízení a proto musí byt velmi rychlá.

Po změně počtu neuronů výstupní vrstvy na 88 (aby sítě byli užitečný pro klasifikaci not) byli provedený testy rychlosti. Na vstup 10000 krát byl podán stejný obrázek. Testy byli provedeny na následujícím počítači:

- Procesor: 2,7 GHz Intel Core i5
- RAM: 8 GB DDR3
- Operační systém: macOS Mojave

Výsledky jsou znázorněny v tabulce 3.1.

| Model | Avg-t(s) | Max-t(s) | Min-t(s) |
|---|---|---|---|
| VGG16 | 0.34 | 1.8 | 0.2 |
| MobileNetV2 | 0.05 | 0.29 | 0.027 |
| Real-time NN | 0.001 | 0.004 | 0.001 |

Tabulka 3.1: Porovnání rychlosti různych architektur neuronových síti

Jak je vidět nejbližší výsledky k real-time ukazuje MobileNetV2. Ale přesto že minimální hodnoty úplně stačí pro účely výsledné aplikace, průměrná hodnota bude způsobovat citlivé zatížení systému. Tady je potřeba brat v potaz, že než neuronová síť začne zpracovávat vstup, na začátek je potřeba načíst z mikrofonu audio vzorky(20ms) a provést redukci sumu a převést výsledný signál do CQT(víc dal). Pravě proto rychlost uvedených výše neuronových sítí nestačí.

### 3.3.2 Vlastní neuronová sít

Z uvedených výše důvodu bylo rozhodnuto trénovat vlastní neuronovou síť úplně od začátku. Jako možné kandidáty architektur se dá považovat RNN a CNN. Pomoci frameworku Keras jsem vytvořil male neuronové sítě uvedených typu. A na málem datasetu jsem porovnal rychlosti s jakou dokážou trénovat. Bylo provedeno jedno málé trénování. Účelem daného trénování bylo se podívat jak uvedené architektury neuronových síti zvladnou data z naše datové sady. Jako limit délky trénovaní byl stanoven na 100 epoch. Výsledky můžete vidět v tabulce 3.2 Jak je vidět přesnosti sítí jsou srovnatelné, ale délka trénování u RNN mnohem

| Model | Loss | Acc | Čas (m) |
|---|---|---|---|
| CNN | 0.0034 | 0.5575 | 11 |
| RNN | 0.0041 | 0.5454 | 19 |

Tabulka 3.2: Porovnání trénování CNN a RNN, kde Loss - ztrátová funkce a Acc - přesnost modelu, Čas - čas v minutech který byl věnovan 100 epocham trénování

výše. Proto k dalšímu trénování byla zvolena pouze CNN síť. Výsledky testu rychlosti pro CNN jsou popsané v tabulce 3.1 v řadku *Real-time NN*.

### 3.3.3 Vytvaření datasetu

K tomu abych dokázal natrénovat vlastní neuronovou síť je potřeba vytvořit dataset. Autoři (6) po trénování jejích neuronové sítí pokračovali ve sbíraní dat do nového datasetu -

MAESTRO v2, který byl zveřejněn na podzimu 2019. Tento dataset obsahuje 11 krát více dat pro trénování než předchozí dataset MARS (víc porovnaní datasetu 2.2) a má celkem 121.8 GB pianových nahrávek a příslušných MIDI souborů.

paragraphPřiprava datasetu

Původně dataset MAESTRO v2 obsahuje *.wav* kompozice a příslušné $.MIDI$ soubory . V takové podobě dataset je skoro neužitečný. Proto musíme jeho určitým způsobem upravit tak, aby bylo možně na něm trénovat naši neuronovou sít. Úpravy budou se tykat:

- Čištění dat
- Transformace celých kompozic (.wav, .MIDI) do malých dvojic (.csv, .csv)

paragraphČištění dat Po zkoumání datasetu bylo odhaleno několik kompozici s jinými hudebníma nástroji(housle). Tyto nastroje hrají zpravidla odlišné noty. V rámci trénování neuronové sítě pro klasifikaci pianových not tyto odlišné nastroje by pouze zvětšovali šum a bránili by neuronové sítě zobecnit užitečná data. Proto každý audiozáznam(.wav) v datasetu byl v rychlosti poslechnout a kompozice s více nastrojí byli eliminovaný z datasetu. Celkem bylo eliminováno 6 kompozic.

Taky v datasetu byla odhalená velká disproporce not. Na Obr. 3.2 se ukazuje počet každé noty v datasetu.

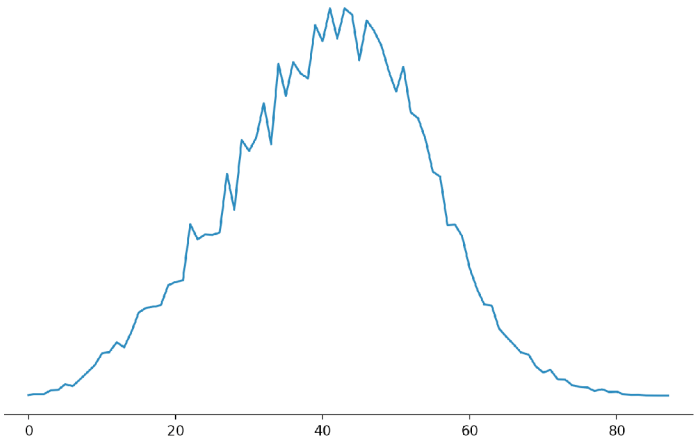


Obrázek 3.2: Distribuce not v původním datasetu

Jak je vidět z obrázku počet vzorků s noty od 25 do 60 je mnohém výši než ostatních. Tato skutečnost může způsobit úplné ignorování not s malým počtem výskytu. Kvůli tomu a faktu že v rámci diplomové prací těžko trénovat neuronovou sít s $> 100$ GB dat, bylo rozhodnuto zmenšit dataset. Ale zmenšování bude probíhat takovým způsobem, který co nejvíce upraví distribuci poctu not v datasetu. V podstatě nebudu redukovat tento dataset, ale spíš vytvářím nový dataset ze starého.

Algoritmus pro vytváření nového datasetů:

1. Na začátku dataset je prázdný
2. Všechny kompozice jsou tříděný podle poměru

$$\frac{N}{N'},$$

kde $N$ - celkový počet not, $N'$ - počet not s MIDI kódem $< 25$ nebo $> 60$

3. Nad každou dvojici souboru (.wav, .MIDI) provést diskretizaci s krokem v 20 ms. Z toho dostaneme dvojici (PCM vzorky, seznam MIDI kódu).

4. Eliminovat zbytečné dvojice(víc dal).

5. Přidat augmentované vzorky(víc dal).

6. Pokud nepřevýšen limit ve počtu vzorků nebo v obsažené pamětí pokračuj, jinak přeskoč na bod 8.

7. Pokračuj od 3.

8. Dataset je připraven.

extbfEliminace zbytečných dvojíc. Dvojice (PCM vzorky, seznam MIDI kódu) se považuje za zbytečný pokud:

- Seznam MIDI kódu je prázdny: dataset i bez těchto trénovacích dojíc obsahuje velkou množinu příkladu kdy nějaká nota je potichu.

- V teto dvojice teprve začala nebo skončila znít nějaká nota: 20ms je zcela male okno, ale klidně může zachytit změnu, což bude znamenat ze část PCM vzorku neodpovídá seznam MIDI kódu.

- Potom z našeho datasetu chceme extrahovat co nejvíc různých vzorku. Ale máme redukovat 120 GB dat do toho co bychom dokázali časově rozume zpracovávat. Tento limit velikosti byl stanoven na 14 GB. Proto do výsledného datasetu byl zařízen pouze každý 5. vzorek.

**Augmentace dvojic**. Jak je bylo uvedeno předtím, máme příliš velkou disproporci poctu not v datasetu. Proto kdy se nám povede najít dobry PCM vzorku které budou mít pouze noty které nám chybí, potom budeme chtít několikanásobně kopírovat tuto dvojici do našeho budoucího datasetu. Ale jednoduché kopírovaní taky může uškodit - neuronová sít bude podceňovat ostatní dvojice. Proto při kopírovaní trénovací dvojice která už je obsazena v datasetu, do PCM vzorku bude přidán malý aditivní bily sum[1].

Po provedeni výše uvedeného algoritmu nad původním datasetu dostali jsem novy dataset. Distribuce poctu not nového datasetu je ukázaná na Obr. 3.3.

Jak je vidět, tato transformace dokázala aspoň trochu vyvažit distribuci poctu not.

**Transformace dat**. Když na dataset bude obsahovat dvojici (audio vzorky, odpověď) neuronová sít bude se učit velmi dlouho. Typický, za účelem pomoct sítí zobecnit data, na audio vzorky se aplikuje nějaká z transformaci: FFT, Mel-spec, CQT(vic 2.1.3). V případě že se jedna o klasifikaci zvuku obvykle se používá Mel-spec nebo CQT. K tomu abych zvolil druh transformace zase byla provedená série experimentů. Z datasetu který obsahoval trénovací dvojice (PCM vzorky, seznam MIDI kódu) bylo vytvořeno dva dalších datasetu:

- (Mel-spektrum, seznam MIDI kódu)

- (CQT-spektrum, seznam MIDI kódu)

CNN síť byla trénováná 100 epoch pro každý druh datasetu. Výsledky experimentů jsou dole v tabulce 3.4: Jak je vidět z dané tabulky, výsledky nad CQT-datasetem mnohem lepší.

[1] TODO Bily sum. numpy

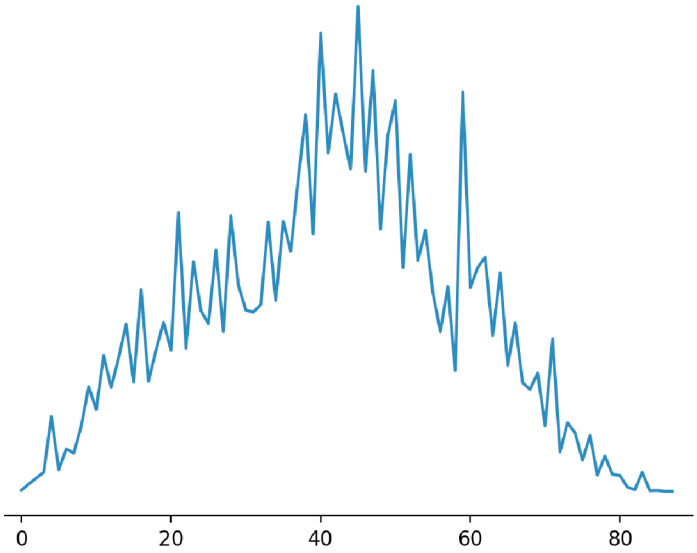


Obrázek 3.3: Distribuce not v novem datasetu

Právě proto výsledný dataset bude tvořen pomoci CQT transformaci audio signálu.

Jak bylo popsano v teoretické části algoritmy strojového účení lepe pracujou na normalizovaných datech - rozsah hodnot vstupních dat musí být (-1, 1). Proto poté co jsme vytvořili CQT-dataset, tento dataset bude normalizovan - CQT koeficienty budou převedeny do jiného měřitka (od -1 do 1).

Následně dataset byl rozdělen do třech menších datasetů: trenováci, testovácí a validační. Trenovácí dataset se používál pro trénováni neuronové sítě. Na validačním datasetu byla provedená průběžná kontrola, zda nedošlo k přeučení neuronové sítě (víc dal). Kontrola byla provaděna jednou za 5 epoch. Testovácí dataset byl použit až na konci k hodnocení výsledné neuronové sítě. Počet trénovácích dvoic v každem datasetu je znazorněn v tabulce 3.3.

| Typ datasetu | Počet trénovácích dvojic |
|---|---|
| Trenováci | 1 722 685 |
| Validační | 215 335 |
| Testovácí | 215 336 |

Tabulka 3.3: Rozdělení datasetu na tři dalších datasety.

## 3.4 Implementace

Tato sekce udělá rychlou rekapitulaci problému a řešení vzniklých během implementaci vysedne aplikaci.

### 3.4.1 Volba užitečného ML frameworku

Pro trénování neuronových sítí existuje spousta ML(strojové učení) framworku. Nejrozšířenější jsou Keras a Pytorch. Pytorch je framework pro strojové učení od Facebook který je

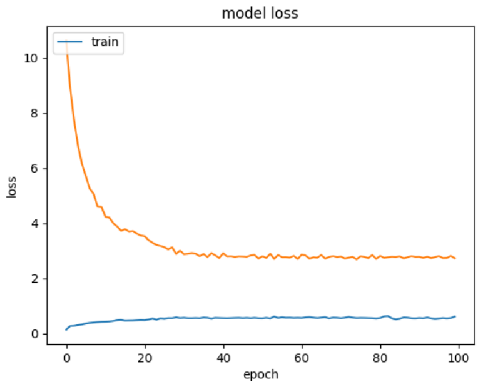


(a) Mel-dataset (a)

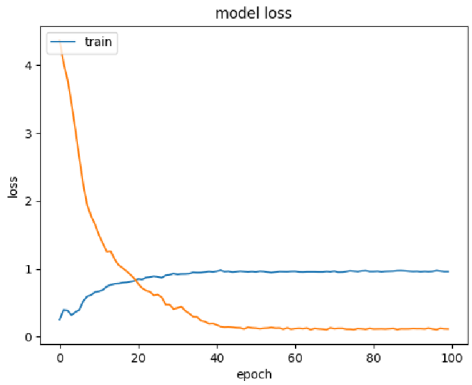


(b) CQT-dataset (b)

Obrázek 3.4: Porovnání rychlosti trénování neuronové sítě nad CQT-datasetem a Mel-datasetem. Modrou barvou označena přesnost neuronové sítě, oranžovou barvou označena ztrátová funkce (víc 2.2.3).

zaměřen spíš na zkoumání: dá se dynamicky měnit architekturu behem trénovani, ale inference[2] sítě prochází pomaleji než u Kerasu. Taky nevýhodou Pytorch je to, že on nemá implementované multiprocesingové trénování. Implementovat samostatně multiprocesingové trénování neuronové sítí může výrazně zkomplikovat vytváření aplikace. Proto jako trénovací framework byl zvolen Keras. Keras ale má taky výrazný nedostatek — když neuronová síť bude dělat inference modelu, Keras bude načítat celou neuronovou síť do operační paměti úplně znova. Načítaní typický zabere půl vteřiny. To bude negovat veškeré naše úsilí o výběr správné architektury. Řešením daného problému je převod Keras modelu do ONNX(Open Neural Network Exchange) modelu. ONNX je knihovna která se používá pro výměnu modelů mezi různými ML frameworky. Kromě toho ale ONNX má i vlastní inference. Tento inference nepotřebuje pokaždé načítat neuronovou síť do operační paměti(stačí pouze jednou, na začátku). Dany fakt výrazně zkrátí časovou zátěž výsledné aplikace.

### 3.4.2 Předzpracování vstupního signálu, redukce sumu.

Tato aplikace je určena pro spuštěni na vlastním počítači, nikoliv na profesionálním přistroje v studii. A proto existuje velké riziko najít ve vstupním signálu z mikrofonu hodně sumu. Vliv tohoto sumu je potřeba redukovat. Za tímto účelem v aplikaci je použita redukce sumu na základe FFT (víz 2.1.3). Algoritmus filtraci sumu je následující:

1. Převést vstupní vzorky do FFT.
2. Na základe pevně stanoveného prahu odstranit všechny frekvence které mají nízkou silu.
3. Provedením inverzní FFT dostat audio signál s redukovaným šumem zpátky.

Vliv použiti daného filtru na reálný audio signál je vidět na 3.5.

[2]Inference je to čast programu, která dokaže spustit neuronovou síť na základě souborů kde daná síť je zapsaná.

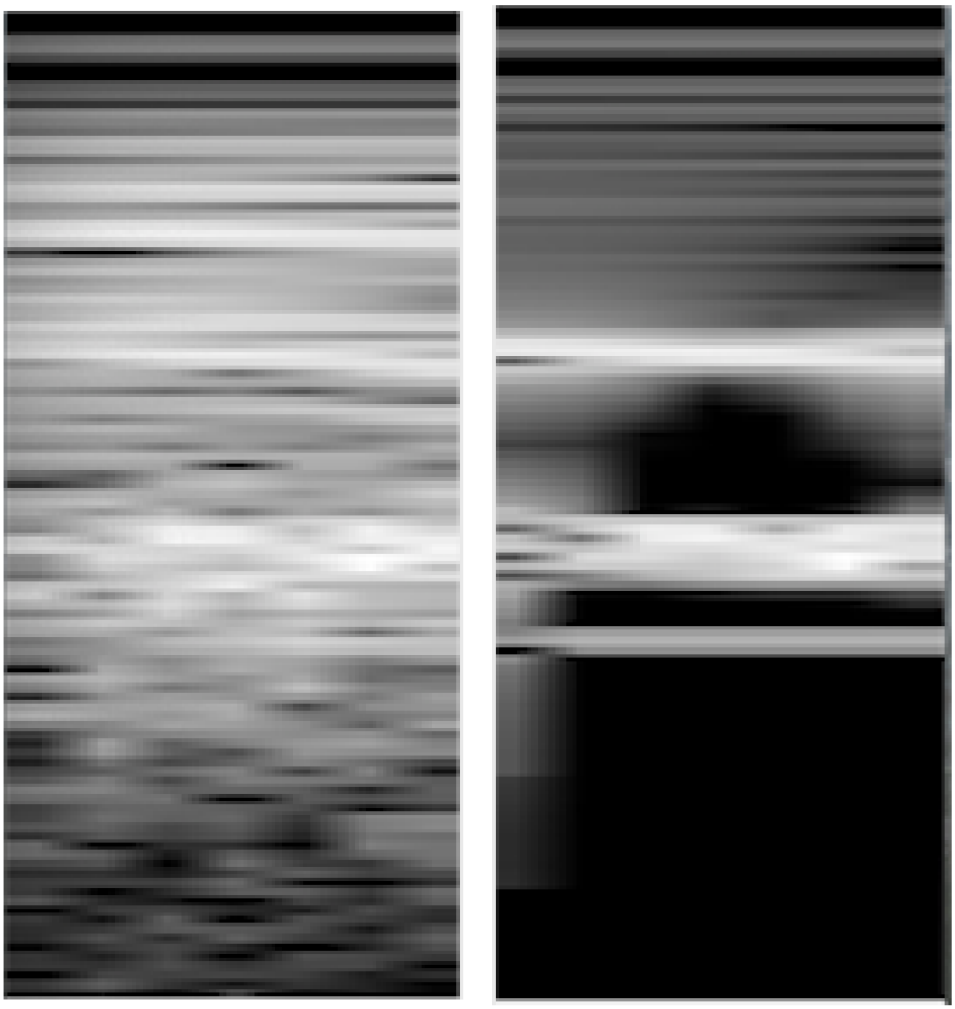

(a) Původní signál

(b) Filtrovaný signál

Obrázek 3.5: Porovnání spektrogramu původní nahrávky z mikrofonu (a) a nahrávky s redukovaným šumem (b).

### 3.4.3 Trénování real-time neuronové sítě

Bylo vyzkoušeno několik architektur typu CNN. Jako nejvíc perspektivní se ukázala architektura která znazorněna v tabulce. 3.4 Trénování probíhalo na vypočetním klasteru

| Typ vrstvy | Počet neuronů |
|---|---|
| Conv | 100 |
| Pooling | - |
| Conv | 100 |
| Pooling | - |
| Conv | 100 |
| Pooling | - |
| Dense | 1000 |
| Dense | 512 |
| Dense | 88 |

Tabulka 3.4: Finalní architektura real-time neuronové sítě, kde *Conv* - konvoluční vrstva, *Pooling* - sdružující vrstva, *Dense* - plně propojena vrstva.

- METACENTRUMTODO cite. Výsldená síť byla trénována během 5ti dnů. Za tento čas bylo provedeno 97 epoch trénovácího cyklu. Za účelem zabránění přeučeni bylo nastaveno dočasné ukončení trénování v případě, že ztratová funkce nebude se zlepšovat během 10ti eopch. Kvůli tomu že nedošlo k dočasnému ukončení se dá říct, že síť má potencial se zlepšit při pokračování trénováni v budoucnu.

### 3.4.4 Grafická část

Grafická část je implementovaná s využitím knihovny Pygame. Z důvodu vzniklých problému ve již vyřešených modulech programu celková aplikace bude mít redukovanou funkcionalitu, a to za účelem robustního fungovaní přípustných modulu. Aplikace bude mít pouze jedno okno které je znázorněné na obrázku 3.6.

Okno obsahuje pouze jedno tlačítko — Výběr Fajlu. Po zmačknutí na toto tlačítko uživateli se zobrazí obsah složky songs (budou zobrazeny pouze soubory: .midi, .mid, .wav a .csv). Pokud uživatel bude chtít cvičit kompozici z vlastního souboru, pak bude muset umístit vlastní soubor do teto složky. Když uživatel zvolí subor který se chce naučit, aplikace začne cvičící proces. Když poslední obdélník (nota) zmizí, cvičili proces se automatický zakonči.

Uživatelský workflow se dá shrnout do následujících bodů:

1. Uživatel zvolí nahrávku pianové kompozici.
2. Aplikace na základě velké neuronové sítě převede tuto nahrávku do speciální vnitřní reprezentaci - note batches.
3. Aplikace na základě reprezentaci note batches začne cvičící proces.

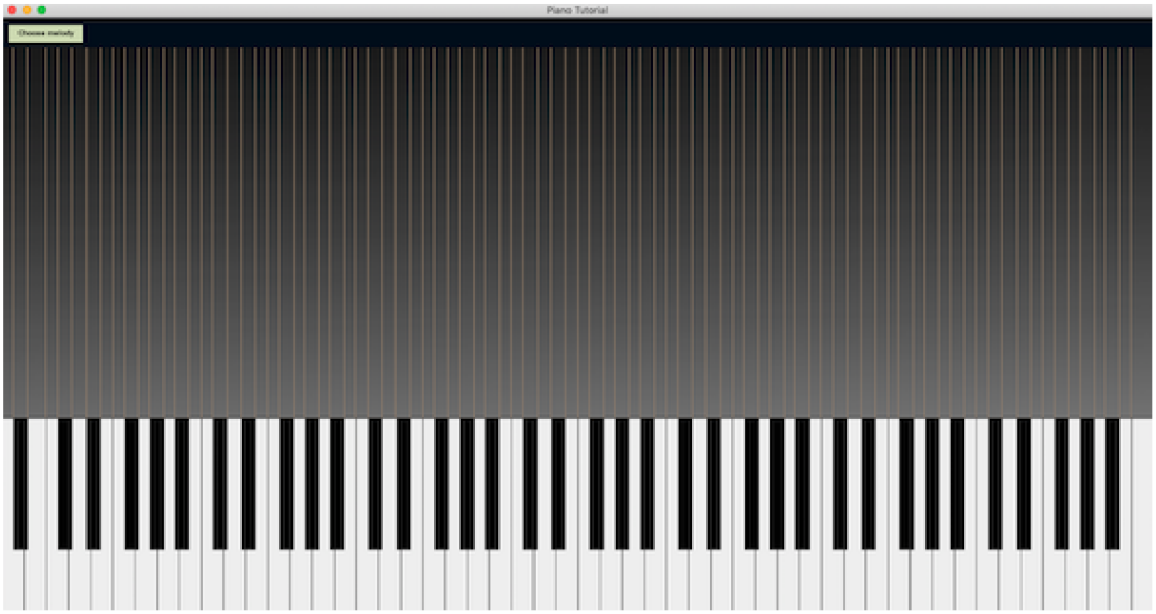


Obrázek 3.6: Ukazka GUI

# Kapitola 4

# Experimentální vychodnocení

Dana kapitola se zabývá experimentálním ohodnocením vytvořené aplikaci.

## 4.1 Časové testy

V tabulce 4.1 jsou znázorněny časy běhu jednotlivých modulů. Tabulka taky obsahuje komulované časy které udávají přehled o celkové rychlosti aplikaci. Jak je vidět z tabulky

| Modul | Avg-t(s) | Max-t(s) | Min-t(s) |
|---|---|---|---|
| Překreslování | 0.007 | 0.085 | 0.003 |
| Zvuk (komplet) | 0.069 | 0.963 | 0.04 |
| CQT | 0.054 | 0.836 | 0.036 |
| Normalizace | 0.0007 | 0.002 | 0.0005 |
| Rozpoznavání | 0.002 | 0.006 | 0.001 |

Tabulka 4.1: Rychlost jednotlivých modulů aplikace, kde: *Překreslování* - kompletní čas vykreslování nové obrazovky (GUI loop), *Zvuk komplet* - čas pro zpracování zvuku (bez načítaní mikrofonu), *CQT* - čas potřebný pro transofrmaci zvukového signálu pomoci CQT, *Normalizace* - čas potřebný pro normalizaci výsledku CQT transofrmaci, *Rozpoznavání* - čas potřebný pro inference neuronové sítě.

průměrná doba od začátku poslouchaní do klasifikaci audio vzorků je *Zvuk (komplet)* + *20*ms = 0.089 sekund což se dá považovat za skoro real-time. Taková mala rychlost moc neobtěžuje systém, kvůli tomu, že grafika se kresli nezávislé od zpracování zvuku. V případě když modul zpracování zvuku nestihne předat rozpoznáné noty do modulu GUI, GUI bude používat rozpoznané noty z minulého okamžiku. A tím cela aplikace dokaže dosahnout v průměru 142 FPS[1]. Taký z této tabulky plně, že CQT transofmace zabírá příliš hodně času. Kdyby v budoucnu se podářilo změnšit čas na převodu zvukového signálu do frekvenční reprezentaci, pak by bylo možně použít větši a přisnější neuronovou síť.

[1]FPS - Snímková frekvence (z anglického frames per second)

## 4.2 Přesnost klasifikaci

Po trénování malá neuronová síť byla testovaná na datech které nebyli v datasetu. Různé metriky přesnosti jsou znázorněný v tabulce 4.2. Z tabulky plne že síť děla rělativně

| Metrika | Hodnota |
|---|---|
| Loss | 0.023 |
| Accuracy | 0.47 |
| f1 | 0.81 |
| precision | 0.87 |
| recall | 0.76 |

Tabulka 4.2: Různé metriky přesnosti výsledné real-time neuronové sítě.

málo chyb (*Loss=0.023*), ale taký plne že síť neprodukuje jísté odpovědi na vstupní data (*f1=0.81*). Pravděpodobně je to dano přiliš kratkou dobou trénování. Což ve výsledné aplikaci se dá vyřešit změnšeným prahem jistoty, kdy nota se považuje za detekovanou.

## 4.3 Hodnocení GUI

Aplikace byla poskytnuta 6 lidem s různým úrovněmi dovednosti hry na klavíru. Subjektivní hodnocení se dá shrnou do následujícího pasáže: 'Aplikace na učení hry na klavíru je celkem funkční. Začíná fungovat špatně při zvýšení úrovně šumu v prostředí kolem. Chybí možnost opakovat segmenty kompozice.'

## 4.4 Omezení

Podle provedených zkoušek aplikace může (subjektivně) dobře fungovat pouze pokud šum v prostředí je méně než 38 dB, pokud šum 40 dB a větší aplikaci je dost těžko použit.

# Kapitola 5

# Budoucí práce

Samozřejmě představená aplikace chce několik vylepšení a to jsou:

- Vyběr jíne frekvenční reprezentaci zvukového signálu nebo optimalizace již existujicích řešení pro vypočet CQT.
- Zvětšení přesntostí real-time neuronové sítí. A to zajmena pomocí zvětšení počtu skrytych konvolučních vrstev v real-time neuronové sítě, delšího trenovacího procesu a zvětšení datasetu.
- Přídaní možnost opakovaně cvičit pouze čast kompozice
- Přídaní možnosti zápisu kompozice pro cvičení přímo v aplikaci.
- Přidaní rozpoznavání více formatů kromě (zatim aplikace umi pouze .wav a .MIDI).
- Přidaní možnosti upravovat komozici a ukladat ji do MIDI formatu.

# Kapitola 6

# Závěr

Cílem dané diplomové prací bylo vytvořeni aplikaci pro podporu cvičeni hry na klavíru. Návrh takové aplikace představuje netriviální úlohu, zejména kvůli následujícím dvěma problémům. Prvním problémem je přesný překlad zvukového záznamu uživatele do vnitrní reprezentace, na základe které pak bude uživatel trénován. Druhým problémem je pořízení zvuku z mikrofonu a kontrola v reálném čase zda to, co uživatel hraje, odpovídá originální nahrávce, aby aplikace včas zastavila cvičeni. Hlavním rozdílem mezi prvním a druhým problémem je nárok na přesnost a rychlost. V prvním případě je důležitá přesnost transkripce hudby do not, zatímco rychlost zpracováni kritická není. Oproti tomu ve druhém případě, při real-time kontrole uživatele, je doba zpracování jednoho zvukového fragmentu na prvním místě. Oba dva problémy byli redukovaný na problém klasifikace přehrávaných not podle fragmentu zvukového záznamu.

Naše řešení je bylo založené na použiti dvou různé velkých neuronových síti (každá pro jednotlivé části programu) s různými architekturami. První neuronová síť je zaměřena na přesnou transkripci zvukové nahrávky do vnitřní reprezentaci notového zápisu - note batches. Dana síť s malými změny byla převzata z již existující prací [6]. Druhá síť byla vytvořená vlastními síly a použita za účelem průběžné kontroly zvuku z mikrofonu, během cvičícího procesu. Velka část dané práci se zabývala vytvoření vlastní real-time neuronové sítě: výběru architektury, formátu vstupních dat, přípravou datasetu a trénování.

Za účelem ověřeni přípustnosti nově navrženého řešení byla provedena série experimentu. Aplikace byla testovaná jak z časového hlediska tak i z hlediska použitelnosti konečným uživatelem. Pomoci těchto testu byla ověřena vhodnost zvolených architektur neuronových síti. Taky testy ukázali ze za určitých podmínek(omezeni) aplikace je celkem funkční.

# Literatura

[1] Benetos, E., Dixon, S., Duan, Z. a Ewert, S. Automatic Music Transcription: An Overview. *IEEE Signal Processing Magazine*. Leden 2019, sv. 36, s. 20–30.

[2] Hlavsa, Z. et al. *Pravidla českého pravopisu*. 2. vyd. Academia, 2009. ISBN 80-200-1327-X.

[3] Knuth, D. E. *The TEXbook*. Addison-Wesley Publishing Company, 1996. ISBN 0-201-13447-0.