

Rozpoznávanie posunkovej reči (SLR)

Baška Ľapinová

21.3.2024

Obsah

- Motivácia
- Posunková reč
- Bakalárska práca
- Prechod k diplomovej práci

1. časť

Motivácia

Motivácia

- **Posunková reč** je jazyk používaný komunitou nepočujúcich a ťažko sluchovo postihnutých ľudí.
- Ide o najpodstatnejší spôsob dorozumievania sa pre túto komunitu.
- Aj napriek tomu prevláda **komunikačná bariéra** medzi nepočujúcou a nedoslýchavou minoritou a zvyškom populácie.
- **Nová oblast výskumu** – ropoznávanie posunkovej reči začalo naberat' na popularite začiatkom 90. rokov 20. storočia¹.
- Súčasný stav rozpoznávania posunkovej reči **zaostáva** za systémami rozpoznávania reči z audio nahrávok o približne **30 rokov**².

¹CHEOK, M. J., OMAR, Z., JAWARD, M. H., 2019. A review of hand gesture and sign language recognition techniques. International Journal of Machine Learning and Cybernetics, 10, 131-153.

²ELAKKIYA, R., 2021. RETRACTED ARTICLE: Machine learning based sign language recognition: a review and its research frontier. Journal of Ambient Intelligence and Humanized Computing, 12(7), 7205-7224

2. část

Posunková reč

Posunková reč

- Vizuálny a manuálny jazyk so štrukturovanou formou gest rúk.
- **Bohatý a komplexný** jazyk – umožňuje diferencovanú komunikáciu.
- Vo svete existuje mnoho posunkových jazykov.
- Naša práca sa venuje **Americkej posunkovej reči** (ASL):
 - Až do roku **1960** sa znaky považovali za **neanalyzovateľné** a **neštrukturované**.
 - Prvý deskriptívny systém zaviedol **William C. Stokoe**.
 - **Stokoeho notácia znakovej reči** – každý znak sa skladá z troch parametrov (umiestnenie ruky, tvar ruky, jej pohyb).
 - Ako tvar ruky často slúžia znaky **Americkej manuálnej abecedy** (AMA)³.

³ STOKOE, W. C., 1980. Sign language structure. Annual review of anthropology, 9(1), 365-390.

Posunok

Dnes je už známe, že sa posunok skladá z piatich základných častí:

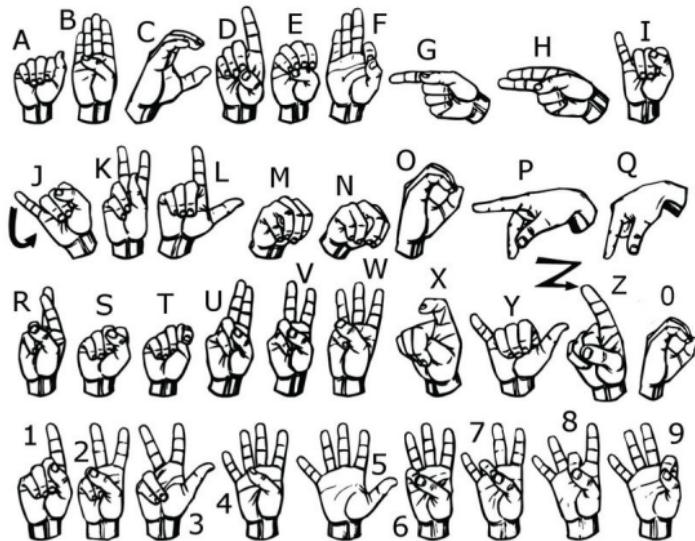
1. Umiestnenie ruky.
2. Tvar ruky.
3. Pohyb, ktorý ruka vykonáva.
4. Orientácia dlane.
5. Výraz tváre.



Obr.: Posunok pre slovo cat⁴.

⁴<https://www.lifeprint.com/asl101/pages-signs/c/cat.htm>

Posunková reč



Obr.: Abeceda a číslice v ASL⁵.

⁵VALLI, C., LUCAS, C., 2000. Linguistics of American sign language: An introduction. Gallaudet University Press.

3. časť

Bakalárská práca

Zadanie bakalárskej práce

Téma: Klasifikácia znakov v posunkovej reči pomocou metód strojového učenia.

- Ciele:**
1. Vytvoriť prehľad aktuálne existujúcich metód strojového učenia na spracovanie obrazu.
 2. Navrhnúť a implementovať kombináciu metód strojového učenia vhodnú na klasifikáciu znakov v posunkovej reči.
 3. Implementovať metódy neurónových sietí na lokalizáciu objektov z obrázkov posunkovej reči a porovnať dosiahnuté výsledky.

Postup riešenia problému



Obr.: Diagram procesu vlastného riešenia problému.

Údajová sada

- Obrázky so znakmi AMA, **okrem písmen J a Z.**
- Dve formy: pôvodná (nespracovaná) a upravená.
- **Pôvodné (nespracované) obrazové údaje:**
 - 1680 obrázkov od siedmich rôznych používateľov.
 - Každý znak je od každého používateľa znázornený na desiatich obrázkoch – tie sa od seba navzájom líšia.
 - Ku každému obrázku máme k dispozícii tabuľku so súradnicami okna, v ktorom sa nachádzajú informácie o polohe ruky na obrázku.



Obr.: Ukážka datasetu⁶.

⁶ REEJITH, S., 2018. Sign Language and Static Gesture Recognition using sklearn [online] [cit. 09.05.2023]. Dostupný na <https://github.com/mon95/Sign-Language-and-Static-gesture-recognition-using-sklearn>

Údajová sada

- Upravené obrázky s extrahovanou oblasťou ruky
 - V podobe štrukturovaných údajov.
 - Rozdelené na trénovaciu a testovaciu množinu.
 - Okrem extrakcie ruky autori tejto sady aplikovali na obrázky rôzne augmentácie, čím vytvorili dokopy takmer 35 000 vstupov.



Obr.: Ukážka obrázkov po predspracovaní⁷.

⁷ Sign Language MNIST, 2017. [online] [cit. 09.05.2023]. Dostupný na <https://www.kaggle.com/datasets/datamunge/sign-language-mnist>

1. Klasifikácia znaku AMA tradičnými metódami strojového učenia

- Použité klasifikátory boli založené na metódach **stroje s podpornými vektormi** (SVM) a **Gaussov naivný Bayes** (GNB).
- Implementácia v programovacom jazyku Python, použité metódy z knižnice *scikit-learn*.
- Ako vstupné údaje boli použité **štrukturované dátá**.
- Pre metódu SVM sme použili tri rôzne jadrové funkcie, metódu GNB sme použili bez ďalších úprav.

Model	Správnosť
SVM - Linear kernel	78%
SVM - RBF kernel	84%
SVM - Sigmoid kernel	2%
GNB	39%

Tabuľka: Výsledky klasifikácie tradičnými metódami strojového učenia.

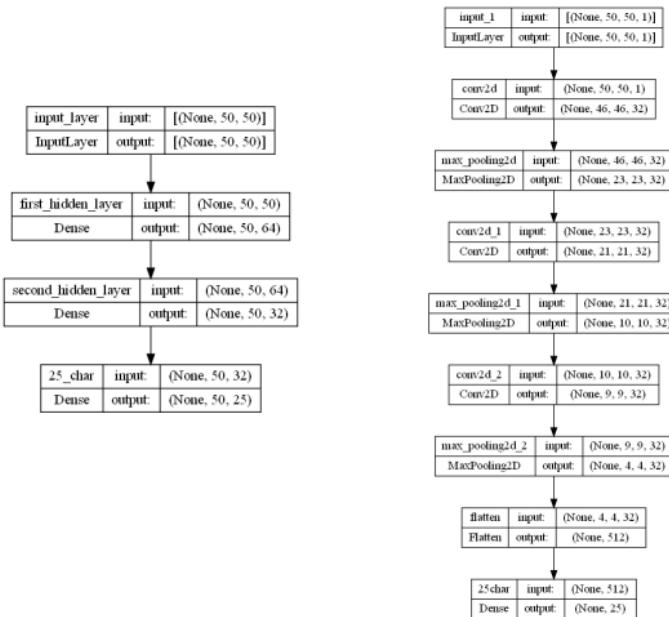
2. Klasifikácia znaku AMA metódami hĺbkového učenia

- Vstupnými údajmi boli v tomto prípade **nespracované obrázky**.
- Implementácia opäť v programovacom jazyku Python, konvolučné a neurónové siete sme zostavili pomocou knižníc *Keras* a *TensorFlow*.
- Dve hlavné časti:
 - **Klasifikácia AMA znakov** doprednými a konvolučnými neurónovými sieťami.
 - **Klasifikácia znaku AMA a lokalizácia posunkujúcej ruky na obrázku** pomocou konvolučných neurónových sietí.

2.1. Klasifikácia znaku AMA

- Prvým krokom bolo **predspracovanie údajov** – každý obrázok sme previedli do farebnej škály odtieňov sivej a orezali ho len na oblasť posunkujúcej ruky.
- **Rozdelenie údajov** na trénovaciu a testovaciu množinu.
- Následne sme zostavili **konvolučnú** a **doprednú** neurónovú sieť.
- Siete sme trénovali na rovnakých vstupných dátach na 50 a 100 epochách.

2.1. Klasifikácia znaku AMA

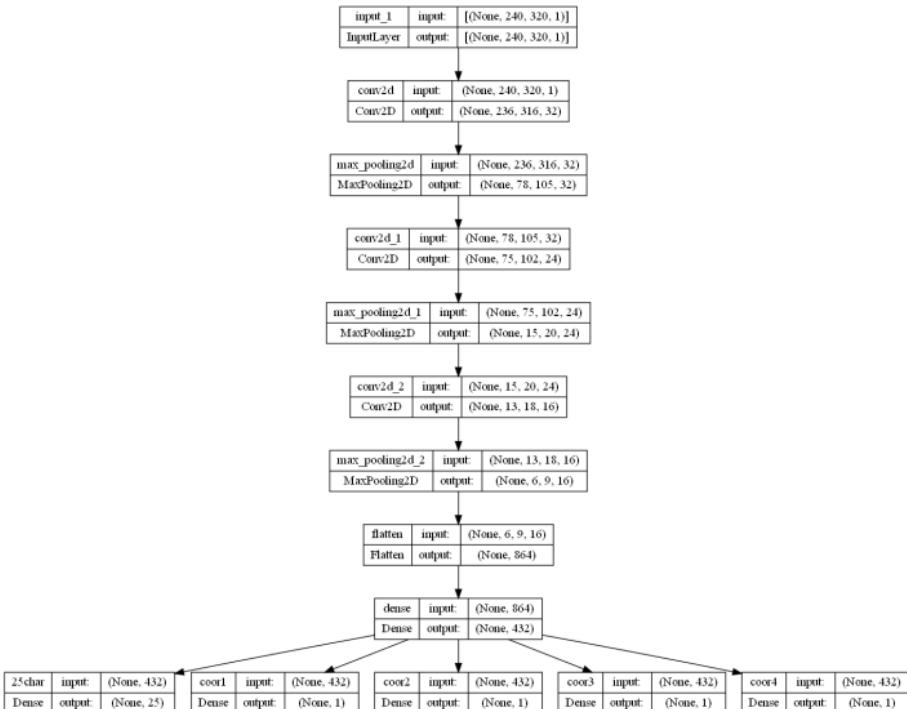


Obr.: Dopredná a konvolučná sieť použitá na klasifikáciu znaku AMA.

2.2. Lokalizácia posunkujúcej ruky a klasifikácia znaku AMA

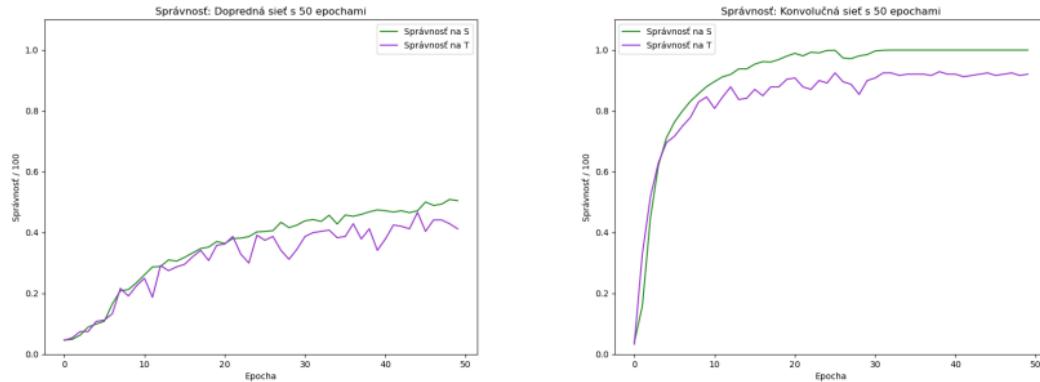
- Rozšírenie úlohy na **klasifikačno-regresnú**.
- Cieľom bolo okrem **znaku** posunkovaného na obrázku predpovedať súradnice **ľavého horného bodu** (x_1, y_1) a **pravého dolného rohu** (x_2, y_2), na základne ktorých sa zostrojí obdĺžnik ohraničujúci ruku – **bounding box**.
- Vstupnými údajmi boli **neorezané obrázky** v plnej veľkosti 320×240 , ktoré obsahovali rôzne rušivé elementy.

2.2. Lokalizácia posunkujúcej ruky a klasifikácia znaku AMA



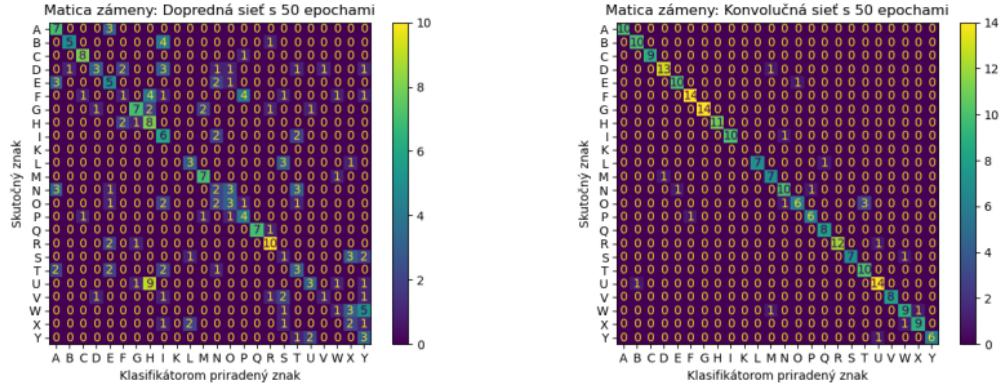
Obr.: Architektúra neurónovej siete pre klasifikačno-regresnú úlohu.

Výsledky – Klasifikácia znaku AMA doprenými a konvolučnými sietami trénovanými na 50 epochách



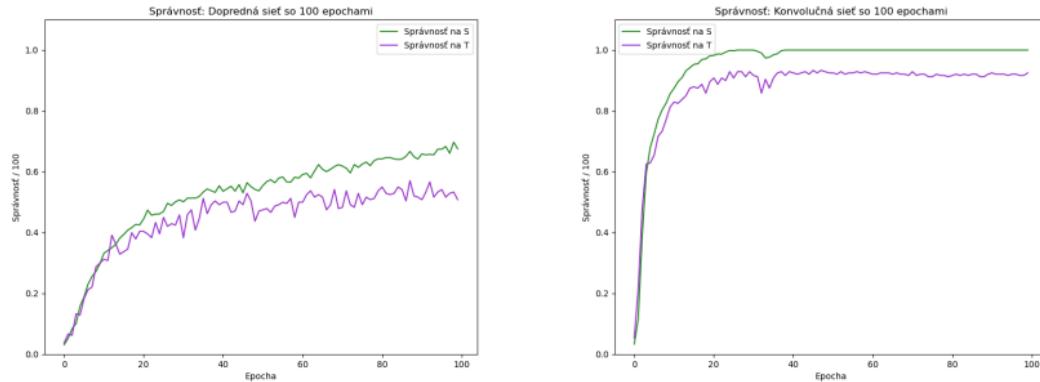
Obr.: Grafy znázorňujúce metriku správnosť v jednotlivých epochách na modeloch trénovaných na 50 epochách.

Výsledky – Klasifikácia znaku AMA doprednými a konvolučnými sietami trénovanými na 50 epochách



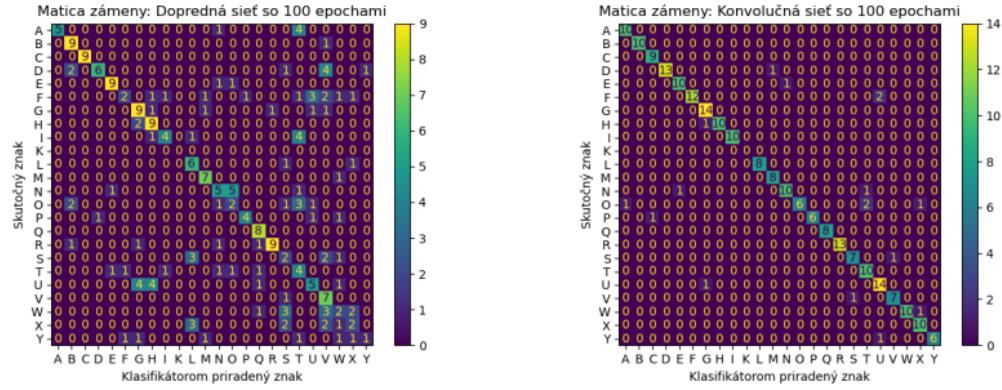
Obr.: Matice zámeny modelov trénovaných na 50 epochách.

Výsledky – Klasifikácia znaku AMA doprednými a konvolučnými sietami trénovanými na 100 epochách



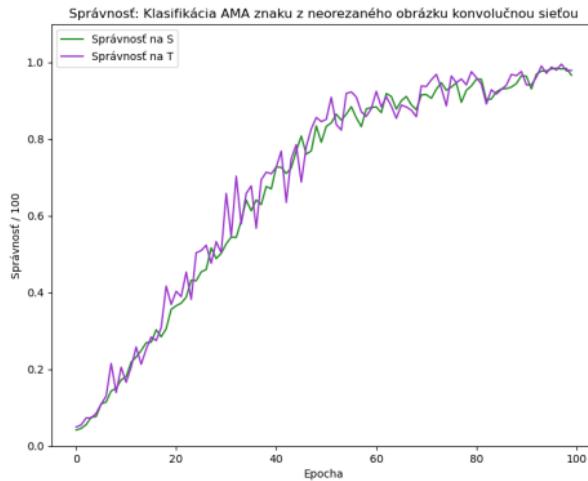
Obr.: Grafy znázorňujúce metriku správnosť v jednotlivých epochách na modeloch trénovaných na 100 epochách.

Výsledky – Klasifikácia znaku AMA doprednými a konvolučnými sietami trénovanými na 100 epochách



Obr.: Matice zámeny modelov trénovaných na 100 epochách.

Výsledky – Klasifikácia znaku AMA a lokalizácia ruky konvolučnými neurónovými sietami



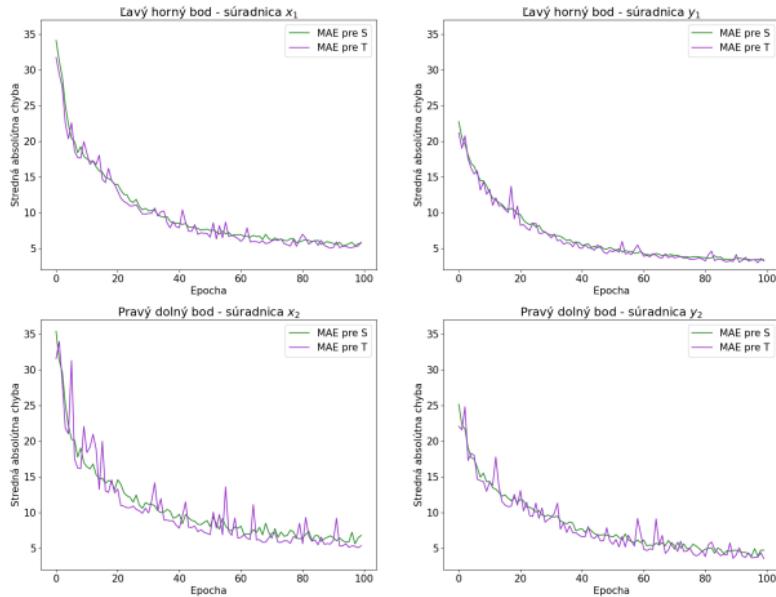
Obr.: Grafické znázornenie správnosti pre jednotlivé epochy klasifikačnej časti klasifikačno-regresnej úlohy.

Výsledky – Klasifikácia znaku AMA a lokalizácia ruky konvolučnými neurónovými sietami

Súradnica	MAE po 100 epochách	RMSE po 100 epochách
Ľavý horný bod – súradnica x_1	5.77	7.48
Ľavý horný bod – súradnica y_1	3.41	4.46
Pravý dolný bod – súradnica x_2	6.81	9.69
Pravý dolný bod – súradnica y_2	4.73	6.01

Tabuľka: Výsledky regresnej časti po 100 epochách.

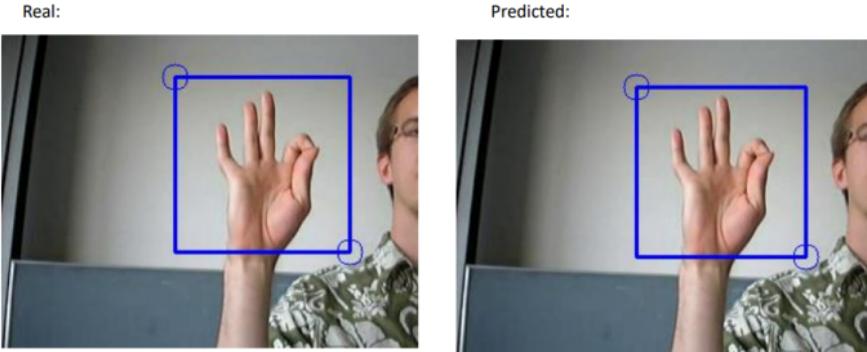
Výsledky – Klasifikácia znaku AMA a lokalizácia ruky konvolučnými neurónovými sietami



Obr.: Grafické znázornenie MAE pre jednotlivé súradnice.

Výsledky – Klasifikácia znaku AMA a lokalizácia ruky konvolučnými neurónovými sietami

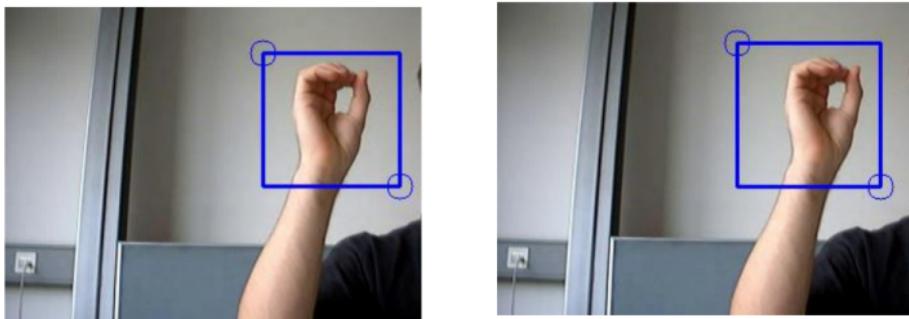
```
Predicted sign: 5, Real sign: 5  
Predicted x1_coordinate: 133.0, Real x1_coordinate: 138  
Predicted y1_coordinate: 32.0, Real y1_coordinate: 36  
Predicted x2_coordinate: 267.0, Real x2_coordinate: 268  
Predicted y2_coordinate: 166.0, real y2_coordinate: 166
```



Obr.: Klasifikácia znaku F a lokalizácia ruky.

Výsledky – Klasifikácia znaku AMA a lokalizácia ruky konvolučnými neurónovými sietami

```
Predicted sign: 14, Real sign: 14  
Predicted x1_coordinate: 198.0, Real x1_coordinate: 184  
Predicted y1_coordinate: 35.0, Real y1_coordinate: 31  
Predicted x2_coordinate: 303.0, Real x2_coordinate: 294  
Predicted y2_coordinate: 137.0, real y2_coordinate: 141
```



Obr.: Klasifikácia znaku O a lokalizácia ruky.

Výsledky – Porovnanie nášho prístupu s prístupmi iných výskumných skupín

Prístup	Model	Typ úlohy	Vyhodnotenie (Správnosť/MAE)
Naše riešenie	CNN	Klasifikačná Regresná	96.69% 5.18 px
Rao et al.	CNN	Klasifikačná	92.88%
Starner et al. (1. prístup)	HMM	Klasifikačná	92.00%
Starner et al. (2. prístup)	HMM	Klasifikačná	98.00%
Pigou et al.	CNN	Klasifikačná	91.70%

Tabuľka: Porovnanie nášho prístupu s podobnými prácamami^{8,9,10}.

⁸ RAO, G. A., SYAMALA, K., KISHORE, P. V. V., SASTRY, A. S. C. S., 2018. Deep convolutional neural networks for sign language recognition. In 2018 conference on signal processing and communication engineering systems, (pp. 194-197). IEEE.

⁹ STARNER, T., WEAVER, J., PENTLAND, A., 1998. Real-time american sign language recognition using desk and wearable computer based video. IEEE Transactions on pattern analysis and machine intelligence, 20(12), 1371-1375.

¹⁰ PIGOU, L., DIELEMAN, S., KINDERMANS, P. J., SCHRAUWEN, B., 2015. Sign language recognition using convolutional neural networks. In Computer Vision-ECCV 2014 Workshops: Zurich, Switzerland, September 6-7 and 12, 2014, Proceedings, Part I 13 (pp. 572-578). Springer International Publishing.

4. čast'

Diplomová práca

Zadanie diplomovej práce

Téma: Rozpoznávanie znakovej reči z pohybu rúk pomocou metód hĺbkového učenia.

- Ciele:**
1. Vytvoriť prehľad aktuálne existujúcich metód hĺbkového učenia na spracovanie videa.
 2. Navrhnúť a implementovať kombináciu metód hĺbkového učenia na rozpoznávanie znakovej reči z pohybu rúk.
 3. Porovnať dosiahnuté výsledky s ďalšími dostupnými štúdiami.

Údajová sada WLASL



(a) The verb “**Wish**” (top) and the adjective “**hungry**” (bottom) correspond to the same sign.



(c) Signers perform “**Scream**” with different hand positions and amplitude of hand movements.

Obr.: Ukážka vstupných obrázkov¹¹.

¹¹ LI, D., et al., 2020. Word-level deep sign language recognition from video: A new large-scale dataset and methods comparison. In Proceedings of the IEEE/CVF winter conference on applications of computer vision (pp. 1459-1469).

Údajová sada WLASL



Obr.: Diverzita údajovej sady¹¹.

¹¹ LI, D., et al., 2020. Word-level deep sign language recognition from video: A new large-scale dataset and methods comparison. In Proceedings of the IEEE/CVF winter conference on applications of computer vision (pp. 1459-1469).

Problémy diplomovej práce

- Zohľadňovanie všetkých komponentov, z ktorých sa skladá posunok – vstupom je video (séria obrázkov).
- Rozpoznávame už teda slová, nie písmená manuálnej abecedy.

To vedie k niektorým problémom z pohľadu počítačového videnia, ktoré sú charakteristické pre SLR:

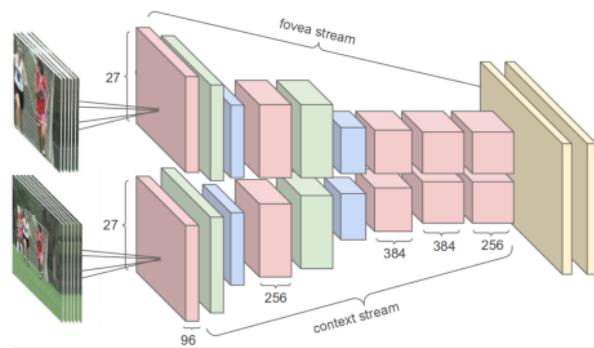
- Rôzne svetlo, citlivosť kamery, pozadie, umiestnenie kamery.
- Niektoré prsty môžu byť mimo záber.
- Detekcia toho, kedy jeden znak končí a druhý už začína.

Problémy diplomovej práce

- **Výpočtové hľadisko:** pri vstupoch v podobe videí si konvolučné siete vyžadujú príliš veľké časové obdobie na efektívnu optimalizáciu parametrov, pretože siet' nespracováva len jeden obrázok, ale priamo sekvenciu obrázkov.

Možná optimalizácia na základe dvoch článkov:

1. prístup:



Obr.: 3D CNN s multirozlišením¹².

¹²KARPATHY, A., et al., 2014. Large-scale video classification with convolutional neural networks. In Proceedings of the IEEE conference on Computer Vision and Pattern Recognition (pp. 1725-1732).

Problémy diplomovej práce

Cieľom bolo ukázať, že nasledujúca modifikácia architektúry urýchľuje runtime performance:

Dva vstupné toky:

- **Context stream:** učí sa príznaky z celých obrazov s nízkym rozlíšením.
- **Fovea stream:** dostane menšie okno z celého rámca, ale vo vysokom rozlíšení (*fovea* - časť oka zodpovedná za ostré centrálne videnie).

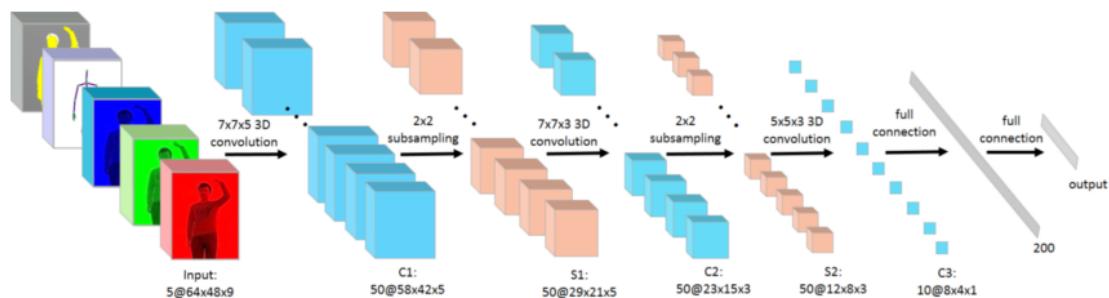
Takáto úprava architektúry viedla k urýchleniu až o 2-4 krát.

Problémy diplomovej práce

2. prístup:

Na vylepšenie výkonnosti sa použilo 5 vstupných tokov:

- 3 RGB kanály.
- Hĺbkové informácie.
- Klíbové informácie.



Obr.: 3D CNN s multikanálmi¹³.

¹³HUANG, J., et al., 2015. Sign language recognition using 3d convolutional neural networks. In 2015 IEEE international conference on multimedia and expo (ICME) (pp. 1-6). IEEE.

Ďakujem za pozornosť.