



ETH zürich



REDUCING SPELLING INCONSISTENCIES IN CODE-SWITCHING ASR USING CONTEXTUALIZED CTC LOSS

Burin Naowarat¹, Thananchai Kongthaworn¹, Korrawe Karunratanakul²,
Sheng Hui Wu³, and Ekapol Chuangsawanich¹

¹Department of Computer Engineering, Chulalongkorn University, Bangkok, Thailand

²ETH Zurich, Switzerland, ³NewEra AI Robotics, Taiwan

ICASSP 2021



Code-Switching Speeches


- Alternating languages within a conversation
- Alternating languages within a sentence
 - Loanwords (mostly)
 - Thai: คนที่มี followers เพียงแค่ 5000
 - Eng: The person who has only 5000 followers.
 - Loanphrases
 - Thai: ผู้ที่ **work from home** มาเกือบจะ 4 เดือนแล้ว
 - Eng: I have **worked from home** for almost 4 months.
- Usually found in bilingual communities

Fully Convolutional Code-Switching ASR model


- Good
 - Fast



- Bad
 - Hard for Code-Switching speech
 - Inconsistent spellings
 - คนที่มี follower (follower) เพียงแค่ 5000
 - Hard for Thai
 - Alphabet orderings
 - ไฉน : The sound of the middle letter, ไ, comes first.
 - อาลัย vs กำໄລ : Consonant first vs vowel first (similar pronunciation).




(a) Autoregressive; (b) Non-Autoregressive



Possible Solutions

- Add dependencies between predicted letters
 - Do beamsearch with language model [1,2,3]
 - Do auto-regressive decoding [1,2,3]
 - **Lose parallelizable ability**
- Utilize language identifier [2,3,4]
 - Predicts language
 - **Requires frame-level ground truths**



[1] Sreeram, Ganji, and Rohit Sinha. "Exploration of End-to-End Framework for Code-Switching Speech Recognition Task: Challenges and Enhancements." *IEEE Access* 8 (2020)

[2] Shan, Changhao, et al. "Investigating end-to-end speech recognition for mandarin-english code-switching." *ICASSP 2019*.

[3] Zeng, Zhiping, et al. "On the end-to-end solution to mandarin-english code-switching speech recognition." *Interspeech 2019*

[4] Li, Ke, et al. "Towards code-switching ASR for end-to-end CTC models." *ICASSP 2019*.


The Proposed CCTC

- Contextualized CTC (CCTC)
 - Mitigates the misspellings
 - Adds the dependencies between predicted letters without:
 - Losing parallelization ability
 - Needing external frame-level alignments
 - Does not increase the inference time


The Proposed CCTC

Add weak dependencies to the predicted letters


- Predict *surrounding* letters
 - Can be done in parallel
- Have similar effects to a low-order language model



CCTC Model (Training)



CCTC Model (Training)




Ground truths of context predictions

Have no ground truth alignment

CCTC intend to encourage consistent spellings


Solution: use prediction from the middle head of previous iterations as ground truths



Ground truths of context predictions

Non-informative symbols

- Consecutive duplicates
- Blank tokens




Ground truths of context predictions

Non-informative symbols


Solution: Skip all of them

Actual CTC output

Final prediction




CCTC Model (Decoding)





Experimental Setups

- Speech Corpus
 - 150 Hours
 - 180k monolingual utterances
 - 8.4k CS utterances
- Text Corpus
 - 96M words
 - 3-gram language model
- Base model
 - Wav2Letter+



Results (CS ASR)

CCTC consistently outperforms CTC



Results (CS ASR)

In Thai

- Fix wrong ordering

In Code-Switching

- Fix alphabets mixing

Argmax	CTC	ฉนย จิ่ง ทรง สามารถ แฟ ศาสนา ของ พระองค์
	CCTC	ใจใน จิ่ง ทรง สามารถ แฟ ศาสนา ของ พระองค์
3-gram LM	CTC	ทน จี น ทรง สามารถ แฟ ศาสนา ของ พระองค์
	CCTC	ใจ น จิ่ง ทรง สามารถ แฟ ศาสนา ของ พระองค์
Ground truth		ใจ น จิ่ง ทรง สามารถ แฟ ศาสนา ของ พระองค์
Argmax	CTC	คน ท ว folower พิยง แค ห้า พัน
	CCTC	คน ที่ ม polower พิยง แค ห้า พัน
3-gram LM	CTC	คน ที่ ม พลัวร์ เพียง แค ห้า พัน
	CCTC	คน ที่ ม follower พิยง แค ห้า พัน
Ground truth		คน ที่ ม follower พิยง แค ห้า พัน

Conclusions

- We proposed CCTC for reducing inconsistent spellings of non-autoregressive Code-Switching ASR models.
- CCTC adds language dependencies to the predicted letters without:
 - Modifying the output units
 - Losing parallelizable ability
 - Needing for frame-level alignments
- CCTC can be integrated with any existing CTC models without increasing the inference time.