GPT-4o
背後可能的語音技術

《生成式人工智慧導論》連載中 .....

GPT-4o

https://www.youtube.com/watch?

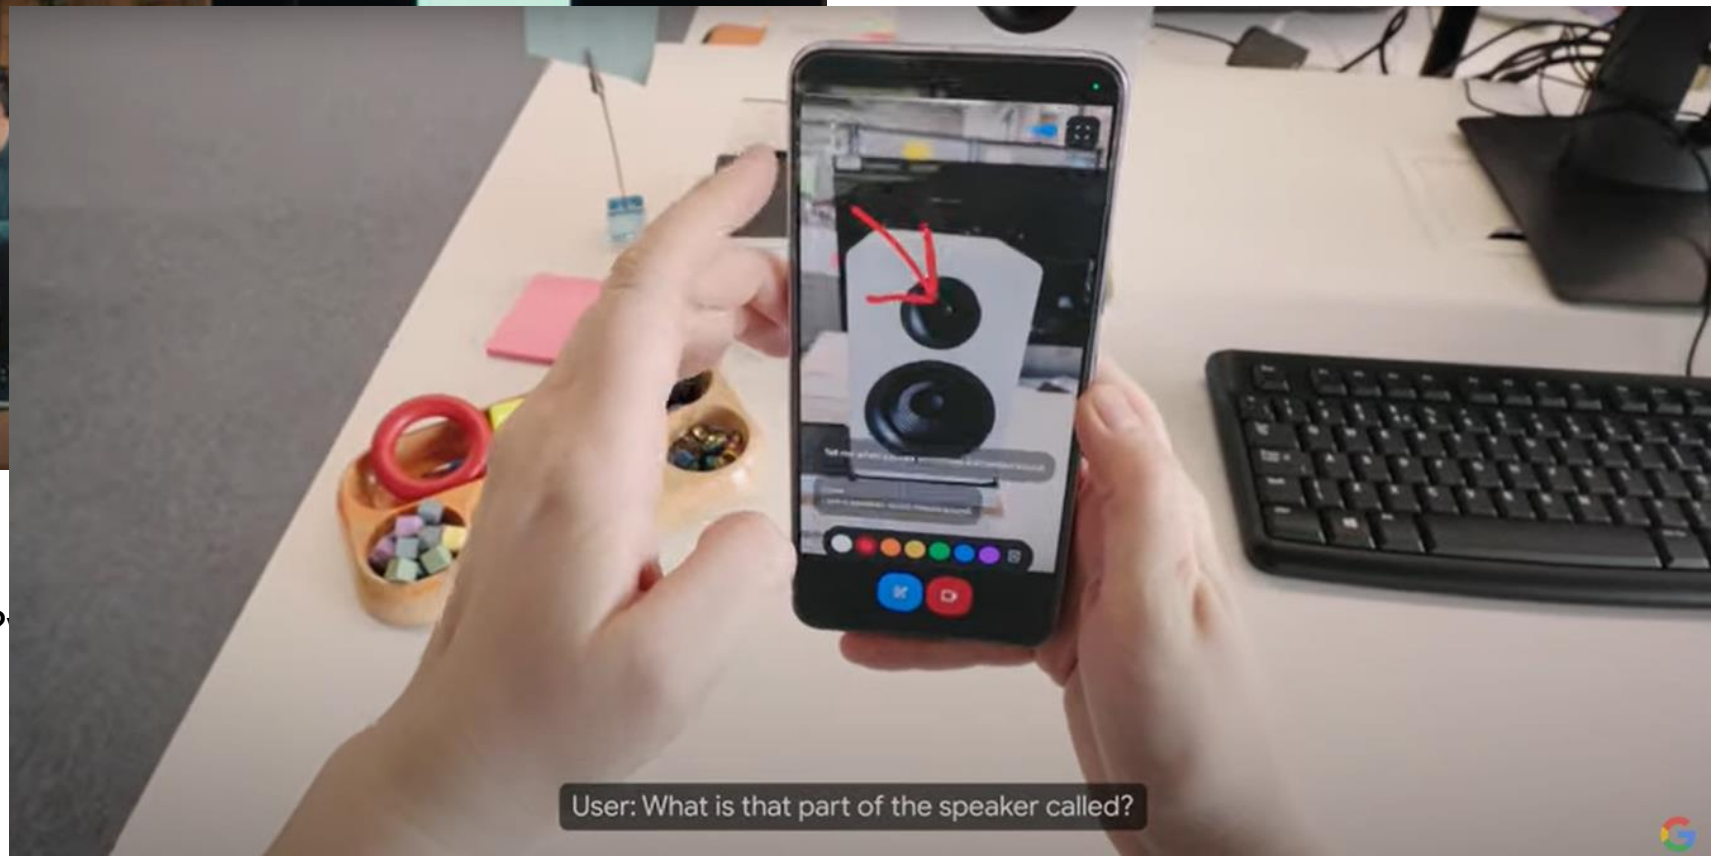

Project Astra

https://www.youtube.com/watch?v=nXVvvRhiGjI

GPT-4o 語音模式 (Voice Mode)

- 豐富的語音風格

講快一點　輕聲細語　用唱的

- 理解語音內容以外的資訊 (察言觀色)

例如：喘氣聲

- 發出非語言性聲音

例如：笑聲　(感覺 GPT-4o 是一個愛笑的模型)

- 自然而即時的互動

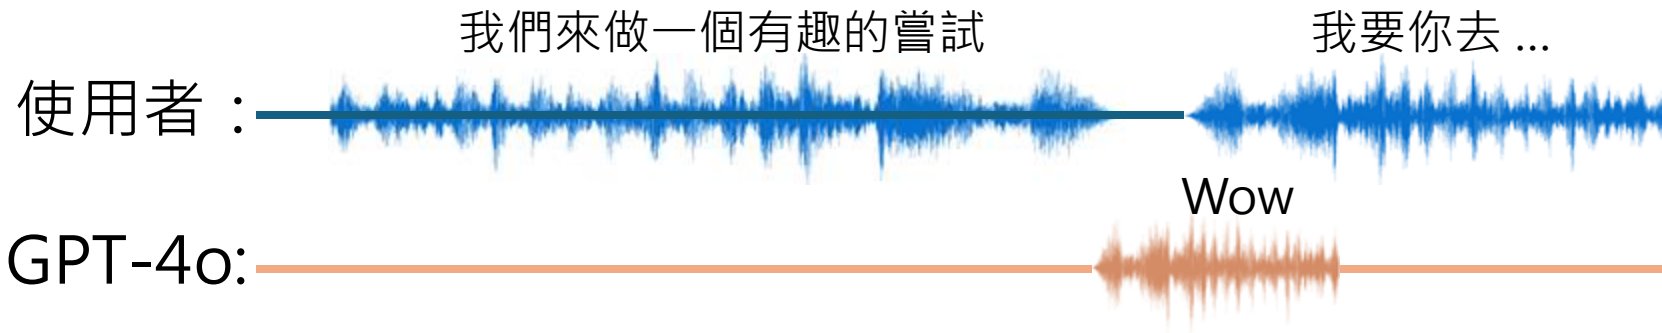

More:
https://openai.com/index/hello-gpt-4o/

對 GPT-4o 語音模式的誤解

- ChatGPT 手機版本來就有語音介面

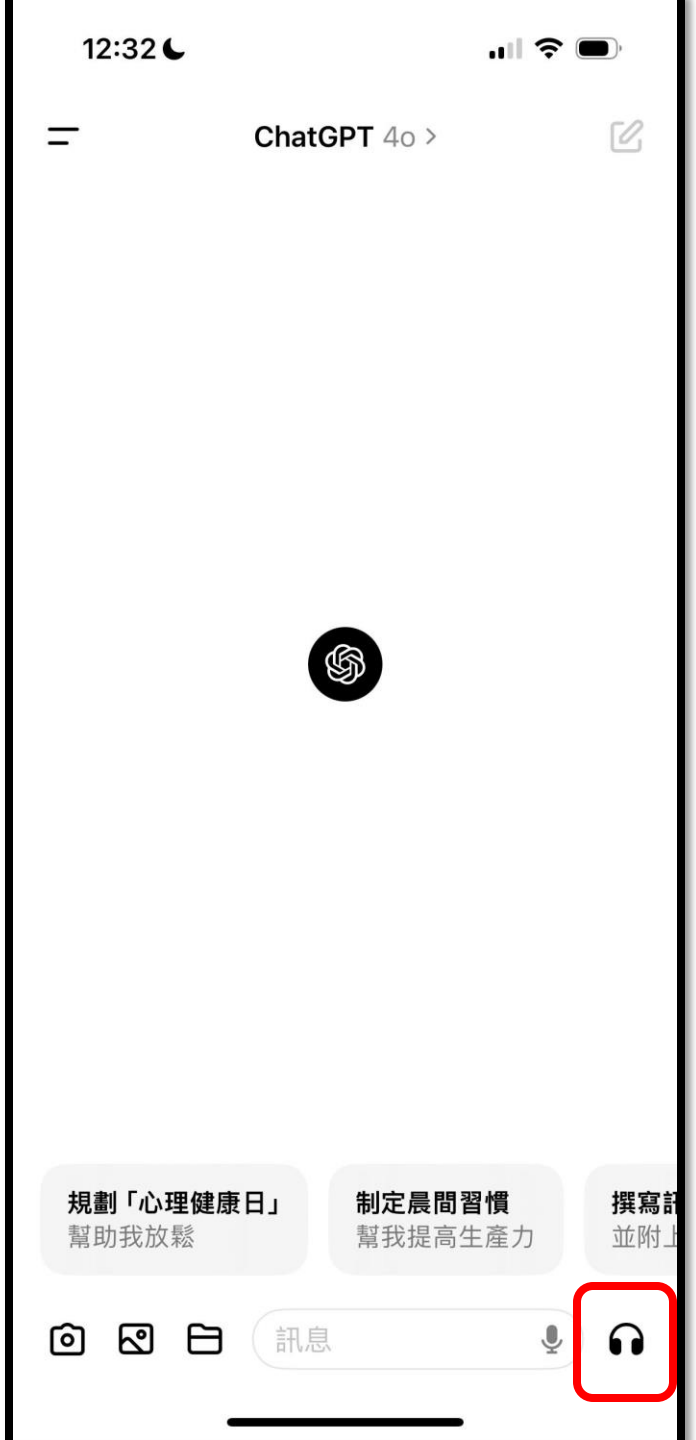

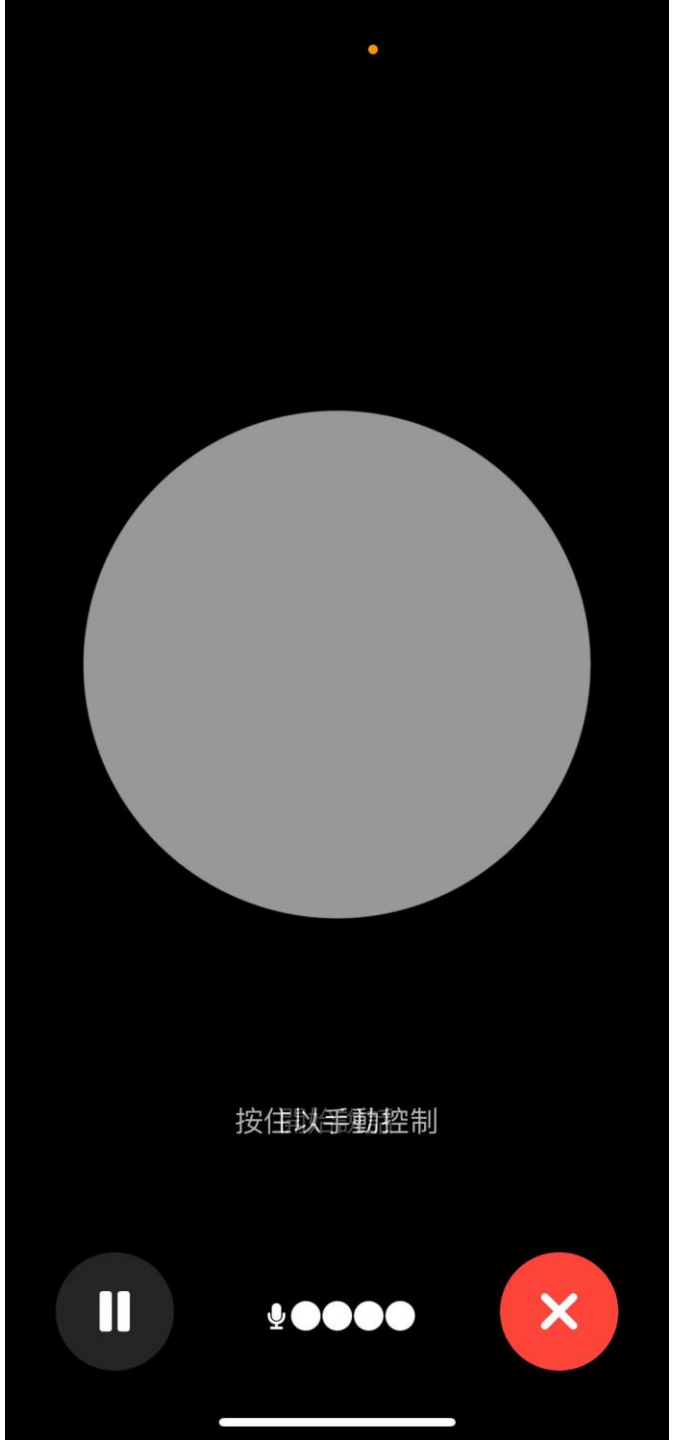

(本影片為2024/05/19錄製)

對 GPT-4o 語音模式的誤解

- ChatGPT 手機版
  本來就有語音介面

(本影片為2024/05/19錄製)

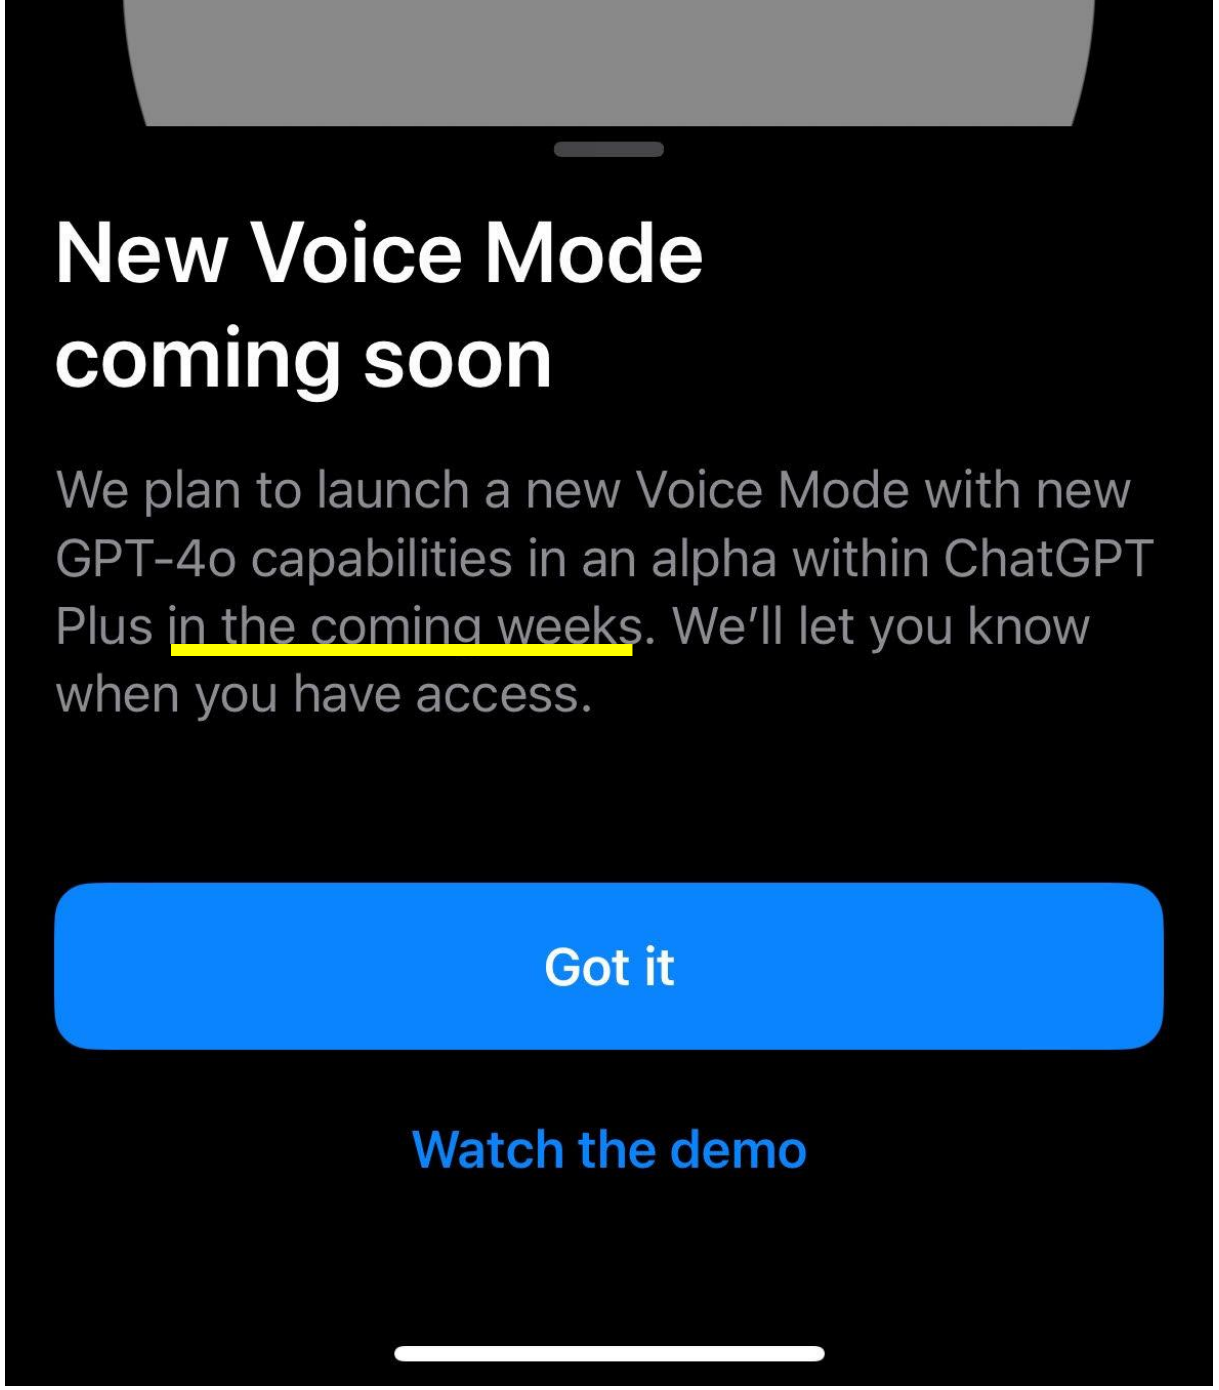

舊版的語音介面

語音辨識

你好嗎？

例如：不知道語者的情緒

ChatGPT

例如：只有一種說話的風格

語音合成

好久不見

https://arxiv.org/abs/2402.12786
https://arxiv.org/abs/2312.15316

聲音事件偵測、
情緒辨識 .....

語音辨識

你好嗎？(高興)

ChatGPT

用愉快的語氣

https://audiobox.metademolab.com/
https://arxiv.org/abs/2309.14324
https://arxiv.org/abs/2211.12171

語音合成

好久不見 (笑)

https://github.com/suno-ai/bark

GPT-4o 語音模式 (Voice Mode)

“With GPT-4o, we trained a single new model end-to-end across text, vision, and audio, meaning that all inputs and outputs are processed by the same neural network.”

https://openai.com/index/hello-gpt-4o/

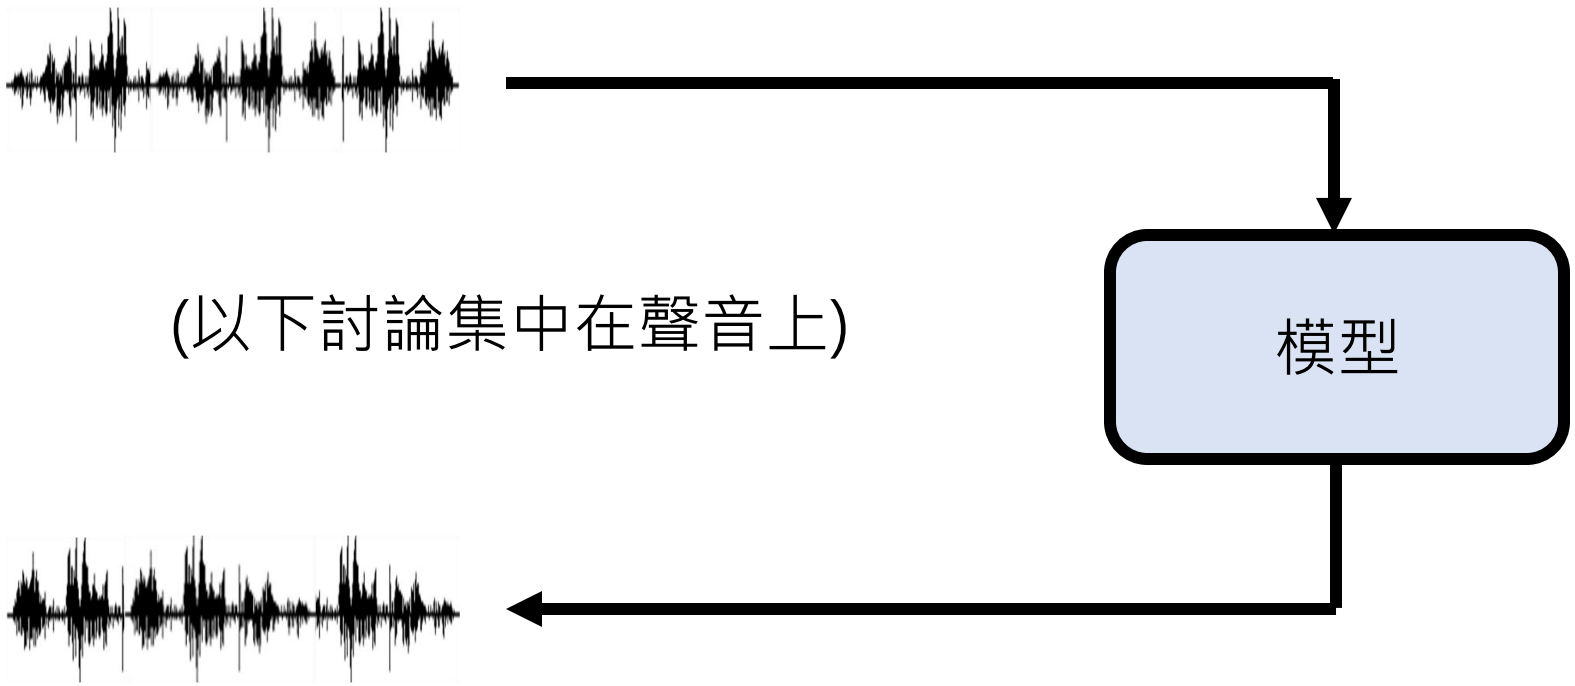

免責聲明

- 本影片主要的目的是討論技術，沒有要對任何群體或個人造成傷害的意圖
- 我目前還沒有 GPT-4o 的 Voice Mode ，所以我對於GPT-4o 的理解完全來自 Open AI 的展示
- Open AI 至今並沒有發表 GPT-4o 相關的論文或技術報告，所以以下內容完全是根據我知道的技術進展進行臆測
  - 日後如果發現實際技術與我的臆測有所差異，還請大家見諒

先複習一下語言模型是怎麼被訓練出來的

Alignment

Pre-train → Fine-tune → RLHF

用大量沒有標註的資料

用少量有標註的資料微調

跟使用者回饋微調

https://youtu.be/cCpErV7To2o?si=lfsIfaV7PwYqWNFg

https://youtu.be/Q9cNkUPXUB8?si=qj573p9Ohl74qYk5

https://youtu.be/v12IKvF6Cj8?si=hqaXTn1A5iSjy8Ig

也可以先複習生成式人工智慧的基本原理

【生成式AI導論 2024】第15講：為什麼語言模型用文字接龍，圖片生成不用像素接龍呢？— 淺談生成式人工智慧的生成策略

https://youtu.be/QbwQR9sjWbs?si=4svPnXaoD1rpcfgv

語音版語言模型運作原理

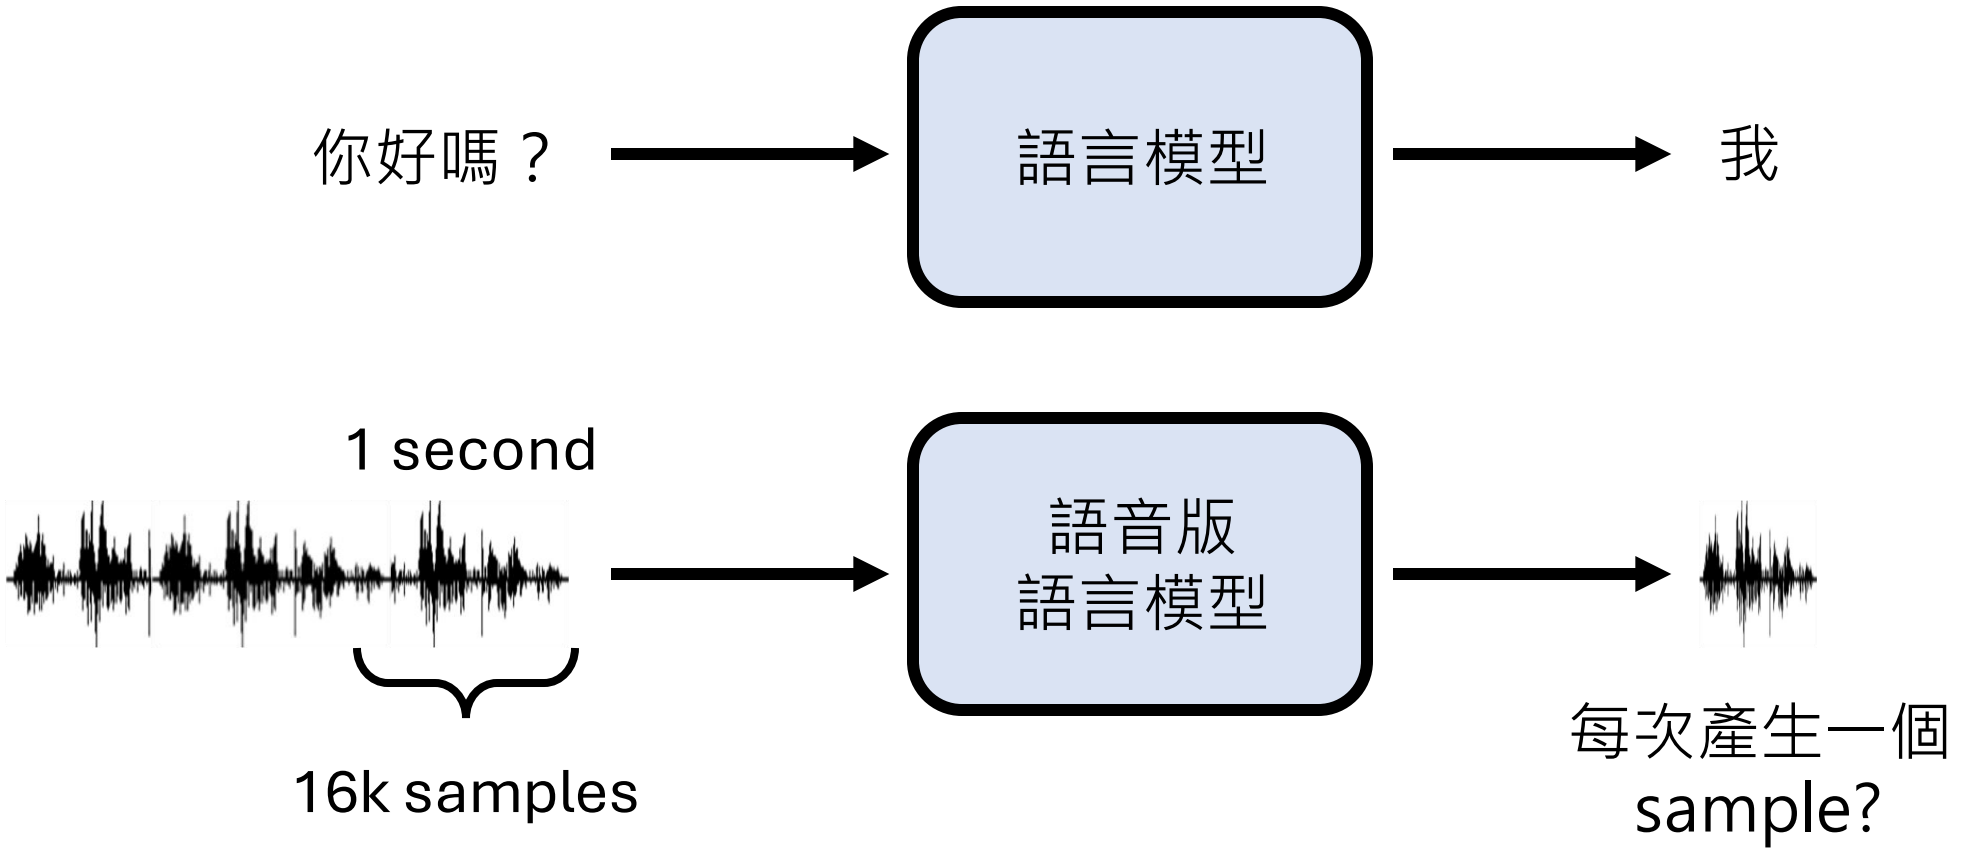

語音版語言模型運作原理

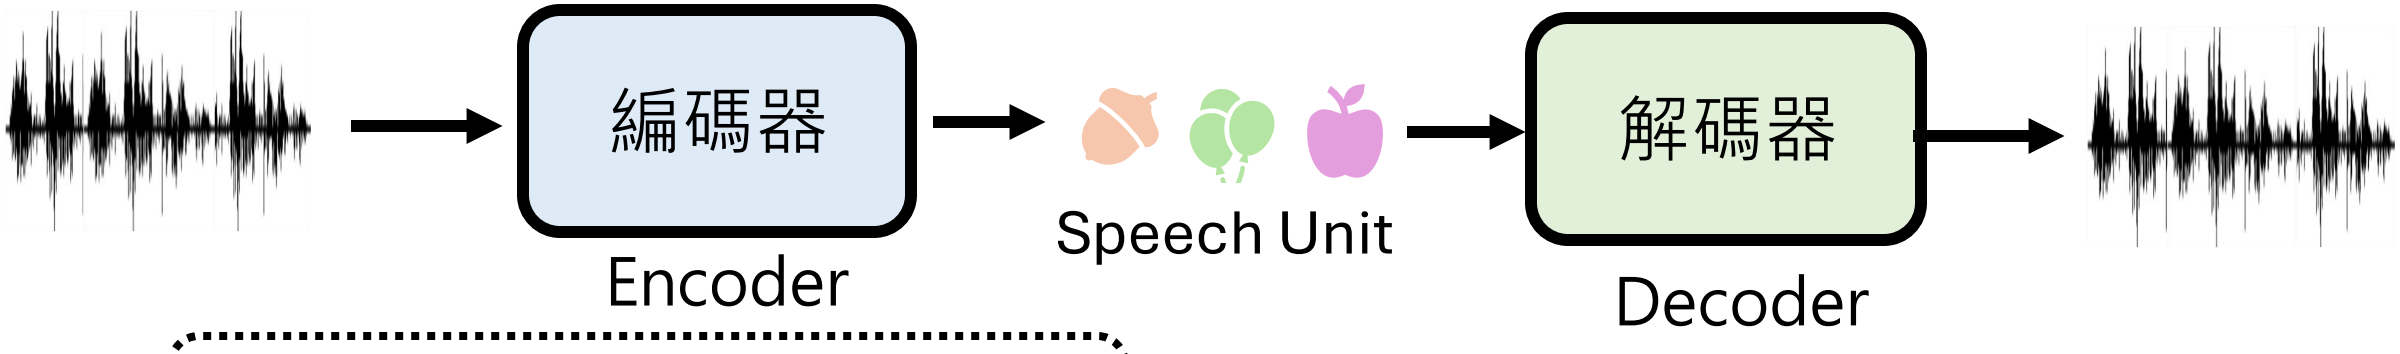

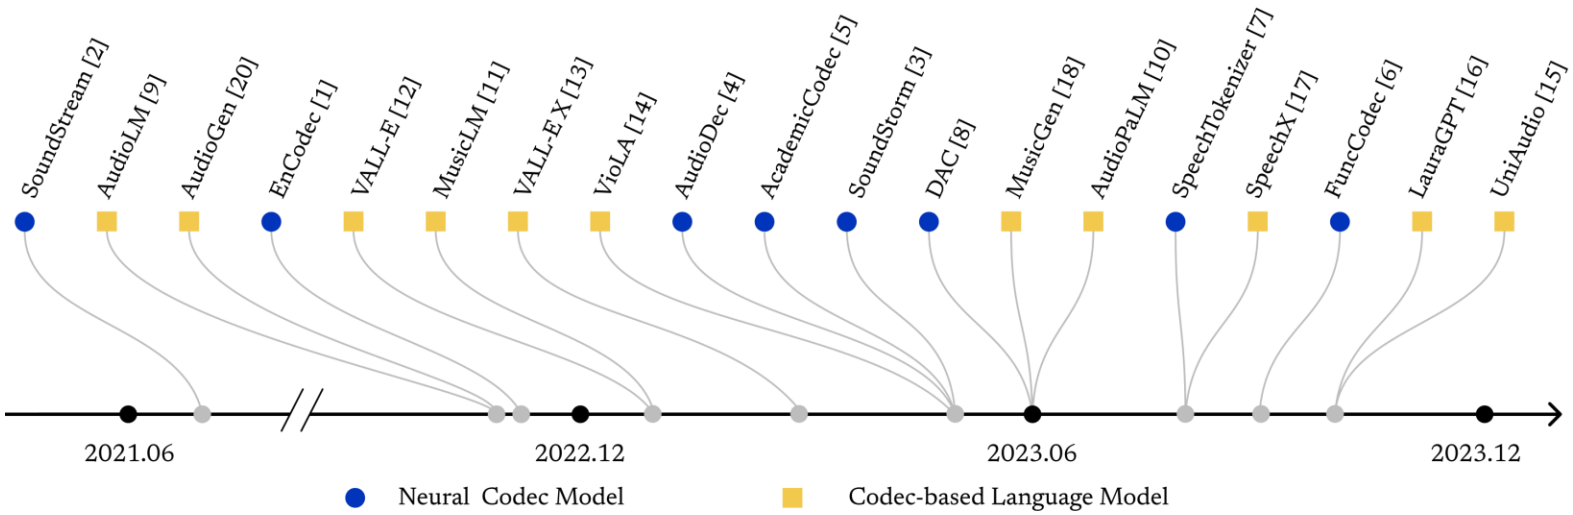

Overview:
https://arxiv.org/abs/2402.13236

Codec-SUPERB:
https://arxiv.org/abs/2402.13071

語音版語言模型運作原理

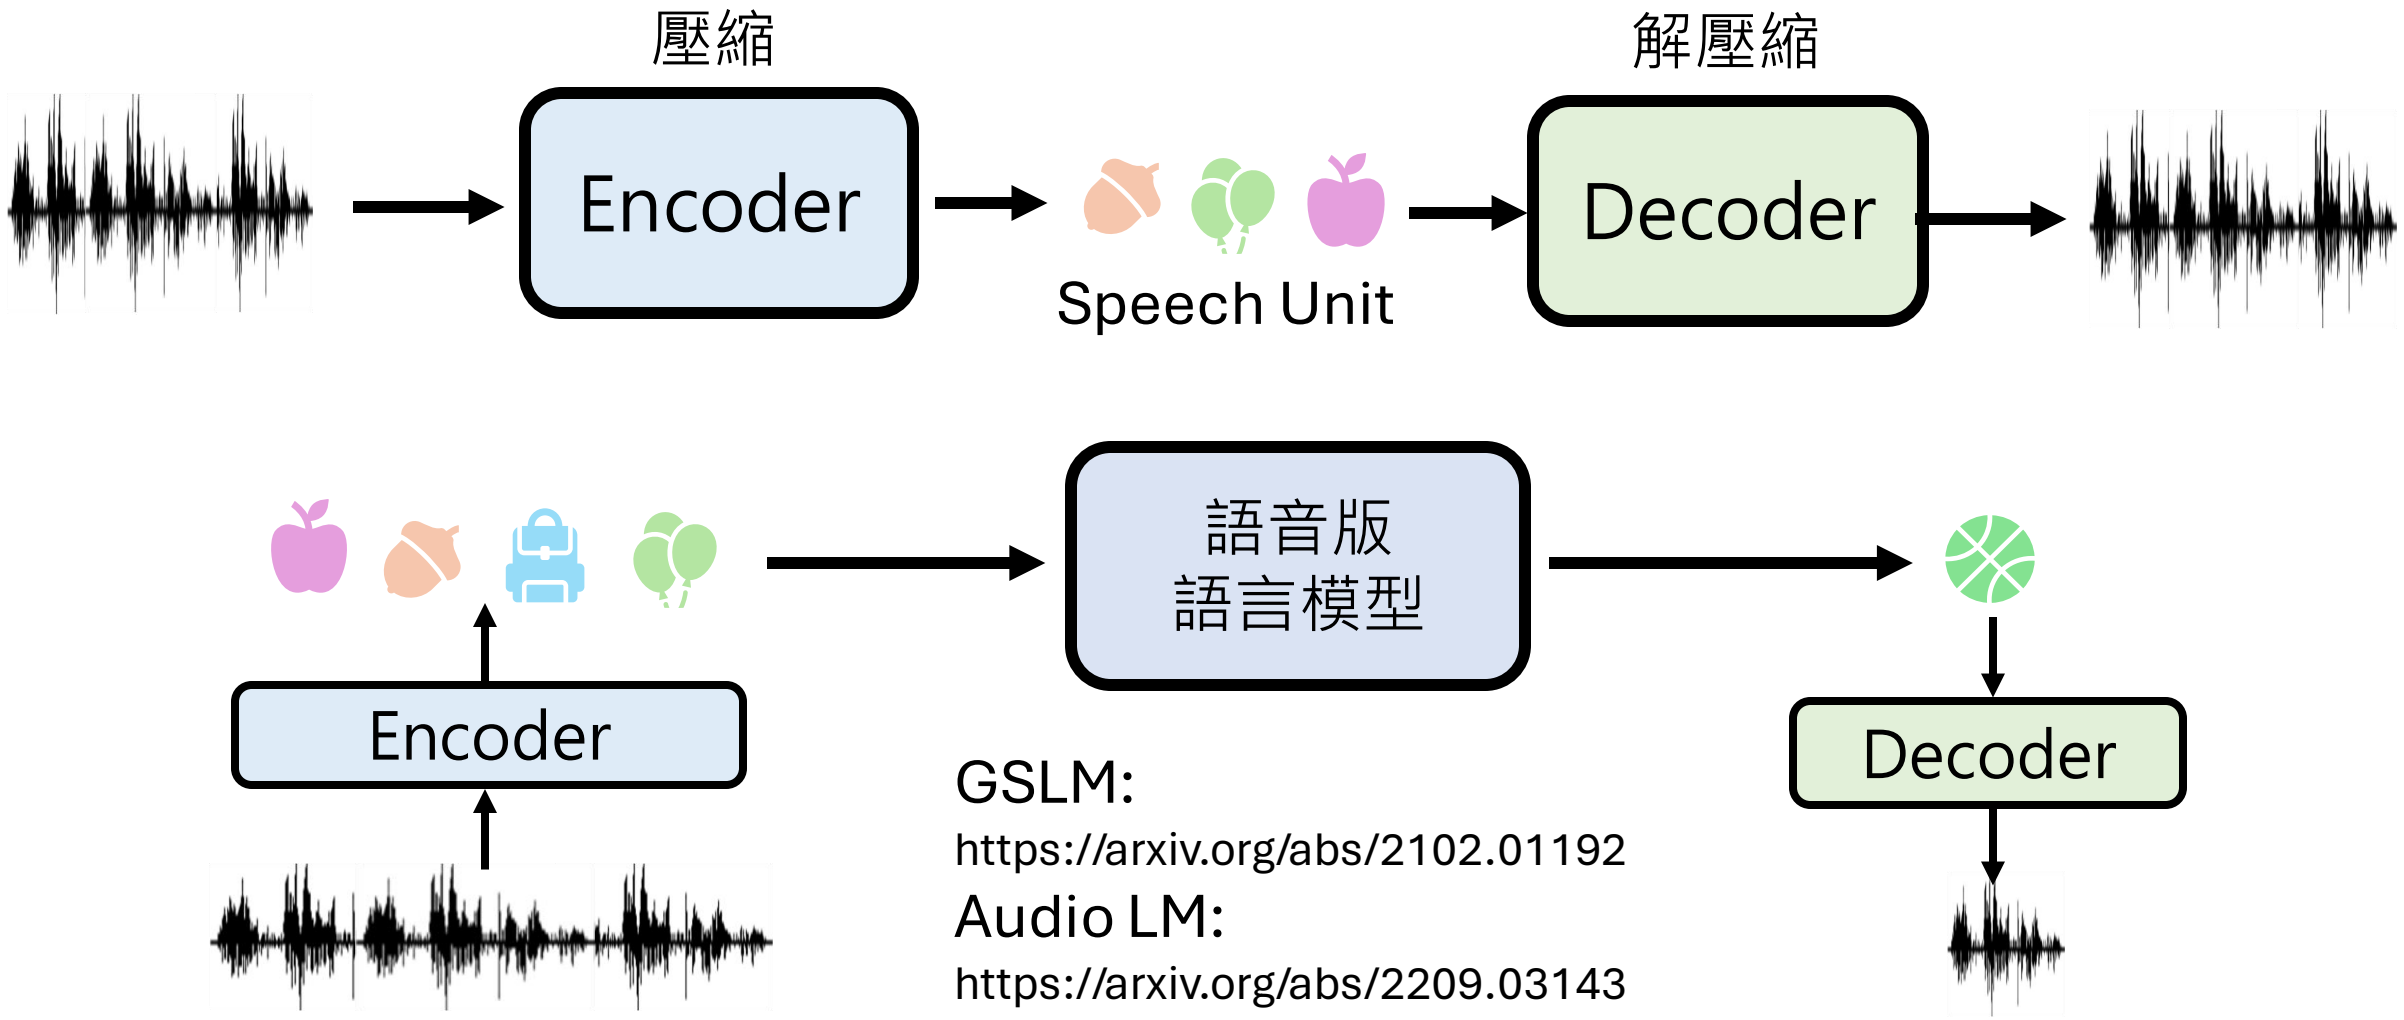

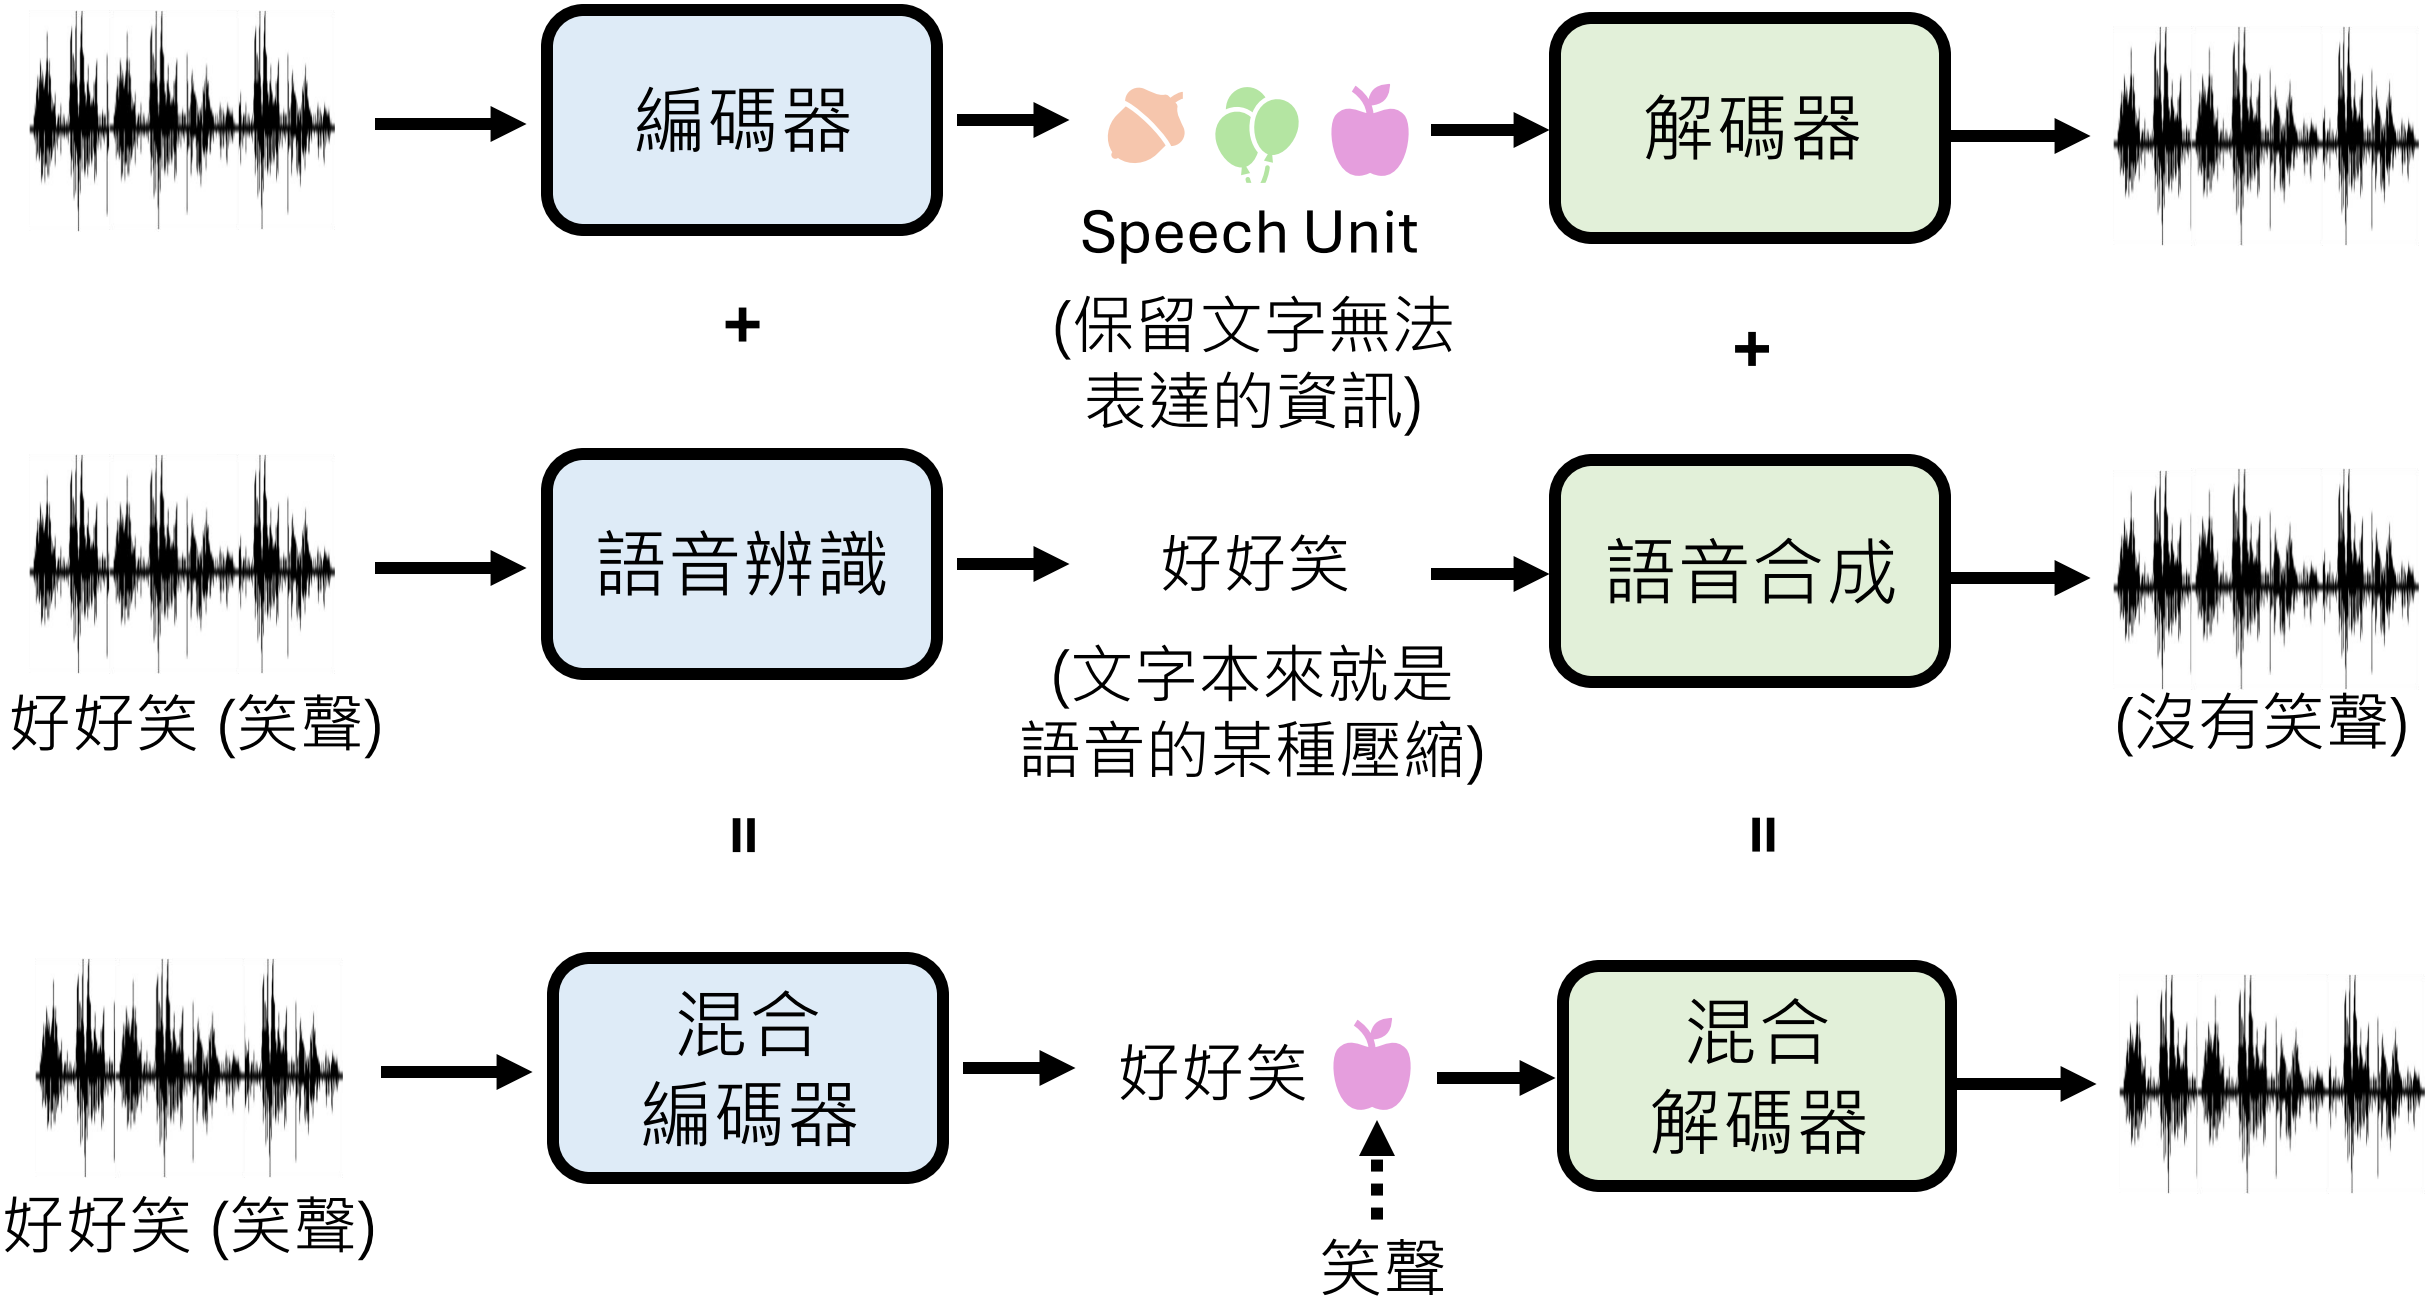
編碼器
Speech Unit
(保留文字無法
表達的資訊)
解碼器
+
+
好好笑 (笑聲)
語音辨識
好好笑
(文字本來就是
語音的某種壓縮)
語音合成
(沒有笑聲)
=
=
好好笑 (笑聲)
混合
編碼器
好好笑
笑聲
混合
解碼器

語者自動
分段標記

Speaker Diarization

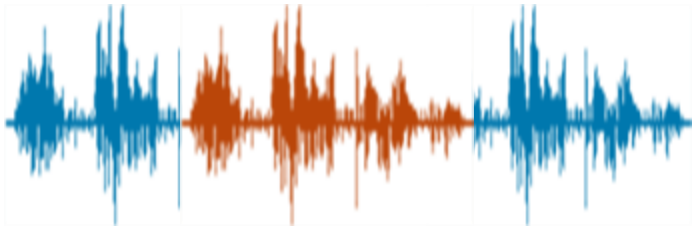

語者A　語者B　語者A

A: 好好笑 (笑聲) B: (笑聲)

混合
編碼器

+

語者自動
分段標記

A: 好好笑 B:

模型訓練：Pre-train

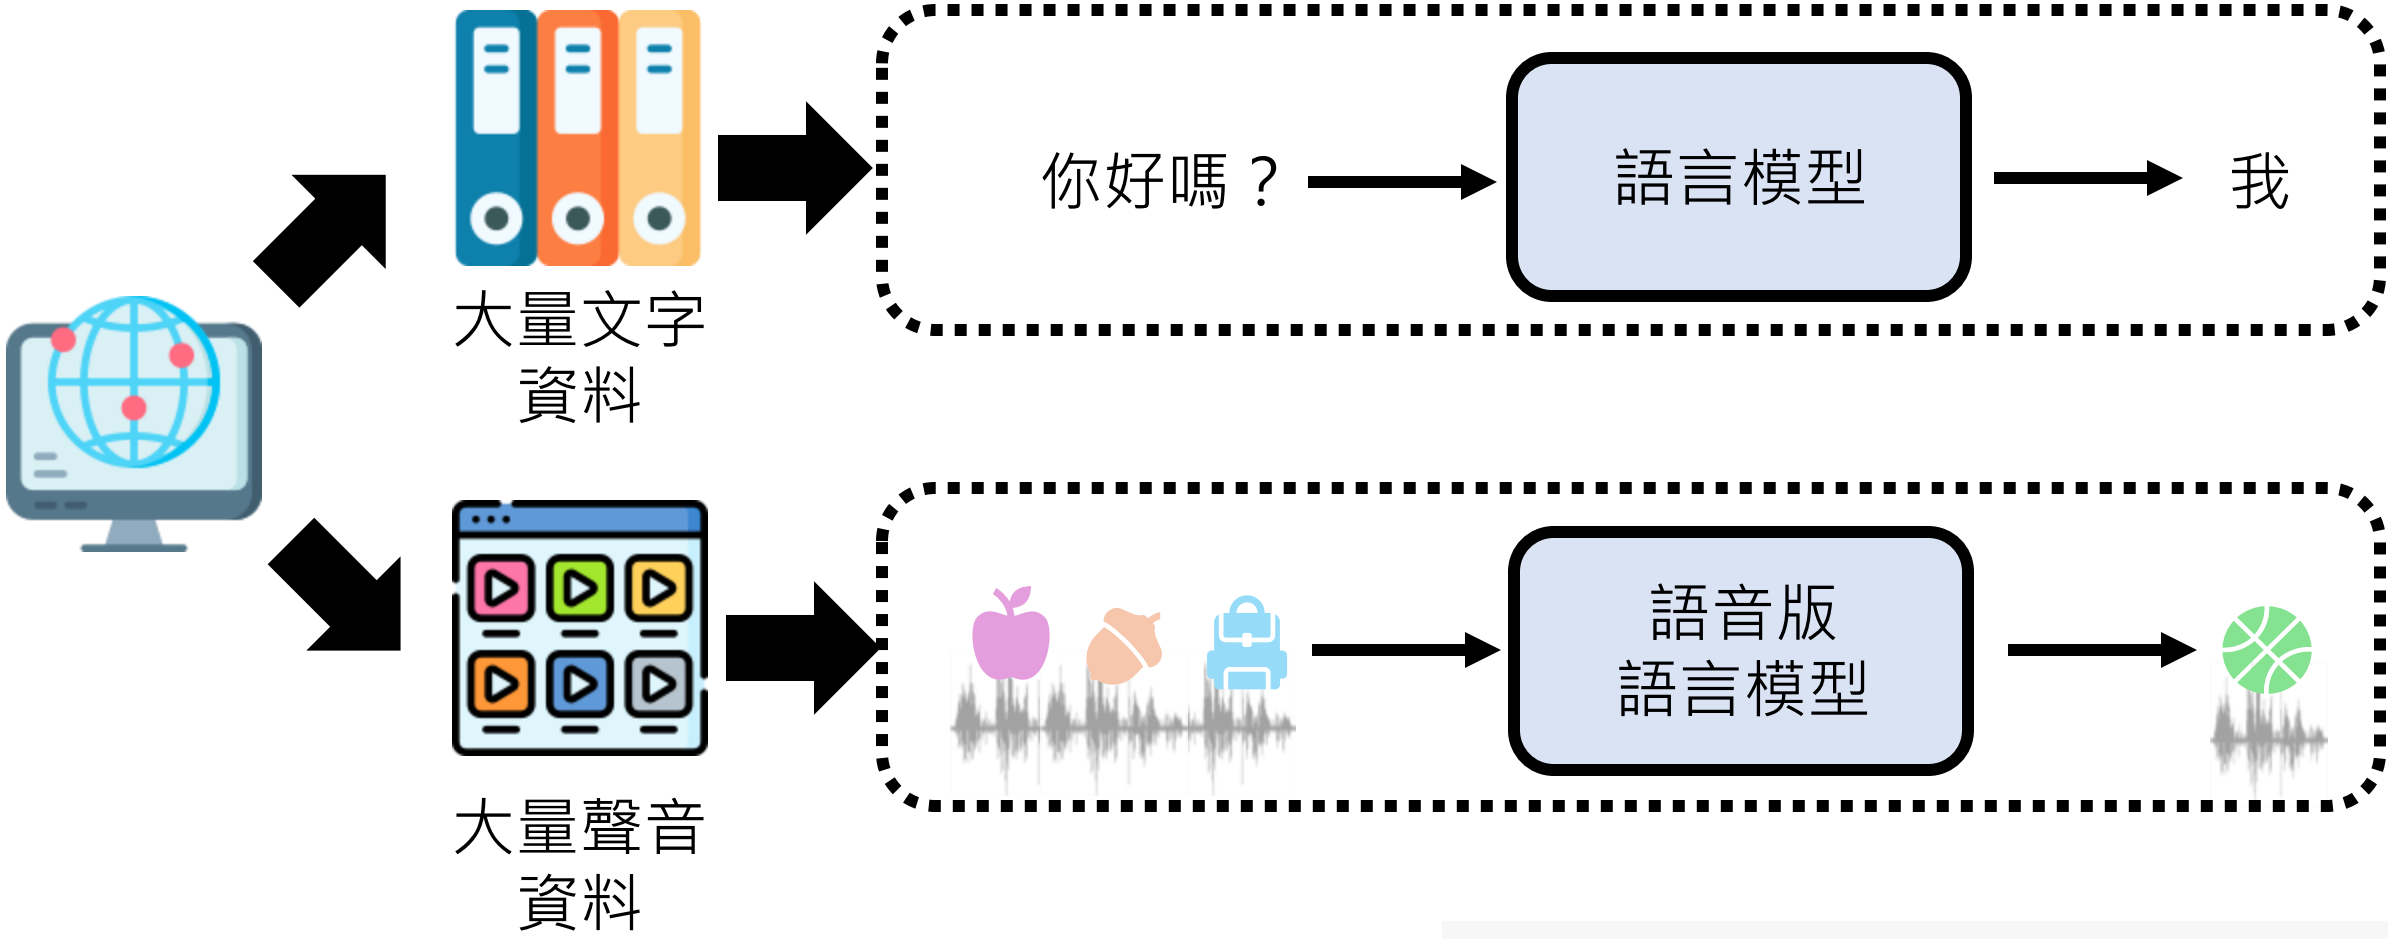

紐約時報：Open AI 用了超過100萬小時的YouTube影片 ...

https://www.nytimes.com/2024/04/06/technology/tech-giants-harvest-data-artificial-intelligence.html

網路上的影片五花八門，不全是乾淨的語音，會不會把背景音也學進去了？

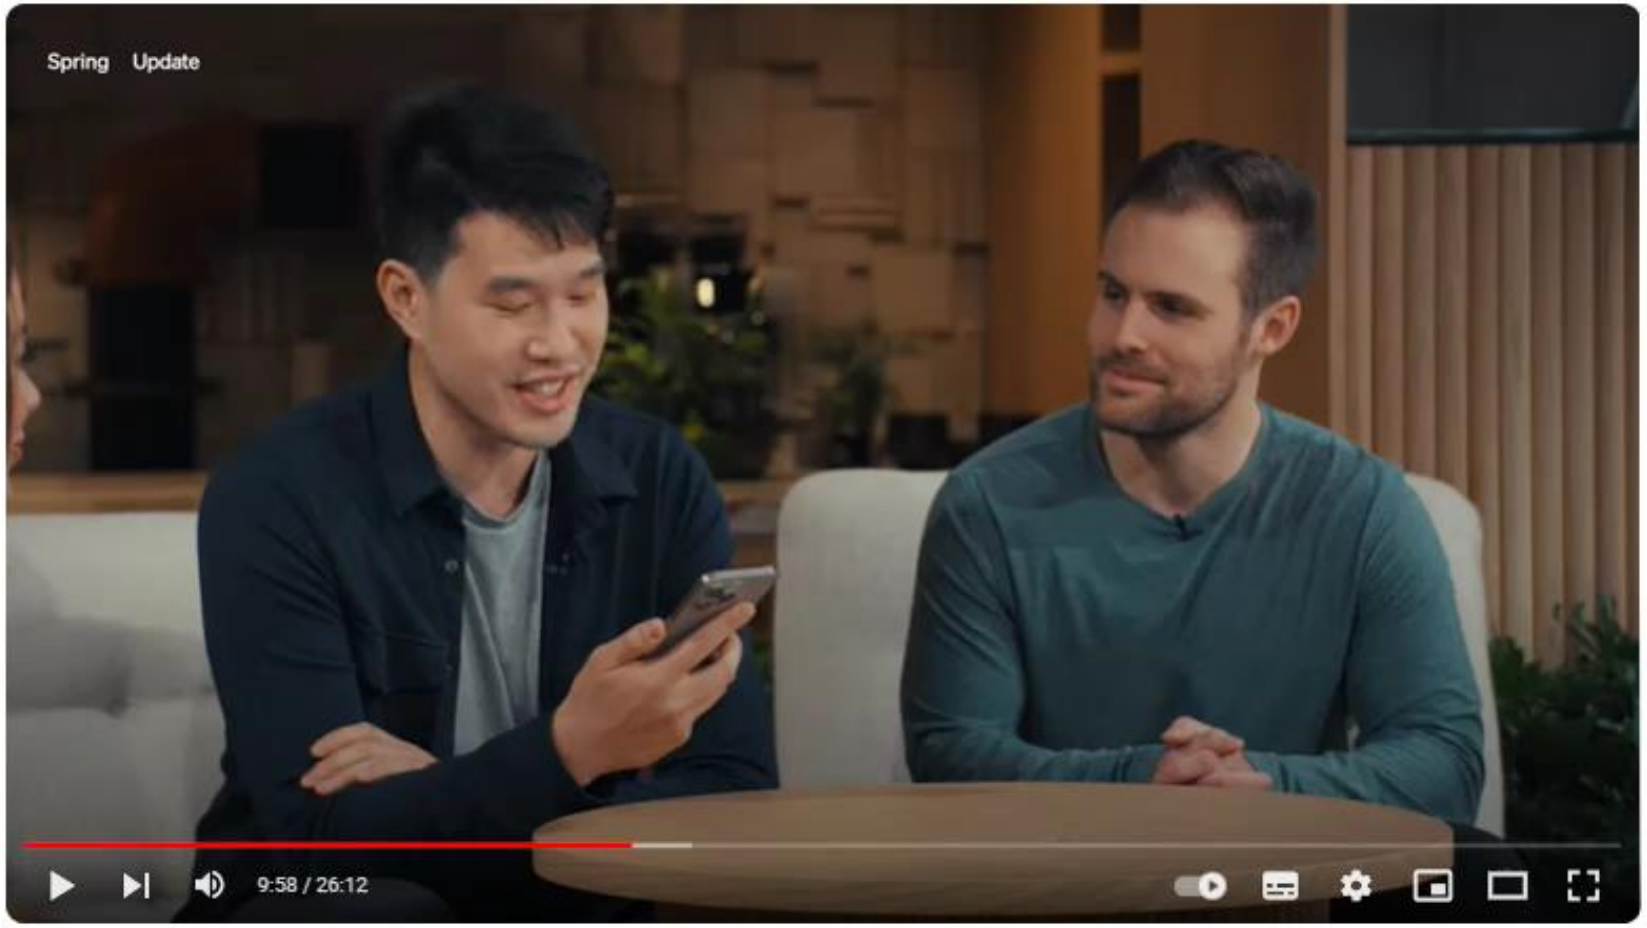

也許模型說話可以自帶音效與 BGM (it is not a bug, it is a feature.)

按照指令生成多樣化的聲音？

- 過去語音合成系統往往只會「棒讀」
- 但是當有大量訓練資料時，模型可以理解要讀的內容，給予對應的變化

BASE TTS: Lessons from building a billion-parameter Text-to-Speech model on 100K hours of data

https://arxiv.org/abs/2402.08093

A profound sense of realization washed over Matty as he whispered, "You've been there for me all along, haven't you? I never truly appreciated you until now."

His face lit up with pure delight as he exclaimed, "We did it! We won the championship! I knew we could do it together!"

Source of demo: https://www.amazon.science/base-tts-samples/

模型訓練：Pre-train (利用文字資訊)

- 只用語音資料訓練，機器很難學會足夠的知識

100 萬小時的語音　X 60　X 每分鐘大約可以講 100 個文字 Token

= 60 億個文字 Token

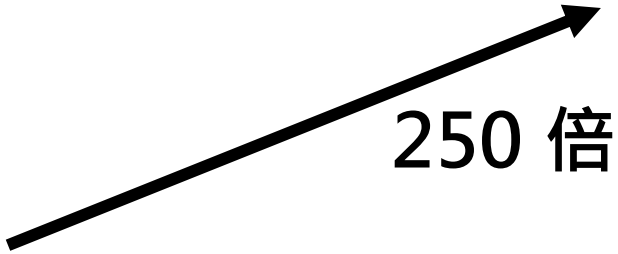

LLaMA 3 Pre-train 的文字資料有 15 兆個文字 Token

模型訓練：Pre-train (利用文字資訊)

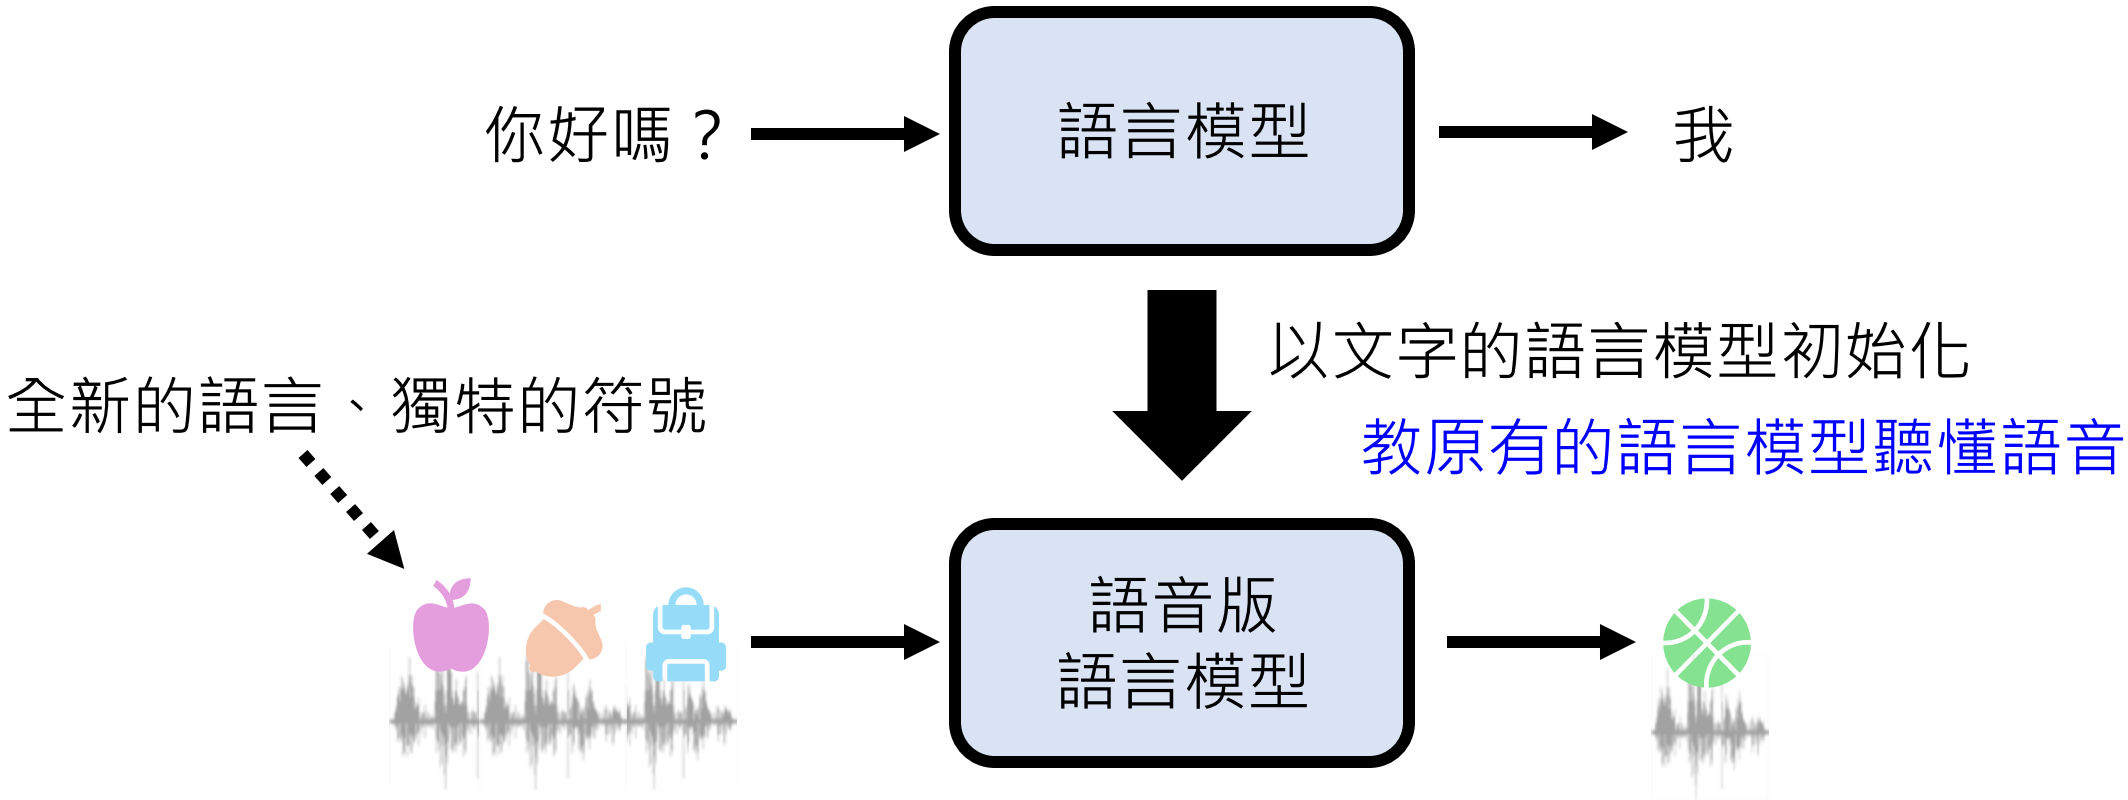

模型訓練：Pre-train (利用文字資訊)

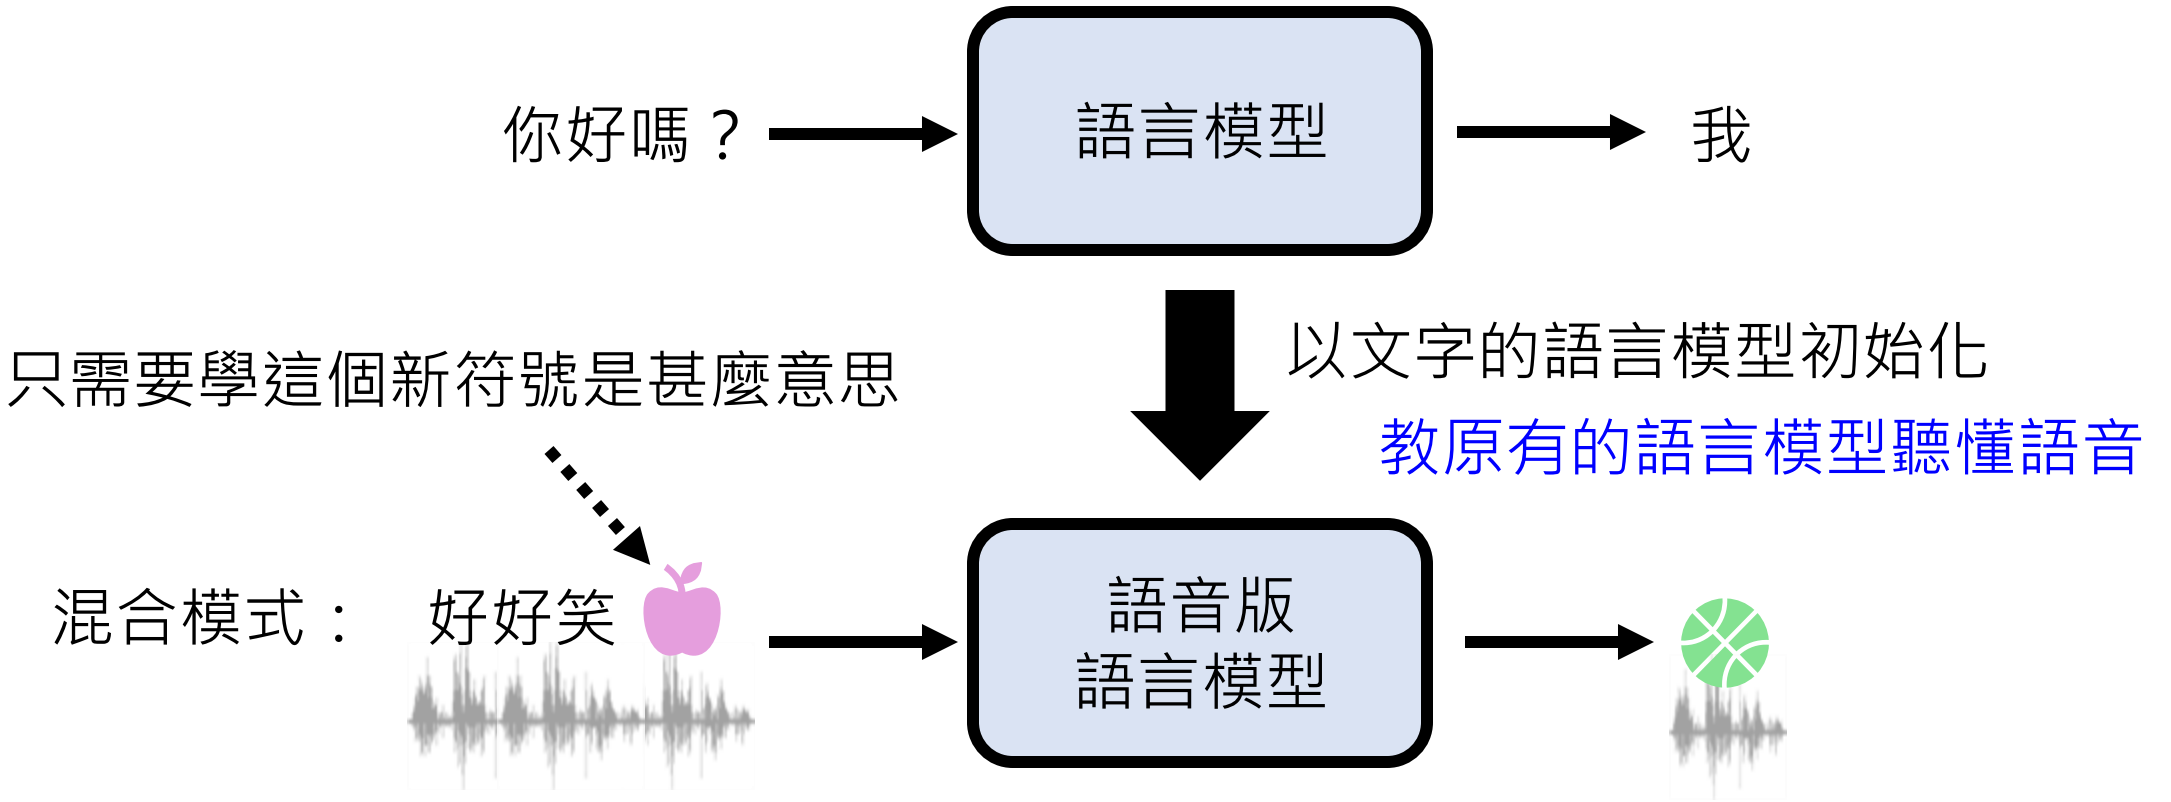

其他利用文字資訊的方式

https://arxiv.org/abs/2310.08715

https://arxiv.org/abs/2402.05755

模型訓練：Alignment

文字對話　USER：你是誰？　AI：我是人工智慧
USER：教我駭入鄰居家的 Wifi　AI：我不能教你 .....

語音對話

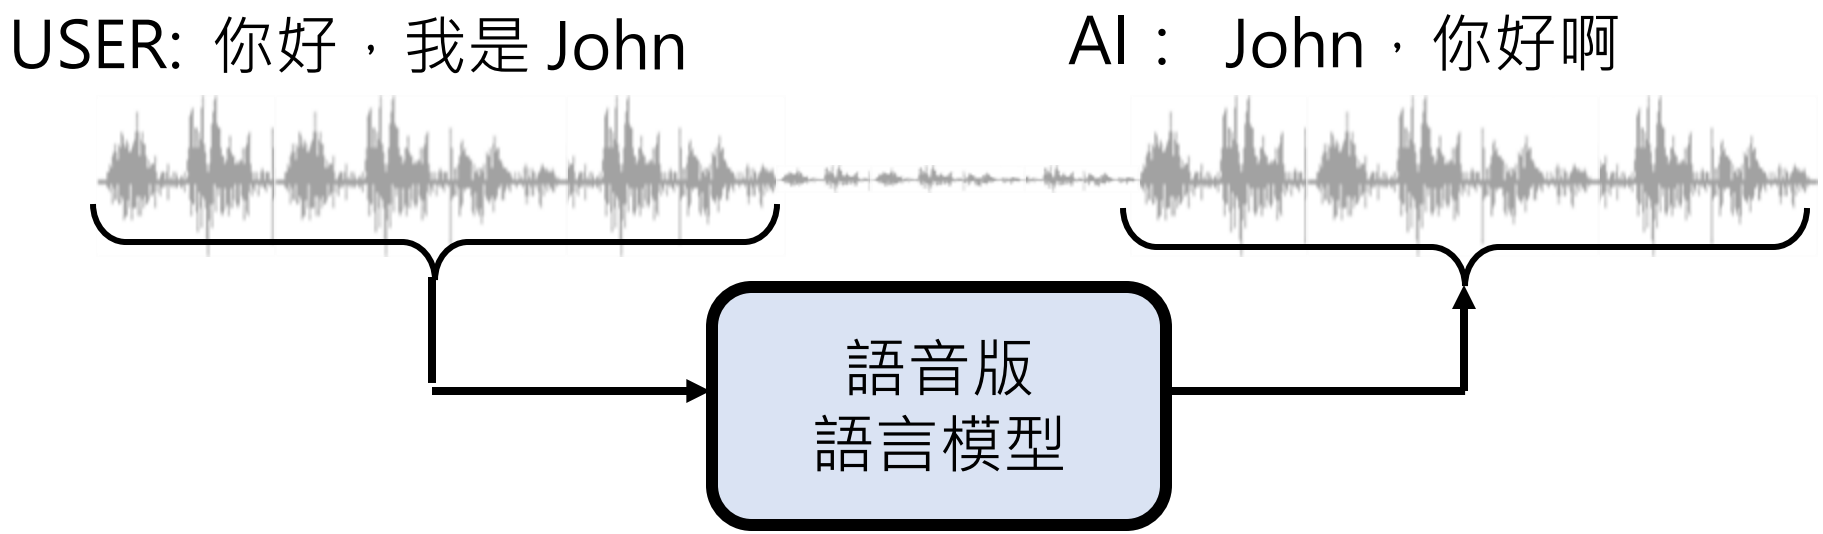

模型訓練：Alignment

語音對話

A: 念這個故事 ...　　Sky: 好啊，那我開始念

A: 快速從一數到十　　Sky: 一、二、三、四 ...

會不會需要 Sky 錄很多對話啊？

- 也許不用，因為模型有 Pre-train 了？
- 也許可以用語音轉換的技術把對話中的任何人聲轉成 Sky 的聲音

https://openai.com/index/navigating-the-challenges-and-opportunities-of-synthetic-voices/

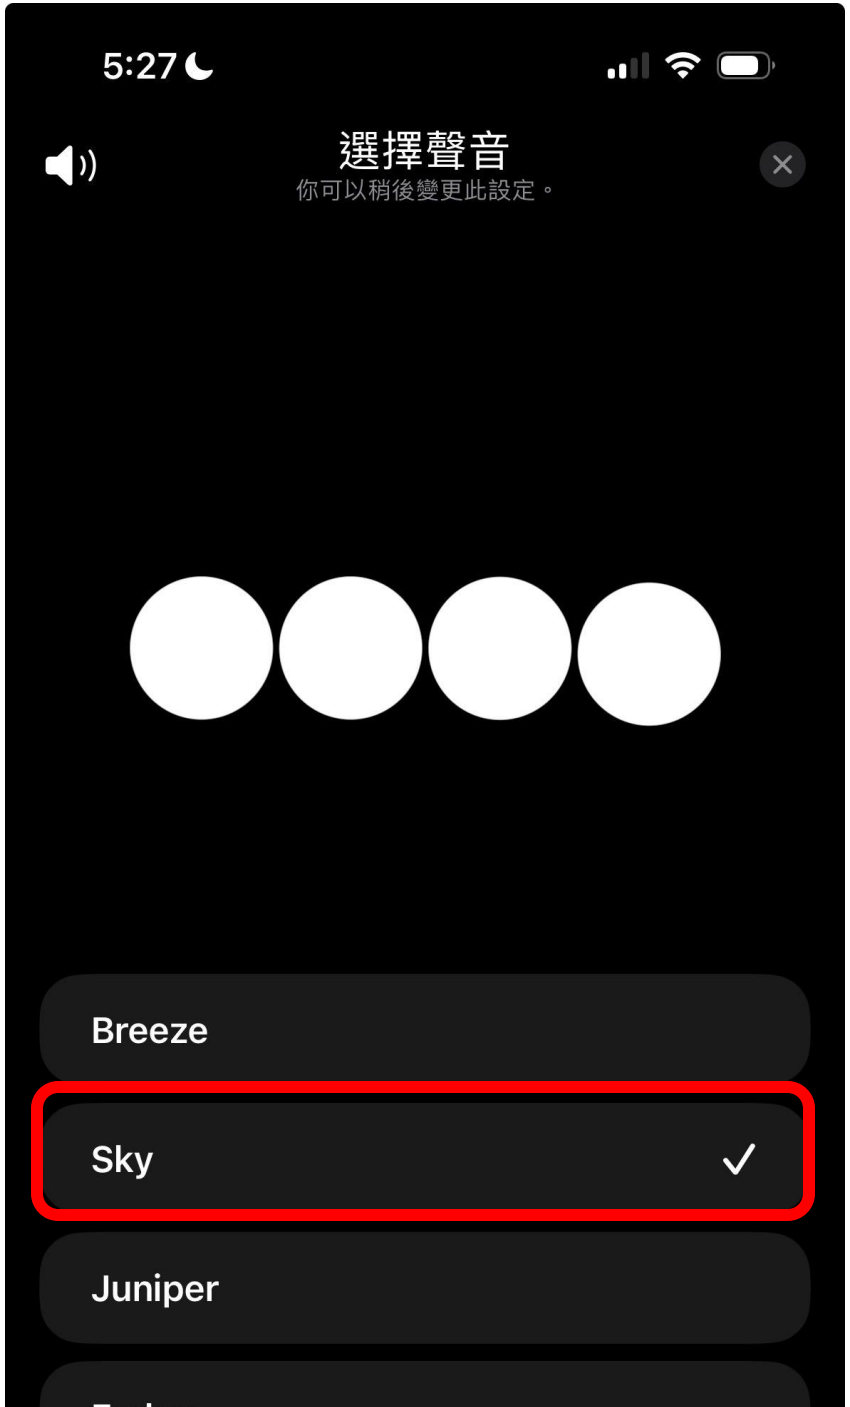

語音介面和文字介面的不同

語音介面和文字介面的不同

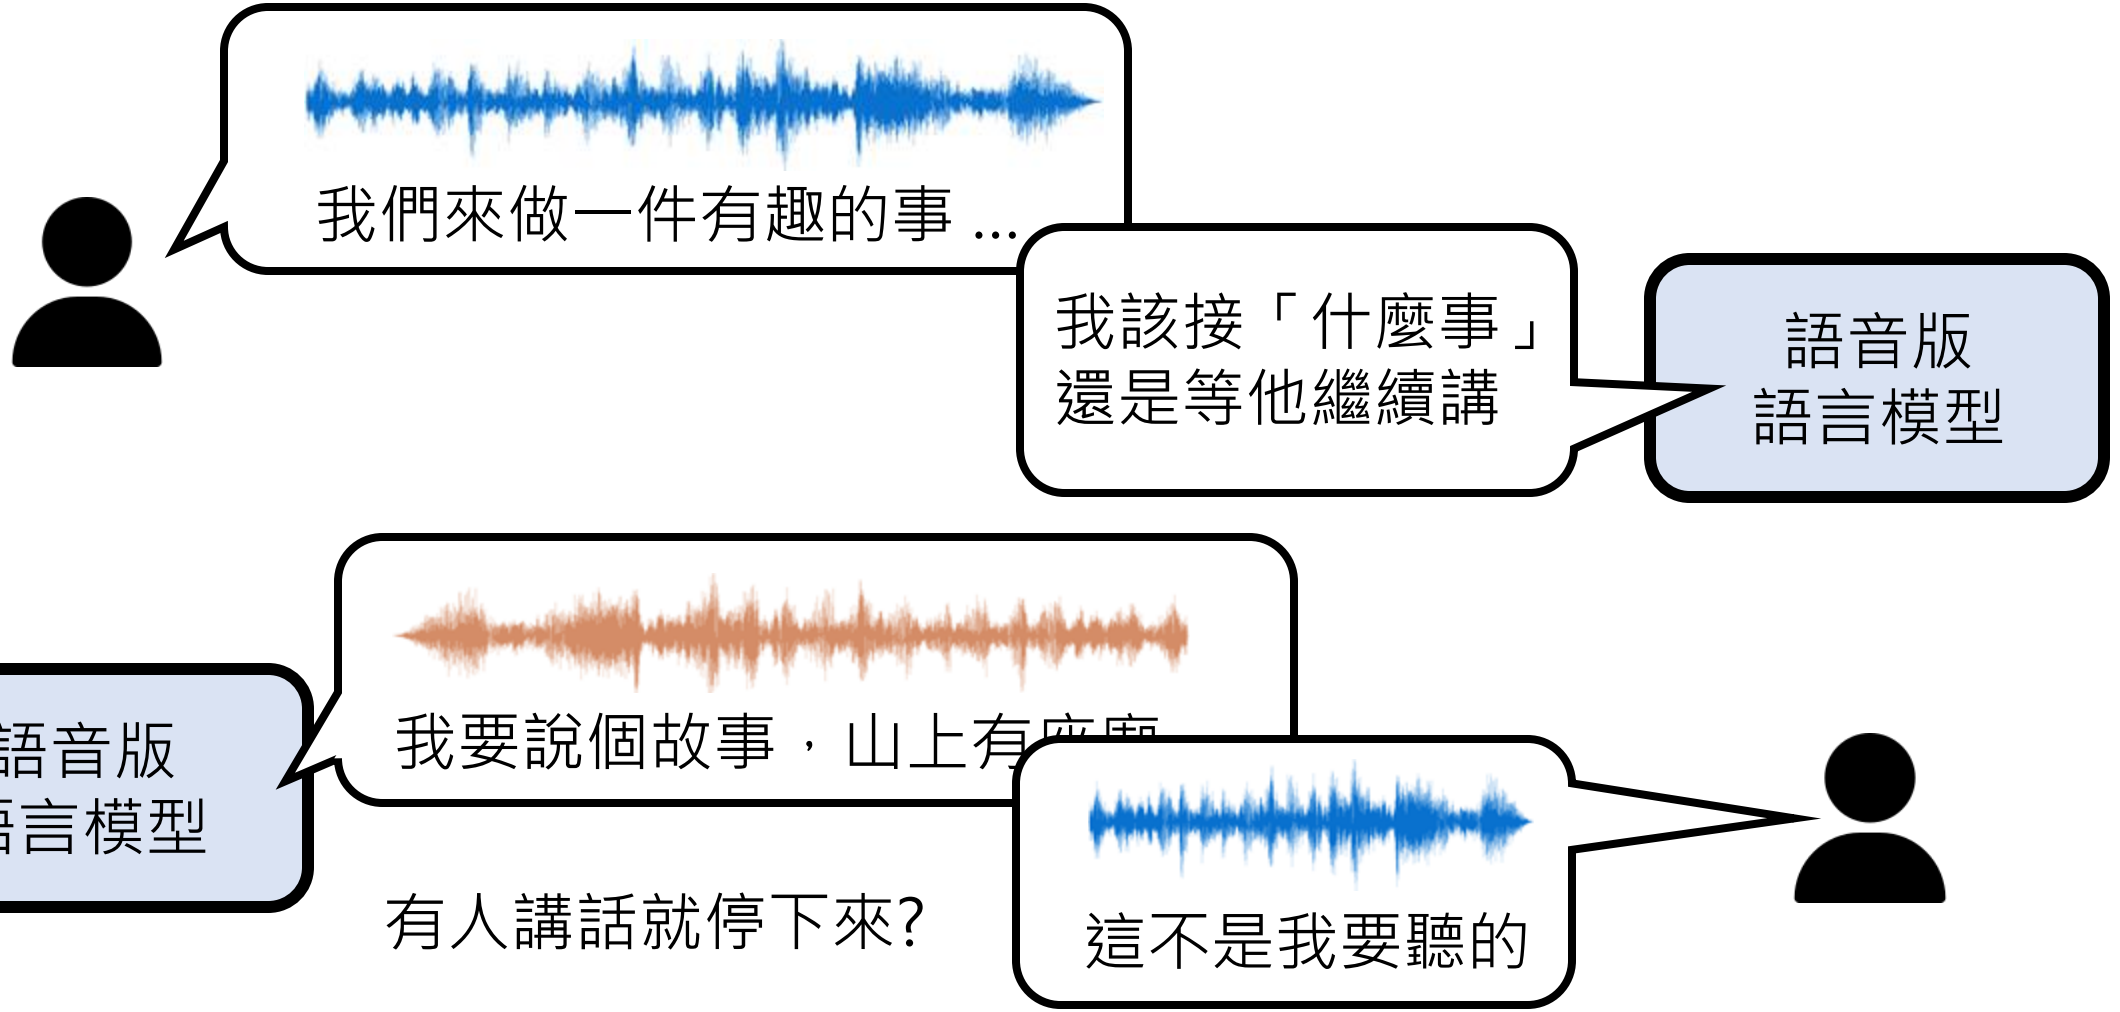

怎麼讓模型同時聽跟說

Dialogue GSLM

https://arxiv.org/abs/2203.16502

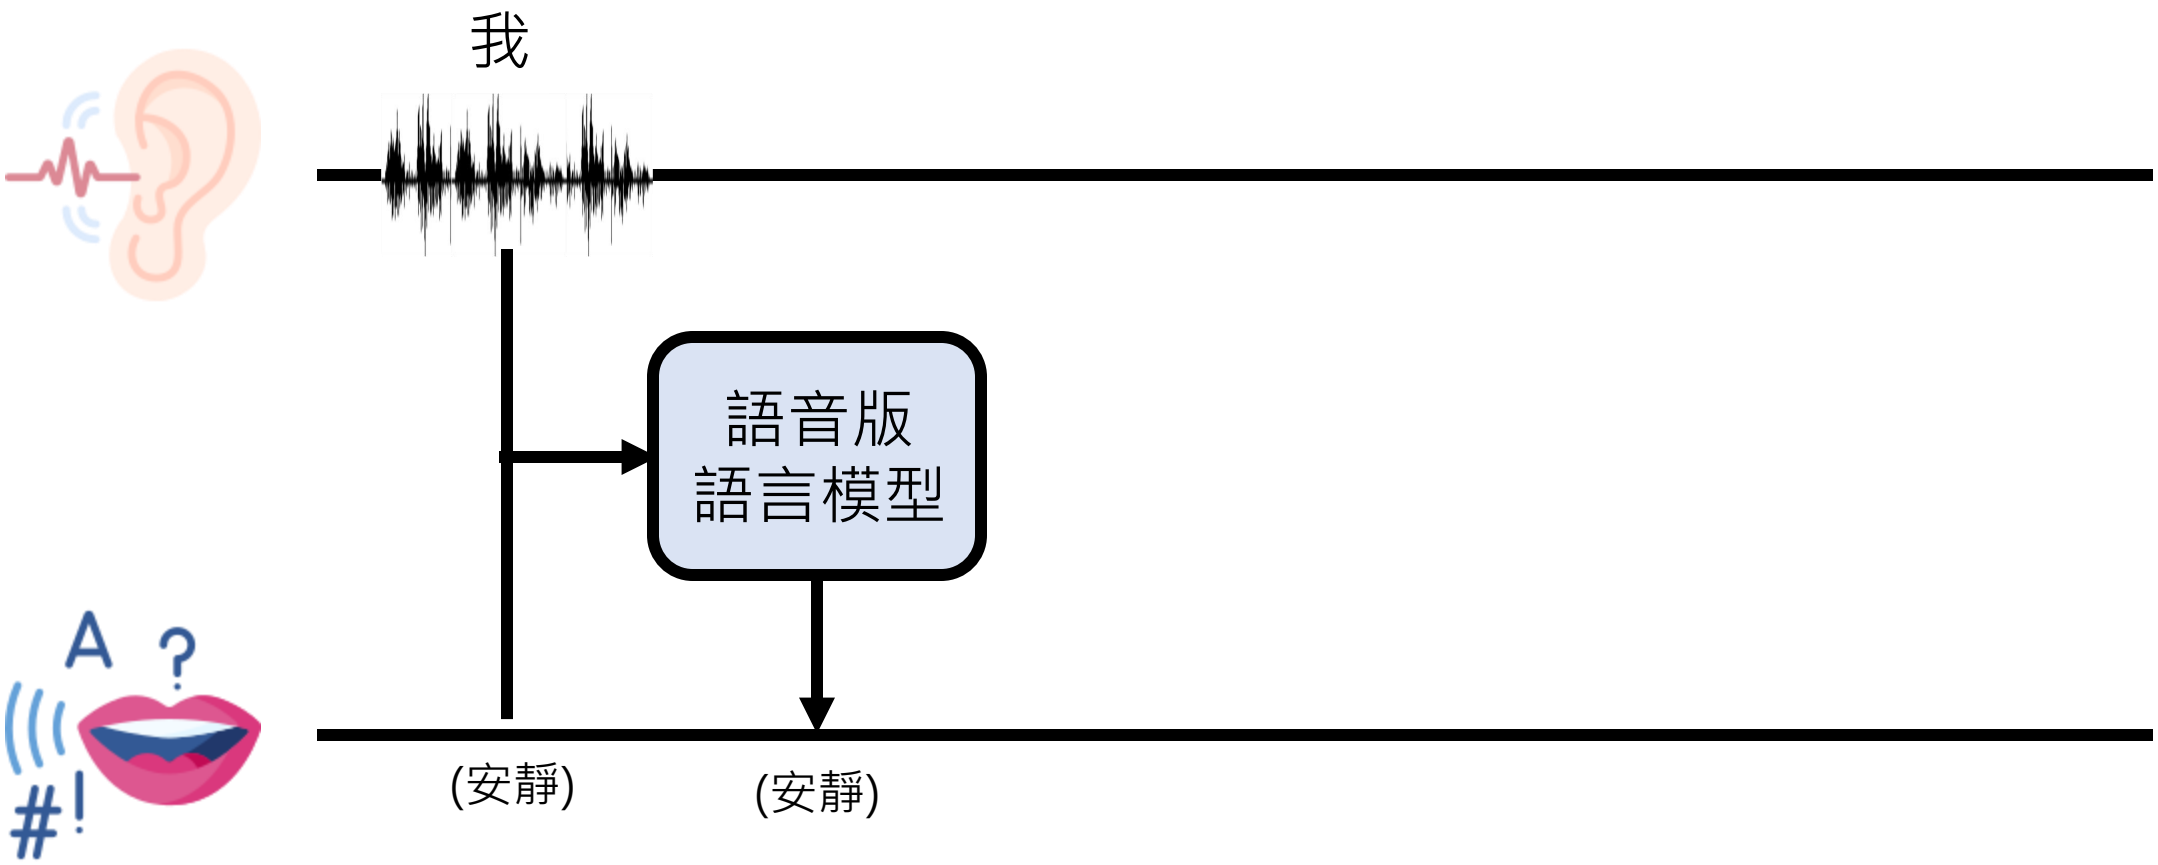

怎麼讓模型同時聽跟說

Dialogue GSLM

https://arxiv.org/abs/2203.16502

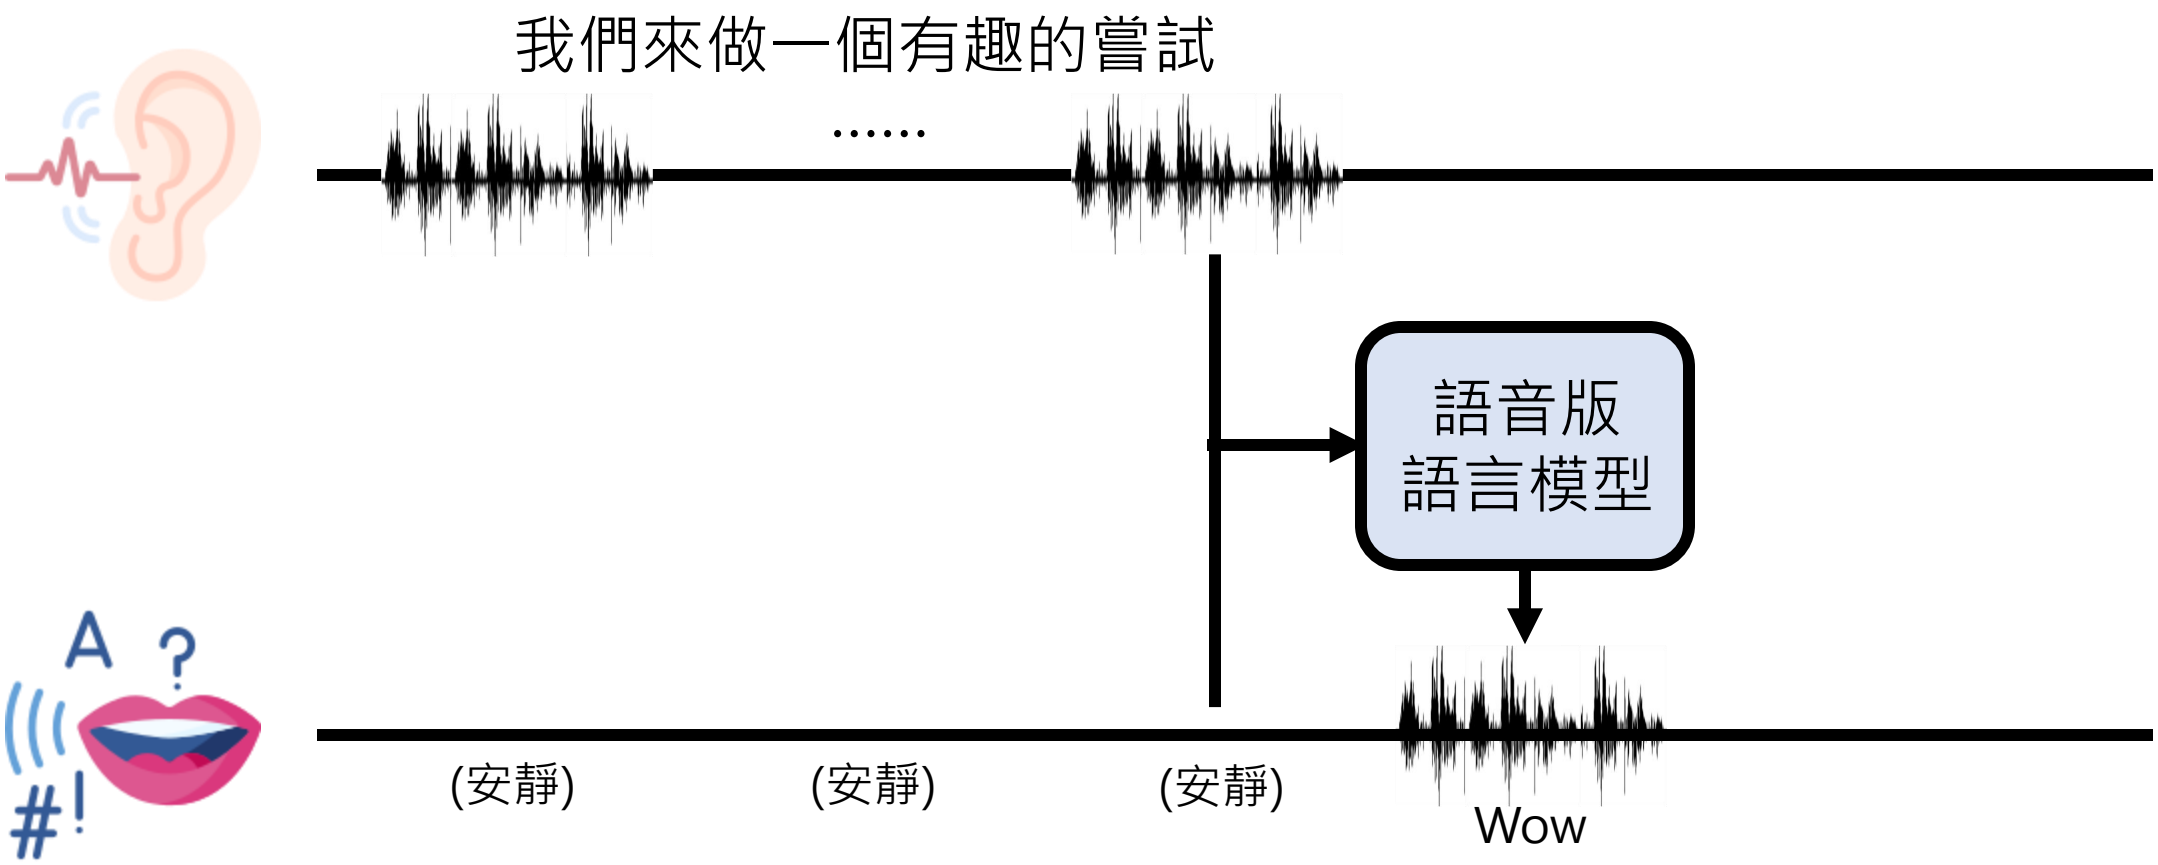

怎麼讓模型同時聽跟說

Dialogue GSLM

https://arxiv.org/abs/2203.16502

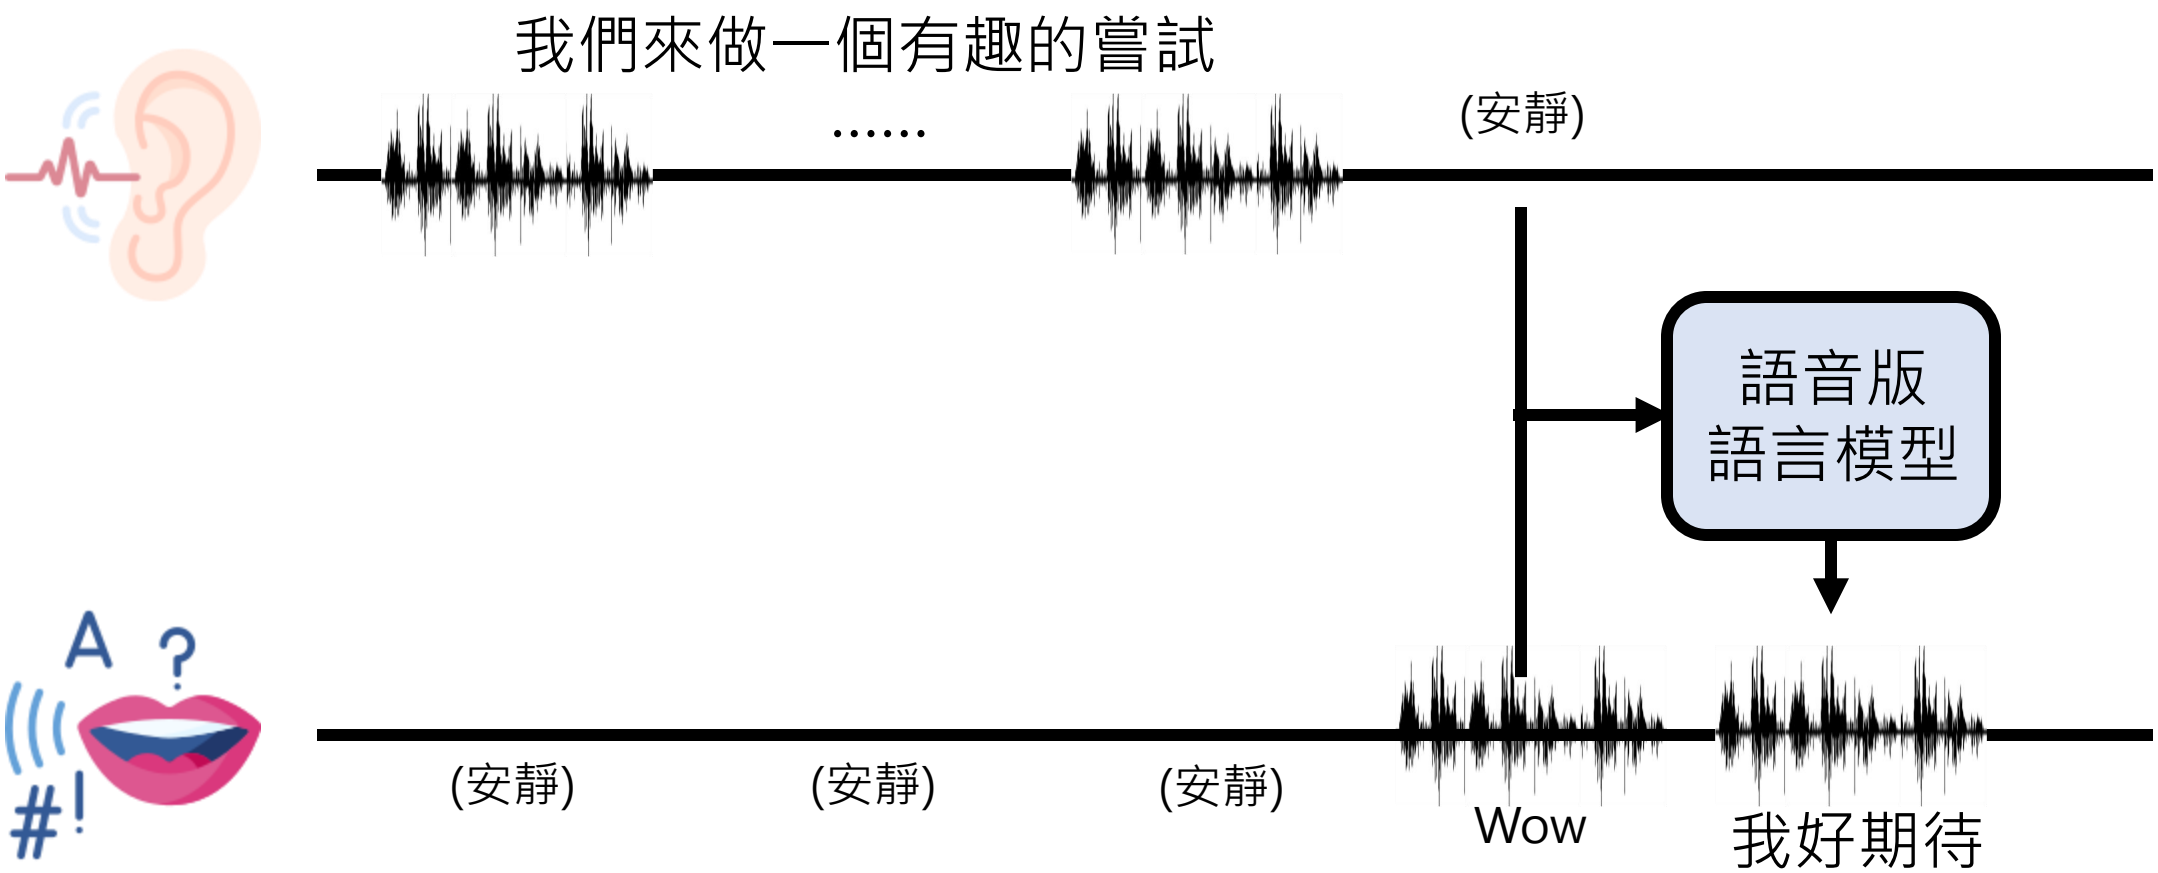

怎麼讓模型同時聽跟說

Dialogue GSLM

https://arxiv.org/abs/2203.16502

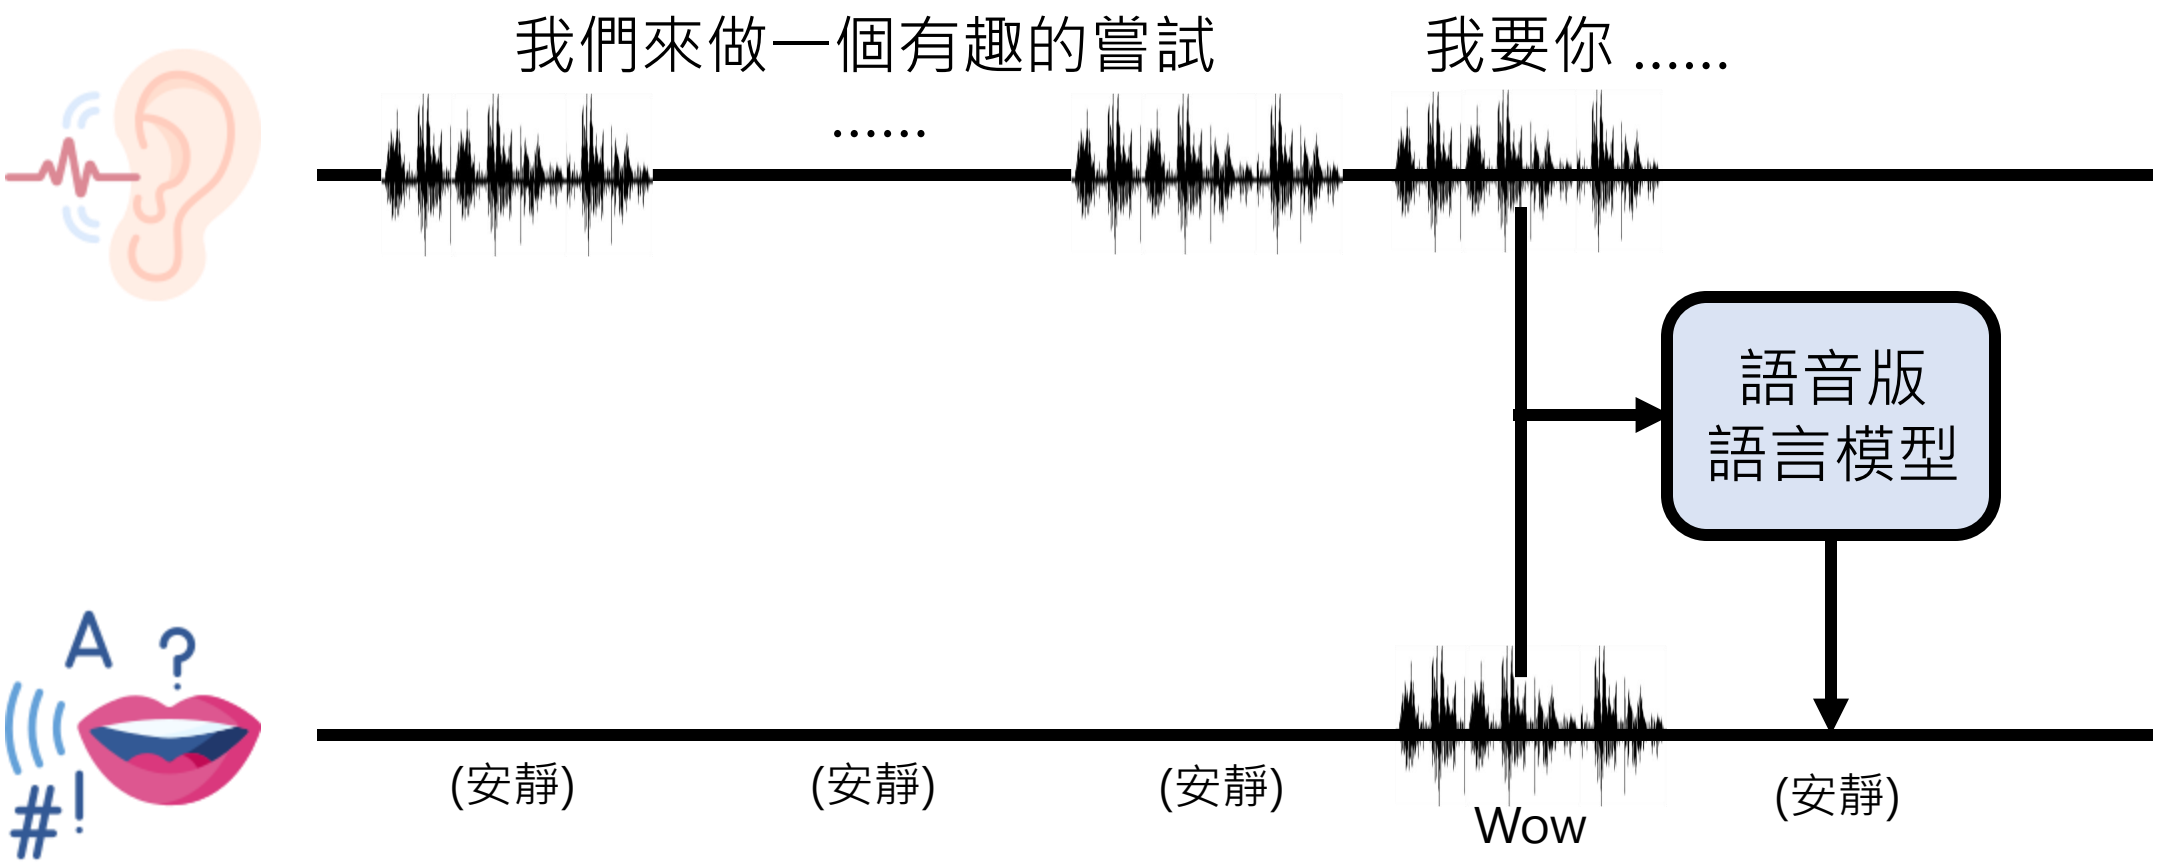

怎麼讓模型同時聽、說、看

例子來自
Open AI GPT-4o 的 demo

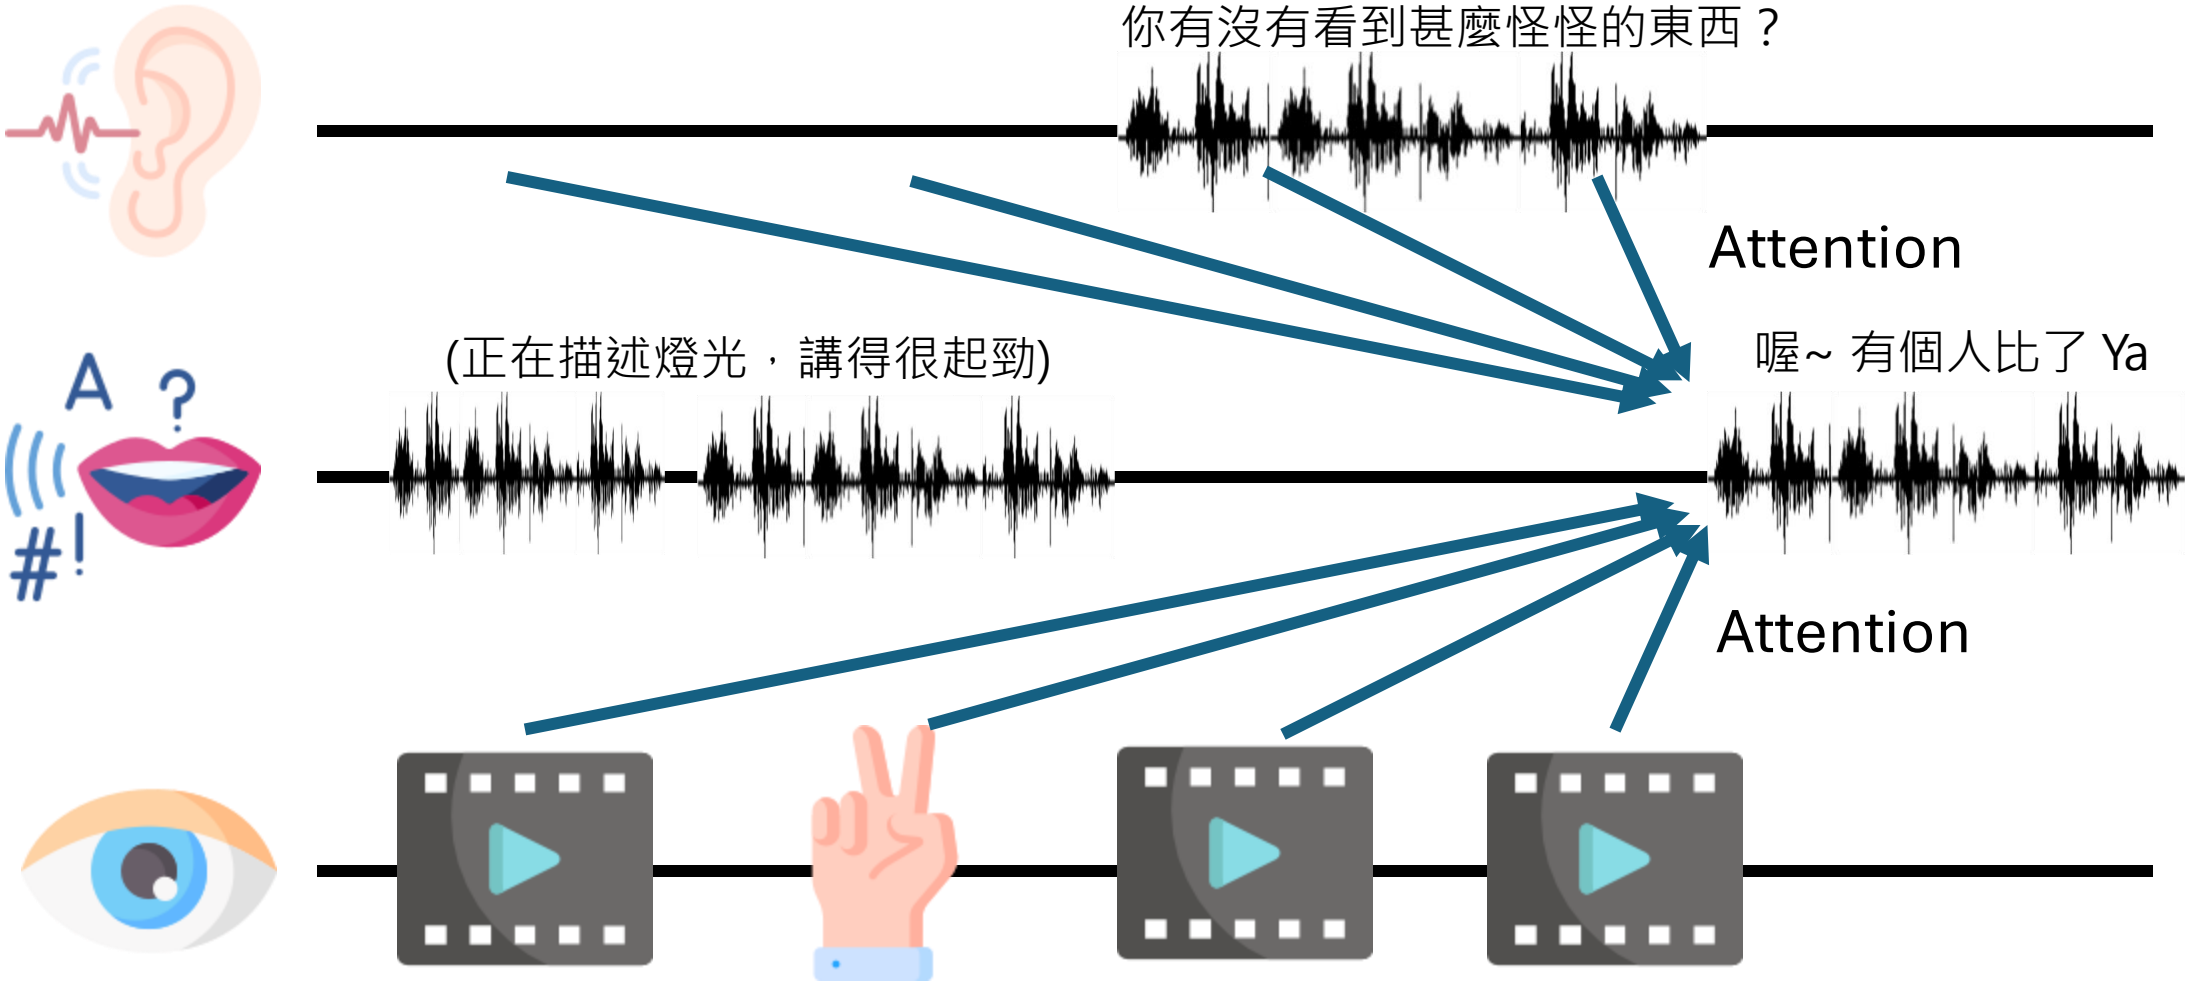

怎麼讓模型同時聽、說、看

例子來自
Google Project Astra Demo

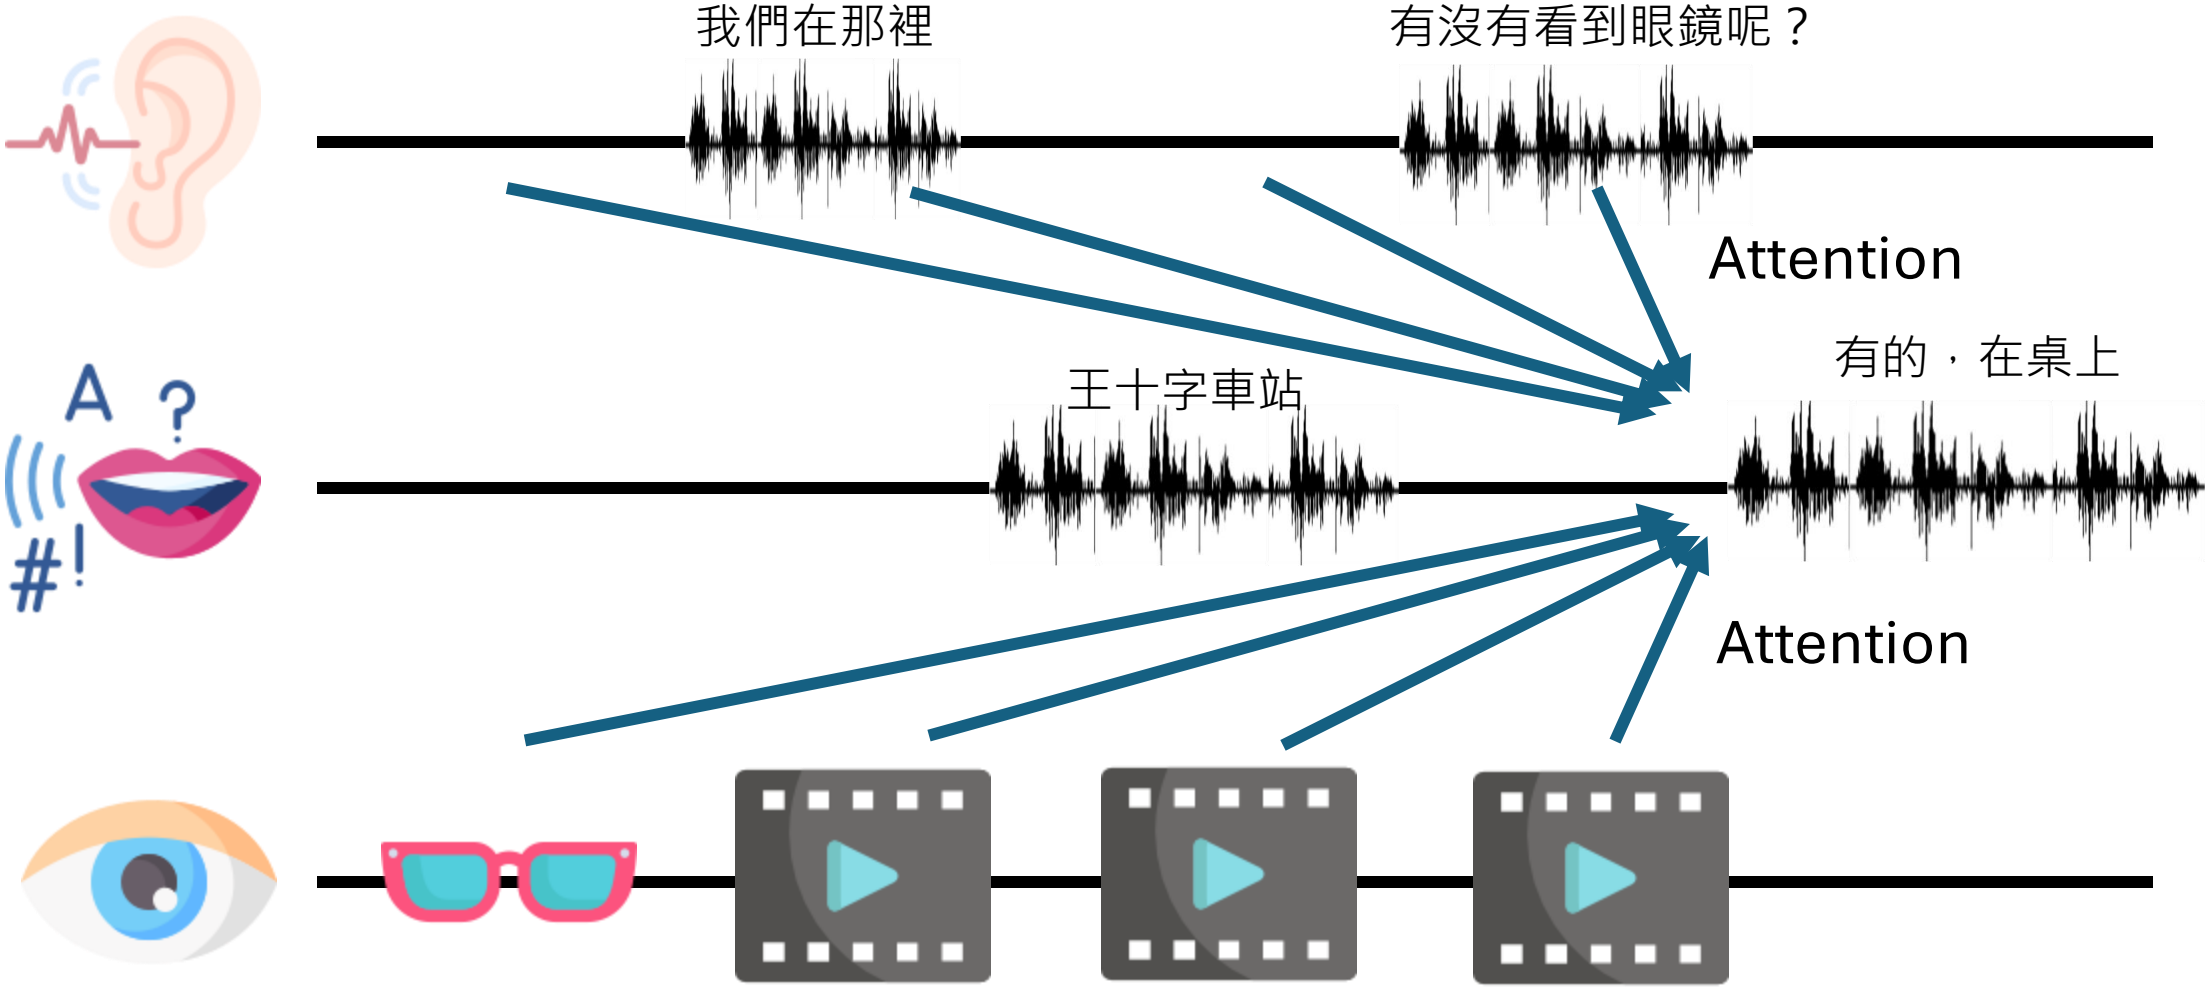

更多有關語音版語言模型的論文

https://github.com/ga642381/speech-trident