

# Audio-LLM

Павел Андреев

[pavel.andreev@heygen.com](mailto:pavel.andreev@heygen.com)

# План

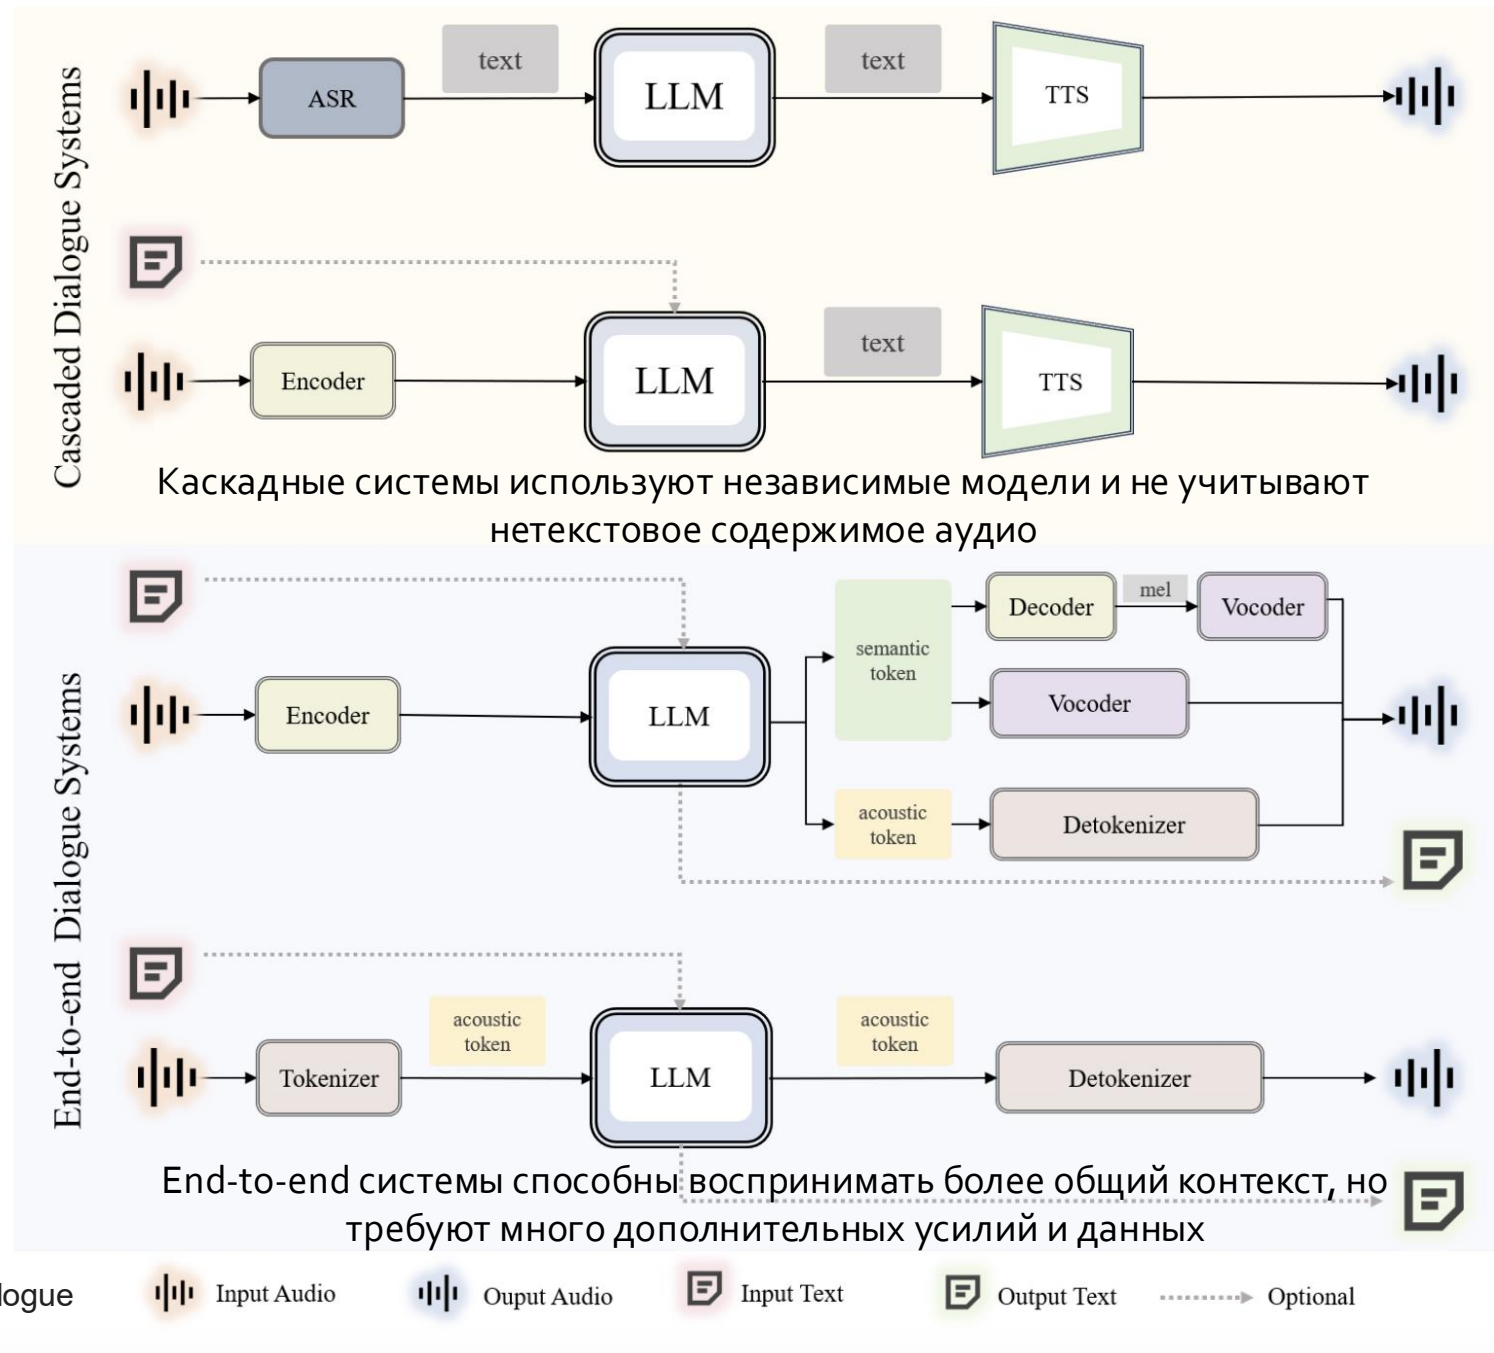
- Верхнеуровневое ревью подходов
- Представления речи
- Этапы обучения
- Дуплексные системы, интерактивность
- Ревью статьи: Moshi
- Ревью статьи: Qwen2.5-omni

# Верхнеуровневое ревью подходов

Чего мы хотим от  
audio-LLM?

1. Мы хотим чтобы Audio-LLM могла делать все что делает обычная LLM
2. Мы хотим чтобы она могла принимать и анализировать аудио сигнал на вход
3. Мы хотим чтобы она могла генерировать аудио сигнал в ответ, имея ввиду аудио сигнал на входе, смысл и контекст ситуации
4. Иногда мы хотим чтобы она могла вести интерактивный диалог, то есть моделировать структуру диалога: понимать когда нужно начать говорить, когда заканчивать, а когда нет

# Верхнеуровневое ревью подходов

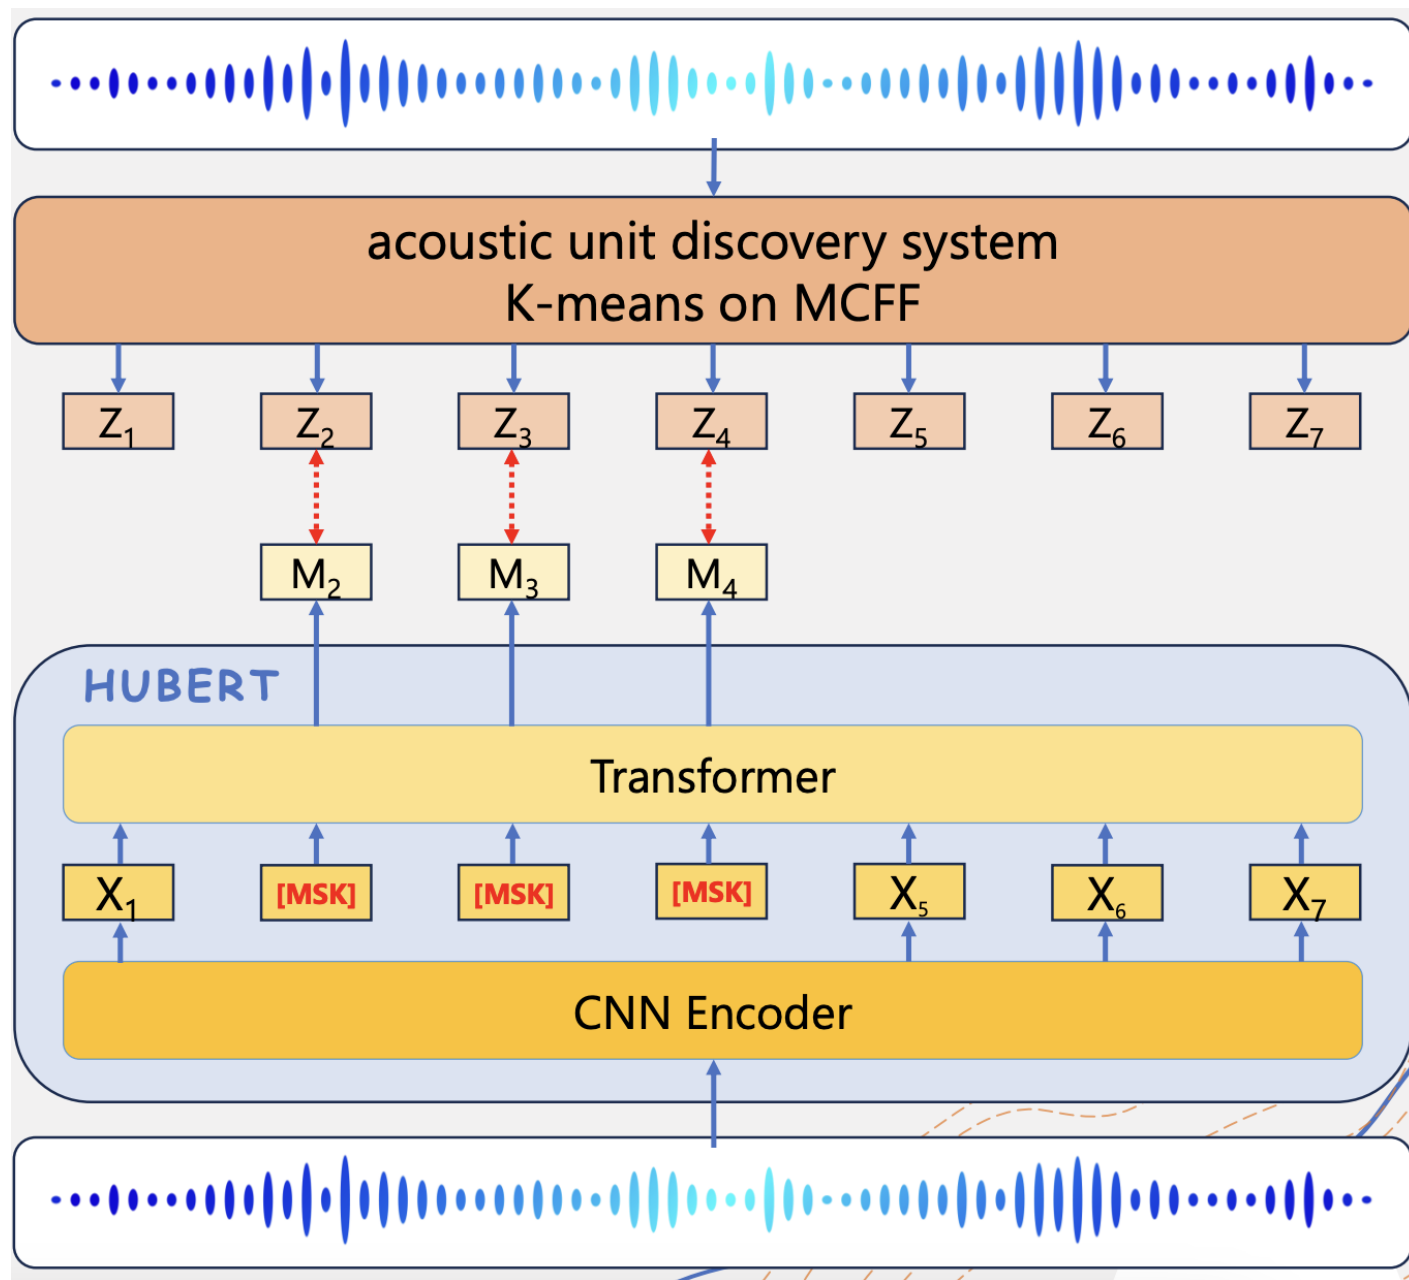


## Представле- ния речи

- **Семантические** -> цель: иметь представления речи как можно более близкие к речи; обычно генерируются из self-supervised либо ASR моделями
- **Акустические** -> цель: иметь представления, из которых исходное аудио восстанавливается наиболее точно
- **Смешанные** -> цель: объединить акустические и семантические
- Чтобы LLM могла генерировать речь, ее представления должны быть **токенизируемыми** (дискретными)


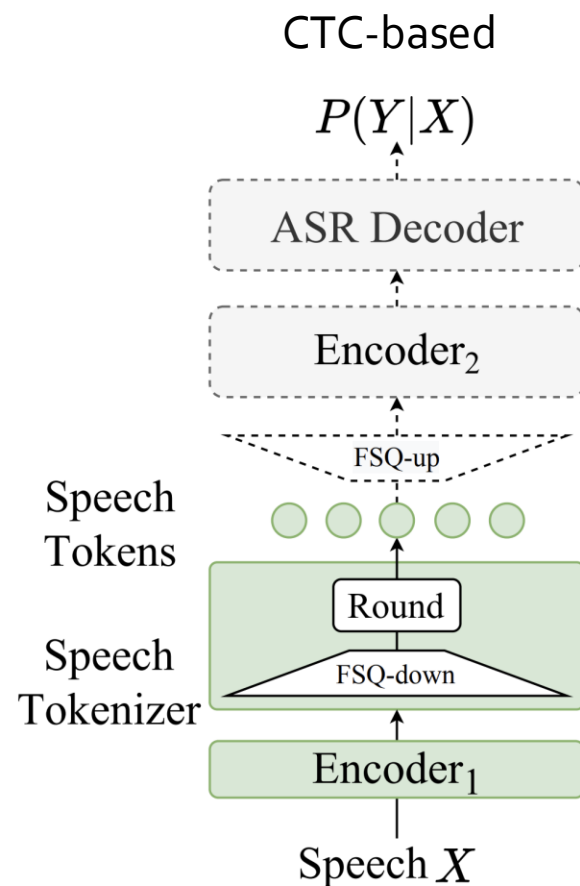
# Представле- ния речи

Семантические self-  
supervised  
представления



# Представле- ния речи

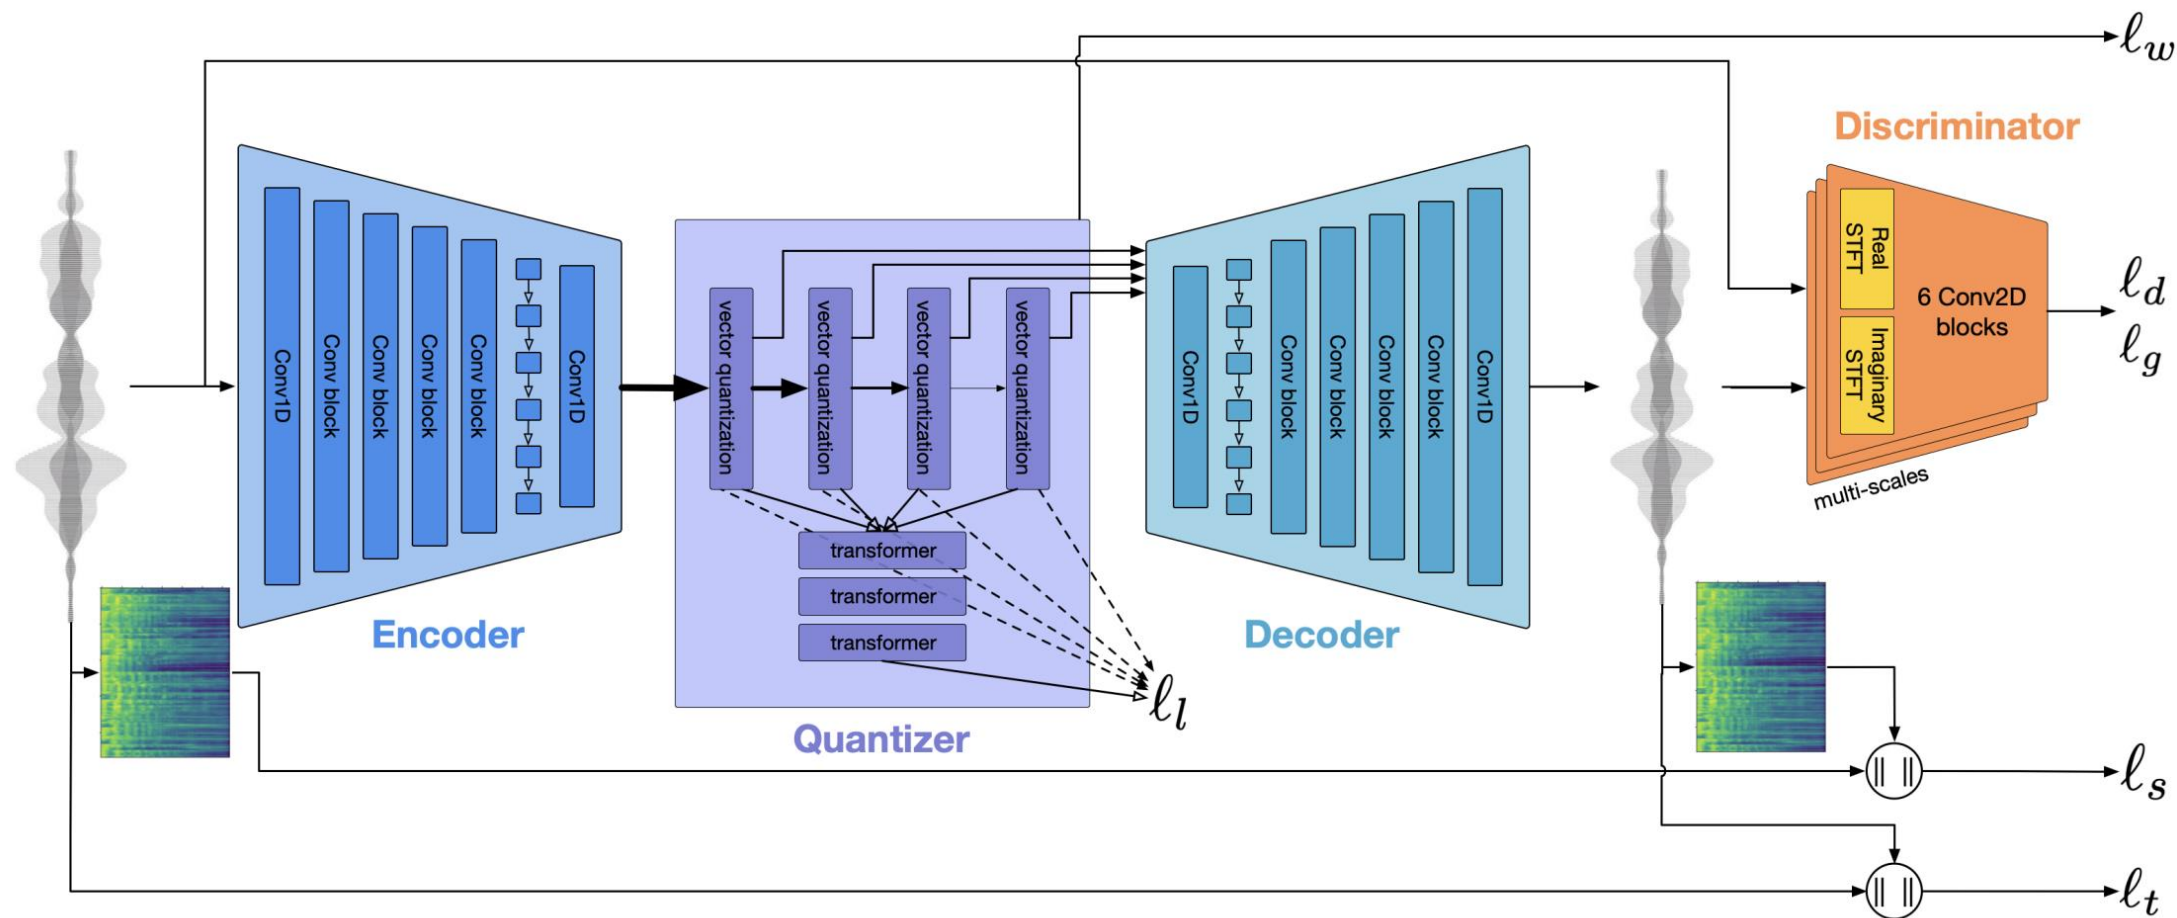
## Семантические ASR представления



# Представления речи

## Акустические представления

Défossez, Alexandre, et al. "High Fidelity Neural Audio Compression." *Transactions on Machine Learning Research*.

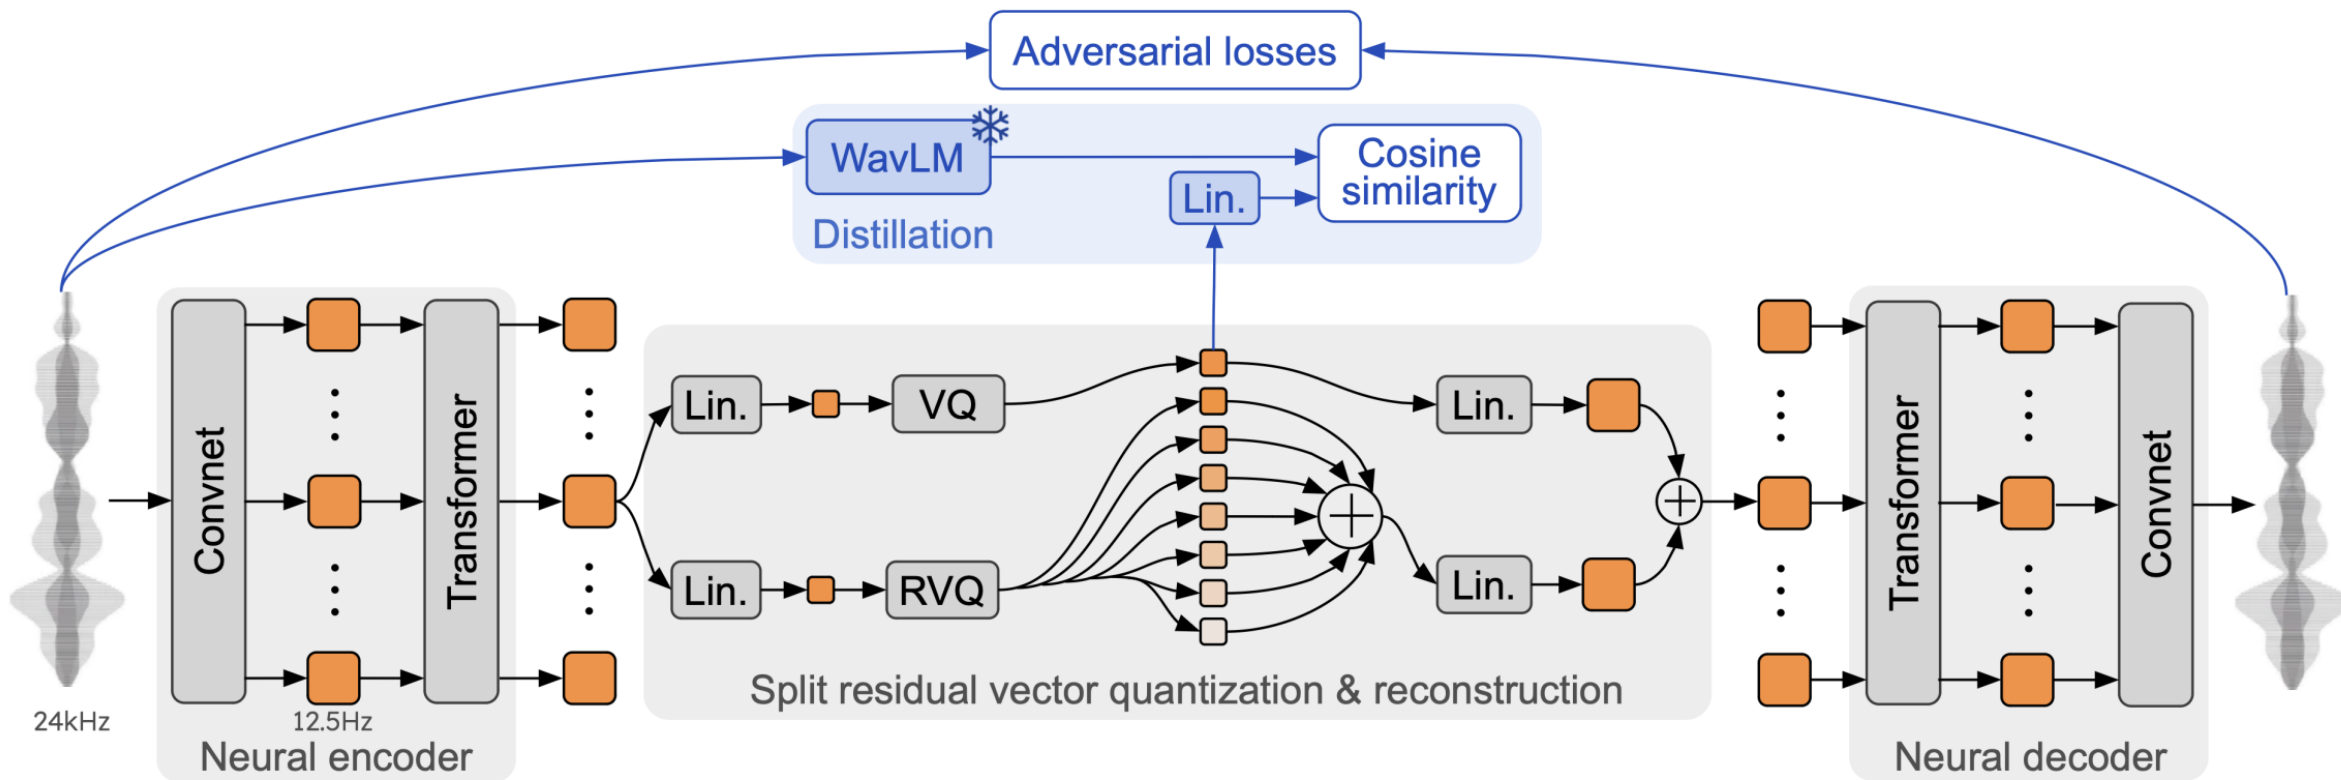




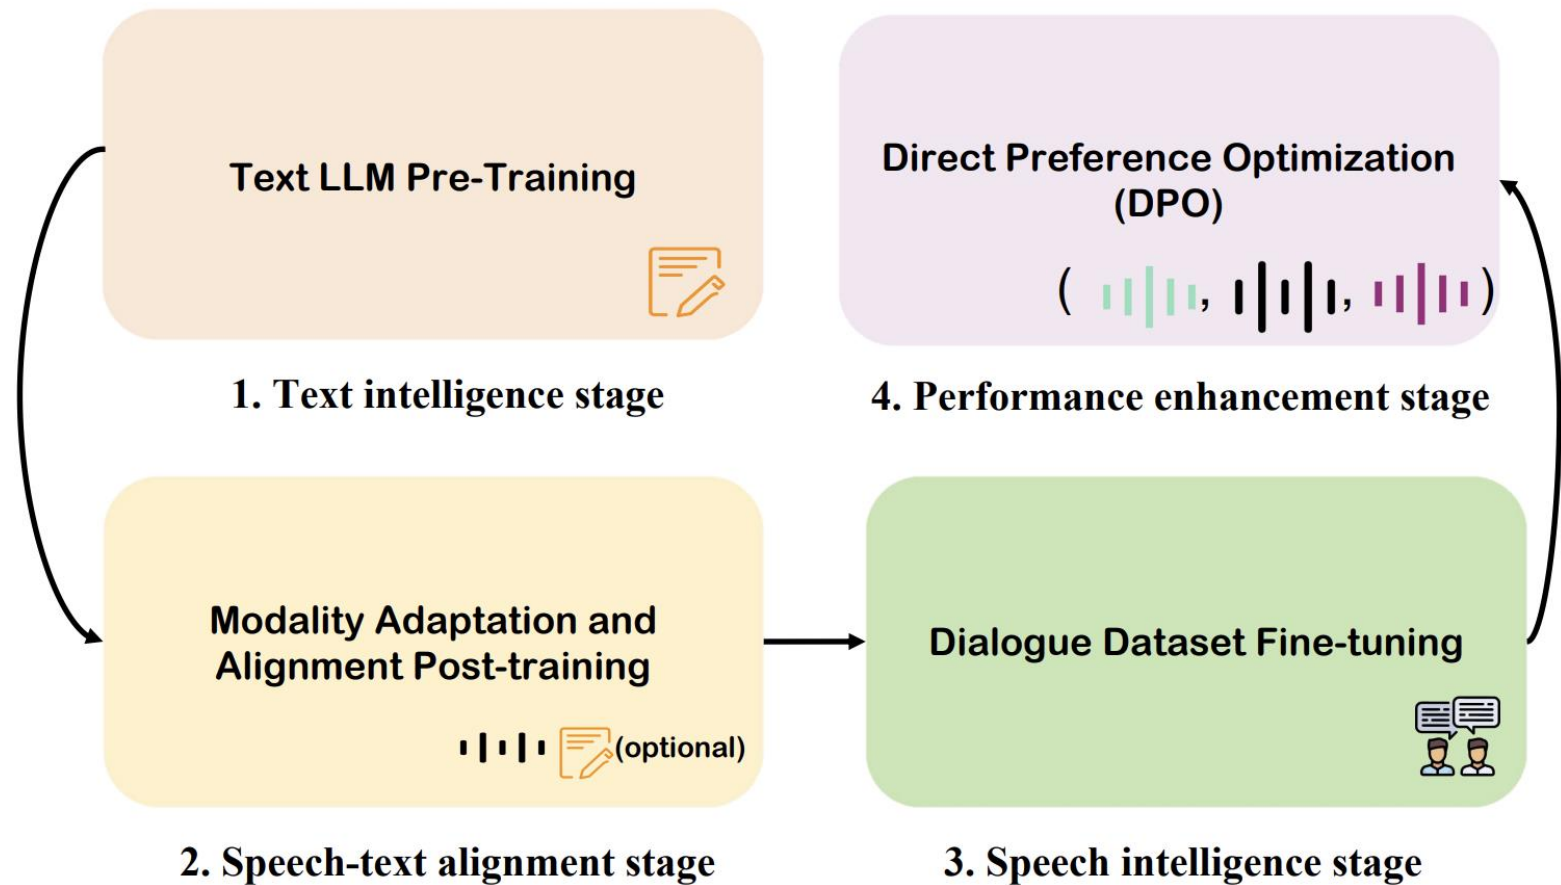
# Представления речи

## Смешанные представления

Défossez, Alexandre, et al. "Moshi: a speech-text foundation model for real-time dialogue." *arXiv preprint arXiv:2410.00037* (2024).



# Этапы обучения



# Этапы обучения

speech-text alignment

Modality Adaptation and Alignment Post-training Tasks

||| | (optional)

## ① Unsupervised Speech Pre-training

[B] [blue square] [blue square] [blue square] [blue square] [blue square] [blue square] [blue square] [E]

## ② Speech to Text conversion

[blue square] [blue square] [blue square] [blue square] [blue square] [blue square] [blue square] | [green square] [green square] [green square]

## ③ Text to Speech conversion

[green square] [green square] [green square] | [blue square] [blue square] [blue square] [blue square] [blue square] [blue square]

## ④ Interleaved Speech and Text tokens

[S] [blue square] [blue square] [blue square] [T] [green square] [green square] [S] [blue square] [blue square]

[B] <bos>

[E] <eos>

[S] speech tag

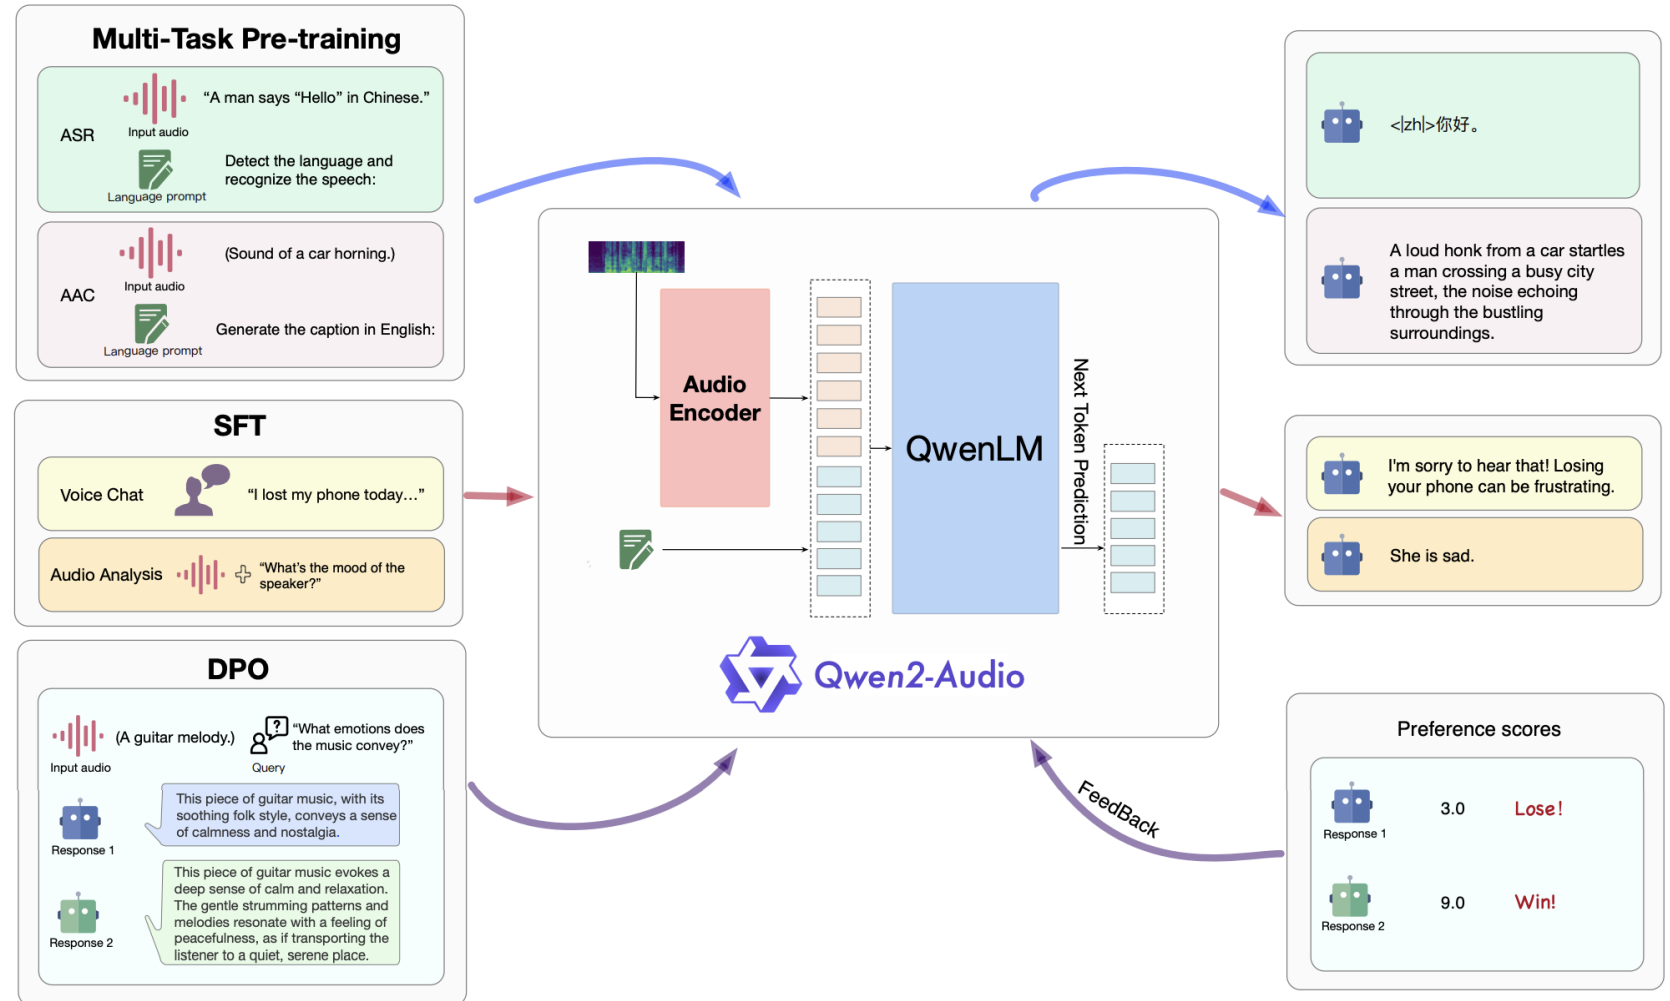
[T] text tag

[green square] text token

[blue square] speech feature or token

# Этапы обучения

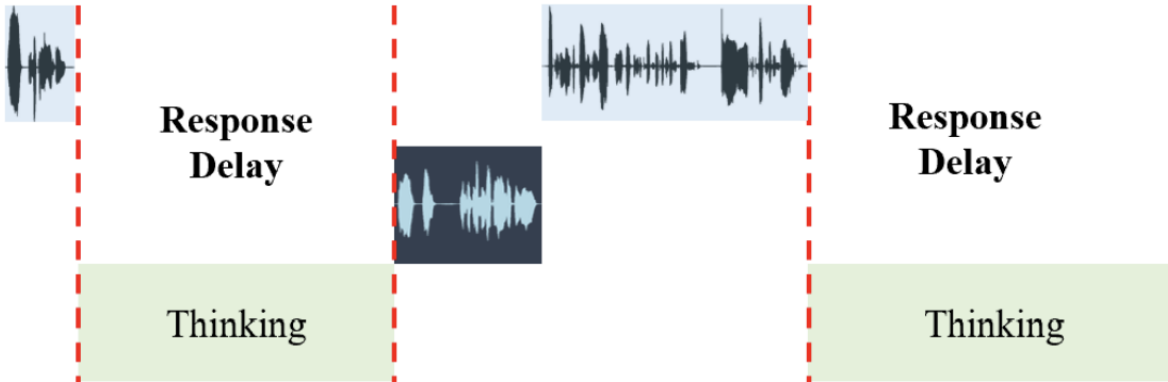
## speech-text alignment и DPO



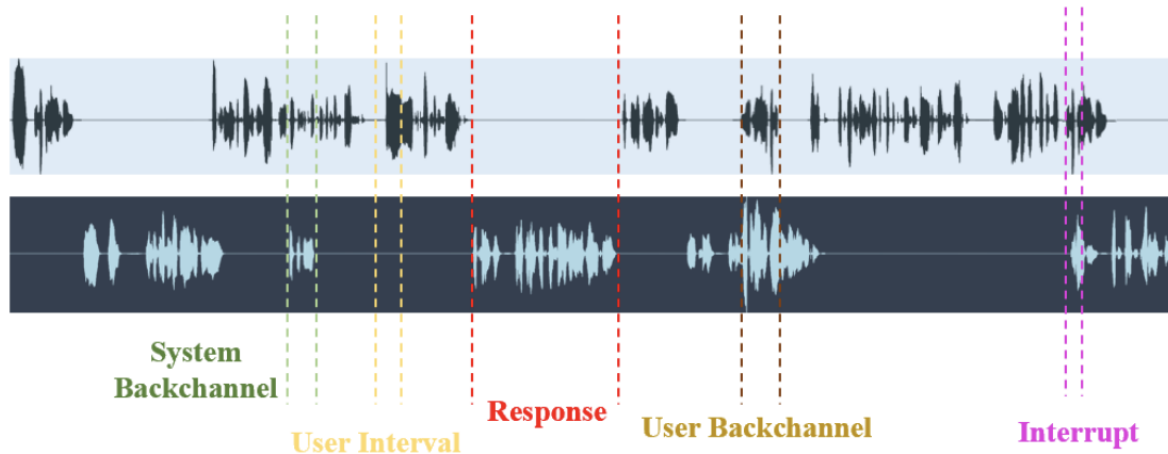
# Дуплексные системы, интерактивность



(a) Simplex: One-way communication, and the direction is fixed.



(b) Half-duplex: Two-way communication, but not simultaneously.

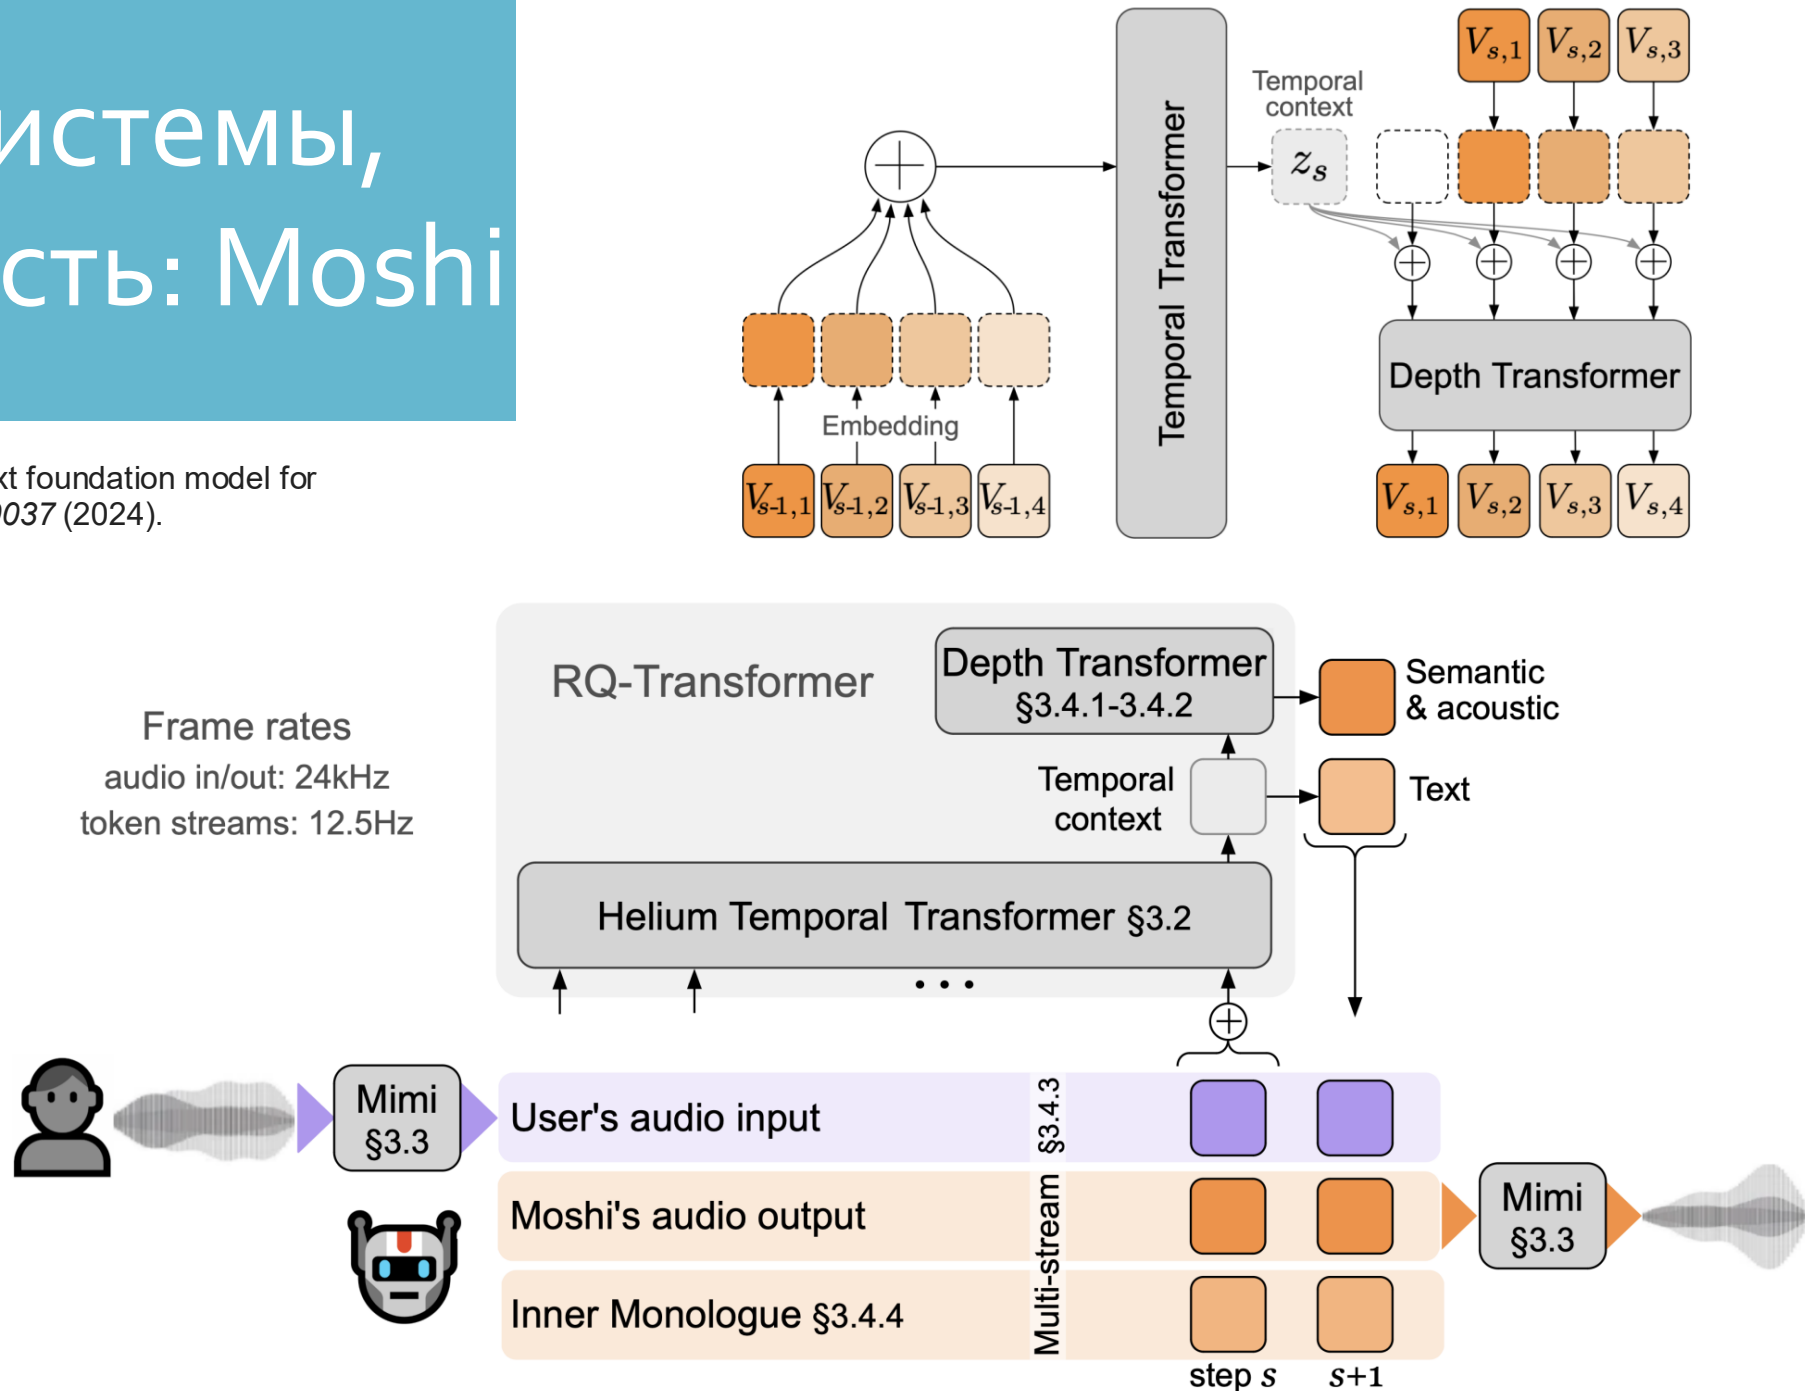


(c) Full-duplex: Two-way communication, simultaneously.

# Дуплексные системы, интерактивность: Moshi


Défossez, Alexandre, et al. "Moshi: a speech-text foundation model for real-time dialogue." *arXiv preprint arXiv:2410.00037* (2024).

1. End-to-end дуплексная audio-llm
2. Разработали Mimi
3. Сделали иерархическую структуру предсказания аудио токенов, моделирующую речь обоих спикеров
4. Предложили идею "внутреннего диалога"
5. Обучают на текст -> raw audio -> аудио диалоги

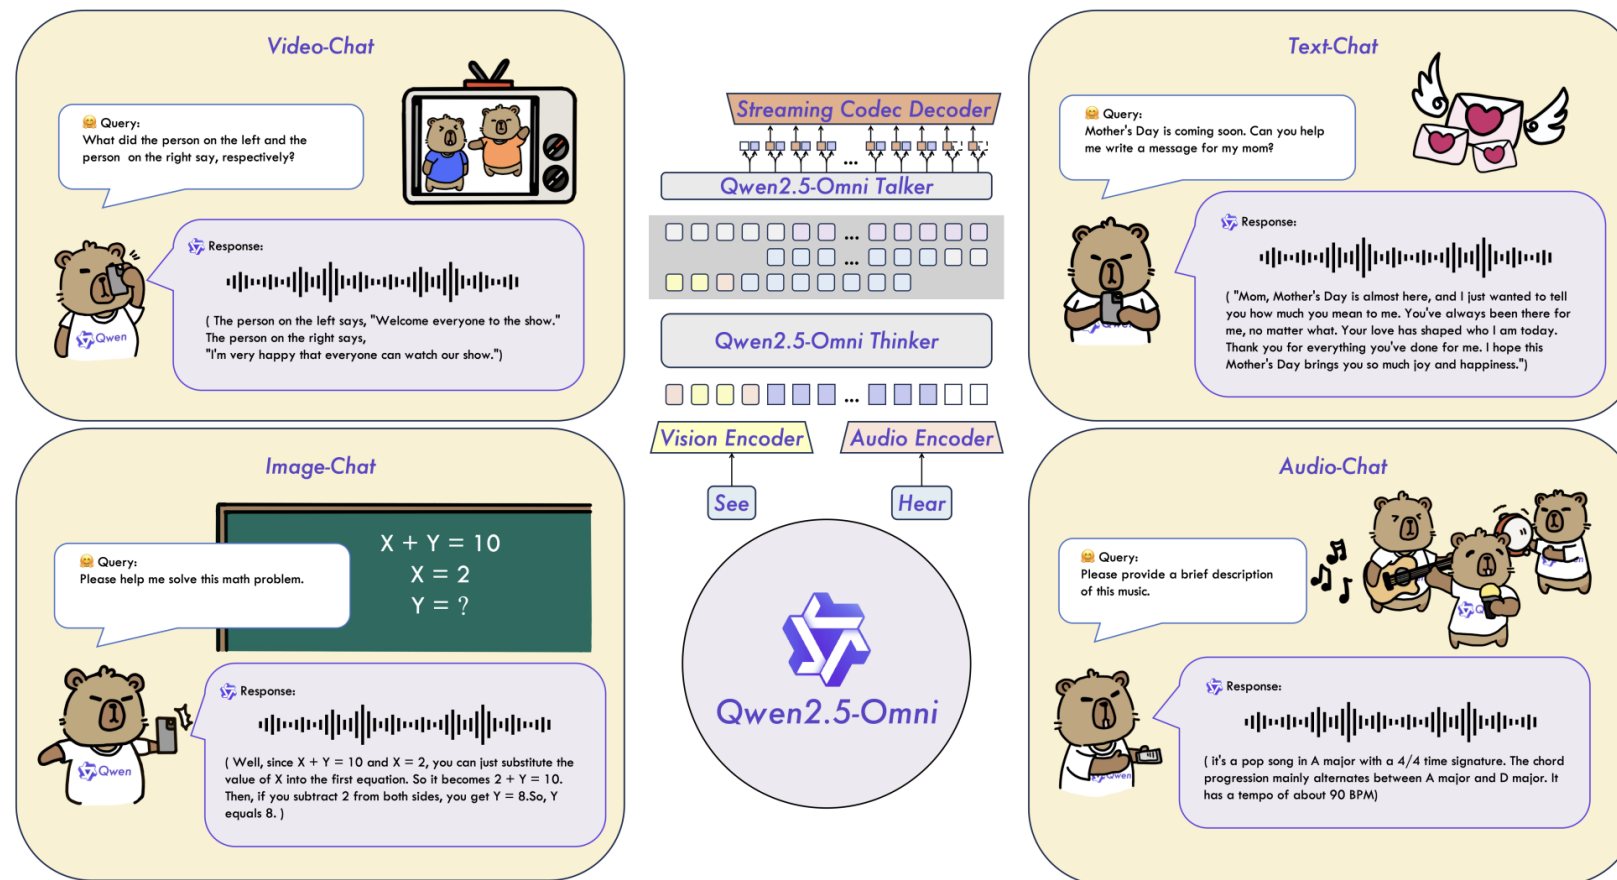


# Дуплексные системы, интерактив- ность Moshi

Используют задержку акустических токенов относительно семантических



# SoTA: Qwen2.5-omni

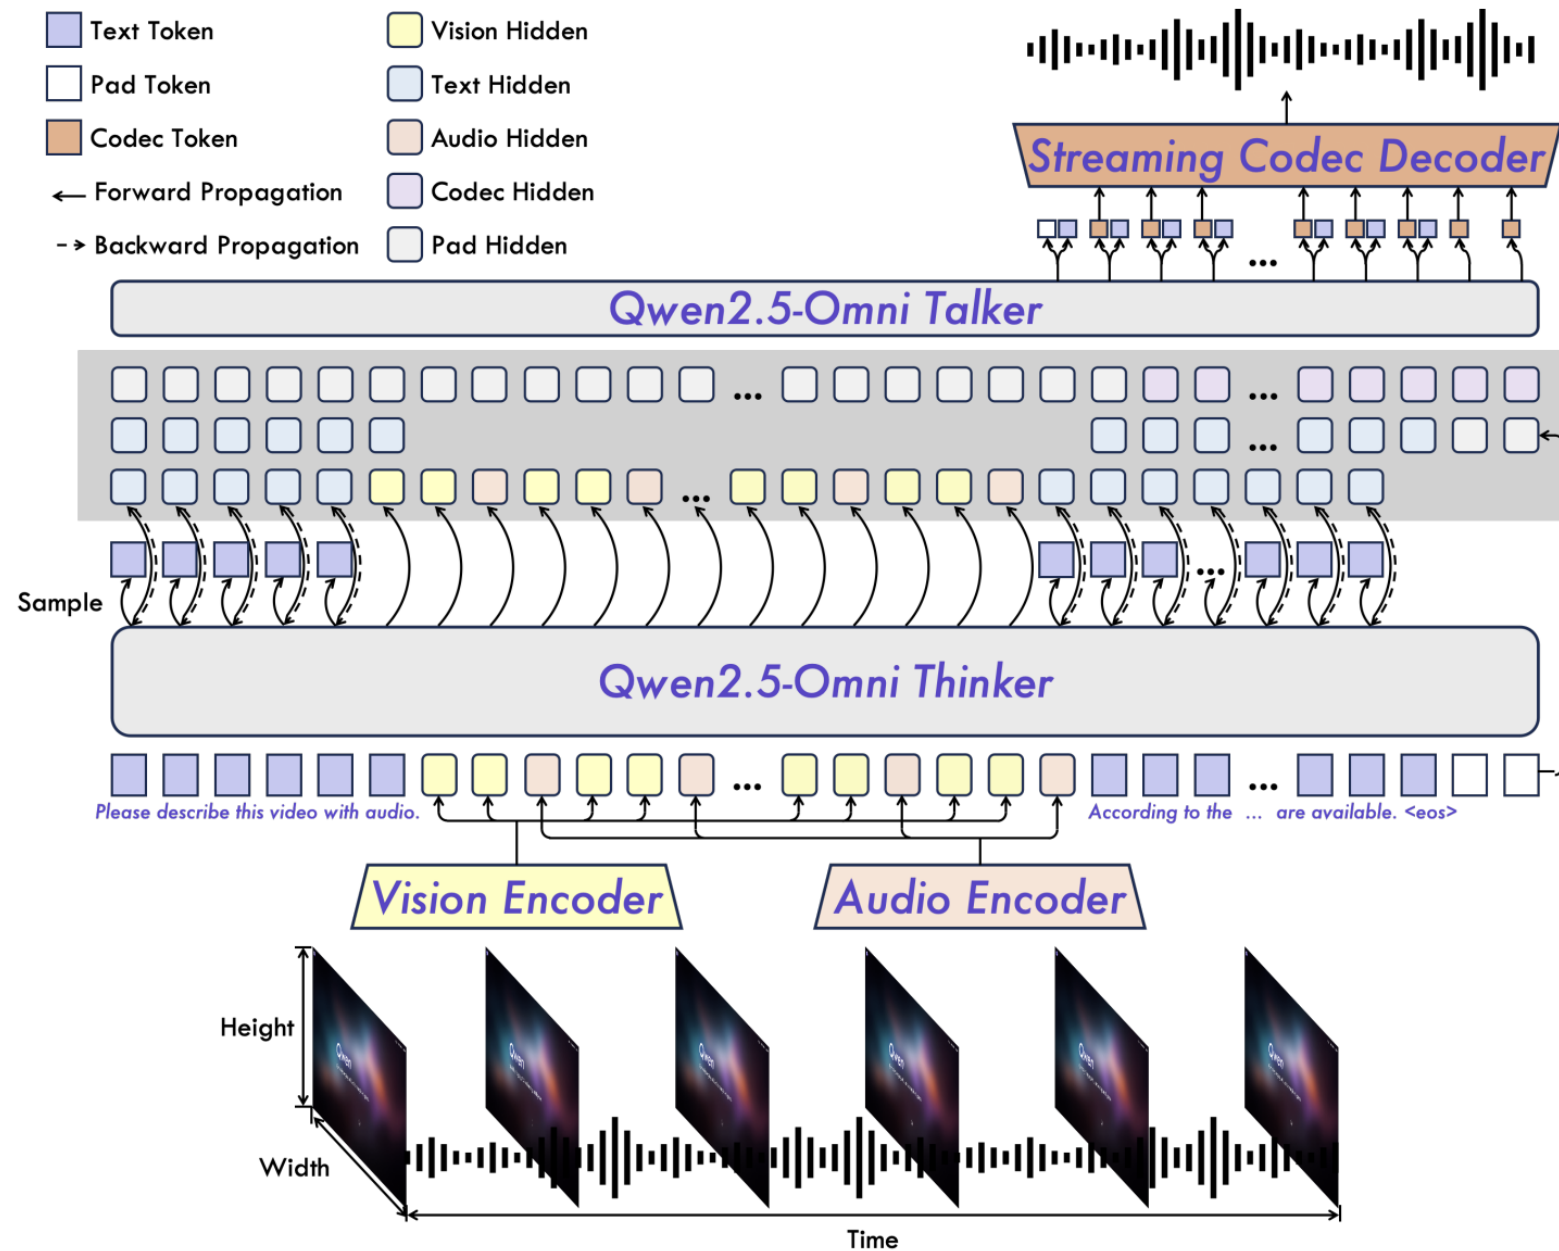


1. Текст, видео, аудио на вход; текст, аудио на выход
2. Thinker-Talker архитектура
3. Берут текстовую LLM, добавляют энкодер визуальной информации и аудио энкодер (whisper)
4. Сначала замораживают параметры LLM и энкодеров и тренируют адаптеры, потом энкодеры, и финально - всю модель
5. Pretrain на сырых мультимодальных данных, дальше instruction following и DPO



# SoTA: Qwen2.5-omni

Похоже на RQ-transformer как у Moshi, но talker берет весь контекст



# SoTA: Qwen2.5-omni

Table 1: Text → Text performance of 7B+ pure text models and Qwen2.5-Omni

Datasets	Gemma2-9B	Llama3.1-8B	Qwen2-7B	Qwen2.5-7B	Qwen2.5-Omni-7B
<i>General Tasks</i>					
MMLU-Pro	52.1	48.3	44.1	<b>56.3</b>	47.0
MMLU-redux	72.8	67.2	67.3	<b>75.4</b>	71.0
LiveBench <sub>0831</sub>	30.6	26.7	29.2	<b>35.9</b>	29.6
<i>Mathematics &amp; Science Tasks</i>					
GPQA	32.8	32.8	34.3	<b>36.4</b>	30.8
MATH	44.3	51.9	52.9	<b>75.5</b>	71.5
GSM8K	76.7	84.5	85.7	<b>91.6</b>	88.7
<i>Coding Tasks</i>					
HumanEval	68.9	72.6	79.9	<b>84.8</b>	78.7
MBPP	74.9	69.6	67.2	<b>79.2</b>	73.2
MultiPL-E	53.4	50.7	59.1	<b>70.4</b>	65.8
LiveCodeBench <sub>2305-2409</sub>	18.9	8.3	23.9	<b>28.7</b>	24.6

SoTA:  
Qwen2.5-omni

Table 3: Audio → text performance of State-of-the-art and Qwen2.5-Omni

Datasets	Model	Performance
<i>SER</i>		
Meld	WavLM-large (Chen et al., 2022)	0.542
	MiniCPM-o (Yao et al., 2024)	0.524
	Qwen-Audio (Chu et al., 2023a)	0.557
	Qwen2-Audio (Chu et al., 2024a)	0.553
	Qwen2.5-Omni-7B	<b>0.570</b>
<i>VSC</i>		
VocalSound	CLAP (Elizalde et al., 2022)	0.495
	Pengi (Deshmukh et al., 2023)	0.604
	Qwen-Audio (Chu et al., 2023a)	0.929
	Qwen2-Audio (Chu et al., 2024a)	<b>0.939</b>
	Qwen2.5-Omni-7B	<b>0.939</b>
<i>Music</i>		
GiantSteps Tempo	LLark-7B (Gardner et al., 2023)	0.86
	Qwen2.5-Omni-7B	<b>0.88</b>
MusicCaps	LP-MusicCaps (Doh et al., 2023)	0.291   0.149   0.089   <b>0.061</b>   <b>0.129</b>   0.130
	Qwen2.5-Omni-7B	<b>0.328</b>   <b>0.162</b>   <b>0.090</b>   0.055   0.127   <b>0.225</b>