

Séminaire LIS

Titre : End-to-end model for named entity recognition from speech without paired training data



Salima Mdhaffar

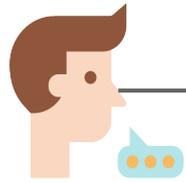
Post-doc au Laboratoire d'Informatique d'Avignon (LIA)

- **Avancements significatives en traitement automatique de la parole**
 - Architecture neuronale de bout en bout
 - Apprentissage auto-supervisée
 - Existence d'une large quantité de données

- **Avancements significatives en traitement automatique de la parole**
 - Architecture neuronale de bout en bout
 - Apprentissage auto-supervisée
 - Existence d'une large quantité de données
- **Reconnaissance d'entités nommées**
 - Tâche de la compréhension de la parole
 - Détecter les entités nommées dans la parole
 - **Entité nommée** : brique élémentaire de l'information contenue dans les documents

<time demain > <organisation rfi > présente le
huitième festival de jazz de <location saint louis > au
<location sénégal >

Approche cascade



Speech

Reconnaissance
automatique de la
parole

demain rfi
présente le
huitième festival
de jazz de saint
louis au sénégal

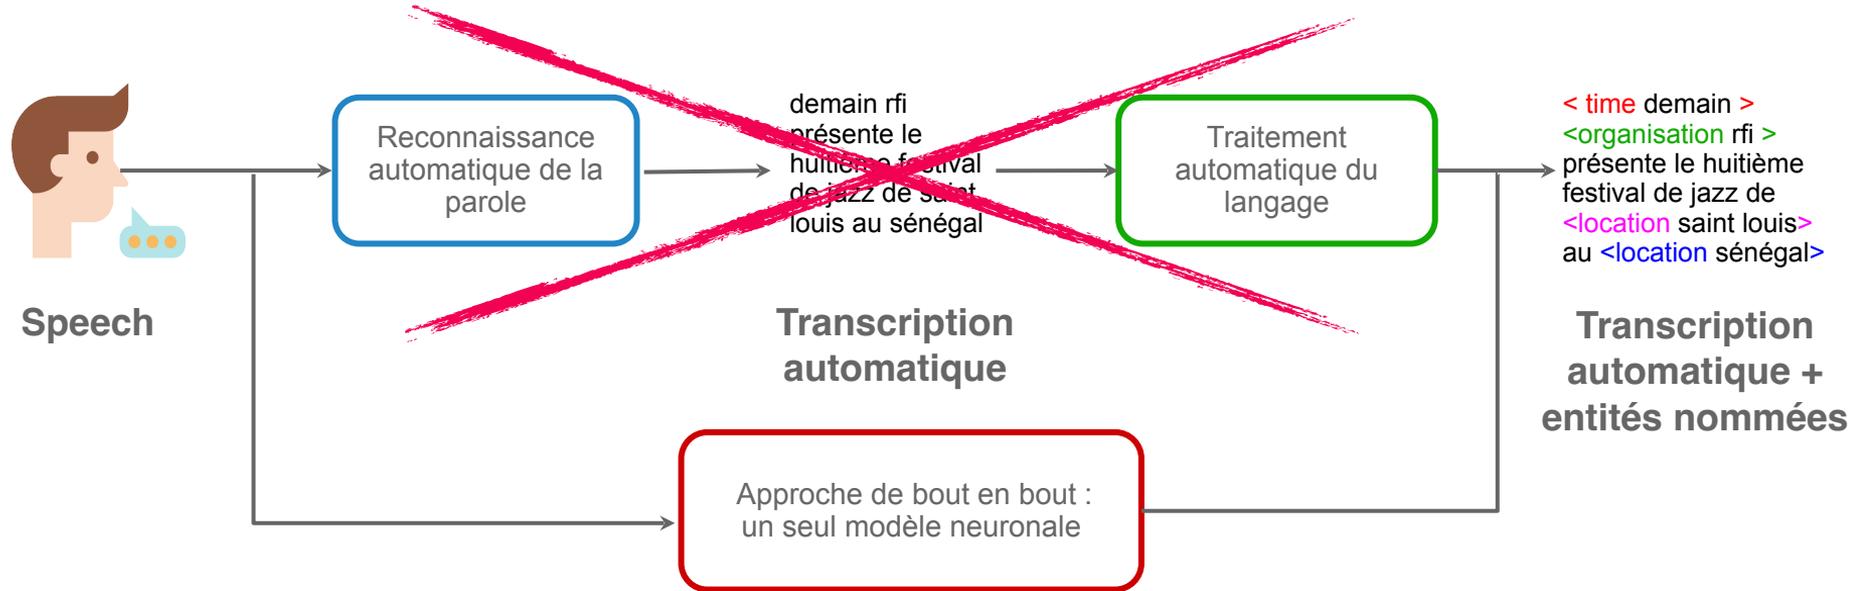
Transcription
automatique

Traitement
automatique du
langage

< time demain >
<organisation rfi >
présente le huitième
festival de jazz de
<location saint louis >
au <location sénégal >

Transcription
automatique +
entités nommées

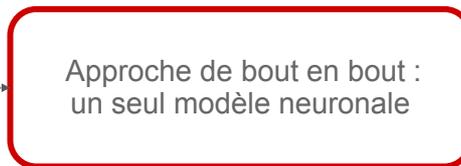
Approche bout en bout



Approche bout en bout

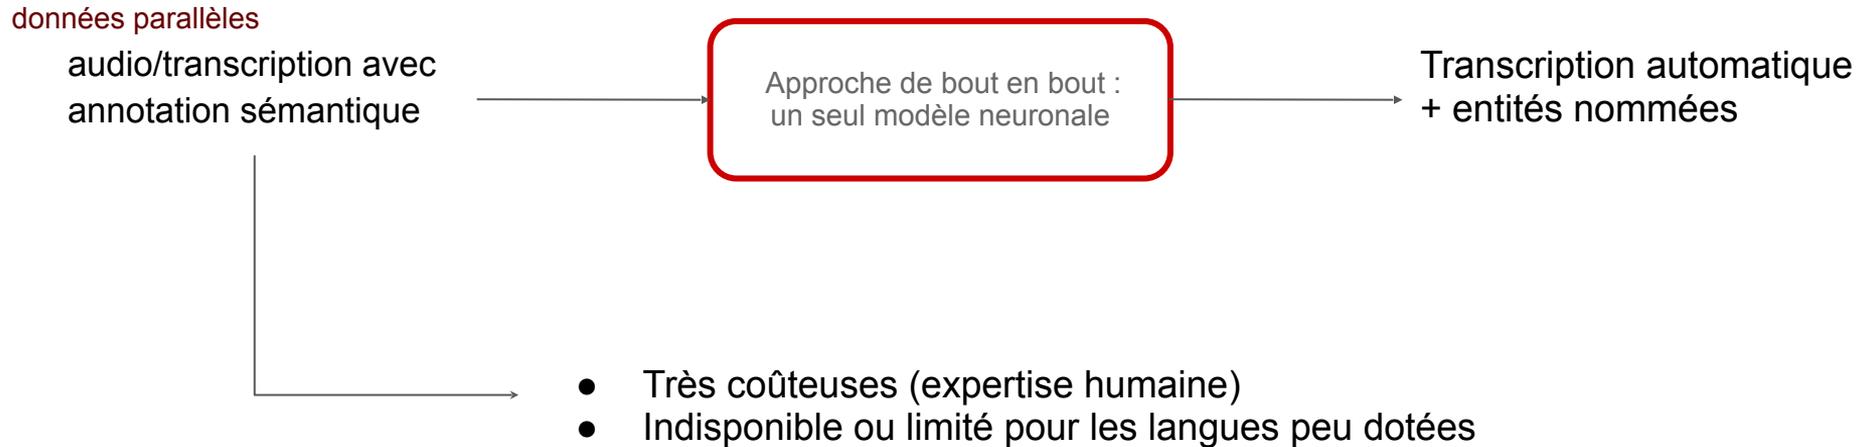
données parallèles

audio/transcription avec
annotation sémantique



Transcription automatique
+ entités nommées

Approche bout en bout



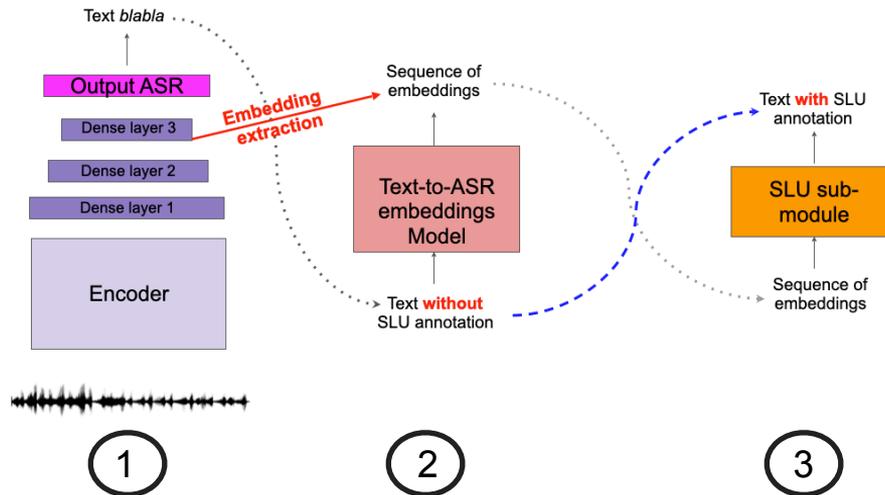


Proposer une approche neuronale de bout en bout pour construire un modèle permettant l'extraction sémantique pour un scénario où **zéro données parallèles** (audio/transcription avec annotation sémantique) est disponible.

Approche proposée

L'approche proposée est composé de trois modèles :

1. Modèle Text-to-ASR Embeddings
2. Modèle SLU
3. Modèle final

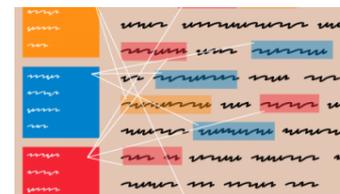
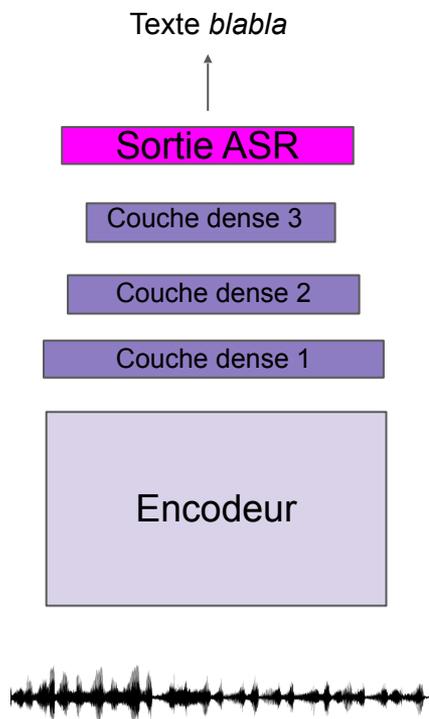


Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale



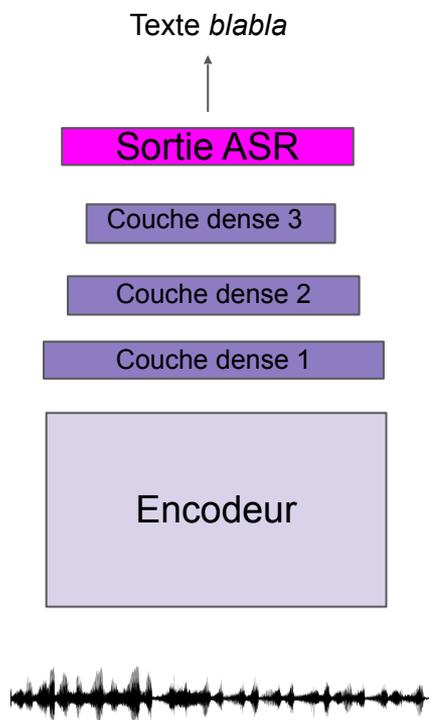
Données textuelles
avec annotation en
entités nommées

Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale

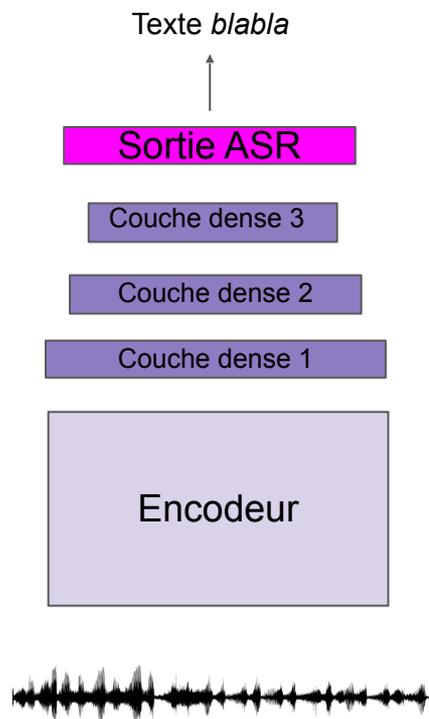


Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale



Modèle
Text-to-ASR
embeddings

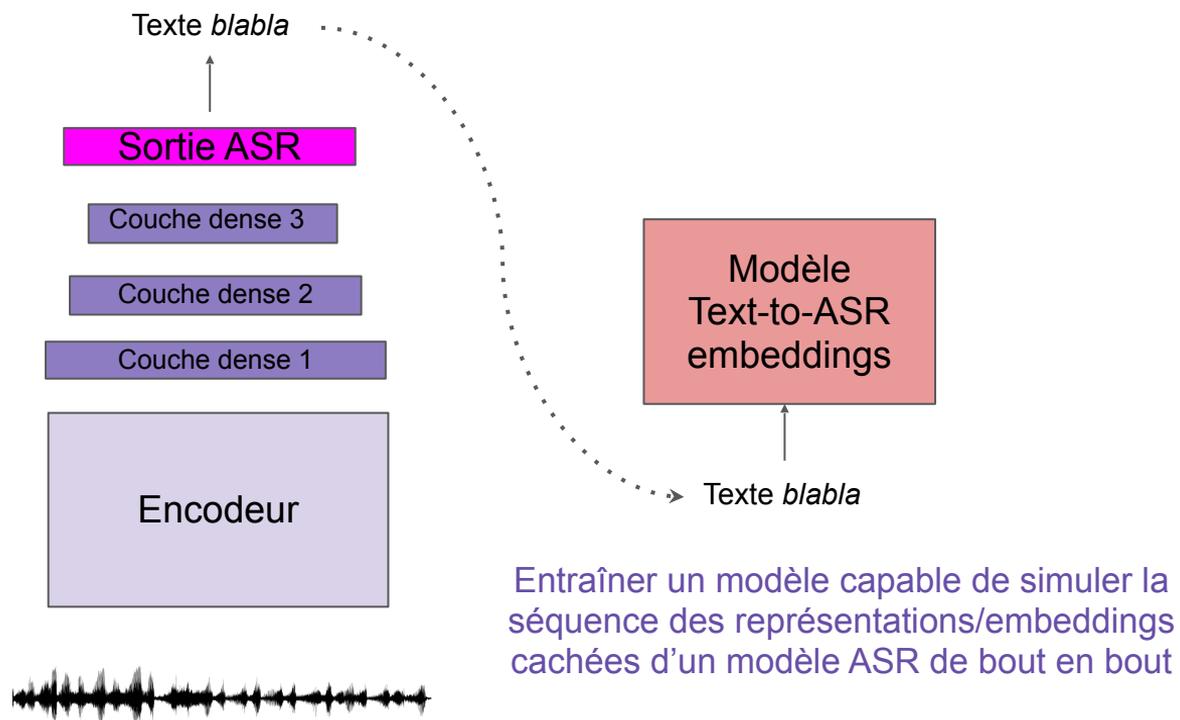
Entraîner un modèle capable de simuler la
séquence des représentations/embeddings
cachées d'un modèle ASR de bout en bout

Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale

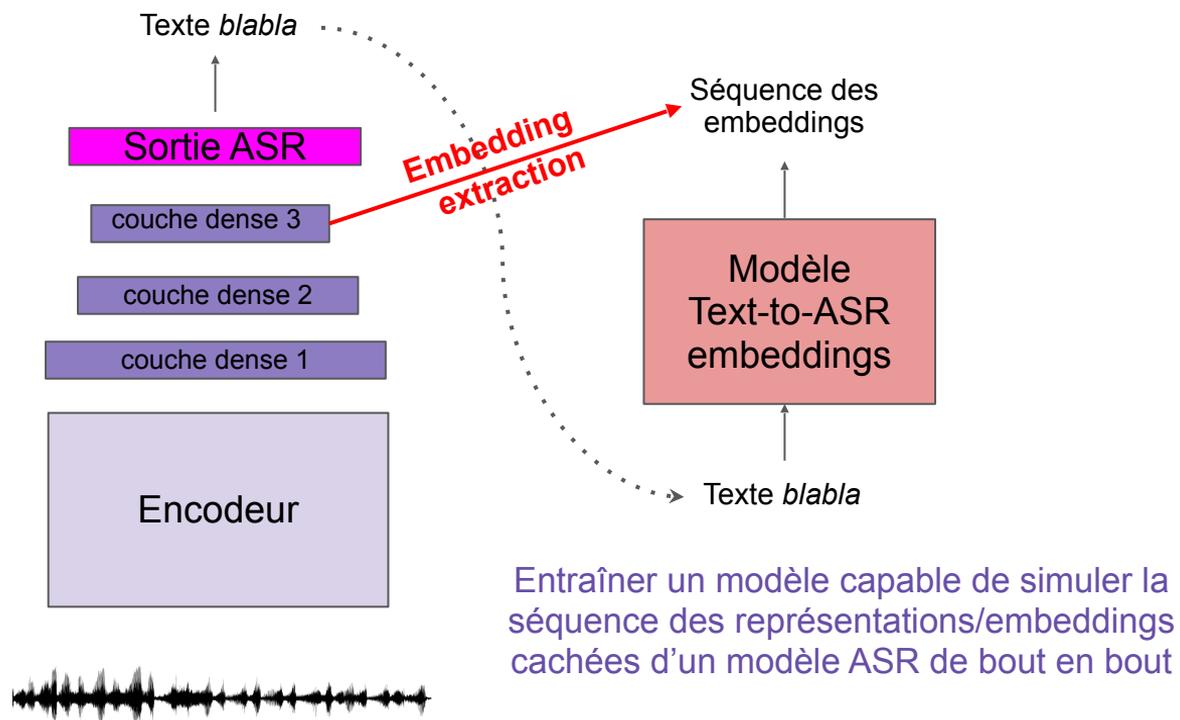


Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale



Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale



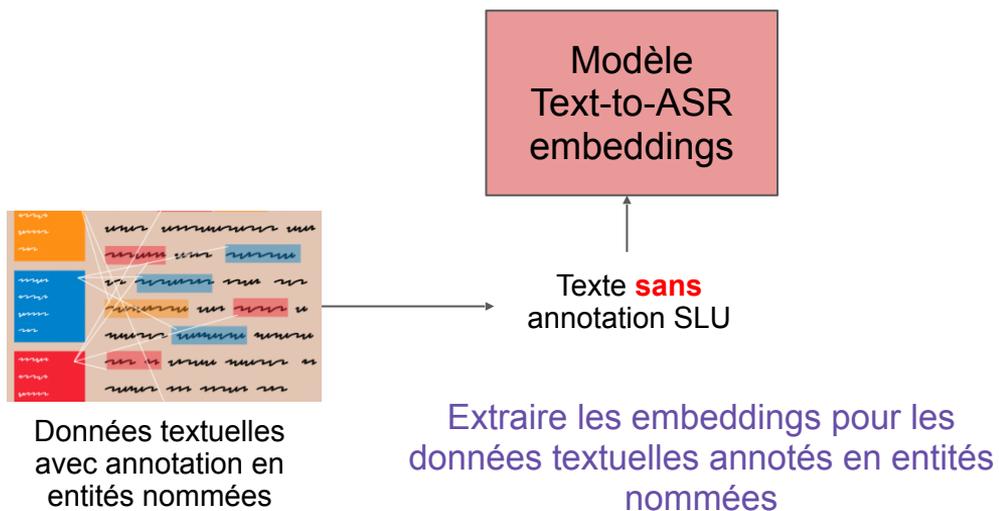
Données textuelles
avec annotation en
entités nommées

Approche proposée

1. text-to-ASR embeddings

2. **Modèle SLU**

3. Modèle finale

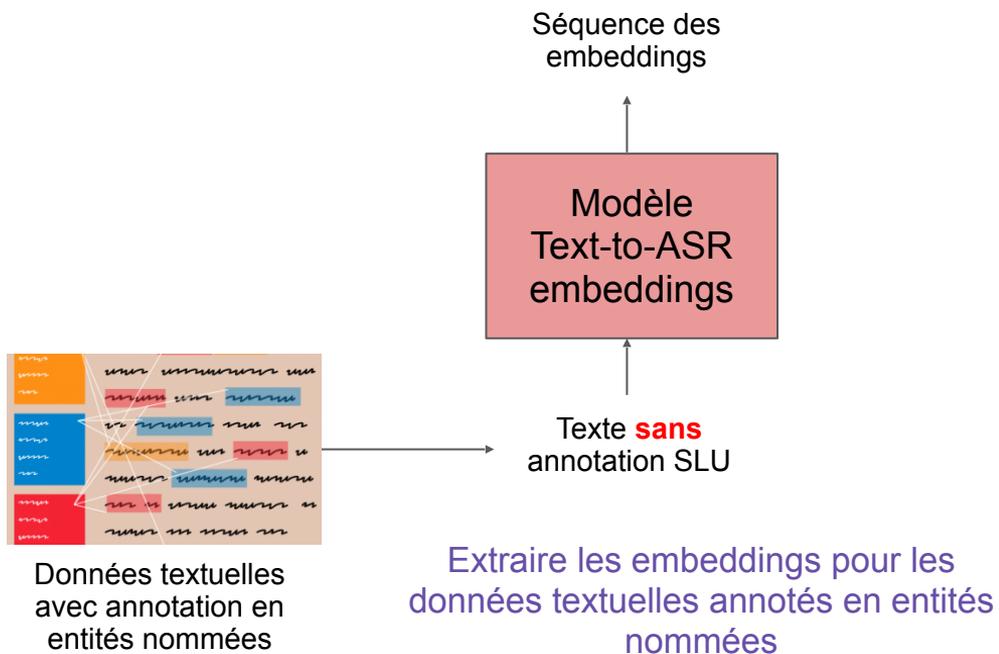


Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale

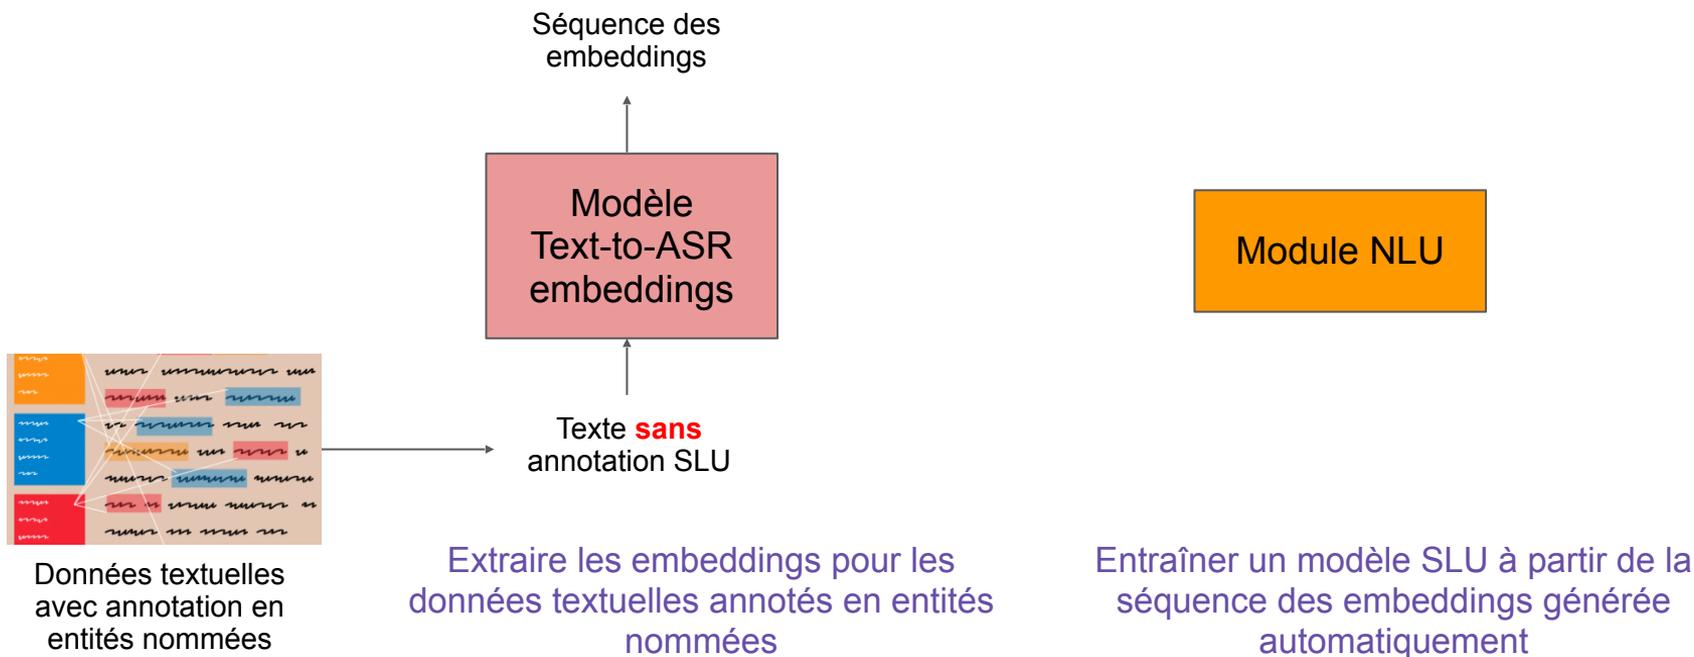


Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale

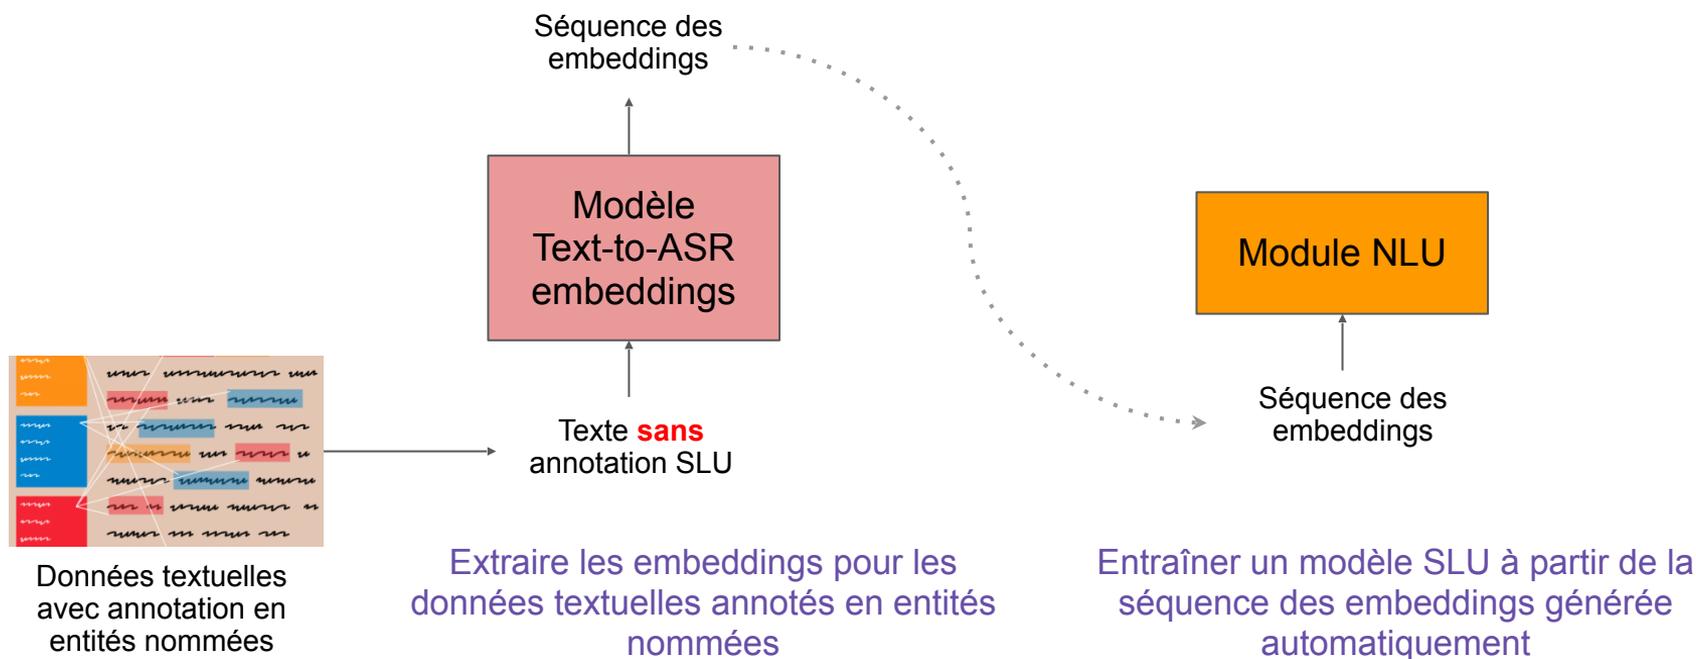


Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale

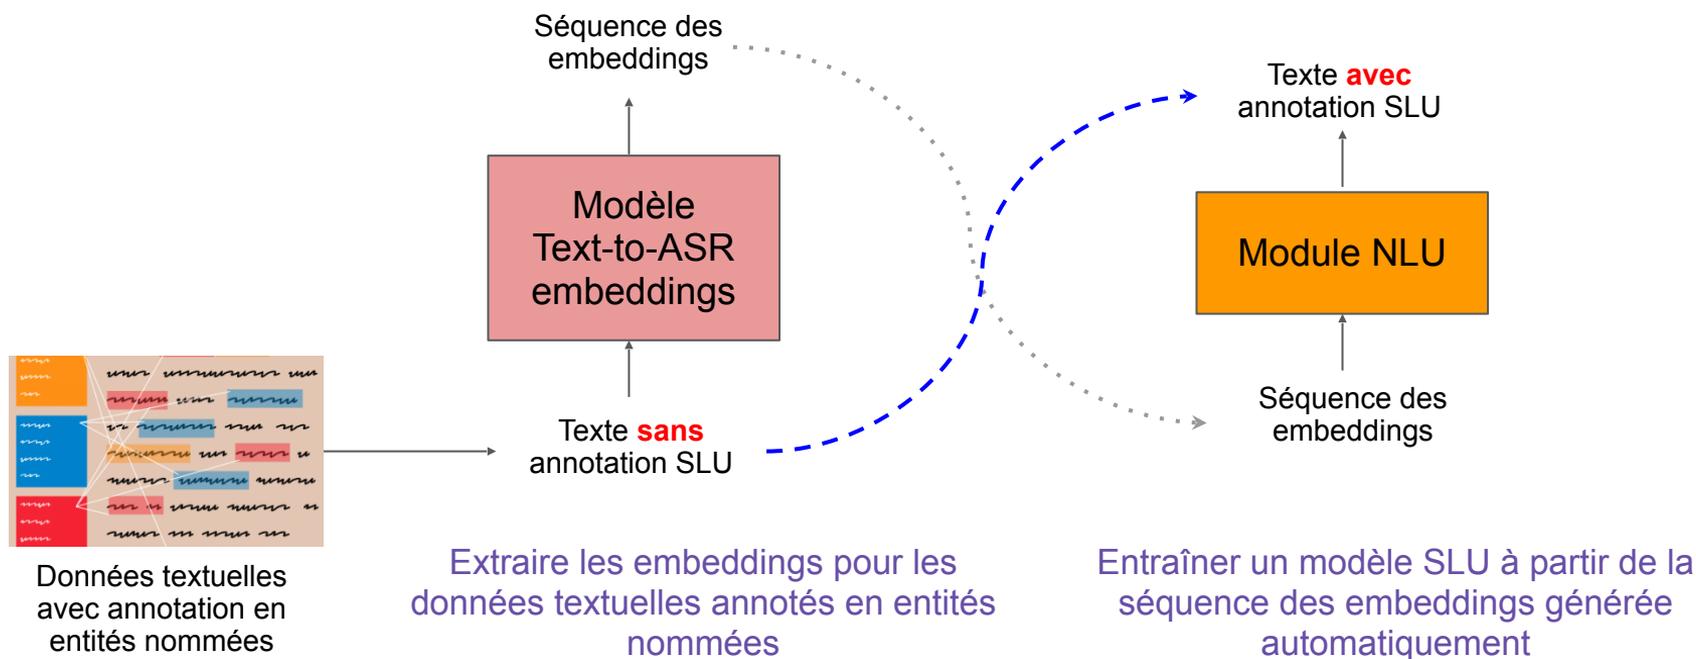


Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale

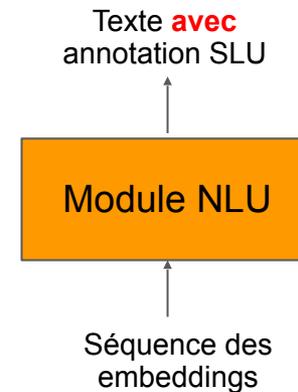
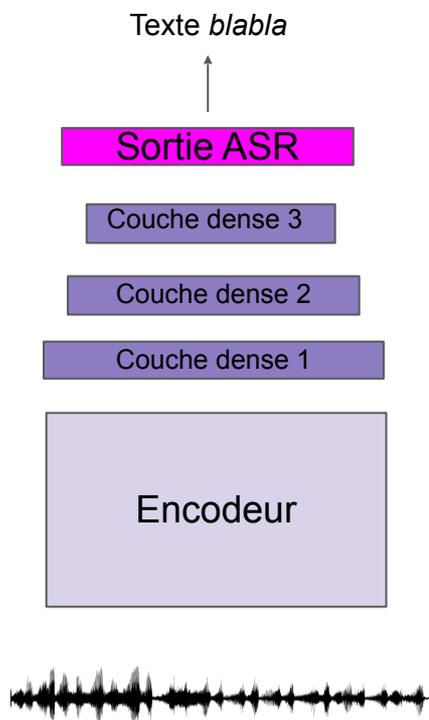


Approche proposée

1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale

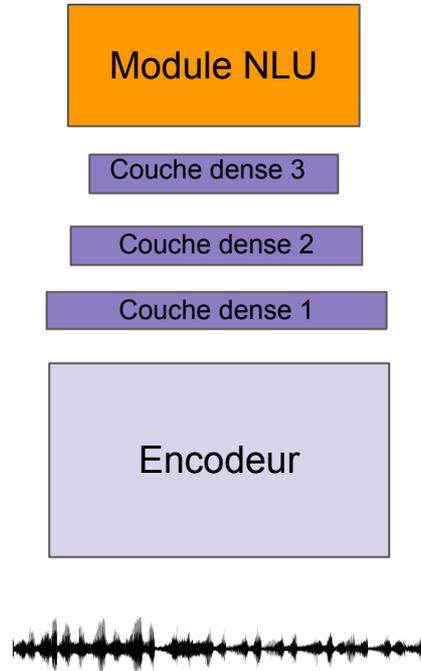


Approche proposée

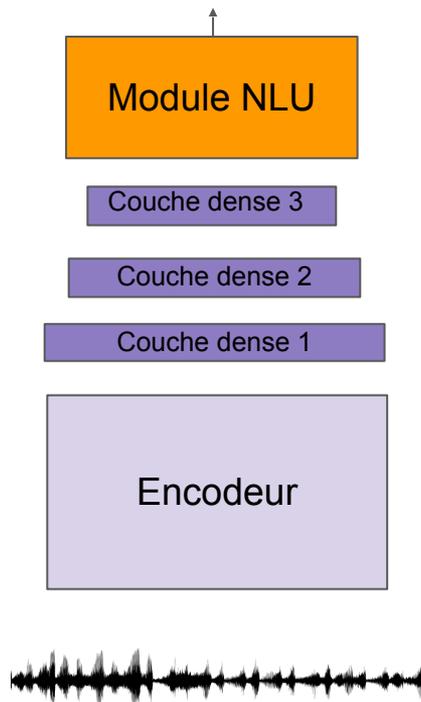
1. text-to-ASR embeddings

2. Modèle SLU

3. Modèle finale



Transcription automatique avec annotation SLU

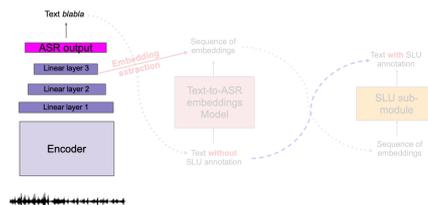


Cadre expérimental : données

1. ASR

2. text-to-ASR embeddings

3. SLU



- Données d'actualités collectés à partir du radio et de la télévision (Français):
 - REPERE [Giraudel et al, 2012] : 35,5 heures
 - ESTER2 [Galliano et al, 2009] : 91 heures
 - EPAC [Grouin et al, 2011] : 70,5 heures

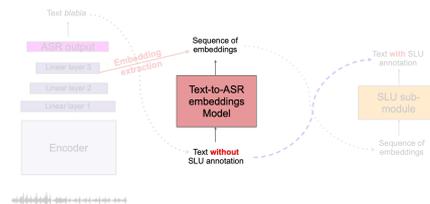
=> total : 197 heures

Cadre expérimental : données

1. ASR

2. text-to-ASR embeddings

3. SLU

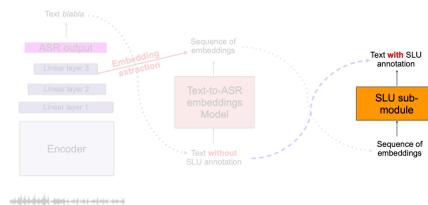


Entrée

Labels

Texte <i>blabla</i>	→	0.6	-0.2	0.8	0.9	-0.1	-0.9	-0.7
Texte <i>blabla</i>	→	0.7	0.3	0.9	-0.7	0.1	-0.5	-0.4
.					.			
.					.			
Texte <i>blabla</i>	→	0.5	-0.4	0.7	0.8	0.9	-0.7	-0.6

- Entrée : transcription automatique pour 197 heures utilisées dans l'apprentissage de l'ASR
 - WER pour la transcription automatique : 7.41%
- Sortie : embeddings pour 197 heures utilisées dans l'apprentissage de l'ASR



- Train : transcription manuelle de QUAERO [Grouin et al, 2011]
 - 7 types d'entités nommés : personne, localisation, organization, produit, temps, quantité et fonction.
 - Exemple :
 - demain rfi présente le huitième festival de jazz de saint louis au sénégál
 - <time demain > <organisation rfi > présente le huitième festival de jazz de <location saint louis > au <location sénégál >

- Dev & test : audio / transcription avec annotation sémantique

Data	# mots	# vocab	# Concepts	# Utterance	# Heures
Train	993.7k	33.5k	89.6k	90.3k	81h
Dev	81.5k	8.7k	5.5k	10.9k	6.5h
Test	119.3k	13.4k	10.8k	4.0k	10h

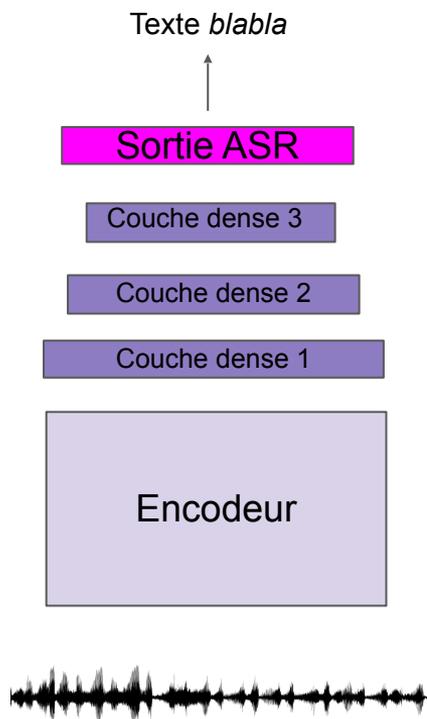
Statistiques des données QUAERO

Cadre expérimental : architecture

1. ASR

2. text-to-ASR embeddings

3. SLU



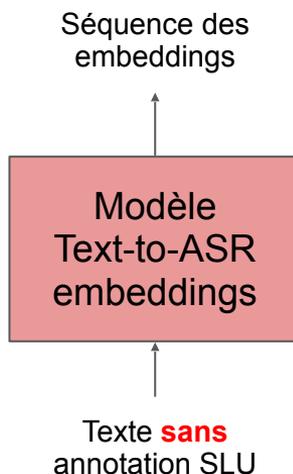
- Encodeur : wav2vec 2.0 LeBenchmark [\[Evain et al, 2021\]](#)
- Couches dense:
 - Couche dense 1 : 1024
 - Couche dense 2 : 512
 - Couche dense 3 : 80
- Sortie ASR : taille 47 / fonction du loss : ctc

Cadre expérimental : architecture

1. ASR

2. text-to-ASR embeddings

3. SLU



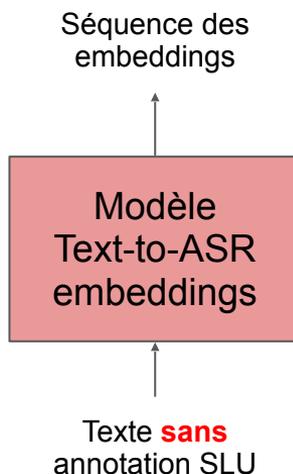
- basé sur l'architecture Tacotron 2 [Shen et al, 2018]
 - module qui transforme les embeddings de caractères en des spectrogrammes
 - vocodeur qui transforme les spectrogrammes en fichier audio

Cadre expérimental : architecture

1. ASR

2. text-to-ASR embeddings

3. SLU



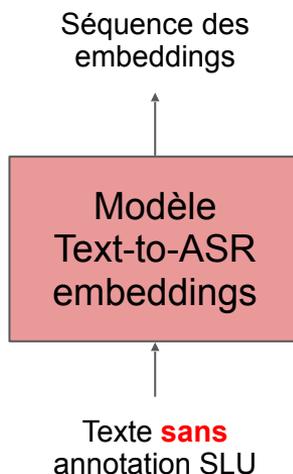
- basé sur l'architecture Tacotron 2 [Shen et al, 2018]
 - **module qui transforme les embeddings de caractères en des spectrogrammes**
 - vocodeur qui transforme les spectrogrammes en fichier audio

Cadre expérimental : architecture

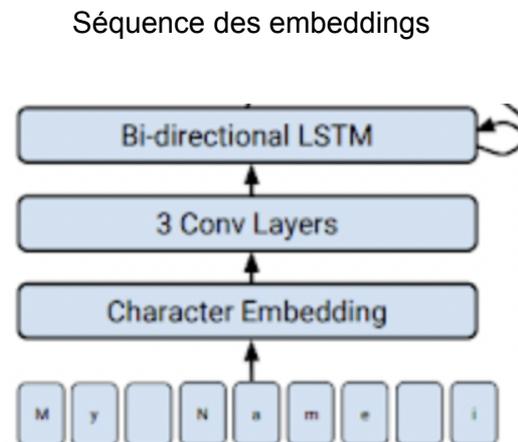
1. ASR

2. text-to-ASR embeddings

3. SLU



- basé sur l'architecture Tacotron 2 [Shen et al, 2018]
 - **module qui transforme les embeddings de caractères en des spectrogrammes**
 - vocodeur qui transforme les spectrogrammes en fichier audio

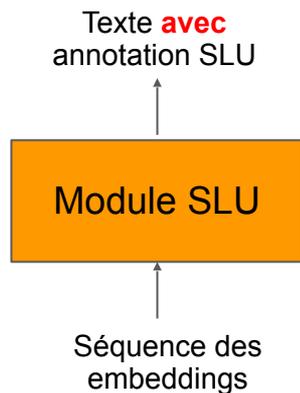


Cadre expérimental : architecture

1. ASR

2. text-to-ASR embeddings

3. SLU



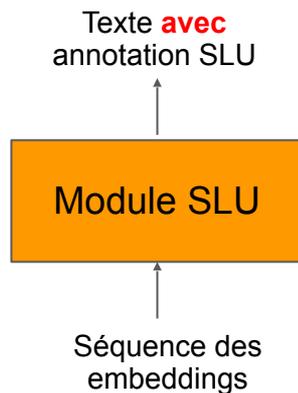
- BiLSTM architecture:
 - 5 stack of BiLSTM couches
 - Dimension : 512
- Sortie : taille de softmax = 54 (47 ASR + 7 entities)

Cadre expérimental : architecture

1. ASR

2. text-to-ASR embeddings

3. SLU



- BiLSTM architecture:
 - 5 stack of BiLSTM couches
 - Dimension : 512
- Sortie : taille de softmax = 54 (47 ASR + 7 entities)

A	personne
B	organisation
.	fonction
.	localisation
.	produit
.	temps
Z	quantité

Results

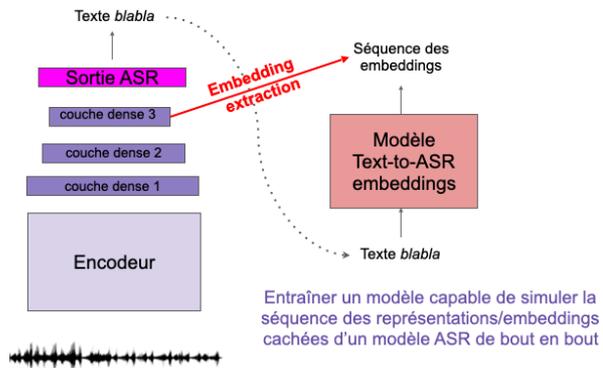
1. NER evaluation

2. NER with generated embeddings

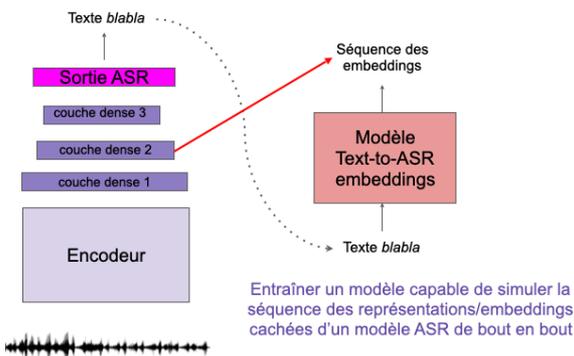
3. Cascade NER

- Évaluation de la qualité reconnaissance de la parole en utilisant les embeddings générés
 - (1) Apprendre des modèles Text-to-Embeddings à partir de différentes couches

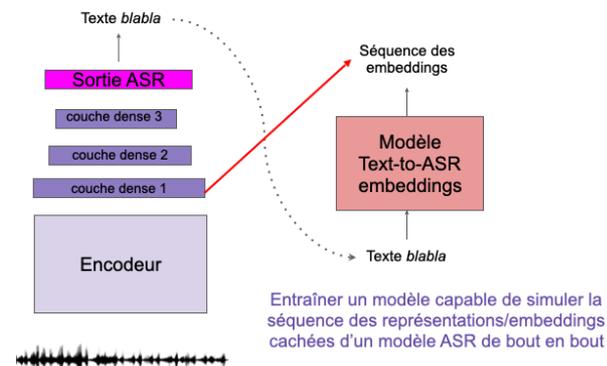
Couche dense 3



Couche dense 2



Couche dense 1



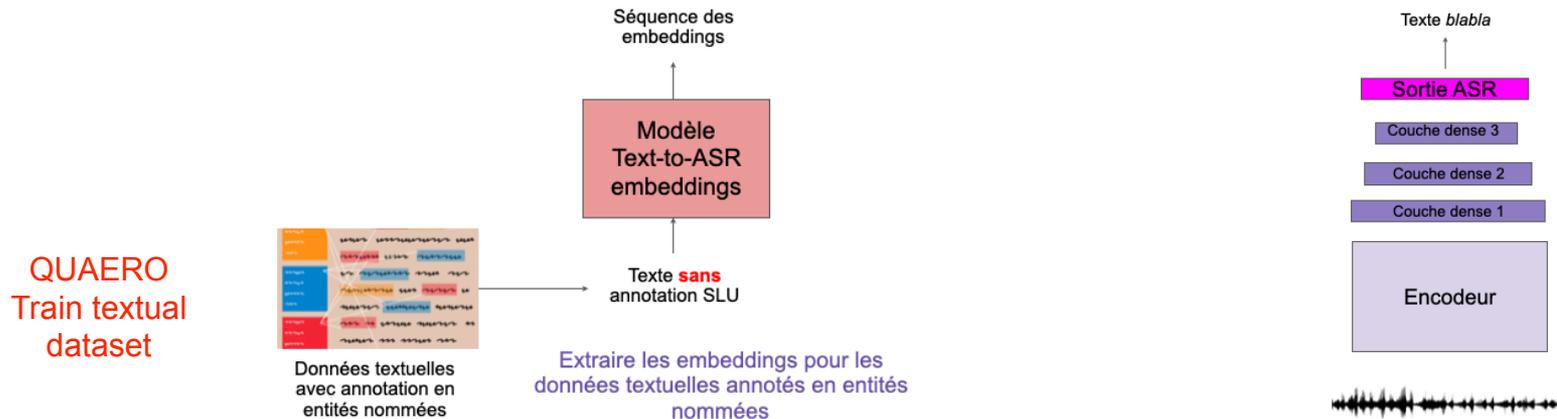
Results

1. NER evaluation

2. NER with generated embeddings

3. Cascade NER

- Évaluation de la qualité reconnaissance de la parole en utilisant les embeddings générés
 - (1) Apprendre des modèles Text-to-Embeddings à partir de différentes couches
 - (2) Pour chaque modèle, générer des embeddings avec les modèles appris et remplacer la couche ciblée avec embeddings générés (en inférence)



Results

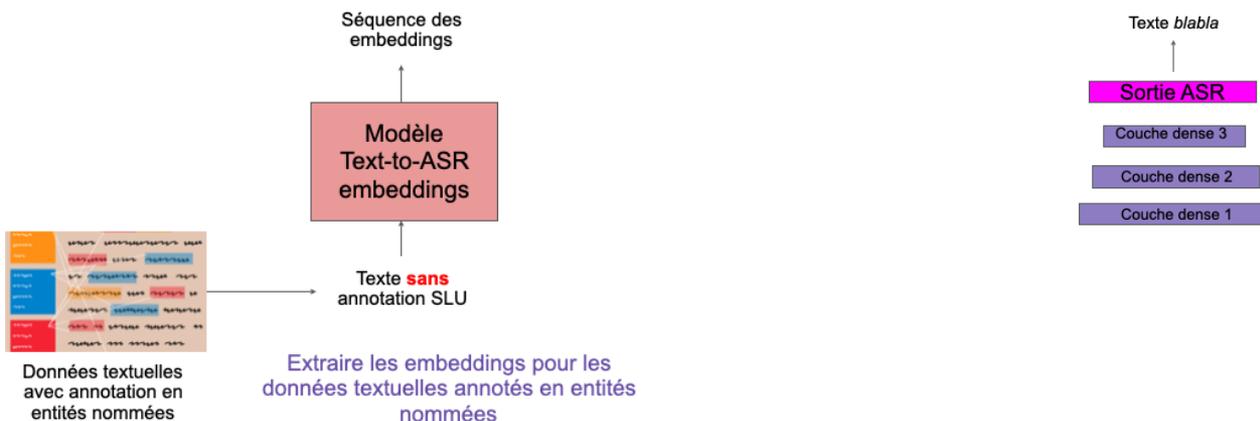
1. NER evaluation

2. NER with generated embeddings

3. Cascade NER

- Évaluation de la qualité reconnaissance de la parole en utilisant les embeddings générés
 - (1) Apprendre des modèles Text-to-Embeddings à partir de différentes couches
 - (2) Pour chaque modèle, générer des embeddings avec les modèles appris et remplacer la couche ciblée avec embeddings générés (en inférence)

QUAERO
Train textual
dataset



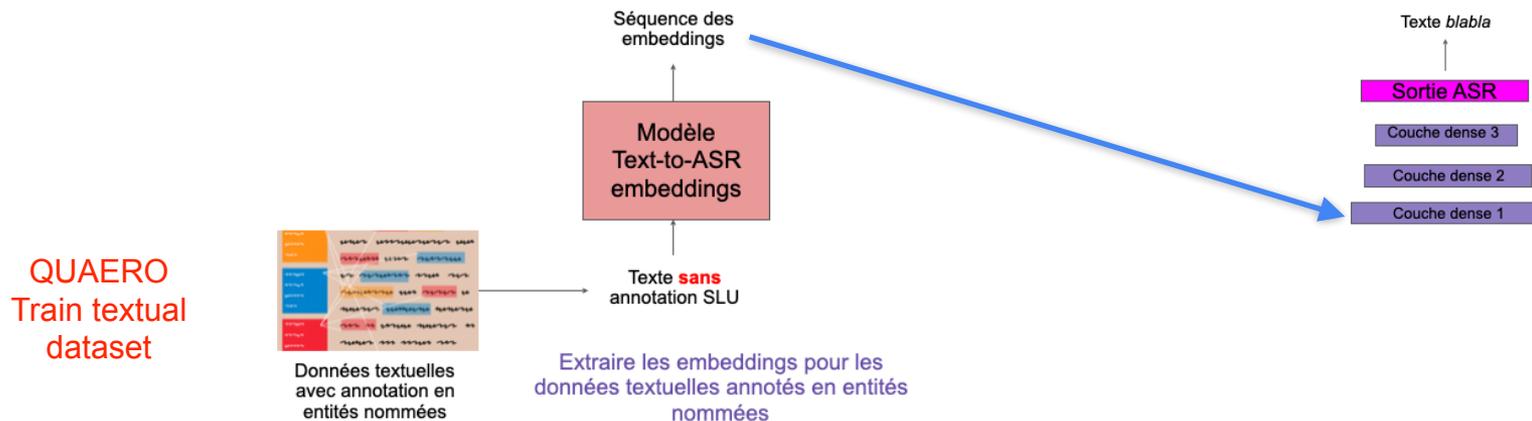
Results

1. NER evaluation

2. NER with generated embeddings

3. Cascade NER

- Évaluation de la qualité reconnaissance de la parole en utilisant les embeddings générés
 - (1) Apprendre des modèles Text-to-Embeddings à partir de différentes couches
 - (2) Pour chaque modèle, générer des embeddings avec les modèles appris et remplacer la couche ciblée avec embeddings générés (en inférence)



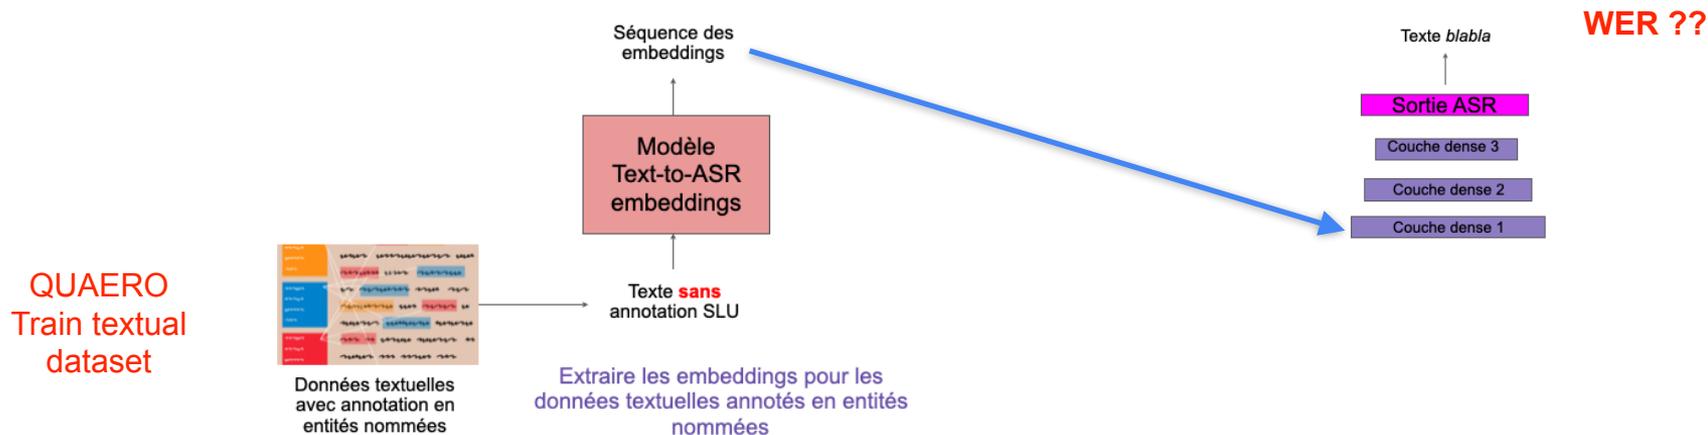
Results

1. NER evaluation

2. NER with generated embeddings

3. Cascade NER

- Évaluation de la qualité reconnaissance de la parole en utilisant les embeddings générés
 - (1) Apprendre des modèles Text-to-Embeddings à partir de différentes couches
 - (2) Pour chaque modèle, générer des embeddings avec les modèles appris et remplacer la couche ciblée avec embeddings générés (en inférence)
 - (3) Calculer un WER



- Évaluation de la qualité reconnaissance de la parole en utilisant les embeddings générés
 - (1) Apprendre des modèles Text-to-Embeddings à partir de différentes couches
 - (2) Pour chaque modèle, générer des embeddings avec les modèles appris et remplacer la couche ciblée avec embeddings générés (en inférence)
 - (3) Calculer un WER

	Layer 1	Layer 2	Layer 3	Wav QUAERO
WER	80,29 %	56,68 %	15,56 %	9,08 %

WER pour les embeddings générés sur les données de train QUAERO

- **Métrique d'évaluation:**
 - **NEER: N**amed **E**ntity **E**rror **R**ate

$$\text{NEER} = \frac{S + D + I}{n}$$

- S: Nombre d'erreurs de substitution
- D: Nombre d'erreurs de suppression
- I: Nombre d'erreurs d'insertion
- n: Nombre de références

- **Métrique d'évaluation:**
 - **NEER: Named Entity Error Rate**

$$\text{NEER} = \frac{S + D + I}{n}$$

S: Nombre d'erreurs de substitution
D: Nombre d'erreurs de suppression
I: Nombre d'erreurs d'insertion
n: Nombre de références

Référence: < time demain > <organisation rfi > présente le huitième festival de jazz de <location saint louis> au <location sénégal>
Hypothèse: < time demain > <organisation rfi > présente le huitième festival de jazz de <person saint louis> au sénégal

NEER evaluation:

Référence: <time> <organisation> <location> <location>

Hypothèse: <time> <organisation> <person>

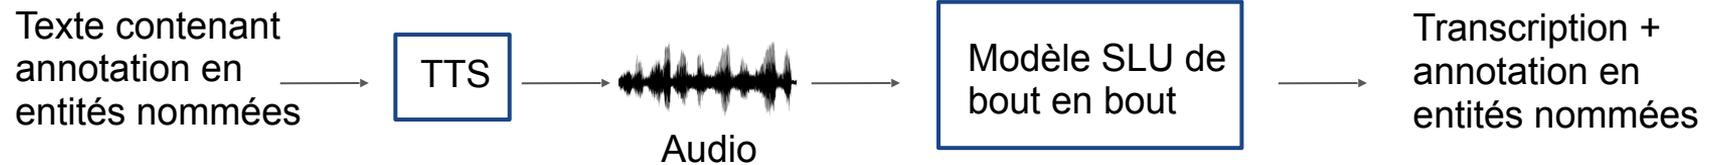
= = S D

NEER = 2/4 = 0.5

Données d'apprentissage	Dev NEER	Test NEER
ASR embeddings simulation (ours)	47,6 %	39,1 %
Oracle (real data)	45,9 %	34,1 %

Évaluation du modèle end-to-end NER sans des données d'apprentissage parallèles en comparaison avec une approche miracle où des données parallèles sont disponibles

Comparer l'approche proposée avec un système appris la voix synthétique :



	Wav TTS	Wav QUAERO
WER	21,60 %	9,08 %

Evaluation des données train QUAERO générés avec le TTS

Données d'apprentissage	Dev NEER	Test NEER
ASR embeddings simulation (ours)	47,6 %	39,1 %
Synthetic speech (all weights are updated)	65,2 %	62,7 %
Synthetic speech (frozen speech encoder)	86,4 %	92,5 %
Oracle (real data)	45,9 %	34,1 %

Évaluation de l'approche proposée pour entraîner un modèle end-to-end sans des données parallèles en comparaison avec d'autres approches en utilisant de la voix synthétique

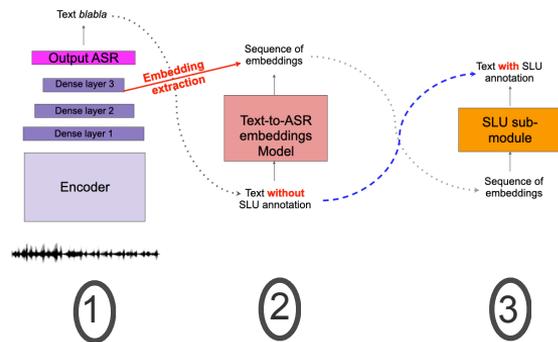
Comparer l'approche proposée avec un système en cascade :

Données d'apprentissage	Dev NEER	Test NEER
ASR embeddings simulation (ours)	47,6 %	39,1 %
Text-to-text NER on manual transcripts	39,6 %	30,0 %
Text-to-text NER on automatic transcripts	48,0 %	40,2 %

Résultats de notre approche en comparaison de en comparaison d'une simple
approche en cascade

Conclusion

- Une approche neuronale de bout en bout pour construire un modèle permettant l'extraction sémantique pour un scénario où zéro données parallèles est disponible.
- L'approche proposée est basée sur:
 - (1) Un modèle extérieur permettant de générer une séquence de représentations vectorielles à partir du texte
 - (2) Un modèle SLU
 - (3) Un modèle final



- Les résultats sont prometteuses et dépassent un simple modèle en cascade et les approches en utilisant de la voix synthétique

Merci pour votre attention



Salima Mdhaffar

<https://sites.google.com/site/salimamedhaffar>

- Post-doc au LIA
- Domaines de recherche:
 - Reconnaissance automatique de la parole
 - Compréhension de la parole
 - Apprentissage auto-supervisée
 - Apprentissage fédéré
- Projets actuels : Européen SELMA, ANR DeepPrivacy, LeBenchmark