

# Architecture Légère de Transformer pour la Reconnaissance d'Écriture Manuscrite

Killian Barrere

10 décembre 2021

Encadré par :

Yann Soullard, Aurélie Lemaitre, Bertrand Coüasnon  
Équipe IntuiDoc, Univ. Rennes, CNRS, IRISA

# État de l'art de la Reconnaissance d'Écriture : des RNN aux Transformers

Approche usuelle : Convolutional Recurrent Neural Networks (CRNN)

- CNN + RNN

⇒ **Mauvaise parallélisation des RNN** qui limite la vitesse d'apprentissage

# État de l'art de la Reconnaissance d'Écriture : des RNN aux Transformers

## Approche usuelle : Convolutional Recurrent Neural Networks (CRNN)

- CNN + RNN

⇒ **Mauvaise parallélisation des RNN** qui limite la vitesse d'apprentissage

## Approches Fully Convolutional Networks

- Composés majoritairement de CNN
- Pas de RNN

⇒ **Difficile d'apprendre des dépendances contextuelles larges**

# État de l'art de la Reconnaissance d'Écriture : des RNN aux Transformers

## Approche usuelle : Convolutional Recurrent Neural Networks (CRNN)

- CNN + RNN

⇒ **Mauvaise parallélisation des RNN** qui limite la vitesse d'apprentissage

## Approches Fully Convolutional Networks

- Composés majoritairement de CNN
- Pas de RNN

⇒ **Difficile d'apprendre des dépendances contextuelles larges**

## Couches Transformer / Attention à têtes multiples

- Capable d'apprendre des **dépendances contextuelles larges** et **parallélisable**


⇒ **Besoin de beaucoup de données** pour obtenir des résultats convenables

## Thématiques abordées :

**But** : Reconnaissance de textes manuscrits anciens

# Thématiques abordées :

**But** : Reconnaissance de textes manuscrits anciens  $\Rightarrow$   
Transformers : Modélisation de la langue (LM)




[Vaswani et al., 2017]

# Thématiques abordées :

**But :** Reconnaissance de textes manuscrits anciens  $\Rightarrow$   
Transformers : Modélisation de la langue (LM)

**Idée :** Modèle basé sur un Transformer :

- Reco. optique + Modélisation de la langue
- S'entraîne de manière **“end-to-end”**



[Vaswani et al., 2017]


# Thématiques abordées :

**But** : Reconnaissance de textes manuscrits anciens  $\Rightarrow$   
Transformers : Modélisation de la langue (LM)

**Idée** : Modèle basé sur un Transformer :

- Reco. optique + Modélisation de la langue
- S'entraîne de manière "**end-to-end**"

**Problème** : Besoin de beaucoup de données



[Vaswani et al., 2017]

# Thématiques abordées :

**But** : Reconnaissance de textes manuscrits anciens  $\Rightarrow$   
Transformers : Modélisation de la langue (LM)


**Idée** : Modèle basé sur un Transformer :

- Reco. optique + Modélisation de la langue
- S'entraîne de manière "**end-to-end**"

**Problème** : Besoin de beaucoup de données


Architecture basée Transformer proposée :

- Architecture **légère**
- Utilisant une **loss hybride**




[Vaswani et al., 2017]


# Du CRNN vers mon Architecture




# Du CRNN vers mon Architecture




# Du CRNN vers mon Architecture




# Du CRNN vers mon Architecture



# Du CRNN vers mon Architecture




# Du CRNN vers mon Architecture




# Du CRNN vers mon Architecture


## Encoder




# Du CRNN vers mon Architecture



# Du CRNN vers mon Architecture



# Du CRNN vers mon Architecture




# Comparaison de l'influence de la taille


## But de l'expérience

On compare :

- La même architecture
- Avec **différentes tailles**
  - **Modèle léger : 7.7M paramètres**
  - **Modèle lourd : 29.9M paramètres**
- Sur IAM (Anglais Moderne)




# Loss Hybride



## Loss Hybride [Michael et al., 2019] (Inspirée des réseaux Denses)

- Connectionist Temporal Classification (CTC) pour l'Encoder
- Cross Entropy (CE) pour le Decoder

# Loss Hybride




$$\mathcal{L} = \lambda \cdot \mathcal{L}_{CTC} + (1 - \lambda) \cdot \mathcal{L}_{CE}$$
$$\lambda = 0.5$$

Loss Hybride [Michael et al., 2019] (Inspirée des réseaux Denses)

- Connectionist Temporal Classification (CTC) pour l'Encoder
- Cross Entropy (CE) pour le Decoder

# Loss Hybride



$$\mathcal{L} = \lambda \cdot \mathcal{L}_{CTC} + (1 - \lambda) \cdot \mathcal{L}_{CE}$$
$$\lambda = 0.5$$

## Loss Hybride [Michael et al., 2019] (Inspirée des réseaux Denses)

- Connectionist Temporal Classification (CTC) pour l'Encoder
- Cross Entropy (CE) pour le Decoder

## Intérêt

- Aider l'entraînement des couches plus profondes
- Convergence beaucoup plus rapide


⇒ **Amélioration des résultats**

# Comparaison des fonctions de coûts

## But de l'expérience

On étudie :

- La même architecture (mon Transformer léger)
- **L'intérêt de la loss hybride**
- Sur IAM (Anglais Moderne)



Model	Validation		Test	
	CER	WER	CER	WER
CE seule	7.89	22.36	10.29	26.36
Hybride (CTC + CE)	4.11	15.27	5.70	18.86

# Comparaison à l'État de l'art sur IAM

Model Encoder	# params.	Additional information	Test	
			CER	WER
CRNN + LSTM [Michael et al., 2019]			5.24	
FCN [Yousef et al., 2020]	3.4M		<b>4.9</b>	
VAN (line level) [Coquenot et al., 2020]	1.7M		4.95	16.24
Transformer [Kang et al., 2020]	100M	-	7.62	24.54
		synth. data	4.67	<b>15.45</b>
FPHR Transformer [Singh et al., 2021]	28M	synth. data	6.5	
Bidi. Transformer [Wick et al., 2021]			5.67	
<b>Our Transformer-based</b>	<b>7.7M</b>		<b>5.70</b>	<b>18.86</b>

# Comparaison à l'État de l'art sur IAM

Model Encoder	# params.	Additional information	Test	
			CER	WER
CRNN + LSTM [Michael et al., 2019]			5.24	
FCN [Yousef et al., 2020]	3.4M		<b>4.9</b>	
VAN (line level) [Coquenot et al., 2020]	1.7M		4.95	16.24
Transformer [Kang et al., 2020]	100M	- synth. data	7.62 4.67	24.54 <b>15.45</b>
FPHR Transformer [Singh et al., 2021]	28M	synth. data	6.5	
Bidi. Transformer [Wick et al., 2021]			5.67	
<b>Our Transformer-based</b>	<b>7.7M</b>		<b>5.70</b>	<b>18.86</b>

# Comparaison à l'État de l'art sur IAM

Model Encoder	# params.	Additional information	Test	
			CER	WER
CRNN + LSTM [Michael et al., 2019]			5.24	
FCN [Yousef et al., 2020]	3.4M		<b>4.9</b>	
VAN (line level) [Coquenot et al., 2020]	1.7M		4.95	16.24
Transformer [Kang et al., 2020]	100M	-	7.62	24.54
		synth. data	4.67	<b>15.45</b>
FPHR Transformer [Singh et al., 2021]	28M	synth. data	6.5	
Bidi. Transformer [Wick et al., 2021]			5.67	
<b>Our Transformer-based</b>	<b>7.7M</b>		<b>5.70</b>	<b>18.86</b>

# Comparaison à l'État de l'art sur IAM

Model Encoder	# params.	Additional information	Test	
			CER	WER
CRNN + LSTM [Michael et al., 2019]			5.24	
FCN [Yousef et al., 2020]	3.4M		<b>4.9</b>	
VAN (line level) [Coquenot et al., 2020]	1.7M		4.95	16.24
Transformer [Kang et al., 2020]	100M	- synth. data	7.62 4.67	24.54 <b>15.45</b>
FPHR Transformer [Singh et al., 2021]	28M	synth. data	6.5	
Bidi. Transformer [Wick et al., 2021]			5.67	
<b>Our Transformer-based</b>	<b>7.7M</b>		<b>5.70</b>	<b>18.86</b>

# Conclusion

- **Architecture de Transformer légère**, peu coûteuse  
⇒ Plus rapide à entraîner que les autres Transformers
- Entraînée avec une **loss Hybride** pour améliorer les performances
- **Des résultats corrects** sans données ajoutées  
⇒ De la marge de progression

# Conclusion

- **Architecture de Transformer légère**, peu coûteuse  
⇒ Plus rapide à entraîner que les autres Transformers
- Entraînée avec une **loss Hybride** pour améliorer les performances
- **Des résultats corrects** sans données ajoutées  
⇒ De la marge de progression

- Le modèle semble sur-apprendre  
⇒ Besoin de **plus de données** pour obtenir de meilleurs résultats  
⇒ Besoin de plus de techniques de **régularisation**

# Travaux futurs

## Documents anciens

- Capacité de **modélisation de langue** des transformers cruciale pour de l'ancien
- **Très peu de données annotées** ⇒ Intérêt d'utiliser une petite architecture


# Travaux futurs

## Documents anciens

- Capacité de **modélisation de langue** des transformers cruciale pour de l'ancien
- **Très peu de données annotées** ⇒ Intérêt d'utiliser une petite architecture


## Besoin de plus de données ?

- **Génération de données synthétiques**  
⇒ Premiers résultats encourageants



# A l'entrainement : Decoding en parallèle et Teacher Forcing


A MOVE to stop Mr. Gaitskell from  
 <sos>A MOVE to stop Mr. Gaitskell from



# A l'inférence : Decoding séquentiel

A MOVE to stop Mr. Gaitskell from

Decoding  
Séquentiel



# CER and WER

## Definition

- CER: Character Error Rate
- WER: Word Error Rate
- Edit distance between prediction and groundtruth

$$CER = \frac{I+D+S}{N}$$

*I* Number of Insertions

*D* Number of Deletions

*S* Number of Substitutions

*N* Length of the groundtruth