

Analyse et Implémentation d'un Modèle de Deep Learning

Show, *Attend and Tell*

Angelo Bou Tanous, Basile Joret, Hugo Tondenier

Insa Rouen

May 3, 2025

Plan de la présentation

1. Introduction
2. Présentation du papier
3. Implémentation
4. Entraînement et Défis
5. Résultats et Analyse
6. Regard critique et impact sociétal
7. Conclusion

Introduction

Contexte du projet

- ▶ Objectif : étude approfondie d'un modèle de Deep Learning
- ▶ Implémentation d'un article scientifique
- ▶ Analyse des performances et amélioration du modèle

Choix du papier

- ▶ Finance jugée trop complexe et données difficiles à traiter
- ▶ Préférence d'un article de Deep Learning pur

Carte d'identité de l'article

Références

- ▶ **Titre** : Show, Attend and Tell
 - ▶ **Auteurs** : K. Xu et al.
 - ▶ **Conférence** : ICML 2015
 - ▶ **Citations** : 13455+

Visuel

Show, Attend and Tell: Neural Image Caption Generation with Visual Attention

Colvin Xu¹
 Jenny Lei Ba¹
 Ryan Kiteo¹
 KyungHyun Cho¹
 Aaron Courville¹
 Ruslan Salakhutdinov^{1,2}
 Richard S. Zemel¹
 Yoshua Bengio^{1,2}

¹ Université de Montréal, ² University of Toronto, CIFAR

KELVIN.XU@UMONTREAL.CA
JIMMY@PSLUTORONTO.CA
KIRIOS@CS.TORONTO.EDU
KYUNGHEUN.CHO@UMONTREAL.CA
AARON.COURVILLE@UMONTREAL.CA
REALAHOU@CS.TORONTO.EDU
JESSEBL@CS.TORONTO.EDU
YOSHIA.BENGO@UMONTREAL.CA

Abstract

Inspired by recent work in machine translation and object detection, we introduce an attention-based model that automatically learns to focus on the content of images. We describe how one can train this model in a deterministic manner using standard backpropagation techniques and automatically by minimizing a variational loss bound. We also show through visualization that the model is able to automatically learn to focus on salient objects while generating the corresponding words in the output space. We validate the use of attention with state-of-the-art performance on three benchmark datasets: Flickr30k, Flickr8k and MS COCO.

1. Introduction

Automatically generating captions for an image is a task close to the heart of science understanding – one of the primary goals of AI. One of the most important questions that models will be able to solve the computer vision challenges of determining what objects are in an image, but they must also be powerful enough to capture and express their relationships in natural language. For this reason, caption generation has long been seen as a difficult problem. It amounts to mimicking the remarkable human ability to compress huge amounts of salient visual information into descriptive language and is thus an important challenge for machine learning and AI research.

Yet despite the difficult nature of this task, there has been a recent surge of research interest in solving the image caption generation problem. Achieved by advances in image caption neural networks (Krause et al., 2012) and attention mechanisms (Xu et al., 2015; Vaswani et al., 2017), large improvements have been made. In particular, the quality of captions produced using a combination of convolutional neural networks (to extract visual features) and recurrent neural networks to encode the features and generate the final caption has been shown to be state-of-the-art (Vinyals et al., 2015; Xu et al., 2015).

See, 2. One of the main reasons for the success of this approach is that the visual system is the provider of attention (Borod, 2006; Cohen & Shabtai, 2000). Rather than cooperatively, an entire image is static represented, attention allows for static features to dynamically come to the foreground. This is a key mechanism for the ability to identify a cluster of objects in an image. Using representations (such as the very top layer of a network) that is distributed across the image to denote the most salient object is one effective way of achieving this. A mechanism which has been proposed in previous work is the use of loss functions which penalize the information which will be paid for in order to correctly identify the most salient object in an image (Xu et al., 2015).

Contexte et objectif du papier


Problématique

- ▶ Génération automatique de légendes d'images
- ▶ Idée clé : vision + traitement automatique du langage naturel

Approche principale

- ▶ Attention sélective sur régions clés

Architecture du modèle



Architecture globale : encodeur-décodeur

Encodeur CNN

- VGG pré-entraîné
- Carte de caractéristiques $14 \times 14 \times 512$:
 - 196 régions spatiales
 - Vecteurs 512-d

Décodeur LSTM

- Génération mot à mot
- Entrées : mot précédent, état interne, contexte


Mécanisme d'attention

Soft Attention

- ▶ Moyenne pondérée de toutes les régions
- ▶ Tout reste différentiable

Hard Attention

- ▶ Sélection d'une région via échantillonnage
- ▶ Regard plus "précis"



Jeux de données et métriques

Datasets

- ▶ Flickr8k
- ▶ Flickr30k
- ▶ MS COCO

Évaluation

- ▶ Scores BLEU
- ▶ Scores METEOR

| Dataset | Model | BLEU | | | | METEOR |
|-----------|--|-------------|-------------|-------------|-------------|--------------|
| | | BLEU-1 | BLEU-2 | BLEU-3 | BLEU-4 | |
| Flickr8k | Google NIC(Vinyals et al., 2014) $^{\dagger\Sigma}$ | 63 | 41 | 27 | — | — |
| | Log Bilinear (Kiros et al., 2014a) $^{\circ}$ | 65.6 | 42.4 | 27.7 | 17.7 | 17.31 |
| | Soft-Attention | 67 | 44.8 | 29.9 | 19.5 | 18.93 |
| | Hard-Attention | 67 | 45.7 | 31.4 | 21.3 | 20.30 |
| Flickr30k | Google NIC $^{\dagger\Sigma}$ | 66.3 | 42.3 | 27.7 | 18.3 | — |
| | Log Bilinear | 60.0 | 38 | 25.4 | 17.1 | 16.88 |
| | Soft-Attention | 66.7 | 43.4 | 28.8 | 19.1 | 18.49 |
| | Hard-Attention | 66.9 | 43.9 | 29.6 | 19.9 | 18.46 |
| COCO | CMU/MS Research (Chen & Zitnick, 2014) $^{\alpha}$ | — | — | — | — | 20.41 |
| | MS Research (Fang et al., 2014) $^{\dagger\alpha}$ | — | — | — | — | 20.71 |
| | BRNN (Karpathy & Li, 2014) $^{\circ}$ | 64.2 | 45.1 | 30.4 | 20.3 | — |
| | Google NIC $^{\dagger\Sigma}$ | 66.6 | 46.1 | 32.9 | 24.6 | — |
| | Log Bilinear $^{\circ}$ | 70.8 | 48.9 | 34.4 | 24.3 | 20.03 |
| | Soft-Attention | 70.7 | 49.2 | 34.4 | 24.3 | 23.90 |
| | Hard-Attention | 71.8 | 50.4 | 35.7 | 25.0 | 23.04 |

Résultats obtenus par les chercheurs

Datasets et pré-traitement


Choix et justification des jeux de données

- ▶ **Flickr8k** et **Flickr30k** utilisés ; splits de *Karpathy* (2015) pour une comparabilité maximale.
- ▶ **Pas d'entraînement sur MS COCO** : gain certain en BLEU mais **coût temps / énergie** prohibitif au regard des objectifs pédagogiques.
- ▶ Données brutes : chaque image associée à **5 légendes** descriptives.

Datasets et pré-traitement 2

Format et reproductibilité


- ▶ Application des **splits de Karpathy (2015)** (train/val) afin de garantir la comparabilité avec l'étude originale.
- ▶ Génération d'un dataset final :
 - ▶ datasets/train/, datasets/val/
 - ▶ train_captions.json, train_img_paths.json
 - ▶ val_captions.json, val_img_paths.json
 - ▶ word_dict.json (mapping mot → indice)
- ▶ C'est sur ces splits que nous avons entraîné nos modèles, assurant ainsi une **reproductibilité** exacte des résultats par rapport au papier.



Encodeur CNN testés (backbone gelé)

Backbones comparés

| Backbone | Sortie | Paramètres |
|-------------|----------------------------|--------------|
| VGG19 | $14 \times 14 \times 512$ | ~ 144 M |
| ResNet-152 | $14 \times 14 \times 2048$ | ~ 60 M |
| DenseNet161 | $14 \times 14 \times 2208$ | ~ 29 M |



Décodeur attentif

Architecture LSTM + Attention

- ▶ **Embedding** des mots : dimension 512
- ▶ **LSTM** uni-directionnel à 512 unités
- ▶ Mécanisme **Soft Attention** :
 - ▶ Calcul des scores d'attention : $e_{t,i} = w^\top \tanh(W_h h_{t-1} + W_a a_i)$
 - ▶ Poids $\alpha_{t,i} = \text{softmax}(e_{t,i})$
 - ▶ Contexte : $c_t = \sum_i \alpha_{t,i} a_i$
- ▶ Concaténation (h_{t-1}, c_t) → projection → entrée LSTM
- ▶ Dropout 0.5 sur embeddings et sorties LSTM (par défaut pytorch)


Point Technique

- ▶ Fonction de loss : Cross-Entropy sur vocabulaire
- ▶ Critère de sélection du meilleur modèle : score BLEU-4 sur val


Stratégie d'entraînement

Configuration d'entraînement

- ▶ Taille des batchs : 64
- ▶ Nombre d'époques : variable
- ▶ Learning rate : 0.005 choisi après avoir eu des entraînements instables avec 0.05



Teacher Forcing: Révolution de notre entraînement



Résultats expérimentaux

Hyperparamètres retenus

| | |
|-----------------|-----------|
| batch_size | 64 |
| epochs | 15 |
| lr | 0.0005 |
| step_size | 5 |
| alpha_c | 1 |
| log_interval | 100 |
| network | resnet152 |
| teacher_forcing | true |
| dataset | flickr30k |

Comparatif des métriques


| Métrique | Train 1 | Papier | Final |
|----------|---------|--------|-------------|
| BLEU-1 | 0.48 | 0.67 | 0.64 |
| BLEU-2 | 0.26 | 0.44 | 0.44 |
| BLEU-3 | 0.14 | 0.29 | 0.31 |
| BLEU-4 | 0.07 | 0.20 | 0.21 |

Temps de training nécessaire pour notre modèle : 7h01

Visualisation des résultats




Visualisation des résultats



Visualisation des résultats



Visualisation des résultats



Visualisation des résultats



Visualisation des résultats



Visualisation des résultats



Visualisation des résultats



are



water



<start>



standing



at



two



in



sunset



people



the



<eos>



Analyse critique du modèle

Forces du modèle

- ▶ Très performant sur les images "d'action"
- ▶ Très entraîné sur des images d'humains
- ▶ Produit en sortie des légendes syntaxiquement correctes dans la quasi totalité des cas.

Limites constatées

- ▶ Peu performant sur les images ne comportant pas d'actions ou d'humains
- ▶ A du mal à déduire l'information importante d'une image complexe.

Améliorations proposées

Changement de dataset

Training sur COCO dataset : images plus nombreuses et plus variées.

Exploration sur les hyper-paramètres existants

- ▶ step size pour le learning rate adaptatif
- ▶ alpha c pour la soft attention
- ▶ dégel du backbone en entrée du modèle

Augmentation de la robustesse au bruit

- ▶ Data augmentation
- ▶ Exploration de nouvelles méthodes de régularisation (dropout, label smoothing, ...)

Impacts sociétaux et environnementaux

Consommation énergétique

- ▶ Entraîner un modèle attentionnel profond (ex. ResNet152 + LSTM) nécessite plusieurs heures de calcul sur GPU, parfois sur supercalculateur.
- ▶ Cela engendre une empreinte carbone non négligeable (ex. ~7h d'entraînement dans notre cas).
- ▶ Inférence relativement légère en terme de ressources et de temps

Enjeux sociaux

- ▶ Risques de biais dans les légendes générées (stéréotypes liés aux données d'entraînement).
- ▶ Possibles dérives dans l'usage (ex. surveillance, annotation automatisée à grande échelle).
- ▶ Nécessité de transparence et d'évaluation éthique des usages.

Conclusion

Synthèse du projet

- ▶ Reproduction du modèle combinant CNN et LSTM avec mécanisme d'attention douce.
- ▶ Entraînement réalisé sur le dataset flickr30k, avec ajustement des hyperparamètres et régularisation.
- ▶ Évaluation selon les métriques BLEU : résultats globalement cohérents avec ceux du papier, malgré des écarts.

Apports de l'implémentation

- ▶ Compréhension approfondie du fonctionnement de l'attention visuelle et de sa mise en œuvre pratique.
- ▶ Expérience concrète d'entraînement sur un supercalculateur : gestion des ressources, temps de calcul, monitoring.
- ▶ Meilleure maîtrise des problématiques liées au traitement du langage naturel et à la vision par ordinateur.

Merci de votre attention

Questions?