

# IA Générative & Deep Fake

SAMBET Mathys, GROS Loric, MUNOZ Matéo



# Problématique

Dans quelle mesure les technologies d'IA générative, telles que les deepfakes, représentent-elles une opportunité ou une menace pour la société et la protection des données personnelles ?

# Sommaire

- I. Les IA génératives
- II. Deepfake
- III. Risques et enjeux
- IV. Solutions


# Les IA génératives



# IA Générative ?

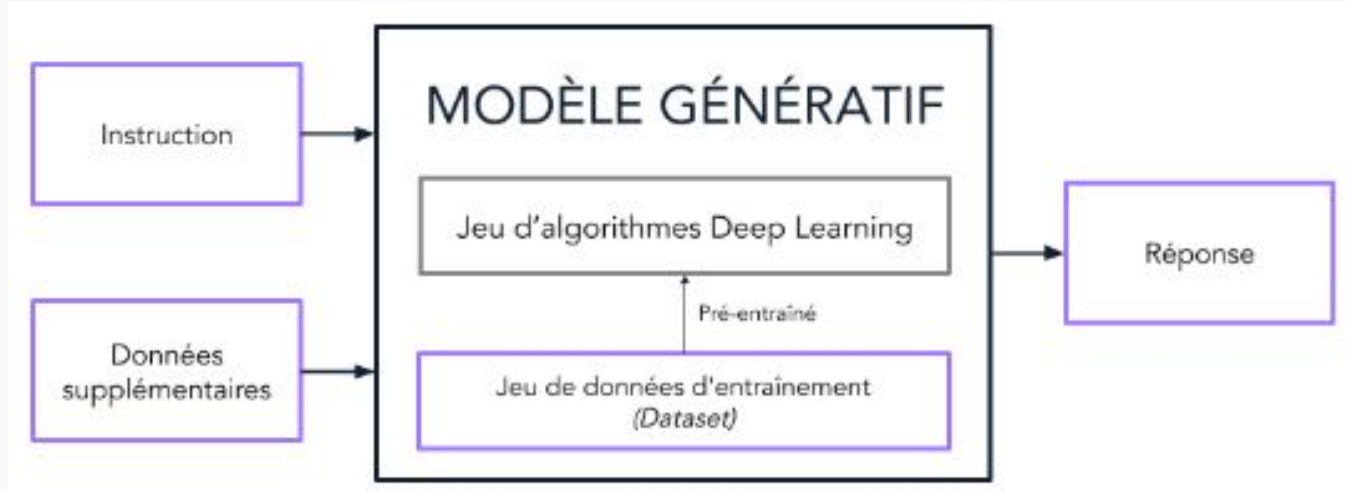
**Définition** : L'IA générative est un type de système d'intelligence artificielle (IA) capable de générer du texte, des images, des vidéos ou d'autres médias en réponse à des requêtes (aussi appelées invites, ou en anglais prompts).

**Source** : Page Wikipedia "Intelligence artificielle générative".



Source :  
<https://www.servicenow.com/fr-ca/now-platform/what-is-generative-ai.html>

# Fonctionnement de l'IA générative

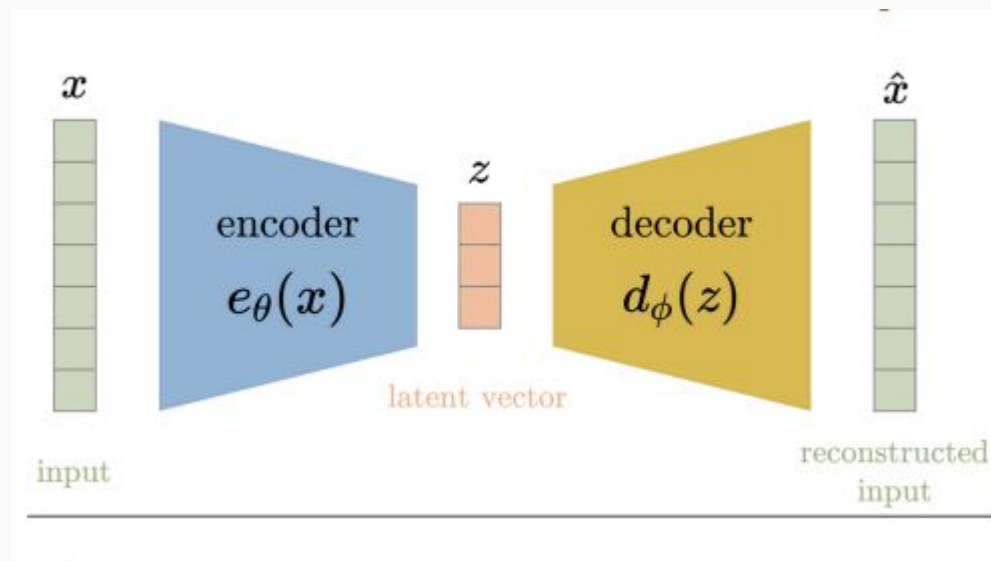


source : <https://www.dynergie.fr/blog/ia-generative-demystification-pour-pme-et-eti>

# Fonctionnement de l'IA générative

VAE, Kingma, D. P., & Welling, M. (2022). *Auto-Encoding Variational Bayes*. arXiv. <https://arxiv.org/abs/1312.6114>

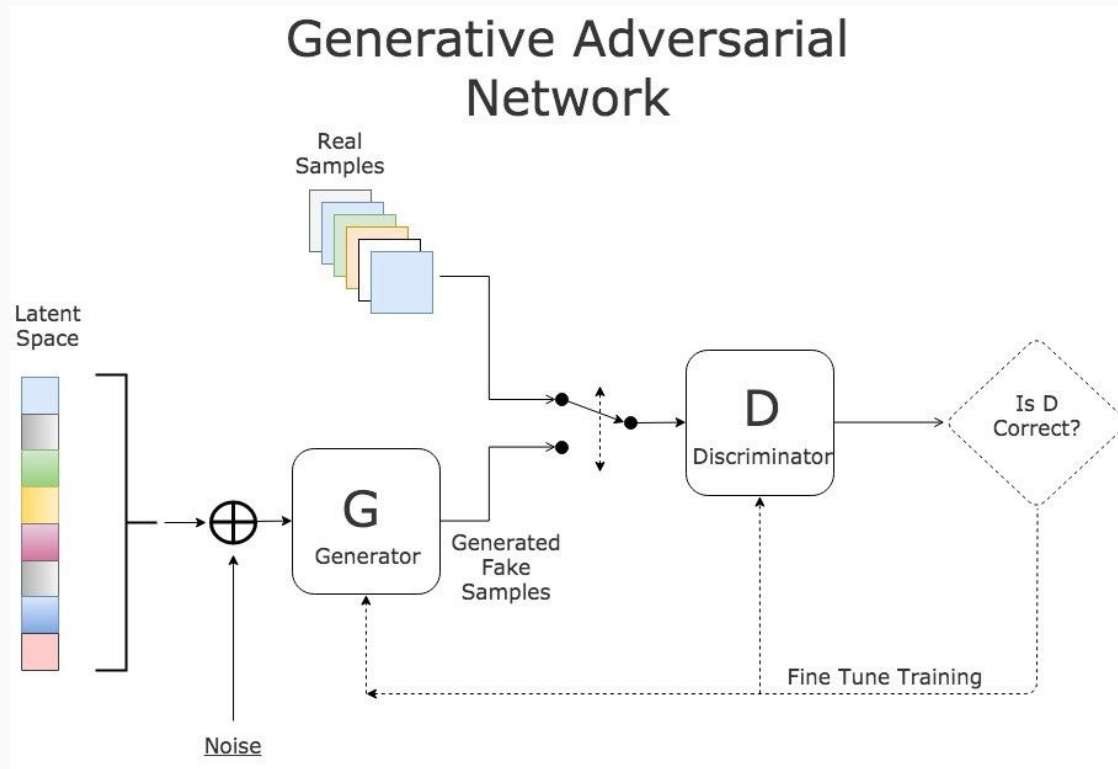
Source de la figure : cours d'image de Mr. Alexandre MEYER



# Fonctionnement de l'IA générative

GANs (DALL-E, Midjourney... Mais aussi GANSynth pour le son)

Source : Goodfellow et al., *Generative Adversarial Networks*, 2014  
[arXiv:1406.2661](https://arxiv.org/abs/1406.2661).

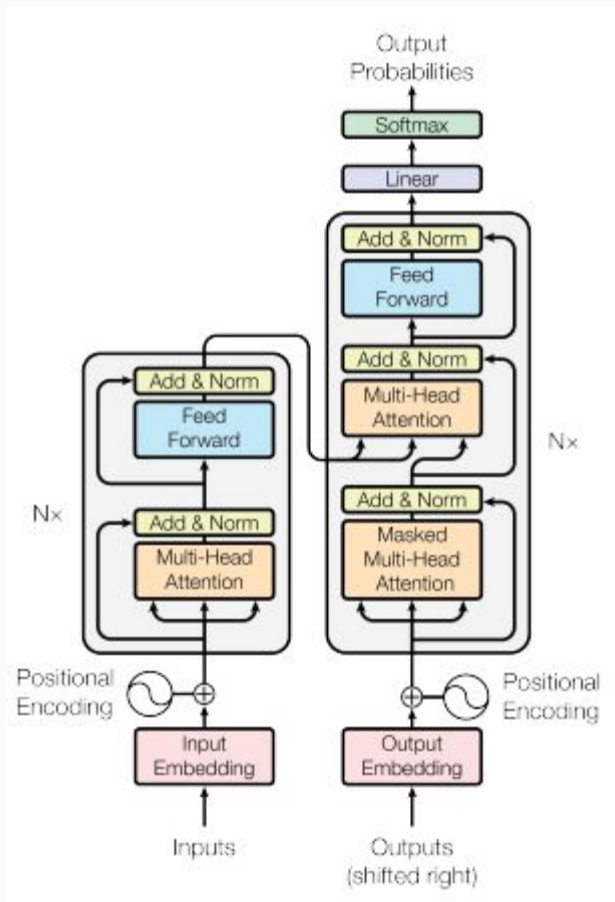




# Fonctionnement de l'IA générative


Architecture transformers (ChatGPT, Gemini..)

Source : Vaswani et al., *Attention Is All You Need*, 2017 [arXiv:1706.03762](https://arxiv.org/abs/1706.03762).



# Utilisations de l'IA générative

## Generative AI Use Case Prevalence



Source : <https://voicebot.ai/2023/08/29/how-consumers-are-using-generative-ai-chart/>

# Des avantages !

- Créativité et Innovation
- Accessibilité accrue aux connaissances
- Efficacité et Productivité
- Amélioration de la collaboration
- Apprentissage et développement de compétences

## ... Et inconvénients

- Risque de désinformation
- Atteinte à la vie privée
- Impact sur l'éducation
- Menace pour l'emploi
- Empreinte carbone élevée

# Risques et enjeux



# Evolution des deepfakes

- Prémices des deepfakes : Truquage manuel
- Début des deepfakes 2014 - 2017 : GAN, image de faible qualité
- Popularisation 2017 - 2019 : Devient viral, contenus trompeurs
- Accessibilité 2019 - aujourd'hui :
  - Logiciels simplifiés et accessibles
  - Réaliste
  - Exploités pour la fraude

# Déshumanisation des relations

## Conversation vide de sens

Simulation de conversation

Interactions sans authenticité

Impact sur l'éducation

## Isolement social

Réduction des interactions humaines

Affectation émotionnelle



# Manipulation des informations

## Propagation de fausses informations

Influence l'opinion publique

Impact des réseaux sociaux

## Réduction de la confiance

Deepfake → Désinformation

Différencier le vrai/faux





# Atteinte à la vie privée

## Vidéos diffamatoires

Menace la vie personnelle / professionnelle

Droit à l'image

## Sécurité

Imitation des voix / visages

Exposition aux fraudes



# Exemple : ChatGPT et confidentialité

[Lien vers un exemple réel](#)



Figure 5: **Extracting pre-training data from ChatGPT.** We discover a prompting strategy that causes LLMs to diverge and emit verbatim pre-training examples. Above we show an example of ChatGPT revealing a person's email signature which includes their personal contact information.

# Remplacement des créatifs

## Valeur de la créativité humaine

Créations musicales / visuelles

Place des artistes

## Droit d'auteur

Droit des créations par les IA

Éthiquement correcte ?




Photo gagnante du Sony World Photography Awards  
par Boris Eldagsen

# Exemple : ChatGPT et droit d'auteur

**ChatGPT : Des auteurs attaquent OpenAI en justice pour violation des droits d'auteur** 20 minutes, 11/07/2023

**OPENAI RECONNAÎT ENTRAÎNER CHATGPT SUR DES CONTENUS PROTÉGÉS PAR LE DROIT D'AUTEUR** BFMTV, 09/01/2024



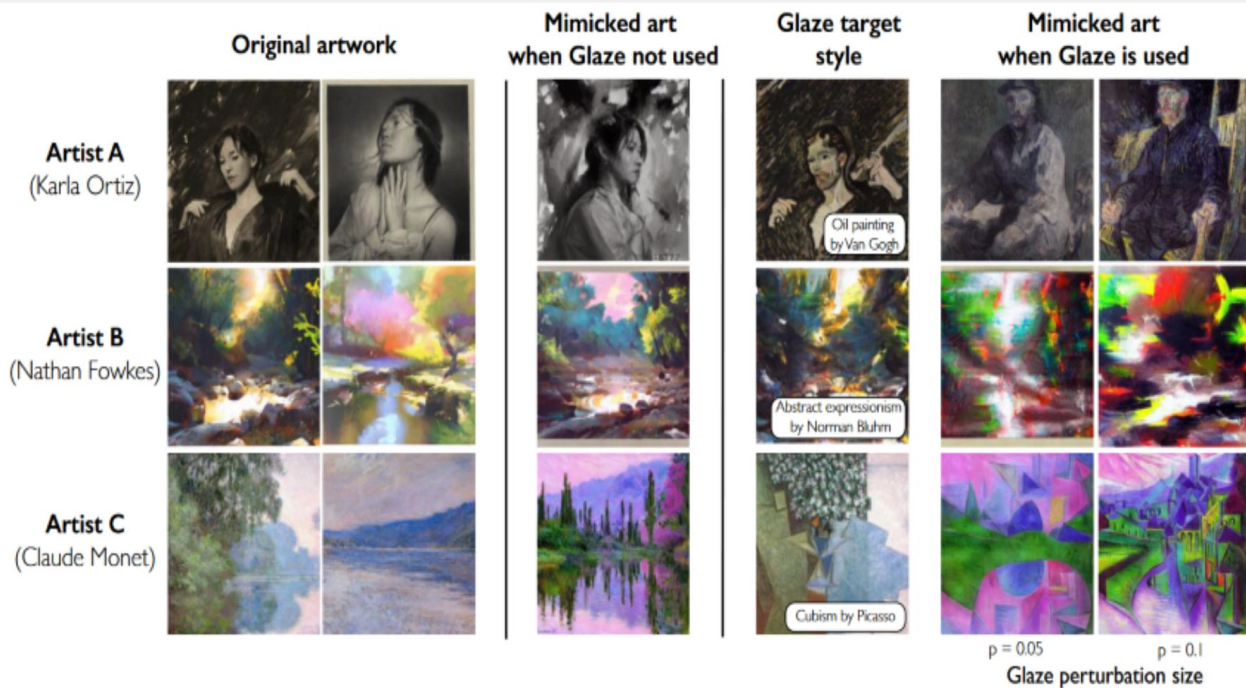
# Solutions



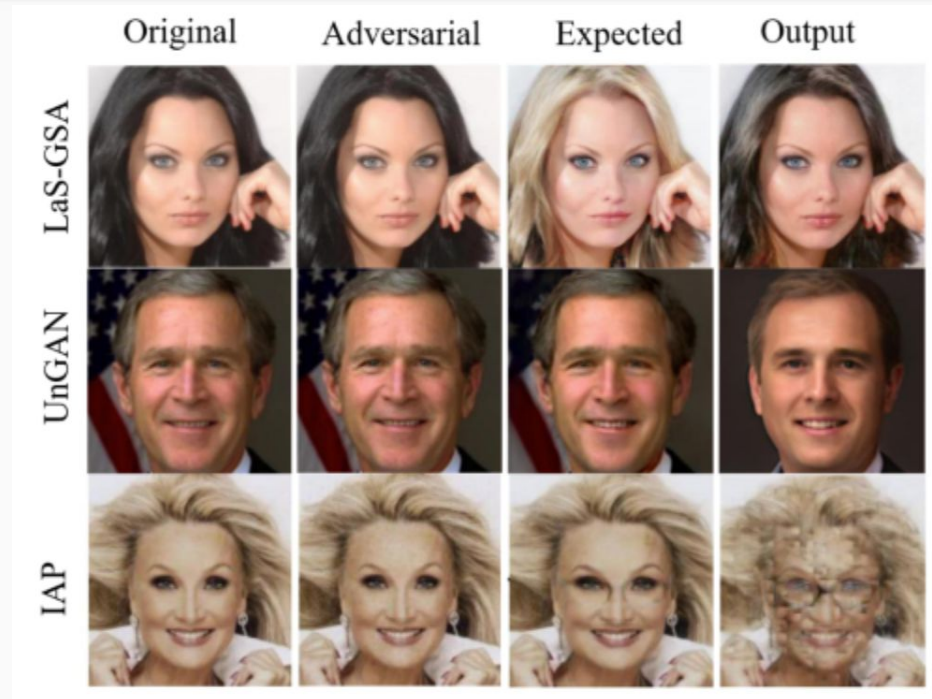
# Réglementation et cadre législatif

- article 9 : vie privé
- article 226-1 et 226-8 : utilisation de l'image d'un individu
- article 313-1 : Tromperie pour obtenir biens ou services
- article 312-10 : extorsion par menace de révéler des informations

# Approche préventive - Tatouage de documents




# Approche préventive - Tatouage de BD






# Détection de deepfake - clignement des yeux

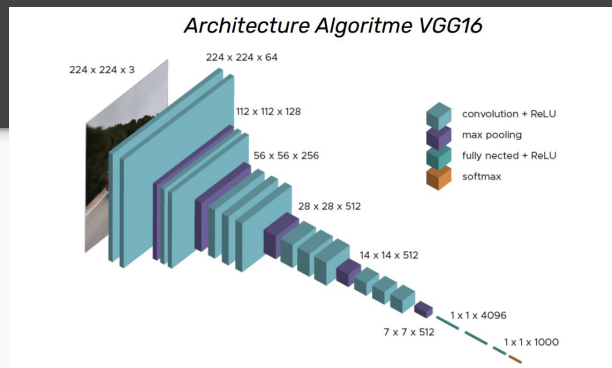


Eye aspect ration threshold (T=0.25)


Blink



Non-Blink

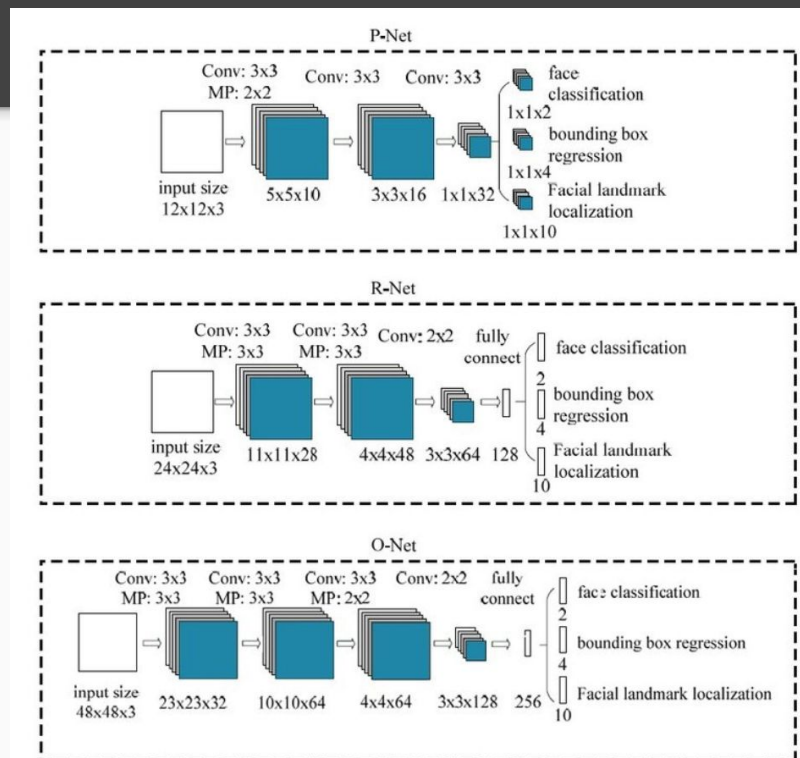


<https://datascientest.com/quest-ce-que-le-modele-vgg>



<https://www.ikomia.ai/blog/mastering-resnet-deep-learning-image-recognition>

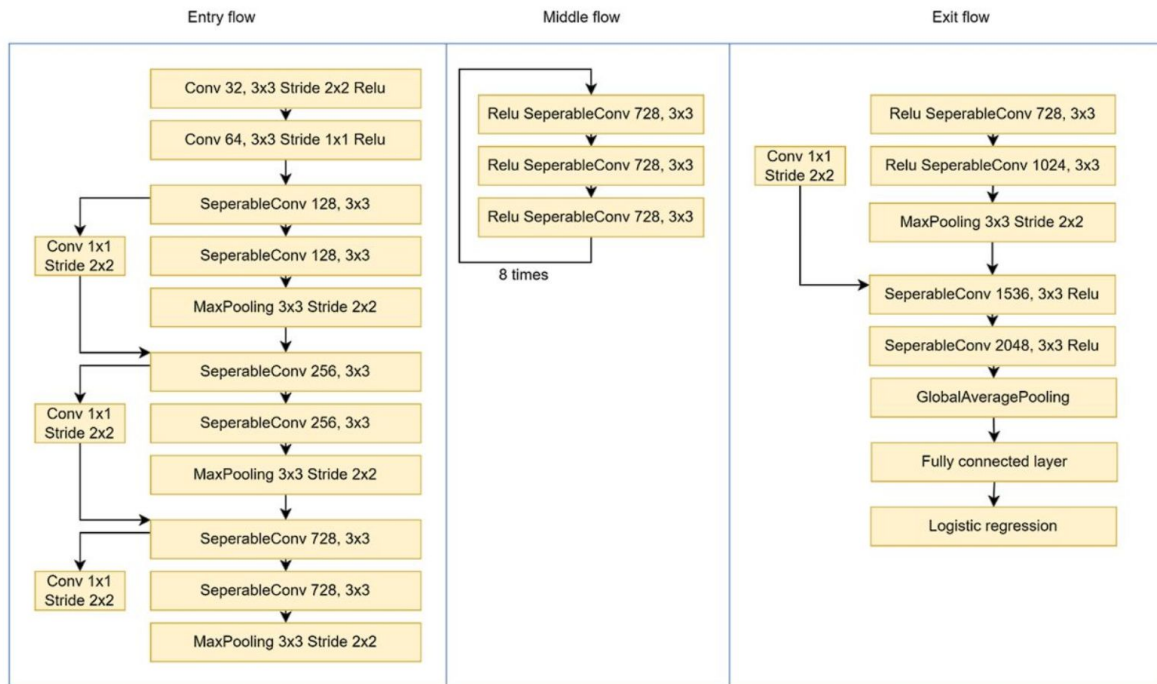
# Détection de deepfake - metric learning (MTCNN)



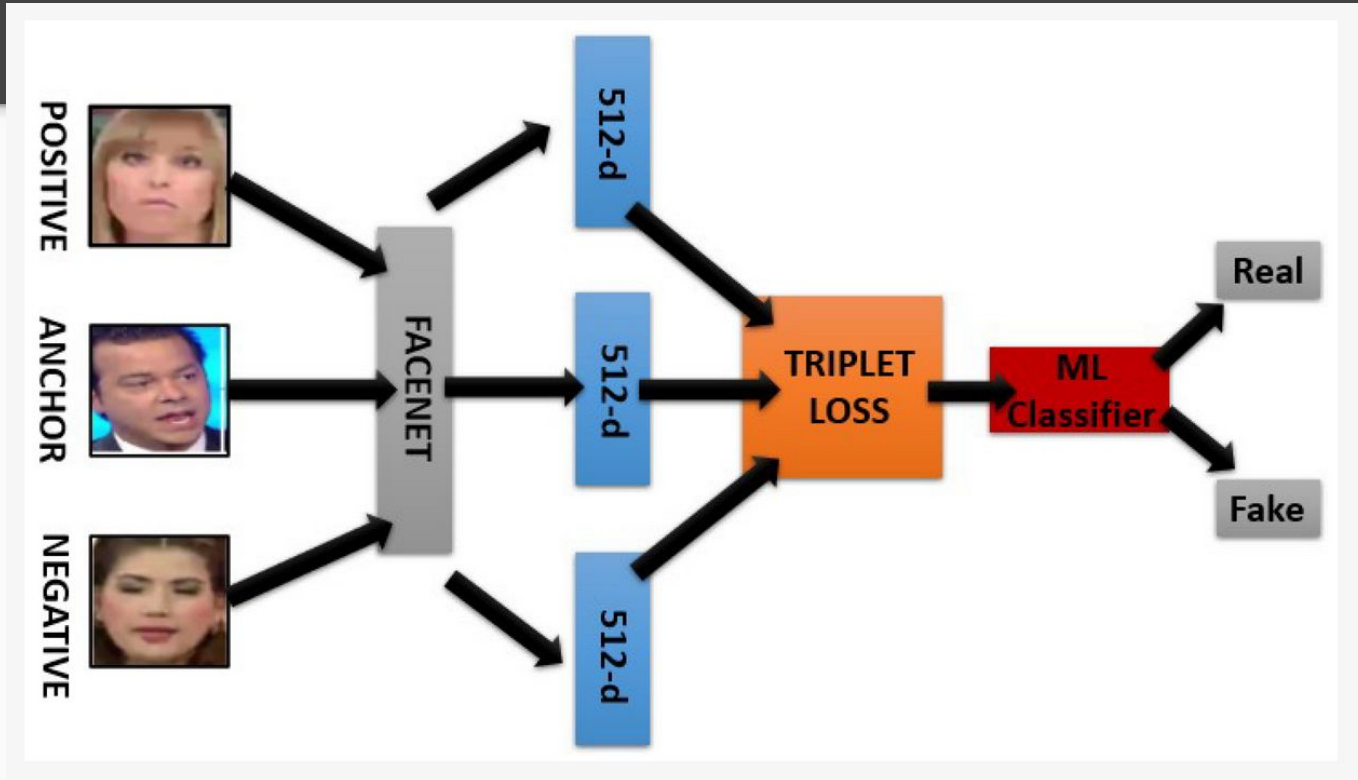
[https://www.researchgate.net/figure/MTCNN-Stage-architecture-of-the-model-used-for-face-detection-and-landmark-extraction\\_fig3\\_341148320](https://www.researchgate.net/figure/MTCNN-Stage-architecture-of-the-model-used-for-face-detection-and-landmark-extraction_fig3_341148320)

# Détection de deepfake - metric learning (Xception)

## Xception Architecture



# Détection de deepfake - metric learning (Apprentissage de Triplet)



# Solutions pour prévenir les abus

- Donner les moyens de comprendre (sensibilisation, expérimentation, Ressources accessibles)
- Responsabiliser (Bonnes pratiques, IA interprétables)
- Observer (usages, dérives..)

# Lien avec la cognition

- Reproduction des biais cognitifs : apparition des biais
- Auto-amélioration : Fonctionnement des GAN qui permet d'améliorer ses productions sans supervision
- Embodiment : Reproduction de visage/voix réaliste pour simuler l'interaction humaine

Question ?

Quelle est l'image générée par l'IA





# Quelle est l'image générée par l'IA

Pensez-vous qu'un jour, il deviendra impossible pour un être humain de discerner les deepfakes sans assistance technologique ? Que cela implique-t-il ?

# Qui doit apprendre à la population à se servir des IA génératives ?

Les États ? Les entreprises à qui appartiennent les IA ? Les deux ?

# Comment croyez vous que l'IA générative dans sa globalité sera utilisée dans le futur ?

Influence sur la société ? Risques potentiels ?

# Télé réalité coréenne utilise l'IA pour ramener cette fille à la vie



# Sources

<https://linc.cnil.fr/le-tatouage-numerique-une-mesure-de-transparence-salutaire-22>

<https://info.haas-avocats.com/droit-digital/la-lutte-contre-les-deepfakes-sorganise>

<https://www.mdpi.com/2079-9292/13/1/95>

<https://www.minalogic.com/livre-blanc-ia-generative-hypertrucages-deepfake/>

<https://www.cnetfrance.fr/news/ai-ou-reel-devinez-si-ce-sont-de-vraies-photos-394872.htm>

<https://link.springer.com/content/pdf/10.1007/s10479-022-05151-y.pdf>