

# Generative adversarial networks for higher resolution images

## Stage M2 Recherche

**Encadrant** : T. Artières et S. Ayache - QARMA@LIS - <https://pageperso.lis-lab.fr/thierry.artieres/>

**Durée** : 5 à 6 mois (Avril - Septembre)

**Rémunération** : Tarif stage (non encore acquise)

### Sujet :

L'apparition de la stratégie d'apprentissage *adversarial*, GANs (Generative Adversarial Networks) [Goodfellow et al., 2014] en Deep Learning, a permis des avancées majeures dans le domaine de la génération de données complexes tels que les sons, les images, les vidéos ou le texte. De nombreux travaux ont démontré un intérêt fort des GANs pour la génération d'images au réalisme jusqu'alors inégalé, mais nécessitant toutefois de très nombreux exemples d'apprentissage et se limitant souvent à des jeux de données de résolution modeste (entre 64 pixels et 256 pixels). Une approche récemment proposée [Karras et al. Nvidia, 2018] consiste à augmenter progressivement la résolution des images générées en incorporant en plusieurs étapes, de nouvelles couches de convolutions dans les générateurs et discriminateurs, facilitant ainsi la génération de portraits haute résolution à 1024 pixels. Parallèlement, les travaux en super-resolution d'images qui consistent à augmenter (jusqu'à 8x) la résolution d'images ont aussi bénéficié de l'apport des GANs [Ledig et al., 2017] ou de stratégies incrémentales [Wang et al., 2018]. Ces méthodes bien qu'efficaces nécessitent des exemples d'apprentissage en haute résolution, souvent difficilement disponibles.

L'apprentissage *adversarial* consiste à entraîner simultanément deux réseaux sur une tâche contradictoire : un *discriminateur* doit distinguer deux sources de données : l'une provenant d'un ensemble d'apprentissage, tandis que l'autre est obtenue par un *générateur*. L'entraînement alterné de ces deux réseaux tend à les rendre meilleurs jusqu'à équilibre où le discriminateur ne peut plus distinguer la provenance d'une donnée. Ce paradigme est particulièrement intéressant car fonctionne de manière non-supervisé, tout en apportant une supervision sur le générateur. Certains travaux ont tiré parti d'un discriminateur *adversarial* pour contraindre des parties de réseau à produire une certaine distribution de données, permettant alors un meilleur contrôle sur l'apprentissage ou lors de la phase d'inférence. [Makhzani et al., 2016] utilisent un critère adversarial pour contraindre un autoencodeur à projeter les données proches d'une distribution fixée a priori. [Ganin et al., 2016] ou [Tzeng et al., 2017] intègrent un discriminateur *adversarial* dans un réseau convolutionnel pour résoudre une tâche d'adaptation de domaine.

Le modèle AmbientGAN [Bora et al., 2018] s'intéresse à la situation où les données d'apprentissage sont une version dégradées/imparfaites des données réelles. L'idée de l'apprentissage est qu'un générateur est entraîné à produire des données, qui passent ensuite à travers un module simulant la dégradation. Un discriminateur apprend à distinguer entre la dégradation simulée de données générées, et la vraie observation dégradée de données réelles.

Par ce mécanisme, le modèle est ainsi capable de générer de vrais images à partir d'images dégradées, et ainsi d'envisager la génération d'images hautes résolutions à partir de faibles résolutions.

Ce sujet de stage vise à proposer une méthode de génération d'images haute résolution dans la situation où seulement peu (voire pas) d'exemples en haute résolution ne sont disponibles. La méthode proposée pourra s'inspirer des approches d'adaptation de domaines et/ou du modèle AmbientGAN, en intégrant une contrainte adversariale pour forcer la génération d'images à plus haute résolution. On étudiera l'apport d'une version itérative où le générateur est un encodeur-décodeur qui vise à augmenter la résolution d'une image donnée. A partir de paires d'images de différentes résolutions, un discriminateur sera entraîné à déterminer l'image de plus haute résolution ; le critère *adversarial* poussera ainsi le générateur à produire des images haute résolution. Similairement aux réseaux Siamese, l'intérêt de considérer des paires de données en entrée du réseau augmente artificiellement la taille du jeu de donnée facilitant l'apprentissage avec peu d'exemples [Koch et al., 2015]. Il est attendu qu'une telle stratégie aide à résoudre la tâche de super-résolution à partir de peu d'exemples.

## References

- [Bora et al., 2018] Ashish Bora, Eric Price, Alexandros G. Dimakis, AmbientGAN: Generative models from lossy measurements, ICLR 2018
- [Ganin et al., 2016] Yaroslav Ganin, Evgeniya Ustinova, Hana Ajakan, Pascal Germain, Hugo Larochelle, François Laviolette, Mario Marchand, Victor Lempitsky, Domain-Adversarial Training of Neural Networks, JMLR 2016
- [Goodfellow et al., 2014] Ian J. Goodfellow and Jean Pouget-Abadie and Mehdi Mirza and Bing Xu and David Warde-Farley and Sherjil Ozair and Aaron C. Courville and Yoshua Bengio, Generative Adversarial Nets, NIPS 2014
- [Karras et al., 2018] Tero Karras Timo Aila Samuli Laine Jaakko Lehtinen, Progressive Growing of GANs for Improved Quality, Stability, and Variation, ICLR 2018
- [Koch et al., 2015] G. Koch, R. Zemel, and R. Salakhutdinov, Siamese Neural Networks for One-shot Image Recognition, 2015
- [Ledig et al., 2017] Christian Ledig, Lucas Theis, Ferenc Husza'r, Jose Caballero, Andrew Cunningham, Alejandro Acosta, Andrew Aitken, Alykhan Tejani, Johannes Totz, Zehan Wang, Wenzhe Shi, Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network, CVPR 2017
- [Makhzani et al., 2016] Alireza Makhzani, Jonathon Shlens, Navdeep Jaitly, Ian Goodfellow, Brendan Frey, Adversarial Autoencoders, ICLR 2016
- [Tzeng et al., 2017] Eric Tzeng, Judy Hoffman, Kate Saenko, Trevor Darrell Adversarial Discriminative Domain Adaptation, CVPR 2017