

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université de 8 Mai 1945 – Guelma
Faculté des Mathématiques, d'Informatique et des Sciences de la matière
Département d'Informatique



Mémoire de Fin d'études Master

Filière : Informatique

Option : Sciences et Technologie de l'Information et de
Communication

Thème :

Génération de données Synthétiques pour les Datasets

Encadré par :
Dr. FAROU Brahim

Présenté par :
M. KLAI Aissa

2021/2022

Remerciement

J'ai tien tout d'abord à remercier Dieu le tout puissant, qui ma donné la force et la patience d'accomplir ce modeste travail.

En second lieu, j'ai tien à remercier mon encadreur Dr. Farou Brahim, pour son précieux conseil et son aide durant toute la période du travail et mes études.

Mes vifs remerciements vont également aux membres du jury pour l'intérêt qu'ils ont porté à mon projet en acceptant d'examiner mon travail et de l'enrichir par leurs propositions.

Enfin, j'ai tien également à remercier toutes les personnes qui ont participé de près ou de loin à la réalisation de ce travail.

Merci.

Dédicace

Je dédie ce modeste travail au Dr. Farou Brahim , mon tuteur de projet de fin d'étude, qui m'a suivi tout au long de cette période.

A mes très chers parents

A mon épouse pour sa patience et son appui

A mes enfants Salsabil , Abderrahmene et Tasnime

A mes collègues du bureau

A tous les étudiants de notre promo.

A tous ceux qui m'ont aidé de loin ou de près durant mes études.

ملخص

تم استخدام خوارزمية تكبير الصورة لزيادة عدد صور معينة بسبب مجموعة البيانات غير المتوازنة ولزيادة متانة النموذج. في هذا المشروع ، تم استخدام [CycleGAN](#) ، أحد نماذج GAN الشرطية ، لزيادة بيانات الصورة لاكتشاف المرض. لقد اقترحنا استخدام متغير يسمح بالترجمة من صورة إلى صورة دون الحاجة إلى أمثلة مقترنة للتحويل من المجال المصدر إلى المجال الهدف. يمكنه تحويل الصورة من مجال إلى آخر دون تعيين واحد لواحد بين المجال المصدر والمجال الهدف. أعطت الاختبارات التي أجريت على قاعدة بيانات صور [Plantvillage](#) نتائج مرضية للغاية.

الكلمات المفتاحية: CycleGAN ، GoogleNet ، أمراض النباتات، تعلم عميق

Résumé

L'algorithme d'augmentation d'image a été utilisé pour augmenter le nombre de certaines images en raison de l'ensemble de données déséquilibré et pour augmenter la robustesse du modèle. Dans ce projet, le CycleGAN, l'un des modèles GAN conditionnels, a été utilisé pour augmenter les données d'image pour la détection des maladies. Nous avons proposé d'utiliser une variante qui permet la traduction d'image à image sans avoir besoin d'exemples appariés de transformation du domaine source au domaine cible. Il peut transformer l'image d'un domaine à un autre sans mappage un à un entre le domaine source et le domaine cible. Les tests effectués sur la base d'image Plantvillage ont donné des résultats très satisfaisants.

Mots clés : CycleGAN, GoogLeNet, Maladies des plantes, Apprentissage profond

Abstract

The image augmentation algorithm was used to increase the number of certain images due to the unbalanced dataset and to increase the robustness of the model. In this project, CycleGAN, one of the conditional GAN models, was used to augment image data for disease detection. We have proposed to use a variant that allows image-to-image translation without the need for paired examples of transformation from source domain to target domain. It can transform the image from one domain to another without one-to-one mapping between source domain and target domain. The tests carried out on the Plantvillage dataset gave very satisfactory results.

Key Words :CycleGAN, GoogLeNet, plant disease, Deep Learning

Table des matières

Introduction Générale	1
1 Réseaux Adversaires Génératifs (GAN)	2
1.1 Introduction	2
1.2 Réseaux Adversaires Génératifs (GAN)	2
1.3 Les Architectures standards des GAN	3
1.3.1 GAN entièrement connecté (FCGAN)	3
1.3.2 GAN bidirectionnel (BiGAN)	3
1.3.3 GAN semi-supervisé (SGAN)	4
1.3.4 GAN conditionnel (CGAN)	4
1.3.5 InfoGAN	5
1.3.6 Classificateur Auxiliaire GAN (ACGAN)	5
1.3.7 Pyramide laplacienne des réseaux GAN (LAPGAN)	6
1.3.8 GAN à Convolution Profonde (DCGAN)	6
1.3.9 GAN avec un Equilibre aux limites(BEGAN)	6
1.3.10 GAN à croissance progressive (PROGAN)	7
1.3.11 Auto-attention GAN (SAGAN)	8
1.3.12 BigGAN	8
1.3.13 rGAN à bruit d'étiquette	9
1.3.14 YLGAN	9
1.3.15 Auto GAN	9
1.3.16 MSG-GAN	9
1.4 Les GAN à variation de perte	10
1.4.1 GAN de Wasserstein	10
1.4.2 WGAN-GP	10
1.4.3 GAN des moindres carrés (LSGAN)	11
1.4.4 f-GAN	11
1.4.5 GAN déroulé(UGAN)	11
1.4.6 GAN sensible aux pertes (LS-GAN)	11
1.4.7 Mode Regularized GAN	12
1.4.8 GAN géométrique	12
1.4.9 GAN relativiste (RGAN)	12

1.4.10	SN-GAN	12
1.4.11	Réaliste GAN	13
1.4.12	Sphère GAN	13
1.4.13	GAN auto-supervisé (SS-GAN)	13
1.5	Conclusion	14
2	Augmentation des données : Application aux bases des plantes	15
2.1	Introduction	15
2.2	Contexte et Résumé	15
2.3	La base des plantes et maladies	17
2.3.1	PlantVillage	17
2.3.2	Motivation	18
2.3.3	Collecte et construction	19
2.3.4	Enregistrements des Données	19
2.3.5	Techniques de Validation	19
2.4	CycleGan	21
2.4.1	Modélisation	21
2.4.2	Motivation	22
2.5	Augmentation des données	23
2.6	GoogLeNet	24
2.6.1	Description	24
2.6.2	Méthodologie de formation	26
2.7	Conclusion	26
3	Génération et Valorisation des donnés	28
3.1	Introduction	28
3.2	Plan de travail expérimental	28
3.3	Outils de développement :	28
3.4	Données	29
3.5	Chargement des données :	29
3.6	Formation(training)	30
3.7	Génération	31
3.8	Valorisation	34
3.8.1	Formation	34
3.8.2	Résultats	35
3.9	Interprétation	36
3.10	Conclusion	36
	Conclusion générale	37
	Bibliographie	40

Table des figures

1.1	Architecture de base d'un GAN [1]	2
1.2	GAN entièrement connecté (FCGAN) [2]	3
1.3	GAN bidirectionnel (BiGAN) [3]	4
1.4	GAN semi-supervisé (SGAN) [4]	4
1.5	GAN conditionnel (CGAN) [2]	5
1.6	InfoGAN [5]	5
1.7	Classificateur Auxiliaire GAN (ACGAN) [2]	5
1.8	Pyramide laplacienne des réseaux GAN (LAPGAN) [6]	6
1.9	GAN à Convolution Profonde (DCGAN) [7]	6
1.10	GAN avec un Equilibre aux limites(BEGAN) [8]	7
1.11	GAN à croissance progressive (PROGAN) [9]	7
1.12	Auto-attention GAN (SAGAN) [10]	8
1.13	BigGAN [10]	8
1.14	MSG-GAN [13]	10
1.15	WGAN-GP [16]	11
1.16	Unrolled GAN (UGAN) [19]	11
1.17	GAN relativiste (RGAN) [22]	12
1.18	Sphère GAN [25]	13
1.19	SS-GAN [26]	13
2.1	Exemples de différents phénotypes de plants de tomates	20
2.2	Architecture de CycLeGAN	21
2.3	Modélisation de CycLeGAN	22
2.4	Perte de cohérence	22
2.5	Exemples des images générés à l'aide de CycLeGAN	24
2.6	Description de GoogLeNet	25
2.7	Réseau GoogLeNet avec toutes les cloches	27
3.1	Les 4 ensembles des données utilisés dans notre étude	29
3.2	Chargement de Pomme	29
3.3	Chargement de Cerise	30
3.4	Chargement de Mais	30
3.5	Chargement de Tomate	30

3.6	Formation de Pomme	31
3.7	Formation de Cerise	31
3.8	Formation de Mais	32
3.9	Formation de Tomate	32
3.10	Exemple de prédiction Pomme	33
3.11	Exemple de prédiction Cerise	33
3.12	Exemple de prédiction Mais	33
3.13	Exemple de prédiction Tomate	33
3.14	Planification de formation de Pomme	34
3.15	Planification de formation de Cerise	34
3.16	Planification de formation de Mais	34
3.17	Planification de formation de Tomate	35
3.18	Résultat de Pomme	35
3.19	Résultat de Cerise	35
3.20	Résultat de Mais	36
3.21	Résultat de Tomate	36

Liste des sigles et acronymes

GAN	<i>Generation Adversarial Networks</i>
FCGAN	<i>Fully Connected GAN</i>
EBGAN	<i>Energy-Based GAN</i>
BiGAN	<i>Bidirectional GAN</i>
CGAN	<i>Conditional GAN</i>
SGAN	<i>Semi-supervised GAN</i>
BEGAN	<i>Boundary Equilibrium GAN</i>
DCGAN	<i>Deep Convolutional GAN</i>
AC-GAN	<i>Auxiliary Classifier GAN</i>
LAPGAN	<i>Laplacian Pyramid GAN</i>
PROGAN	<i>Progressive GAN</i>
SAGAN	<i>Self-Attention GAN</i>
BigGAN	<i>Big GAN</i>
YLGAN	<i>Your Local GAN</i>
MSG-GAN	<i>Multi-Scale Gradients GAN</i>
WGAN	<i>Wasserstein GAN</i>
LSGAN	<i>Least Square GAN</i>
LS-GAN	<i>Loss Sensitive GAN</i>
UGAN	<i>Unrolles GAN</i>
RGAN	<i>Relativiste GAN</i>
SN-GAN	<i>Spectral Normalization GAN</i>

SS-GAN	<i>Self-Supervised GAN</i>
UG99	<i>Champignon Phytopathogène</i>
FAO	<i>Food and Agriculture Organization</i>
Big Ag	<i>Big Agriculture</i>
OGM	<i>Organisme Génétiquement Modifié</i>
SVM	<i>Support Vector Machine</i>
TSP	<i>Traveling Salesman Problem</i>
VRP	<i>Vehicle Routing Problem</i>

Introduction Générale

L'augmentation des données est un processus d'augmentation artificielle de la quantité de données en générant de nouveaux points de données à partir de données existantes. Cela inclut l'ajout de modifications mineures aux données ou l'utilisation de modèles d'apprentissage automatique pour générer de nouveaux points de données dans l'espace latent des données d'origine afin d'amplifier l'ensemble des données.

Dans la détection des maladies foliaires, la collecte et l'étiquetage d'un grand nombre des images de maladies nécessitent beaucoup de main-d'œuvre et de ressources financières. Pour certaines plantes et maladies, la période d'apparition est très courte rendant la tâche de les recueillir très difficile et parfois impossible.

Dans le domaine de l'apprentissage en profondeur, la petite taille de l'échantillon et le déséquilibre des ensembles de données sont les facteurs clés qui menant à un système de reconnaissance pauvre. Par conséquent, pour créer un modèle d'apprentissage en profondeur pour la détection des maladies, l'augmentation de la quantité de données est nécessaire.

Plusieurs méthodes ont été proposées dans l'état de l'art pour générer des données synthétiques. Les méthodes typiques sont la méthode d'expansion physique, le robot d'indexation, l'encodeur variationnel (VAE) et le modèle autorégressif. Les lacunes des échantillons produits par les méthodes d'expansion traditionnelles sont de mauvaise qualité, il crée une diversité inadéquate et génère des inégalités. Pour cela, nous proposons une méthode d'augmentation des données basée sur la génération des réseaux adversaire.

Tous ces éléments sont traités dans ce manuscrit à travers trois chapitres :

- **Chapitre 1 : Réseaux Adversaires Génératifs (GAN)**. Dans ce chapitre nous présentons les différentes techniques GAN utilisées pour l'augmentation des données dans les datasets.
- **Chapitre 2 : Augmentation des données : Application aux bases des plantes**. Ce chapitre aborde les différents concepts relatifs à l'augmentation de données des bases des plantes et le générateur GAN proposé.
- **Chapitre 3 : Génération et Valorisation des données**. Dans ce chapitre, nous abordons les aspects techniques relatifs à l'implémentation, les tests et les résultats de ce projet et de tous les outils qui ont été adoptés pour la réalisation de notre système.

Chapitre 1

Réseaux Adversaires Génératifs (GAN)

1.1 Introduction

Les modèles génératifs ont attiré une attention considérable dans l'apprentissage non supervisé via un nouveau cadre pratique appelé réseaux antagonistes génératifs GAN en raison de leur capacité exceptionnelle de génération de données. De nombreux modèles GAN ont été proposés et plusieurs applications pratiques ont vu le jour dans divers domaines de l'apprentissage automatique.

1.2 Réseaux Adversaires Génératifs (GAN) :

Un GAN typique comprend deux composants, dont l'un est un discriminateur (D) faisant la distinction entre les images réelles et les images générées tandis que l'autre est un générateur (G) créant des images pour tromper le discriminateur. L'objectif d'un GAN est d'apprendre la distribution du générateur qui se rapproche de la distribution réelle des données.

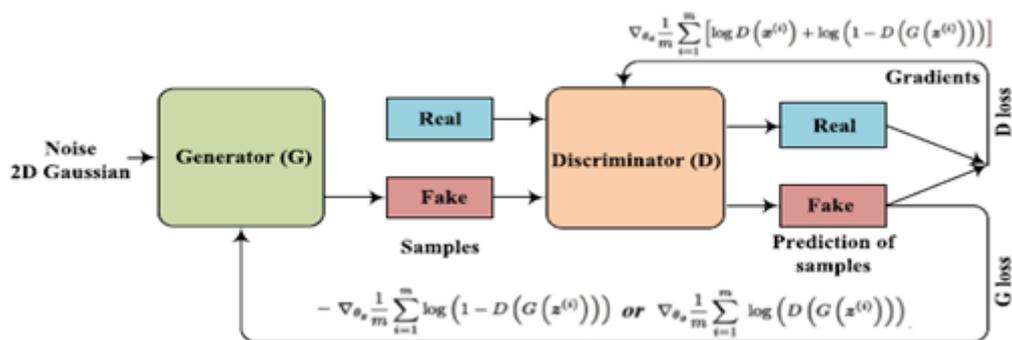


FIGURE 1.1 – Architecture de base d'un GAN [1]

1.3 Les Architectures standards des GAN

Les GANs ont une architecture variable qui dépend principalement de l'application visée. Dans la littérature, plusieurs variantes d'architecture ont été proposées afin d'améliorer les performances des GAN sous les trois aspect :

- l'amélioration de qualité d'image,
- l'amélioration de la diversité d'image,
- la stabilisation de la formation.

1.3.1 GAN entièrement connecté (FCGAN)

L'article original du GAN basé sur l'énergie (EBGAN) utilise des réseaux de neurones entièrement connectés à la fois pour le générateur et le discriminateur. Les auteurs suggèrent k étapes pour optimiser D (discriminateur) et une étape pour optimiser G (générateur).

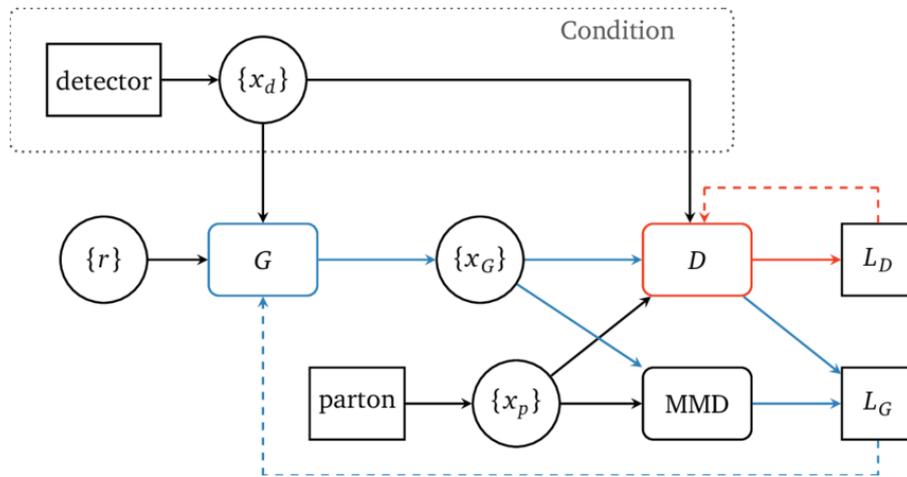


FIGURE 1.2 – GAN entièrement connecté (FCGAN) [2]

1.3.2 GAN bidirectionnel (BiGAN)

Le BiGAN se compose d'un codeur (E) d'un générateur (G) et d'un discriminateur (D). E encode les données d'échantillon réelles (x) en $E(x)$. G décode Z en $G(Z)$. D vise à évaluer la différence entre chaque paire ($E(x), x$) et ($G(Z), Z$). Comme E et G ne communiquent pas directement les auteurs prouvent que l'encodeur et le décodeur doivent apprendre à s'inverser pour tromper le discriminateur.

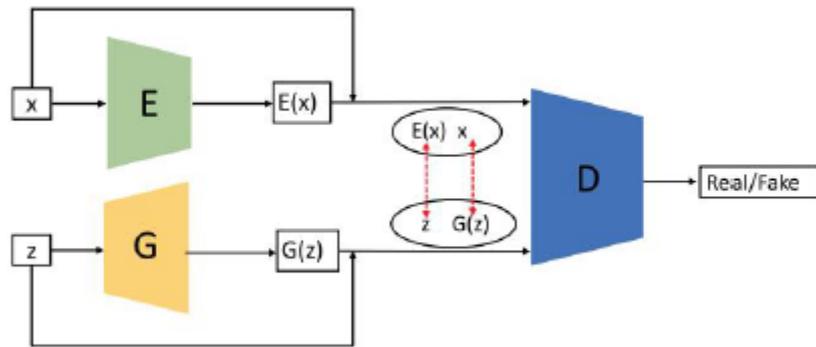


FIGURE 1.3 – GAN bidirectionnel (BiGAN) [3]

1.3.3 GAN semi-supervisé (SGAN)

L'apprentissage semi-supervisé a des étiquettes pour un petit sous-ensemble d'exemples. Ici le discriminateur de SGAN est à plusieurs têtes, c'est-à-dire qu'il utilise à la fois les fonctions softmax et sigmoïde pour classer des données réelles et faire la distinction entre les vrais et les faux échantillons.

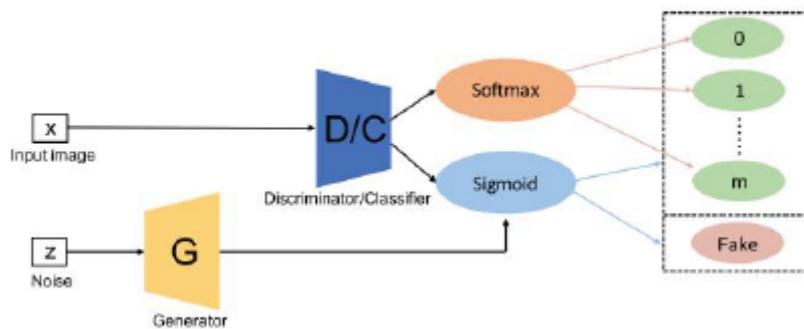


FIGURE 1.4 – GAN semi-supervisé (SGAN) [4]

1.3.4 GAN conditionnel (CGAN)

CGAN fournit des informations supplémentaires Y (Y peut être une étiquette de classe ou d'autres données modales) à la fois au discriminateur et au générateur. Y est normalement codé à l'intérieur du générateur et du discriminateur avant d'être concaténé avec le bruit Z codé et le x codé.

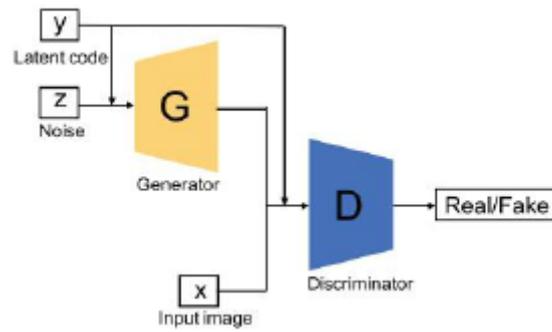


FIGURE 1.5 – GAN conditionnel (CGAN) [2]

1.3.5 InfoGAN

InfoGAN est proposé comme une étape au-delà du CGAN, il introduit un autre classifieur Q pour prédire le Y donné par $G(Z/Y)$. G et Q sont des auto-encodeur et D effectue le même travail qu’avec le FCGAN.

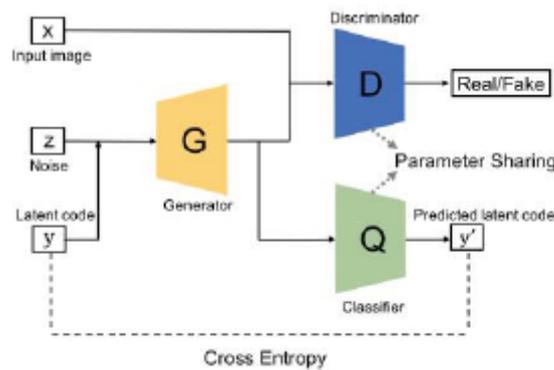


FIGURE 1.6 – InfoGAN [5]

1.3.6 Classificateur Auxiliaire GAN (ACGAN)

Il est similaire à CGAN et InfoGAN dans lequel un classificateur auxiliaire a été ajouté dans l’architecture. Chaque échantillon généré a une étiquette de classe correspondante C en plus de Z . La seule différence en ACGAN et CGAN et InfoGAN est l’information supplémentaire.

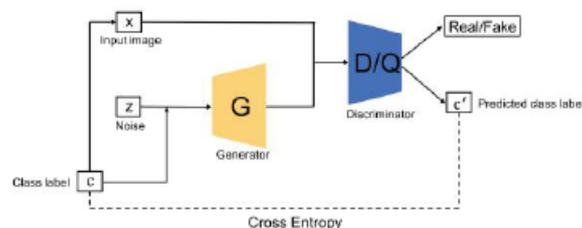


FIGURE 1.7 – Classificateur Auxiliaire GAN (ACGAN) [2]

1.3.7 Pyramide laplacienne des réseaux GAN (LAPGAN)

Il a été proposé pour la production d'image à plus haute résolution à partir d'un GAN d'entrée à plus faible résolution. c'est une approche de codage d'image qui utilise une cascade de CNN.

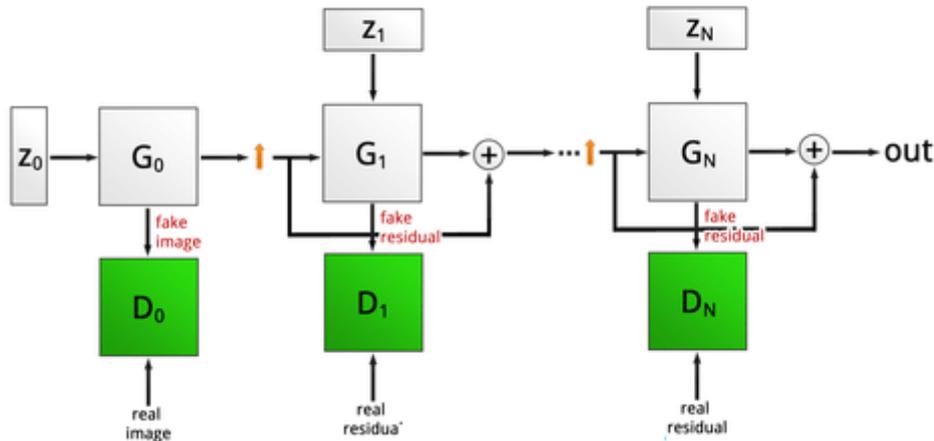


FIGURE 1.8 – Pyramide laplacienne des réseaux GAN (LAPGAN) [6]

1.3.8 GAN à Convolution Profonde (DCGAN)

Il applique une architecture de réseau neuronal déconvolutif pour G. Il y a quelque modification dans l'architecture de DCGAN par rapport au FCGAN d'origine, notamment dans la résolution de modélisation qualifiée de haute et dans la formation de stabilisation. Dans ce modèle, toutes les couches de regroupement sont remplacées par des convolutions à fouler pour D et des convolutions à foulée fractionnaire pour G.

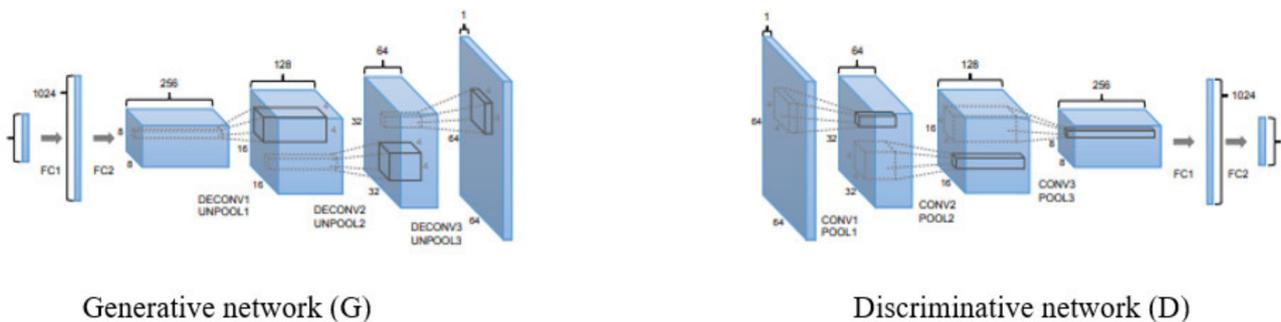


FIGURE 1.9 – GAN à Convolution Profonde (DCGAN) [7]

1.3.9 GAN avec un Equilibre aux limites(BEGAN)

Il utilise une architecture basée sur l'auto-encodeur pour le discriminateur D. La perte de l'auto-encodeur peut être générée pour G et D. l'objectif, lors de la

formation de l'auto-encodeur(D), est de maximiser à la fois la perte de reconstruction des images réelles et la perte de reconstruction pour les images générées.

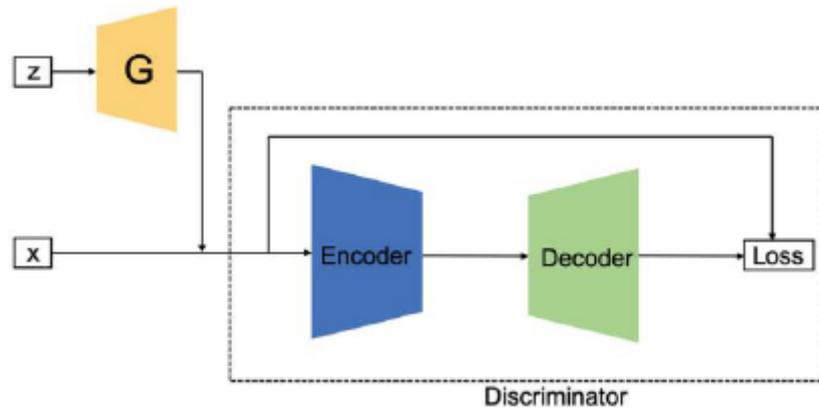


FIGURE 1.10 – GAN avec un Equilibre aux limites(BEGAN) [8]

1.3.10 GAN à croissance progressive (PROGAN)

Il implique des étapes progressives vers l'expansion de l'architecture du réseau. Il utilise l'idée de neurones progressifs, cette technologie ne souffre pas de l'oubli et elle est capable de déployer des connaissances antérieures via des connexions latérales aux caractéristiques précédemment apprises.

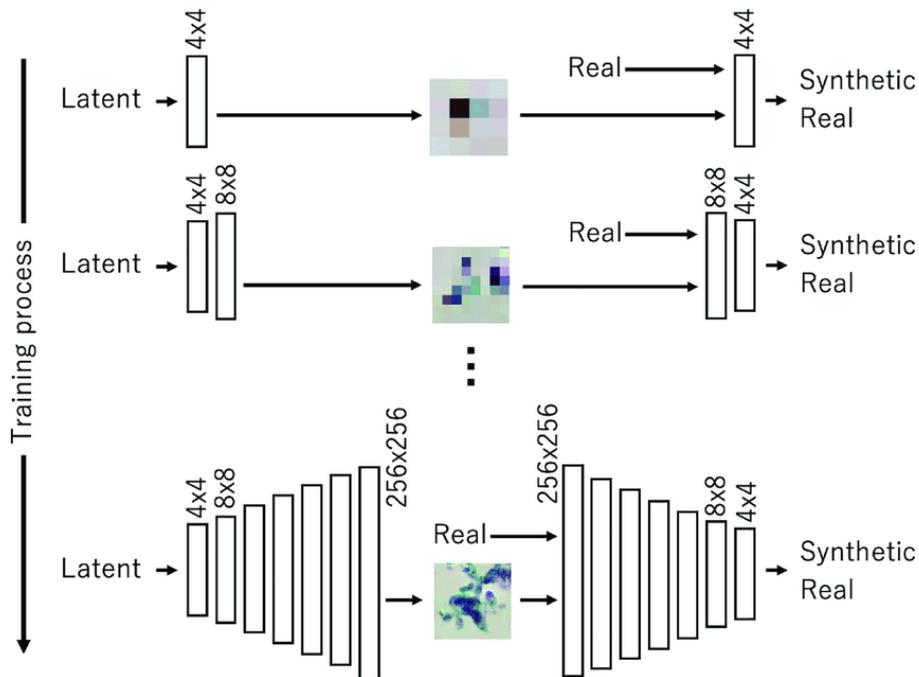


FIGURE 1.11 – GAN à croissance progressive (PROGAN) [9]

1.3.11 Auto-attention GAN (SAGAN)

Les GAN basés sur CNN ont des difficultés à apprendre des ensembles de données d'image multi-classe(ex : ImgeNet). Il déploie un mécanisme d'auto-attention dans la conception des architectures de D et G. Il est capable d'apprendre des dépendances globales à longue portée pour générer des images.

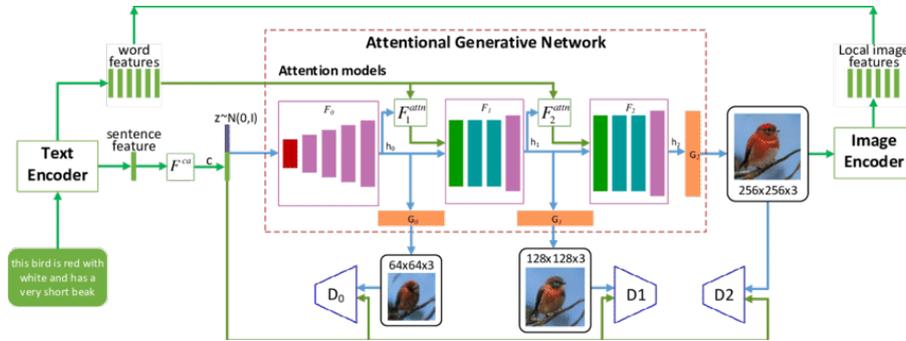


FIGURE 1.12 – Auto-attention GAN (SAGAN) [10]

1.3.12 BigGAN

Ce modèle est une extension du SAGAN afin de résoudre les problèmes liés aux données multi-classes. Dans BigGAN, une distribution gaussienne est utilisée pendant la formation et une gaussienne tronquée est utilisée pendant l'inférence. BigGAN passe par plusieurs opérations pour mettre à l'échelle l'architecture :

- Module d'auto-attention et perte de charnière.
- Information conditionnelle de classe.
- Mettre à jour le discriminateur plus que le générateur.
- Moyenne mobile des poids du modèle.
- Utilisation de certaines opérations sur les réseaux.

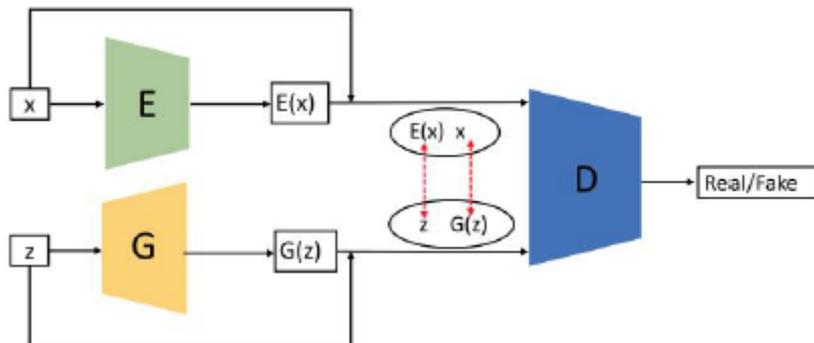


FIGURE 1.13 – BigGAN [10]

1.3.13 rGAN à bruit d'étiquette

Ce modèle a été proposé par KANEKO [11] appelé label-noise rGANs. Il intègre un modèle de transition de bruit capable d'apprendre une distribution générative conditionnelle d'étiquette propre, même lorsqu'il est fourni avec des étiquettes d'apprentissage qui sont bruitées.

1.3.14 YLGAN

Les auteurs de ce modèle ont introduit une nouvelle couche d'attention locale clairsemée qui préserve la géométrie bidimensionnelle et la localité [12]. Pour montrer l'applicabilité de l'idée, ils remplacent la couche d'attention dense de SAGAN par une nouvelle construction. Les principales innovations sont :

- Les schémas d'attention sont bien pris en charge par le cadre théorique de l'information des graphes de flux d'information.
- temps de formation a été réduit d'environ 40%.
- Ils ont fait en sorte que le processus d'inversion naturel consistant à effectuer une descente de gradient sur le travail de perte pour des modèles plus grands plutôt que des travaux antérieurs sur de petits GAN.

1.3.15 Auto GAN

L'auto GAN introduit l'algorithme de recherche d'architecture neuronale (NAS) dans les réseaux antagonistes génératifs (GAN). L'espace de recherche des variations architecturales du générateur est guidé via un RNN avec partage de paramètres et réinitialisation dynamique pour accélérer le processus. Les auteurs pensent qu'il reste encore deux problèmes critiques à résoudre :

- l'espace de recherche de générateur est limité et la stratégie de recherche du discriminateur n'est pas discuté.
- Auto GAN n'a pas encore été testé sur des ensembles de données de génération d'image haute résolution.

1.3.16 MSG-GAN

MSG-GAN est proposé comme un moyen de traiter le problème les gradients passant du discriminateur au générateur deviennent non informatifs lorsqu'il n'y pas suffisamment de chevauchement dans les supports des distributions réelles et fausses selon KARNEWAR.

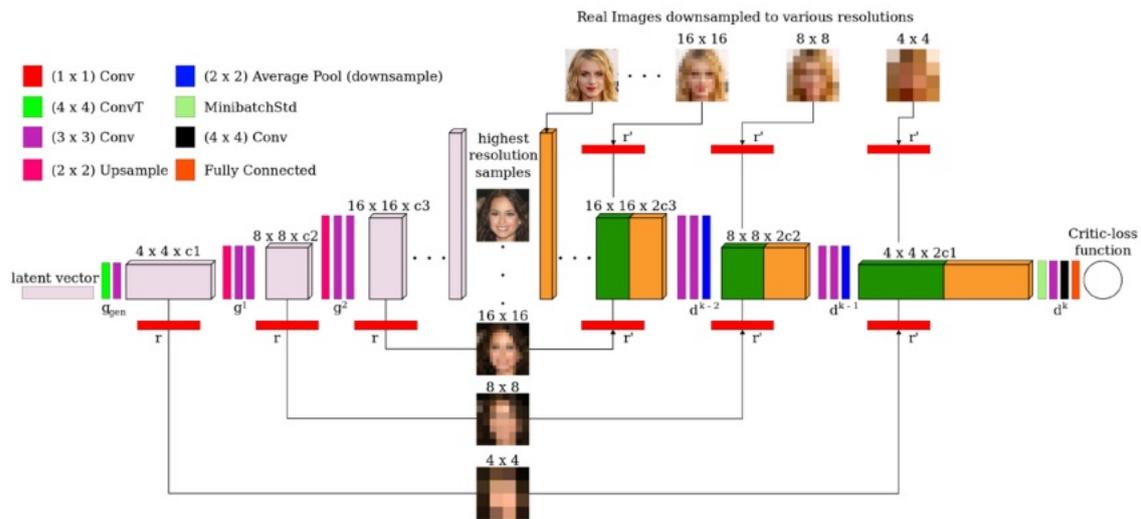


FIGURE 1.14 – MSG-GAN [13]

1.4 Les GAN à variation de perte

C'est une autre alternative de conception dans les GAN qui a un impact significatif sur les performances et le choix de la fonction de perte. Les GAN à variation de perte ont fait l'objet de recherches approfondies pour améliorer la stabilité des GAN et plus précisément dans l'entraînement[14].

1.4.1 GAN de Wasserstein

WGAN a résolu avec succès les deux problèmes posés avec le GAN original en utilisant la distance Earth mover (EM) ou Wasserstein-1 comme mesure de perte pour l'optimisation[15].

1.4.2 WGAN-GP

Même s'il a été démontré que WGAN réussit à améliorer la stabilité de la formation GAN, il n'est pas bien généralisé pour un modèle plus profond. Expérimentalement, il a été déterminé que la plupart des paramètres WGAN sont localisés à $-0,01$ et $0,01$ en raison de l'écrêtage des paramètres. WGAN-GP a été proposé en utilisant une pénalité de gradient pour la perte modifiée pour le discriminateur.

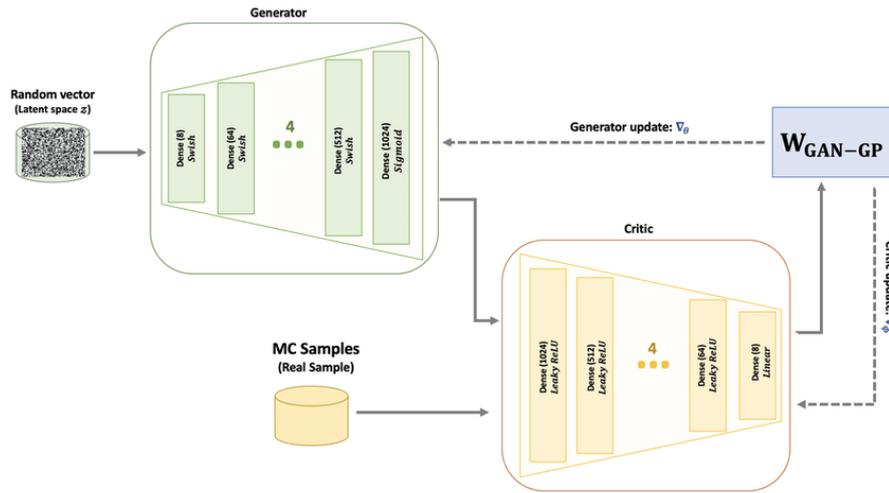


FIGURE 1.15 – WGAN-GP [16]

1.4.3 GAN des moindres carrés (LSGAN)

Le GAN des moindres carrés (LSGAN) est une nouvelle approche proposée pour remédier au problème du gradient de fuite pour G du point de vue de la frontière de décision déterminée par le discriminateur[17].

1.4.4 f-GAN

Le f-GAN fonctionne sur la base que les GAN peuvent être entraînés en utilisant la f-divergence qui mesure la différence entre deux distributions de probabilité[18].

1.4.5 GAN déroulé(UGAN)

Unrolled GAN (UGAN) est une conception proposée pour résoudre le problème de l'effondrement de mode pour les GAN pendant la formation. L'innovation de conception de base d'UGAN est l'ajout d'un terme de gradient pour la mise à jour G, qui a la capacité de capter les réponses du discriminateur à un changement du générateur.

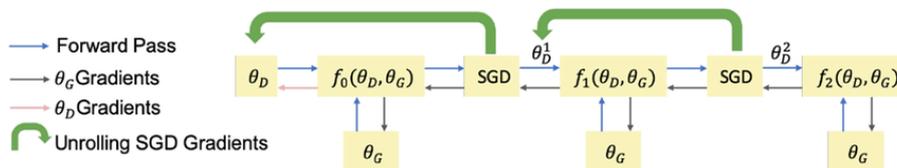


FIGURE 1.16 – Unrolled GAN (UGAN) [19]

1.4.6 GAN sensible aux pertes (LS-GAN)

LS-GAN est introduit pour entraîner le générateur à produire des échantillons réalistes en minimisant les marges désignées entre les échantillons réels et géné-

rés[17].

1.4.7 Mode Regularized GAN

Mode Regularized GAN propose une métrique de régularisation pour pénaliser les modes manquants, qui est ensuite utilisée pour résoudre le problème d'effondrement de mode. L'idée clé derrière ce travail est l'utilisation d'un codeur $E(x)$ pour produire la variable latente z pour G au lieu d'utiliser du bruit[20].

1.4.8 GAN géométrique

La fonction de perte pour les GAN géométriques peut être dérivée via un autre moyen en minimisant la perte de charnière. L'efficacité de la perte de charnière permet de traiter le problème de grande dimension et de faible taille d'échantillon[21].

1.4.9 GAN relativiste (RGAN)

Le GAN relativiste (RGAN) est proposé comme approche générale pour concevoir de nouvelles fonctions de coût à partir de la fonction existante, c'est-à-dire qu'il peut être généralisé à tous les GAN IPM. Le discriminateur dans le GAN d'origine mesure la probabilité pour un échantillon réel donné ou un échantillon généré.

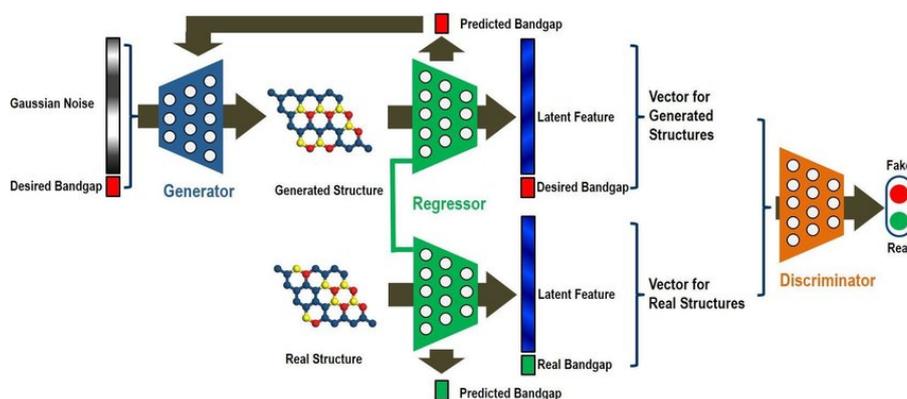


FIGURE 1.17 – GAN relativiste (RGAN) [22]

1.4.10 SN-GAN

SN-GAN propose l'utilisation de la normalisation des poids pour entraîner le discriminateur de manière plus stable. Cette technique est légère en calcul et facilement applicable aux GAN existants. Des travaux antérieurs pour stabiliser l'entraînement des GAN soulignent l'importance que D soit issu de l'ensemble des fonctions continues de K -Lipshitz[23].

1.4.11 Réaliste GAN

Dans la conception originale du GAN, le discriminateur ne produit que 0 et 1, c'est-à-dire vrai et faux au lieu d'une distribution continue comme mesure de la réalité. Xiangli et al. proposent le RealnessGAN pour aborder cette nouvelle perspective, qui traite la réalité comme une variable aléatoire qui peut être estimée à partir des angles multiples[24].

1.4.12 Sphère GAN

Sphere GAN est un nouveau GAN basé sur l'IPM, qui utilise l'hypersphère pour lier les IPM dans la fonction objective, ce qui peut faciliter la stabilité de la formation.

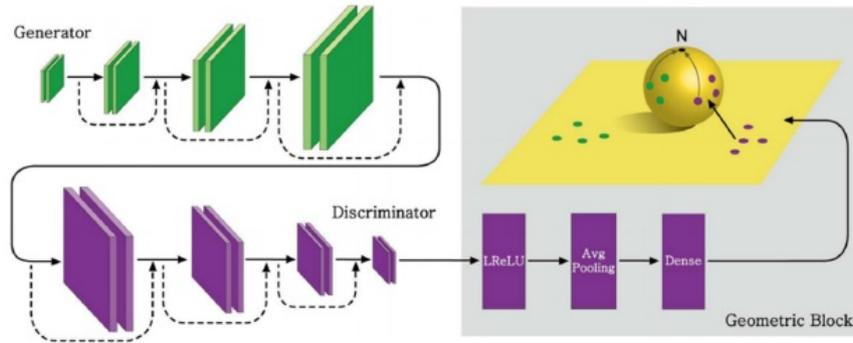


FIGURE 1.18 – Sphère GAN [25]

1.4.13 GAN auto-supervisé (SS-GAN)

Bien que le GAN conditionnel ait obtenu un grand succès dans la synthèse d'images naturelles. Le principal inconvénient des GAN conditionnels est la nécessité de données étiquetées. Il est nécessaire d'exploiter des GAN auto-supervisés par formation contradictoire pour combler le fossé entre les GAN conditionnels et inconditionnels.

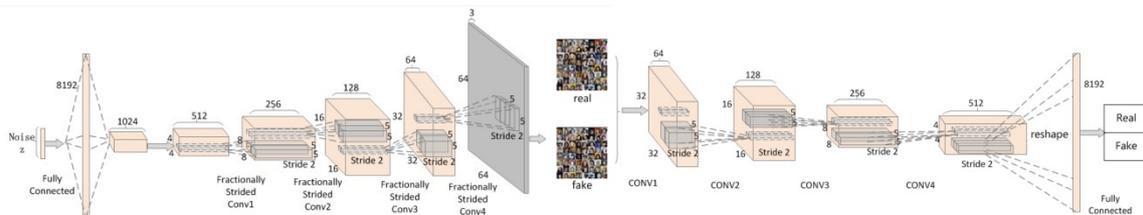


FIGURE 1.19 – SS-GAN [26]

1.5 Conclusion

Nous avons abordé dans ce chapitre les différentes techniques GAN utilisées pour l'augmentation des données dans les datasets. Les GAN ont montré leurs efficacités par rapport à d'autres méthodes pour la génération de données synthétiques qui se rapproche de plus en plus de la réalité. Ce pendant, malgré le nombre important de modèles et de variante, les GAN peuvent subir un effondrement de l'apprentissage si le générateur trouve une faille dans le discriminateur. En plus des difficultés d'apprentissage, les sorties générées sont peu variées.

Chapitre 2

Augmentation des données : Application aux bases des plantes

2.1 Introduction

La société humaine doit augmenter sa production alimentaire d'environ 70 % d'ici 2050 pour nourrir une population attendue qui devrait dépasser 9 milliards de personnes. Actuellement, contagieux les maladies réduisent le rendement potentiel de 40 % en moyenne avec de nombreux agriculteurs dans les pays en développement connaissant des pertes de rendement pouvant atteindre 100 %. La diffusion généralisée des smartphones parmi les cultivateurs du monde entier avec 7 milliards de smartphones attendus d'ici 2023 le potentiel de transformer le smartphone en un outil précieux pour diverses communautés en pleine croissance aliments. Une application potentielle est le développement de diagnostics mobiles de maladies par apprentissage automatique.

2.2 Contexte et Résumé

Peut-être que la plus grande avancée technologique que l'homme ait jamais faite a été la domestication des plantes lors de la révolution agricole il y a 8-12 000 ans sur plusieurs sites dans le monde [27]. Ces événements ont créé des civilisations grâce à la constante, apport calorique prévisible qui pourrait être obtenu avec des quantités d'énergie de plus en plus faibles dépensées par le travail humain. L'énorme augmentation de la population humaine d'environ 1 milliard au début des années 1800 à notre situation actuelle de plus de 7,2 milliards a été rendue possible par une et une base agricole productive[28].

Cependant, cet apport constant de calories est actuellement menacé, car bon nombre des avancées résultant de la révolution verte des années 1950 sont échec en raison de maladies infectieuses et de ravageurs propagés par la mondialisation et aggravés par le climat changement[29].

De nombreuses histoires ont enregistré l'énorme impact que les maladies in-

fectieuses ont eu sur cultures vivrières[30]. L'exemple emblématique est la famine irlandaise de la pomme de terre de 1845-49 où une dépendance excessive à l'égard d'une seule culture avec peu de diversité génétique a ouvert la voie à une baisse de rendement qui a entraîné 1,2 million de décès sur une population de 9 millions [31]. A l'époque, les maladies des plantes étaient peu étudiées et la famine irlandaise de la pomme de terre est largement répandue.

Identifié comme l'événement qui a lancé la discipline scientifique des maladies des plantes[32]. Il marque également le système formel de vulgarisation où les connaissances scientifiques sont fournies aux agriculteurs par des agents de vulgarisation employés par l'État [33]. Dans l'intervalle 170 années, la pathologie végétale s'est développée pour devenir une discipline solide offrant aux producteurs de cultures de multiples des solutions allant de la lutte chimique au génie génétique en passant par la lutte intégrée contre les ravageurs. Au même Au fil du temps, des systèmes de vulgarisation formalisés se sont également développés pour fournir des connaissances aux producteurs.

Cependant, le fait que l'approvisionnement alimentaire mondial soit réduit chaque année en moyenne de 40% [34] démontre que notre combat collectif contre les maladies et les ravageurs des plantes cultivées n'est pas gagné. En effet, l'émergence et la propagation de nouvelles maladies des cultures très virulentes comme la rouille de la tige UG99 qui attaque le blé, la cabosse noire du cacao et les infections virales du manioc suggèrent que la situation peut en fait s'aggraver. C'est troublant à un moment où la FAO des Nations Unies nous recommande doit en effet augmenter l'offre alimentaire de 70% pour nourrir la population future.

Dans les pays à revenu élevé, où l'approvisionnement alimentaire est actuellement n'est pas un problème, un coup d'œil rapide aux médias montre un niveau de préoccupation de plus en plus élevé au sujet de la production alimentaire, et de nombreuses personnes expriment un malaise face à la domination du "Big Ag", l'attention accrue sur les monocultures (par exemple le maïs) pour la production de viande et les biocarburants, ainsi que sur les OGM [29]. Depuis les années 1980, ils ont assisté à une augmentation du nombre de petits exploitants agricoles qui cherchent à promouvoir diverses pratiques et cultures[35]. Reconnaissant cela, les institutions de santé publique encouragent de plus en plus les consommateurs à cultiver leur propre nourriture, car le processus de culture des aliments (exercice par le biais du jardinage) et le rendement (fruits et légumes frais) contribuent à des résultats bénéfiques pour la santé publique. En effet, le jardinage, et le jardinage urbain en particulier, est devenu de plus en plus populaire au cours des deux dernières décennies, inversant une longue tendance selon laquelle les consommateurs s'impliquent de moins en moins dans la culture de leur nourriture. À l'échelle mondiale, Google Trends capture cela et signale une augmentation constante de l'intérêt pour le "jardinage urbain".

Alors que de nombreuses communautés dans les pays à revenu élevé choisissent de cultiver des aliments à petite échelle, une telle agriculture à petite échelle est la norme dans les régions les plus pauvres du monde. C'est une nécessité imposée plutôt qu'un choix. Dans de nombreux pays (par exemple ceux d'Afrique subsaharienne), jusqu'à 80% de la population sont des agriculteurs avec des familles individuelles cultivant diverses cultures sur de petites parcelles (2-5 hectares) avec un minimum d'intrants mécaniques ou chimiques (engrais, pesticides) [36].

À cette échelle, l'impact relatif des écarts de rendement (l'écart entre le rendement potentiel et le rendement réel) est très élevé [33]. Un coin constant réduisant notre capacité à combler cet écart est les maladies infectieuses et les ravageurs. Étant donné que la majeure partie de l'agriculture de subsistance se produit aujourd'hui autour des tropiques et que la biodiversité de toutes les maladies infectieuses (humaines, animales et végétales) est plus élevée sous les tropiques, la pression des maladies est alors la plus élevée dans ces régions. Il est courant que les petits exploitants agricoles perdent régulièrement 80 à 100 % d'une récolte donnée à cause des ravageurs et des maladies[34].

2.3 La base des plantes et maladies

Nous avons trouvé plusieurs bases de données disponibles sur l'Internet, notamment : Nouvel dataset sur les maladies des plantes, dataset de semis de plantes V2, plantVillage, dataset sur les plantes riz, plant pathology apple dataset . . .etc. Nous avons choisie d'appliquer l'augmentation sur plantVillage dans le cadre d'un projet de recherche au niveaux du laboratoire LabStic.

2.3.1 PlantVillage

Ces dernières années, Une plate forme en ligne dédiée à la santé et aux maladies des cultures, appelée PlantVillage (disponible sur www.plantvillage.org) a été fondée. Cette plate-forme a été modelée sur les plates-formes en ligne populaires dans le domaine de la programmation informatique, y compris Stack Overflow (www.stackoverflow.com), un forum communautaire où tout le monde peut poser et répondre à des questions liées à la programmation. En fournissant des réponses qui sont votées par la communauté, les utilisateurs peuvent construire une réputation en ligne, capturée par un score numérique. Plus le score est élevé, plus un utilisateur obtient de droits sur la plateforme.

Ce modèle, qui a très bien fonctionné dans de nombreux contextes différents, a également réussi dans PlantVillage, et la plateforme a vu son trafic augmenter de 250 % d'une année sur l'autre. À l'automne 2015, la plateforme accueillait le 2 millionième visiteur du site.

En plus de cette résolution de problèmes participative, ils ont également créé une bibliothèque d'informations en libre accès sur plus de 150 cultures et plus de 1 800 maladies, accessibles sur le même site Web. Ce contenu a été rédigé par des experts en phytopathologie, reflétant des informations provenant de la littérature scientifique. Cependant, comme le site s'adresse directement aux producteurs d'aliments, plutôt qu'aux phytopathologistes professionnels, un grand soin a été apporté à la rédaction du contenu d'une manière facile à comprendre. Actuellement, la plupart du contenu est écrit en anglais, mais ils ont récemment commencé à le traduire en français, espagnol et portugais.

Bien que le diagnostic de maladie assisté par l'homme soit un outil puissant, nous pensons que le potentiel du diagnostic de maladie assisté par machine a un énorme potentiel. Le phénotypage de la maladie, lorsqu'il est effectué par des humains, implique généralement une analyse visuelle de la présentation de la maladie sur la plante. Pour certains phénotypes visuels, l'identification de la maladie par des repères visuels est simple ; pour d'autres, cela peut être plus difficile. Néanmoins, le diagnostic visuel, si possible, nécessite jusqu'à présent l'homme. Cependant, malgré le défi de la santé des cultures sur une planète de plus en plus peuplée (sécurité alimentaire), l'investissement dans la formation des phytopathologistes n'a pas augmenté en conséquence, et a même souvent diminué[37].

2.3.2 Motivation

Si un diagnostic visuel (par un humain) est possible, alors les outils informatiques devraient, en principe, être en mesure de soutenir le diagnosticien humain. Dans de nombreux cas, un outil de diagnostic informatique serait en effet le seul moyen d'obtenir un diagnostic, en raison de l'absence d'aide d'experts dans de nombreuses régions du monde. Même là où l'expertise en diagnostic humain est disponible, sa mise à l'échelle pour répondre à la demande mondiale n'est pas anodine. Depuis les années 1980, la FAO des Nations Unies a promu les écoles pratiques d'agriculture qui se sont concentrées sur l'amélioration de la santé des cultures dans les pays en développement [38]. Plus récemment, les efforts de la Plantwise Clinic de CABI ont entrepris des efforts similaires [39]. Bien que les deux soient excellents, ils ne sont pas évolutifs sans le type d'investissement observé dans les pays développés il y a 150 ans [33]. Cela implique qu'un système informatique qui pourrait aider au diagnostic des maladies, seul ou en tant que support, serait à la fois extrêmement bénéfique et intrinsèquement évolutif s'il était fourni en ligne. Un tel système nécessiterait la capacité de reconnaître une maladie à partir d'une image, et serait donc un système de reconnaissance d'image basé sur l'intelligence artificielle.

2.3.3 Collecte et construction

Toutes les images de la base de données PlantVillage ont été prises dans des stations de recherche expérimentales associées aux universités Land Grant aux États-Unis (État de Penn, État de Floride, Cornell et autres). Des stations de recherche expérimentales (publiques et privées) offrent la possibilité de prendre de nombreuses images en un temps réduit. La majorité des images ont été prises par deux techniciens travaillant en équipe.

À partir d'essais au champ de cultures infectées par une maladie, les techniciens récoltaient les feuilles en les retirant de la plante. Les feuilles étaient ensuite placées sur une feuille de papier qui fournissait un fond gris ou noir. Toutes les images ont été prises à l'extérieur en pleine lumière. La lumière peut être un fort soleil ou un nuage et ils ont intentionnellement recherché une gamme de conditions, car l'utilisateur final (producteur avec un smartphone) prendra finalement des images dans une gamme de conditions. Pour chaque feuille, ils ont généralement pris 4 à 7 images avec un appareil photo compact standard utilisant le mode automatique est un appareil photo numérique standard (Sony DSC - Rx100/13 20,2 mégapixels). Pour les cultures telles que le maïs (*Zea mays*) et la courge (*Cucurbita* spp.), les feuilles étaient trop grandes pour être capturées dans une seule image tout en conservant des vues de proximité à haute résolution. Dans ces cas, des images de différentes sections de la même feuille ont été prises. Une fois les images collectées, elles ont été modifiées en recadrant une grande partie de l'arrière-plan et en orientant toutes les feuilles de manière à ce qu'elles pointent vers le haut[40].

2.3.4 Enregistrements des Données

Les enregistrements des données contiennent 54 309 images. Les images couvrent 14 espèces des cultures : pomme, myrtille, cerise, maïs, raisin, orange, pêche, poivron, pomme de terre, framboise, soja, courge, fraise, tomate. La base contient des images de 17 maladies fongiques, 4 maladies bactériennes, 2 maladies de moisissures (oomycètes), 2 maladies virales et 1 maladie causée par un acarien. 12 espèces de cultures ont également des images de feuilles saines qui ne sont pas visiblement affectées par une maladie. Les enregistrements des données sont disponibles sur le site Web www.plantvillage.org.

2.3.5 Techniques de Validation

La validation des maladies se fait en demandant aux phytopathologistes experts de déterminer les états pathologiques. Ces experts intervenaient directement sur le terrain avec les deux techniciens réalisant le diagnostic. Les états ont été

déterminés sur la base d'approches de phénotypage standard utilisées par les phytopathologistes. Dans de nombreux cas, les experts avec lesquels ils ont travaillé ont directement infecté la culture en utilisant des approches expérimentales standard en phytopathologie. Dans ces cas, le diagnostic était facile. Dans certains cas, les maladies sont survenues dans des parcelles sentinelles que les stations de recherche expérimentale entretiennent afin d'identifier la présence d'une maladie dans une région donnée. Dans ces cas, le diagnostic a de nouveau été fait par l'expert. Nous conservons toutes les images dans la base de données PlantVillage en utilisant le diagnostic des experts. Seules les feuilles identifiées de manière experte sont présentes dans la base de données.

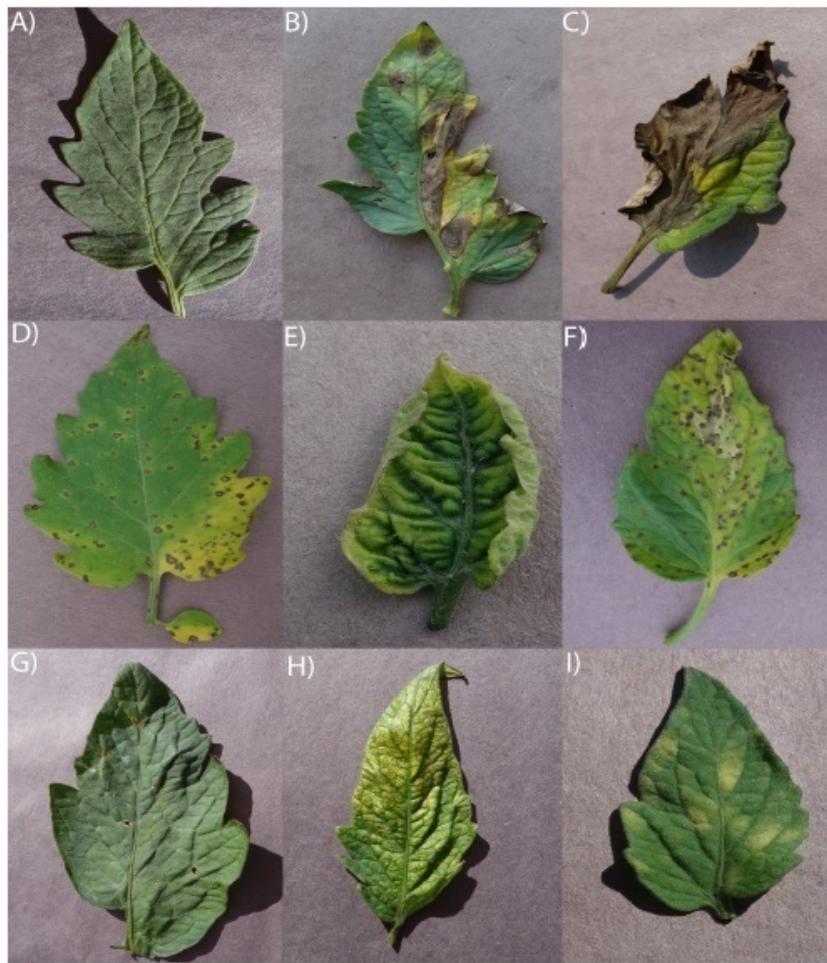


FIGURE 2.1 – Exemples de différents phénotypes de plants de tomates : A)Feuille saine B)Alternariose(*Alternaria solani*)C)Mildiou(*Phytophthora Infesrans*) D)Tache septorienne(*Soptoria lycopersici*)E)Virus de l'enroulement des feuilles jaunes(Famille Geminiviride gene Begomovirus) F)Bactérien Tache(*Xanthomonas campestris pv.vesicatoria*) G)Tache cible(*Corynespora cassiicola*)H)Dégâts du tétranyque(*Tetranychus urticae*)

2.4 CycleGan

Son objectif est similaire au pix2pix, soit, pouvoir générer à partir d'une image sa transformation dans un autre domaine. En effet, une des particularités du CycleGan est d'apprendre conjointement, entre deux domaines d'images (A et B, par exemple photographies et dessins), une transformation de A vers B et une transformation de B vers A. Dès lors, CycleGan sera encouragé pendant son apprentissage à transformer un élément de A vers B, puis à transformer le résultat de B vers A[41].

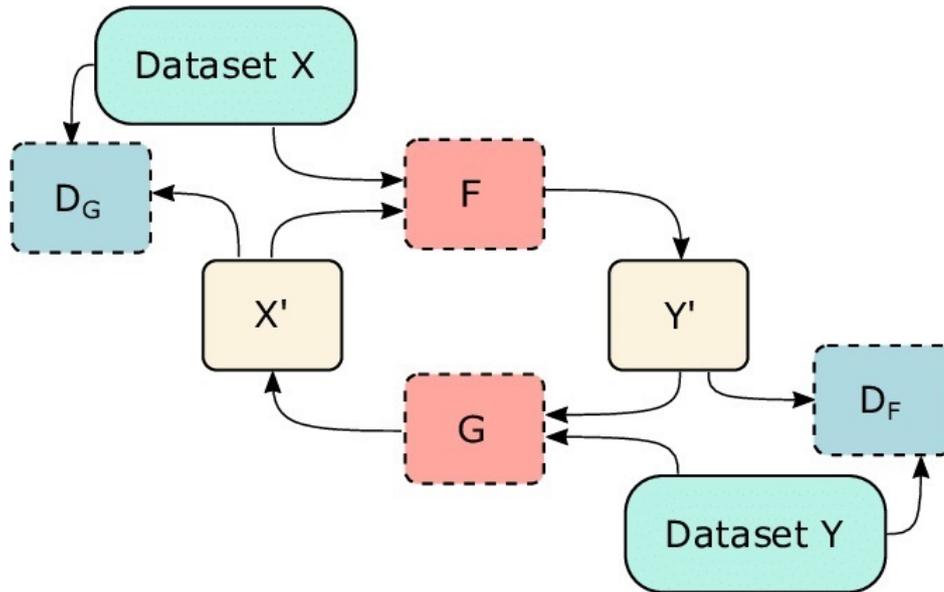


FIGURE 2.2 – Architecture de CycLeGAN

2.4.1 Modélisation

Supposons que nous ayons deux domaines, X et Y, avec pour chacun un grand nombre d'éléments sans correspondance directe d'un élément vers l'autre[42]. L'idée va être de mettre en place deux architectures de Générative Adversarial Network (GAN), chacune cherchant à générer un élément d'un domaine vers l'autre. Nous aurons ainsi :

- Du domaine X vers le domaine Y, un générateur G et un discriminateur DY
- Du domaine Y vers le domaine X, un générateur F et un discriminateur DX.

Dans la figure 2.3.a, le modèle contient deux fonctions d'application $G : X \implies Y$, et les discriminateurs adverses associés D_y et D_x . D_y encourage G à traduire x en sorties indiscernables du domaine Y, et vice versa pour D_x et F. Pour régulariser davantage les mappages, deux pertes de cohérence de cycle sont introduit pour capturer l'intuition. Ainsi, si on traduit d'un domaine à l'autre et vice versa on devrait arriver la ou on à dit. Dans la figure 2.3.b, il y a une perte de cohérence

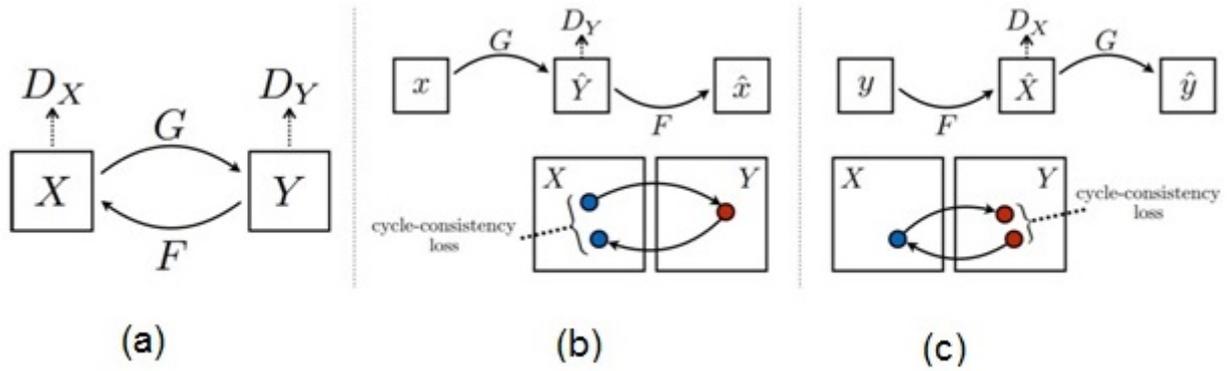


FIGURE 2.3 – Modélisation de CycLeGAN

de cycle avant : $x \rightarrow G(x) \rightarrow F(G(x)) \approx x$ et dans la figure 2.3.c, la perte de cohérence de cycle de mot en retour : $y \rightarrow F(y) \rightarrow G(F(y)) \approx y$

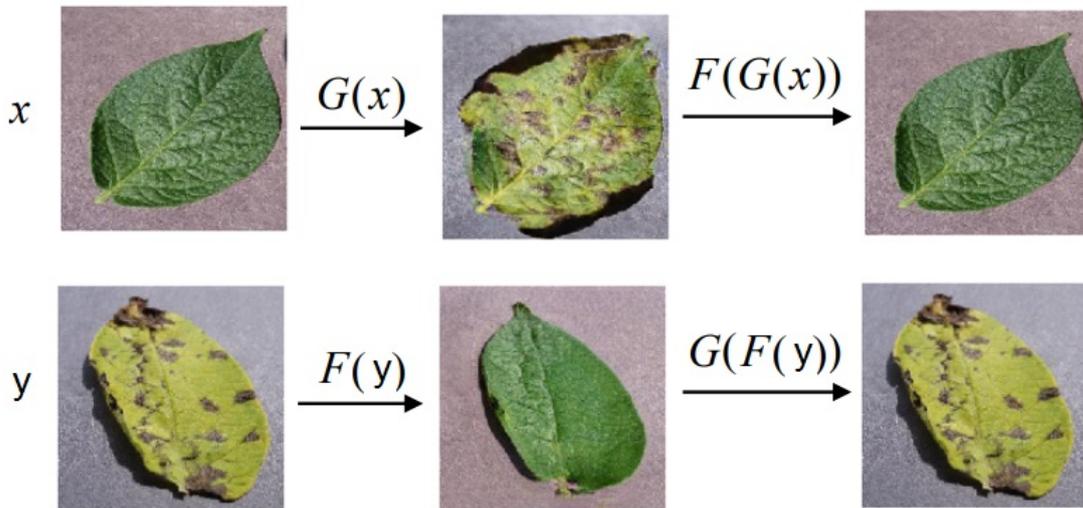


FIGURE 2.4 – Perte de cohérence

2.4.2 Motivation

Dans la littérature, la plupart des méthodes utilisent une formation supervisée, avec un accès à (x, y) paires d'images correspondantes des deux domaines que nous voulons apprendre à traduire entre eux. CycleGAN est intéressant, car il ne nécessitait pas de données d'entraînement appariées. Les données appariées sont plus difficiles à trouver dans la plupart des domaines, et même impossibles dans certains, les capacités de formation non supervisées de CycleGAN sont très utiles[43].

2.5 Augmentation des données

L'algorithme d'augmentation d'image a été utilisé pour augmenter le nombre de certaines images en raison de l'ensemble de données déséquilibré et pour augmenter la robustesse du modèle.

Les schémas d'augmentation conventionnels tels que le flou moyen, la rotation, l'affinement, la traduction, la découpe, le redimensionnement, etc., ainsi qu'un réseau contradictoire génératif ont été utilisés.

Le réseau antagoniste génératif (GAN) est un modèle d'apprentissage automatique qui peut apprendre à imiter une distribution donnée de données.

GAN se compose de deux modèles de réseaux de neurones distincts : un modèle génératif et un modèle discriminatif. Le modèle discriminatif apprend à classer les entrées dans sa classe et dans GAN, il s'agit d'un classificateur binaire pour déterminer si une image donnée est une image réelle de l'ensemble de données réel ou une image créée artificiellement. Le modèle génératif apprend la distribution des données d'apprentissage, il s'agit d'un générateur de données pour transformer les valeurs d'entrée en images via un réseau neuronal déconvolutif. Le but du générateur est de générer les nouvelles images que le discriminateur ne peut pas distinguer des images réelles et le but du discriminateur est de distinguer correctement les images réelles des fausses images créées par le générateur. Depuis la première publication du GAN [44], de nombreux types de GAN ont été développés.

Dans ce projet, le CycleGAN, l'un des modèles GAN conditionnels, a été utilisé pour augmenter les données d'image pour la détection des maladies et c'est l'algorithme de traduction d'image à image sans avoir besoin d'exemples appariés de transformation de la source au domaine cible [<https://junyanz.github.io/CycleGAN/>].

Il peut transformer l'image d'un domaine à un autre sans mappage un à un entre le domaine source et le domaine cible. Par exemple, il peut générer une image de feuille malsaine à partir du domaine d'image de feuille saine et l'image de feuille saine est également générée à partir du domaine d'image de feuille malsaine. Notre ensemble de données était très déséquilibré. Cela signifie que le nombre d'images des classes spécifiques est beaucoup plus petit que les autres et cela peut entraîner un biais dans le modèle.

À l'aide de CycleGAN, les images des classes spécifiques ont été générées et transmises au modèle pour résoudre le problème de déséquilibre.

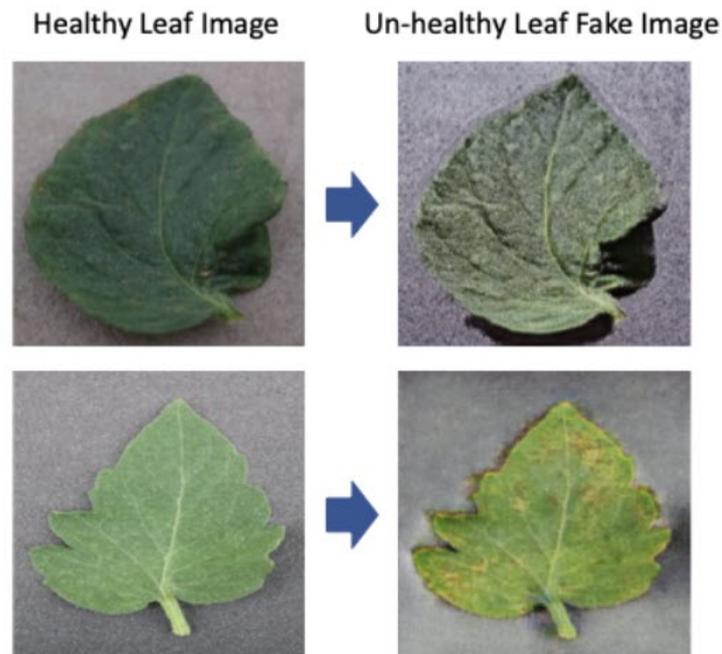


FIGURE 2.5 – Exemples des images générés à l'aide de CycLeGAN

2.6 GoogLeNet

2.6.1 Description

GoogLeNet est choisi comme nom d'équipe dans la compétition ILSVRC14. Ce nom est un hommage à Yann LeCun, pionnier du réseau LeNet 5 .

Ils utilisent également GoogLeNet pour faire référence à l'incarnation particulière de l'architecture Inception utilisée dans la soumission pour le concours. Ils ont également utilisé un réseau Inception plus profond et plus large, dont la qualité était légèrement inférieure, mais l'ajouter à l'ensemble semblait améliorer légèrement les résultats.

Ils omettent les détails de ce réseau, puisque les expériences ont montré que l'influence des paramètres architecturaux exacts est relativement mineure. Ici, l'instance particulière la plus réussie (nommée GoogLeNet) est décrite dans la figure pour fins de démonstration. La même topologie (formée avec différentes méthodes d'échantillonnage) a été utilisée pour 6 des 7 modèles de l'ensemble.

Toutes les convolutions, y compris celles à l'intérieur des modules Inception, utilisent une activation linéaire rectifiée. La taille du champ récepteur du réseau est de 224×224 en prenant des canaux de couleur RGB avec une soustraction moyenne. "3×3 réduites" et "5×5 réduites" représente le nombre de filtres 1×1 dans la réduction couche utilisée avant les convolutions 3×3 et 5×5 .

On peut voir le nombre de filtres 1×1 dans la couche de projection après le maxpooling intégré dans la colonne pool proj.

Le réseau a été conçu dans un souci d'efficacité informatique et de praticité,

taper	taille du patch/ foulée	production Taille	profondeur	#1×1	#3×3 réduire	#3×3	#5×5 réduire	#5×5	bassin projet	paramètres	-----
convolution	7×7/2	112×112×64	1							2.7K	34M
piscine maximale	3×3/2	56×56×64	0								
convolution	3×3/1	56×56×192	2		64	192				112K	360M
piscine maximale	3×3/2	28×28×192	0								
création (3a)		28×28×256	2	64	96	128	16	32	32	158K	128M
création (3b)		28×28×480	2	128	128	192	32	96	64	380K	304M
piscine maximale	3×3/2	14×14×480	0								
lancement (4a)		14×14×512	2	192	96	208	16	48	64	364K	73M
lancement (4b)		14×14×512	2	160	112	224	24	64	64	437K	88M
lancement (4c)		14×14×512	2	128	128	256	24	64	64	463K	100M
création (4d)		14×14×528	2	112	144	288	32	64	64	580K	119M
création (4e)		14×14×832	2	256	160	320	32	128	128	840K	170M
piscine maximale	3×3/2	7×7×832	0								
lancement (5a)		7×7×832	2	256	160	320	32	128	128	1072K	54M
lancement (5b)		7×7×1024	2	384	192	384	48	128	128	1388K	71M
piscine moyenne	7×7/1	1×1×1024	0								
abandon (40%)		1×1×1024	0								
linéaire		1×1×1000	1							1000K	1M
softmax		1×1×1000	0								

FIGURE 2.6 – Description de GoogLeNet

de sorte que l'inférence peut être exécuté sur des appareils individuels, y compris ceux dont les ressources de calcul sont limitées, en particulier avec une faible empreinte mémoire. Le réseau a une profondeur de 22 couches lorsque l'on ne compte que les couches avec paramètres (ou 27 couches si on compte aussi le pooling). Le nombre total de couches (blocs de construction indépendants) utilisées pour la construction du réseau est d'environ 100. Cependant, ce nombre dépend de l'infrastructure du système d'apprentissage automatique utilisé. L'utilisation de la mise en commun moyenne avant le classificateur est basée sur une couche linéaire supplémentaire. Cela permet d'adapter et d'affiner facilement les réseaux pour d'autres ensembles d'étiquettes. Il a été constaté qu'un passage de couches entièrement connectées à la mise en commun moyenne a amélioré la précision du top 1 d'environ 0.6 %. Mais l'utilisation de l'abandon est restée essentielle même après avoir retiré les couches entièrement connectées.

Compte tenu de la profondeur relativement importante du réseau, la possibilité de propager les gradients à travers toutes les couches de manière efficace était une préoccupation. Une idée intéressante est que la forte performance du réseau relativement moins profond sur cette tâche suggère que les caractéristiques produites par les couches dans le milieu du réseau devraient être très discriminantes. En ajoutant des classifieurs auxiliaires connectés à ces couches intermédiaires, on s'attendrait à :

- Encourager la discrimination dans les étages inférieurs du classifieur,
- Augmenter le signal de gradient qui se propage en retour

— Fournir une régularisation supplémentaire.

Ces classifieurs prennent la forme d'un réseau convolutif plus petit placés au-dessus de la sortie des modules Inception.

Pendant l'entraînement, leur perte s'ajoute à la perte totale du réseau avec un poids de remise (les pertes des classifieurs auxiliaires ont été pondérées par 0,3). À temps d'inférence, ces réseaux auxiliaires sont ignorés.

La structure exacte du réseau supplémentaire sur le côté, y compris le classifieur auxiliaire, est la suivante :

- Une convolution 1x1 avec 128 filtres pour la réduction de dimension et l'activation linéaire rectifiée.
- Une couche entièrement connectée avec 1024 unités et activation linéaire rectifiée.
- Une couche de suppression avec un taux de 70 % de sorties supprimées.
- Une couche linéaire avec softmax loss comme classifieur (prédisant les mêmes 1000 classes que le classifieur principal, mais supprimé au moment de l'inférence).

Une vue schématique du réseau résultant est illustrée à la figure 2.7[45].

2.6.2 Méthodologie de formation

Les réseaux ont été formés à l'aide du système d'apprentissage automatique distribué DistBelief en utilisant une quantité modeste de modèle et de parallélisme des données. Bien qu'uniquement une implémentation basée sur le processeur est utilisée, une estimation approximative suggère que le réseau GoogLeNet pourrait être entraîné à la convergence en utilisant quelques GPU haut de gamme en une semaine, la principale limitation étant l'utilisation de la mémoire. La formation a utilisé une descente de gradient stochastique asynchrone avec une impulsion de 0,9, un calendrier de taux d'apprentissage fixe (diminuant le taux d'apprentissage de 4% toutes les 8 époques). La moyenne de Polyak a été utilisée pour créer le modèle final utilisé au moment de l'inférence[45].

2.7 Conclusion

Nous avons présenté dans ce chapitre les différents concepts relatifs à notre objectif qui est l'augmentation de données des bases des plantes. Cette augmentation est importante vu la quantité limitée des images contenant des maladies des plantes. Nous avons présenté la base du sujet d'intérêt, ensuite présenté le générateur GAN proposé pour l'augmentation et finalement présenté l'un des réseaux convolutif le plus utilisés pour la classification des images. Ce dernier a pour rôle de tester l'efficacité des images générées dans la prise de décision du classifieur.

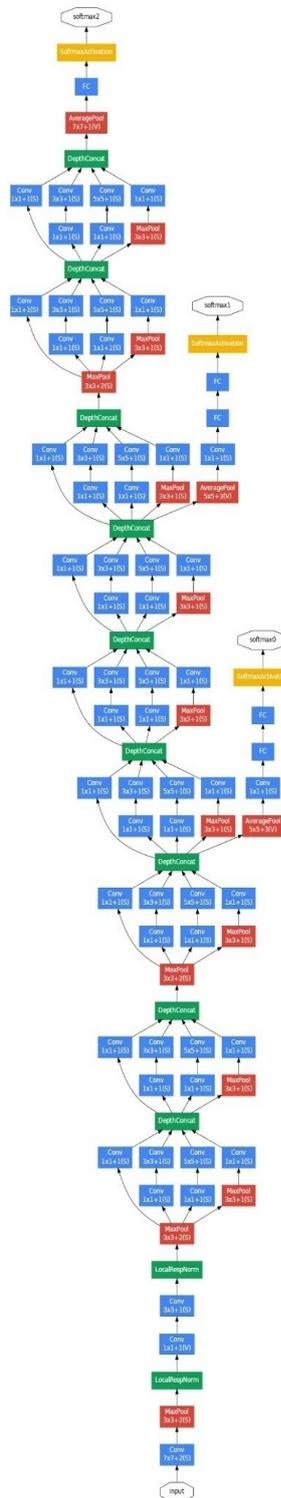


FIGURE 2.7 – Réseau GoogLeNet avec toutes les cloches

Chapitre 3

Génération et Valorisation des données

3.1 Introduction

Ce chapitre est destiné aux tests et aux résultats obtenus après avoir implémenté et exécuté le système GAN proposé sur la base de données Plantvillage.

3.2 Plan de travail expérimental

Nous avons suivi les étapes suivantes :

la première étape ces générés des images avec cyclegan pour chaque type de données choisies.

la deuxième étape ces appliqués GoogleNet sur les images réelles de chaque type et appliqués GoogleNet sur les images augmentées de chaque type et comparés les résultats des images réelles avec les résultats des images augmentées obtenus de chaque type .

3.3 Outils de développement :

Dans ce modeste travail, nous avons utilisé le langage de programmation Python, et cela est dû aux avantages et aux facilités qu'il apporte dans le domaine de l'apprentissage en profondeur. Nous avons utilisé plusieurs packages, dont `tensorflow.keras`, `Model` de `tensorflow.keras.models`, `Input`, `Dense`, `Activation`, `Flatten`, `Conv2D`, `concatenate`, `Sequential`, `BatchNormalization`, `AveragePooling2D` et `MaxPool2D` de `tensorflow.keras.layers`, `Adam` de `tensorflow.keras.optimizers`, `ImageDataGenerator` de `tensorflow.keras.preprocessing.image`, `binary_crossentropy` de `tensorflow.keras.losses`, `classification_report`, `confusion_matrix`, `ConfusionMatrixDisplay`, `plot_confusion_matrix` de `sklearn.metrics` et `matplotlib.pyplot`. Pour l'exécution nous avons utilisé google CoLab comme environnement d'exécution. Cela est dû aux possibilités qu'il offre, mais dans une mesure limitée.

3.4 Données

Notre ensemble de données comprend 4 sources représentant chacun un type de plante :

- Ensemble de données sur les tomates
- Ensemble de données sur les pommes
- Ensemble de données sur les maïs
- Ensemble de données sur les cerise



FIGURE 3.1 – Les 4 ensembles des données utilisé dans notre étude

3.5 Chargement des données :

Nous avons chargé 100 images de feuille saine (bonne santé(healthy)) et 200 images de feuille malsaine(unhealthy) de chaque ensemble de données pendant l'exécution du CycleGAN pour chaque type de feuille.

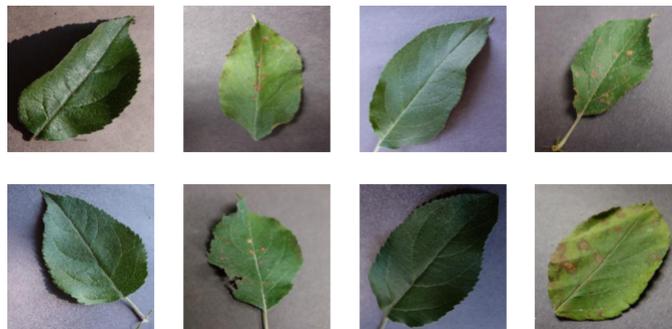


FIGURE 3.2 – Chargement de Pomme



FIGURE 3.3 – Chargement de Cerise



FIGURE 3.4 – Chargement de Mais



FIGURE 3.5 – Chargement de Tomate

3.6 Formation(training)

Nous avons entraîné le modèle 100 époques et dans chaque 8 époques, le modèle nous génère le résultat comme le montre les figures suivants :



FIGURE 3.6 – Formation de Pomme



FIGURE 3.7 – Formation de Cerise

3.7 Génération

Nous avons généré 200 images de feuille malsaine et 200 images de feuille saine pour chaque type .
 les résultats de la génération sont clairement visible dans les figures suivantes.



FIGURE 3.8 – Formation de Maïs

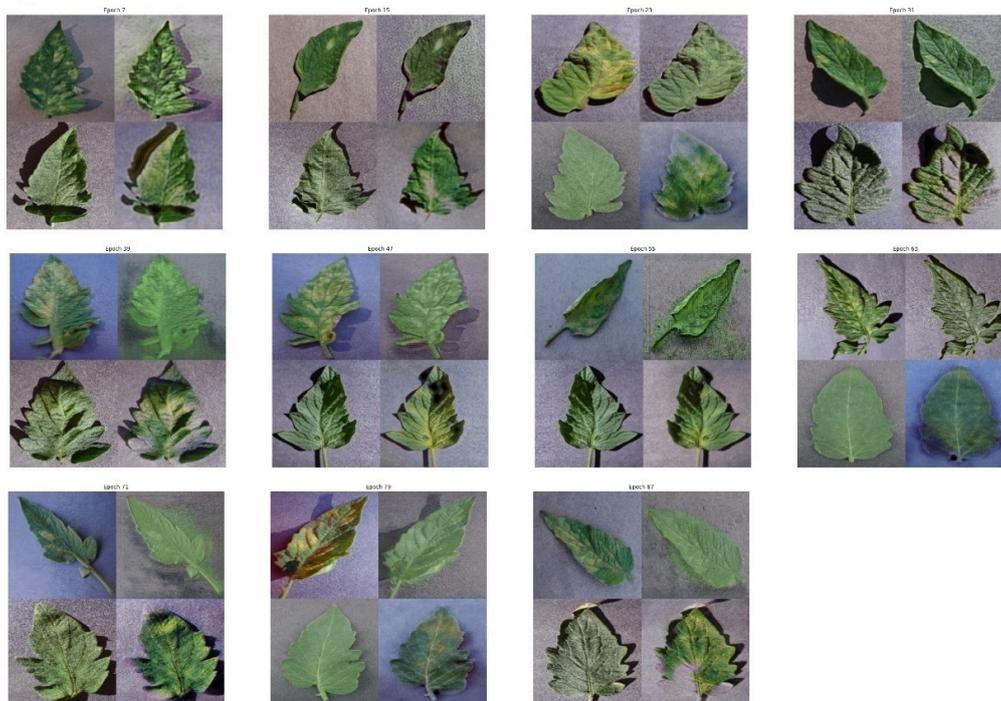


FIGURE 3.9 – Formation de Tomate

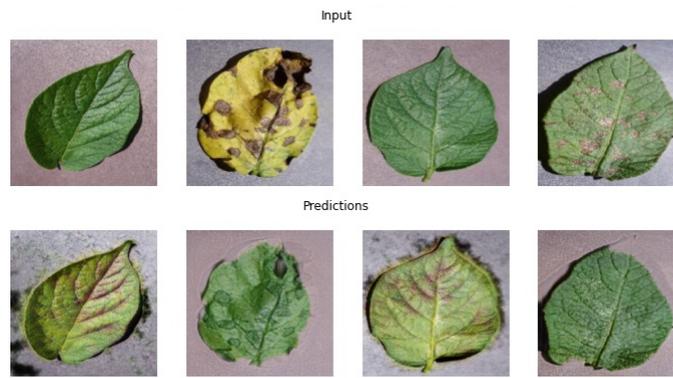


FIGURE 3.10 – Exemple de prédiction Pomme

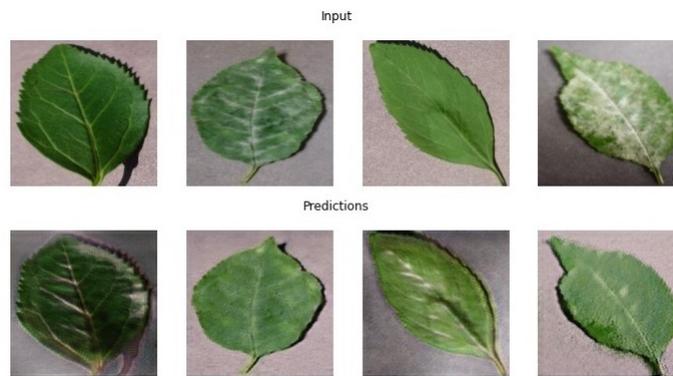


FIGURE 3.11 – Exemple de prédiction Cerise

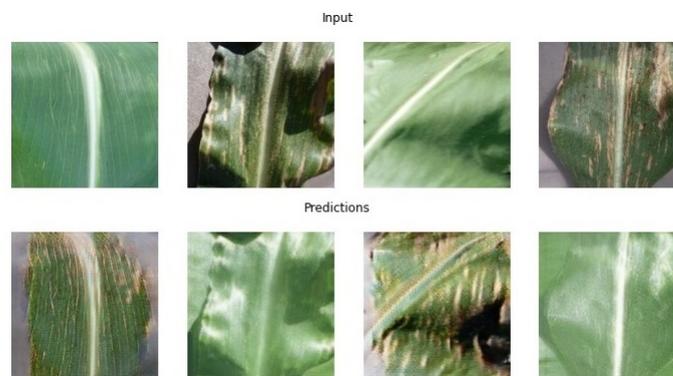


FIGURE 3.12 – Exemple de prédiction Mais

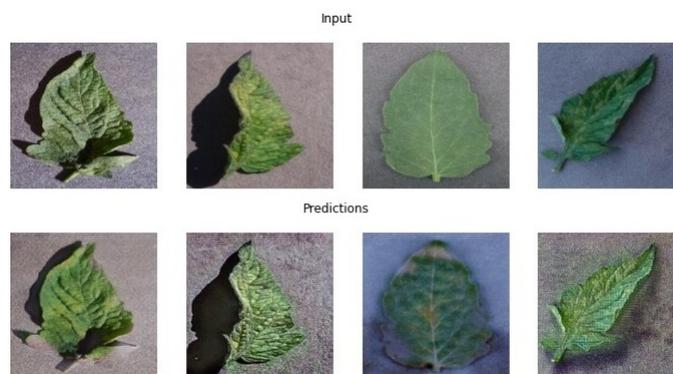


FIGURE 3.13 – Exemple de prédiction Tomate

3.8 Valorisation

Pour valoriser nos images générées nous avons utilisé GoogleLNet et nous avons obtenus les résultats suivants :

3.8.1 Formation

Planification de la formation des différents types :

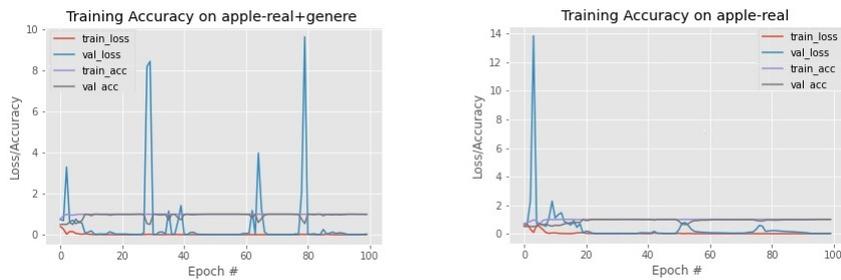


FIGURE 3.14 – Planification de formation de Pomme

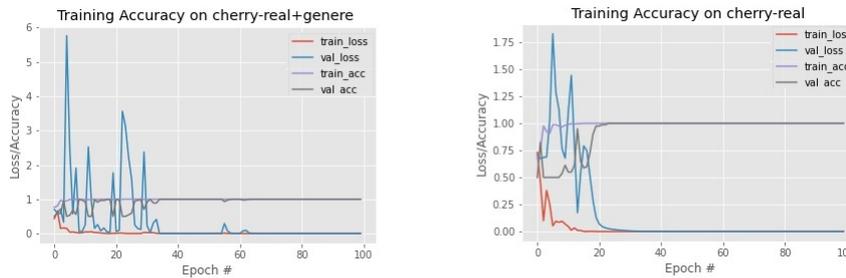


FIGURE 3.15 – Planification de formation de Cerise

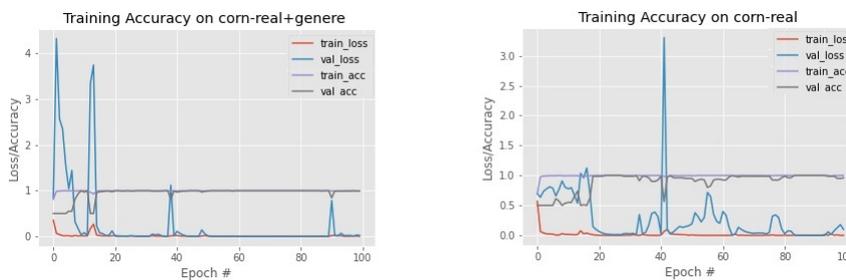


FIGURE 3.16 – Planification de formation de Mais

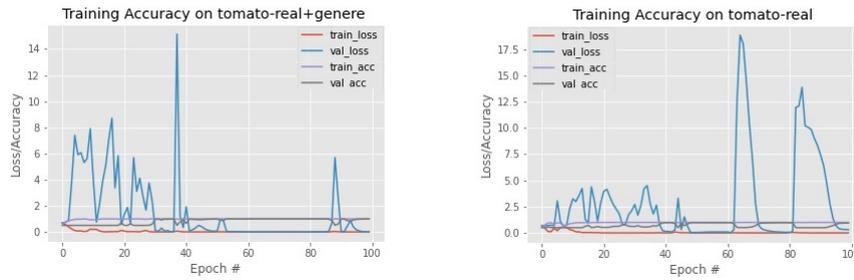


FIGURE 3.17 – Planification de formation de Tomate

3.8.2 Résultats

Nous avons obtenus les résultats suivants :

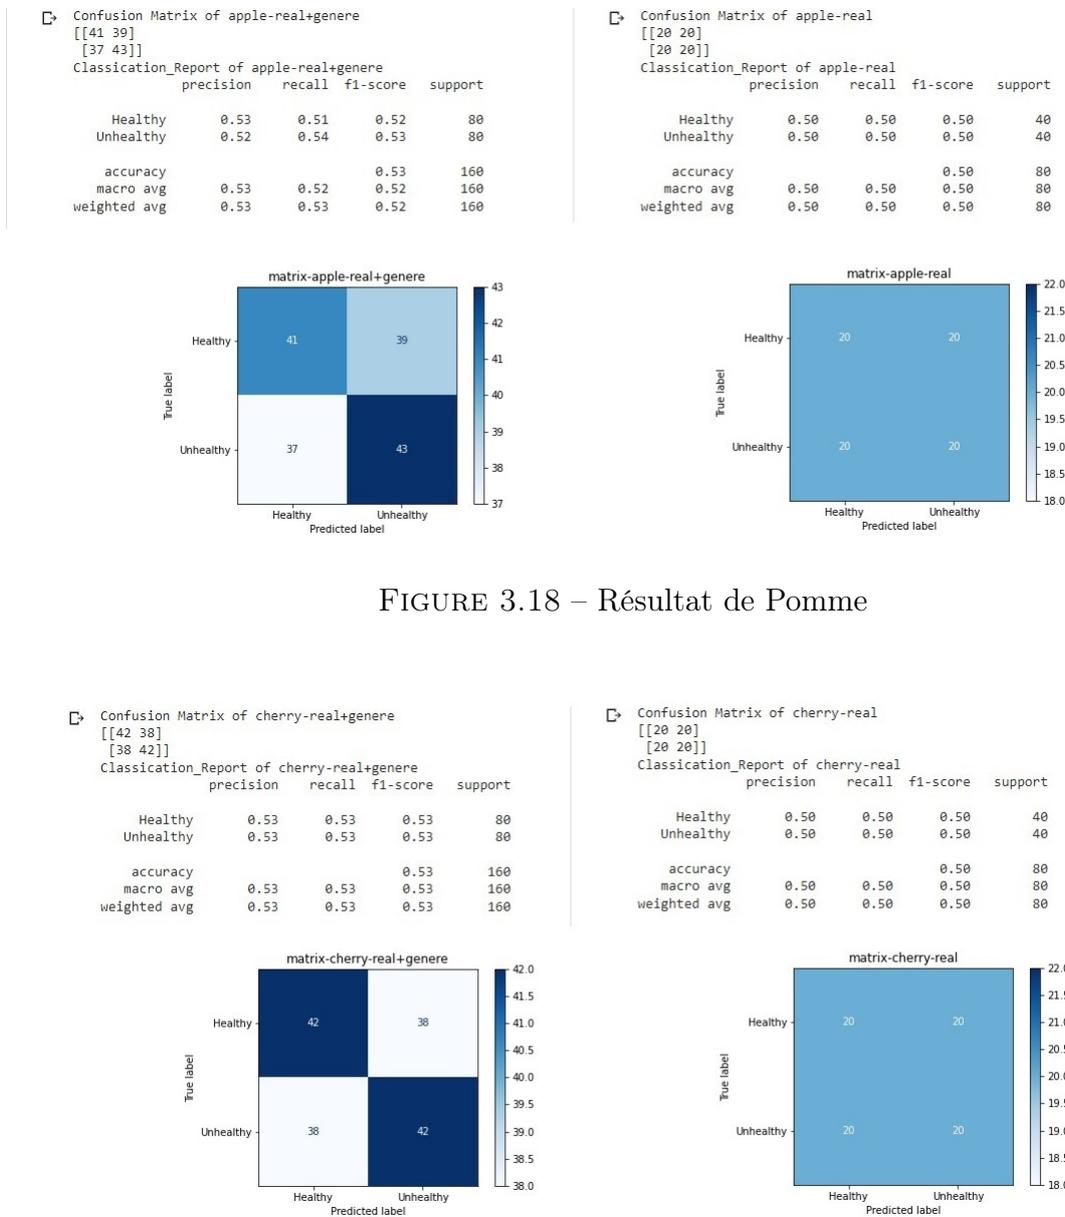


FIGURE 3.18 – Résultat de Pomme

FIGURE 3.19 – Résultat de Cerise

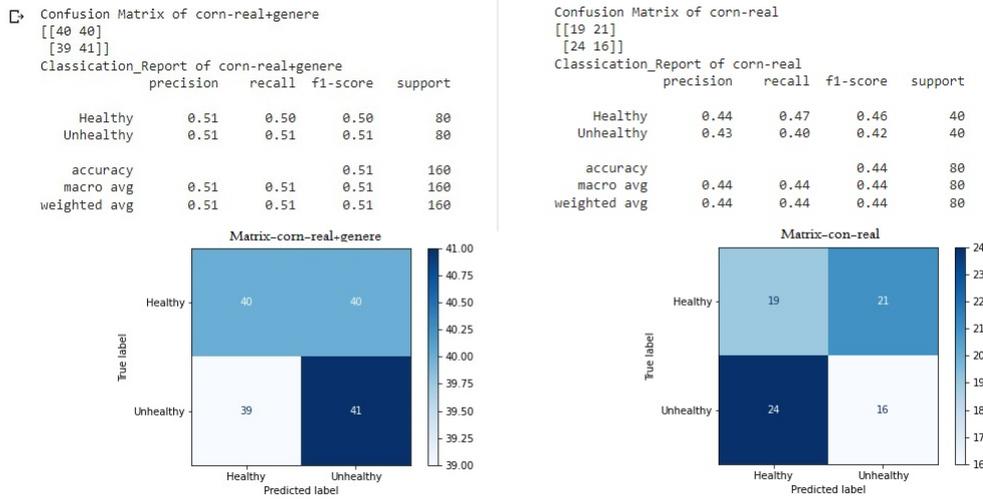


FIGURE 3.20 – Résultat de Mais

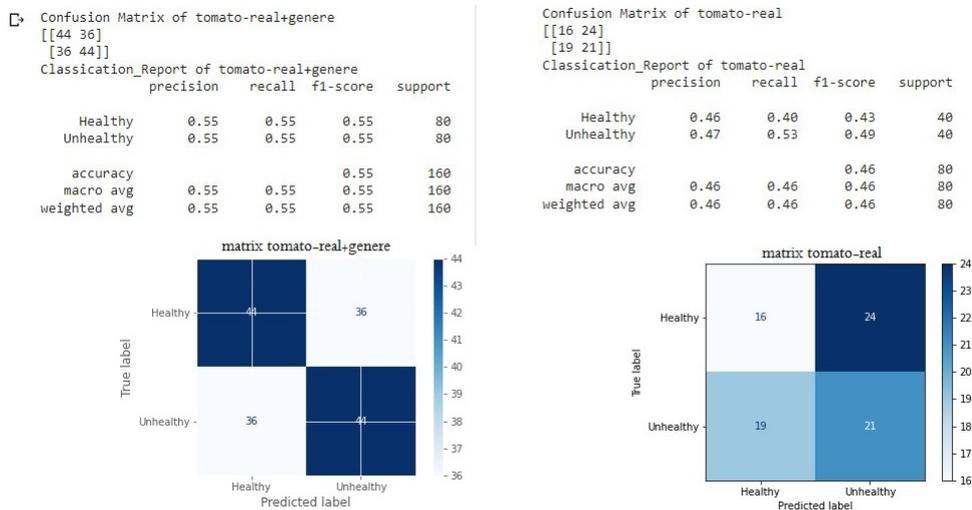


FIGURE 3.21 – Résultat de Tomate

3.9 Interprétation

Les figures 3.18, 3.19, 3.20 et 3.21 montre clairement l’apport des images générées dans le rendement du classifieur malgré le nombre très petit d’images gérées par rapport à un système basé sur le DeepLearning.

3.10 Conclusion

Nous avons présenté dans ce chapitre les résultats obtenus par rapport à la qualité des images générées et par rapport à l’influence de l’augmentation des données dans l’efficacité des classifieurs. Nous avons désiré pousser les tests encore plus loin, mais les limites matérielles au niveau personnel et le temps très réduit des cessions CoLAB ont rendu cette tâche impossible.

Conclusion Générale

Nous avons étudié dans ce modeste travail l'augmentation artificielle de données des bases des plantes avec la technique GAN qui a montré son efficacité par rapport à d'autres techniques de l'état de l'art. En premier lieu, nous avons abordé les différentes techniques GAN utilisées pour l'augmentation des données dans les datasets qu'elles peuvent subir un effondrement de l'apprentissage si le générateur trouve une faille dans le discriminateur. En plus des difficultés d'apprentissage, les sorties générées sont peu variées. Nous avons présenté les différents concepts relatifs à notre objectif. Nous avons présenté le modèle sujet d'intérêt i.e le générateur GAN proposé pour l'augmentation et présenté l'un des réseaux convolutif le plus utilisés pour la classification des images pour tester l'efficacité des images générées dans la prise de décision du classifieur. En troisième lieu nous avons présenté les résultats obtenus par rapport à la qualité des images malgré les limites matérielles et le temps très réduit des sessions CoLAB. Nous pouvons dire que nous avons atteint notre objectif d'augmenter les bases avec des données synthétiques en utilisant la technique GAN qui se rapproche de plus en plus de la réalité.

Bibliographie

- [1] S. J. PEARTON et F. REN, “GaN electronics,” *Advanced Materials*, t. 12, n° 21, p. 1571-1580, 2000.
- [2] B. HUANG, W. CHEN, X. WU, C.-L. LIN et P. N. SUGANTHAN, “High-quality face image generated with conditional boundary equilibrium generative adversarial networks,” *Pattern Recognition Letters*, t. 111, p. 72-79, 2018.
- [3] R. DING, G. GUO, X. YAN, B. CHEN, Z. LIU et X. HE, “BiGAN : collaborative filtering with bidirectional generative adversarial networks,” in *Proceedings of the 2020 SIAM International Conference on Data Mining*, SIAM, 2020, p. 82-90.
- [4] A. ODENA, “Semi-supervised learning with generative adversarial networks,” *arXiv preprint arXiv :1606.01583*, 2016.
- [5] X. CHEN, Y. DUAN, R. HOUTHOOFT, J. SCHULMAN, I. SUTSKEVER et P. ABBEEL, “Infogan : Interpretable representation learning by information maximizing generative adversarial nets,” *Advances in neural information processing systems*, t. 29, 2016.
- [6] J. LIN, D. LIU, H. LI et F. WU, “Generative adversarial network-based frame extrapolation for video coding,” in *2018 IEEE Visual Communications and Image Processing (VCIP)*, IEEE, 2018, p. 1-4.
- [7] F. GAO, Y. YANG, J. WANG, J. SUN, E. YANG et H. ZHOU, “A deep convolutional generative adversarial networks (DCGANs)-based semi-supervised method for object recognition in synthetic aperture radar (SAR) images,” *Remote Sensing*, t. 10, n° 6, p. 846, 2018.
- [8] D. BERTHELOT, T. SCHUMM et L. METZ, “Began : Boundary equilibrium generative adversarial networks,” *arXiv preprint arXiv :1703.10717*, 2017.
- [9] A. TERAMOTO, T. TSUKAMOTO, A. YAMADA et al., “Deep learning approach to classification of lung cytological images : Two-step training using actual and synthesized images by progressive growing of generative adversarial networks,” *PloS one*, t. 15, n° 3, e0229951, 2020.
- [10] L. BOUCAUD, “Mécanismes d’Attention Pour Les modèles Convolutifs Dans Le Cadre De La prédiction De Trajectoires,” thèse de doct., Ecole Polytechnique, Montreal (Canada), 2019.
- [11] T. KANEKO, Y. USHIKU et T. HARADA, “Label-noise robust generative adversarial networks,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, p. 2467-2476.
- [12] G. DARAS, A. ODENA, H. ZHANG et A. G. DIMAKIS, “Your local GAN : Designing two dimensional local attention mechanisms for generative models,” in *Proceedings of the IEEE/CVF Conference on computer vision and pattern recognition*, 2020, p. 14 531-14 539.
- [13] Z. WANG, Q. SHE et T. E. WARD, “Generative adversarial networks in computer vision : A survey and taxonomy,” *ACM Computing Surveys (CSUR)*, t. 54, n° 2, p. 1-38, 2021.

- [14] Z. PAN, W. YU, B. WANG et al., "Loss functions of generative adversarial networks (GANs) : opportunities and challenges," *IEEE Transactions on Emerging Topics in Computational Intelligence*, t. 4, n° 4, p. 500-522, 2020.
- [15] J. ADLER et S. LUNZ, "Banach wasserstein gan," *Advances in Neural Information Processing Systems*, t. 31, 2018.
- [16] J. LI, K. NIU, L. LIAO et al., "A generative steganography method based on wgan-gp," in *International Conference on Artificial Intelligence and Security*, Springer, 2020, p. 386-397.
- [17] J. NIE, Y. XIAO, L. HUANG et F. LV, "Time-frequency analysis and target recognition of HRRP based on CN-LSGAN, STFT, and CNN," *Complexity*, t. 2021, 2021.
- [18] J. ENDER, J. KLARE, I. WALTERSCHEID et al., "Bistatic exploration using spaceborne and airborne SAR sensors : A close collaboration between FGAN, ZESS, and FOMAAS," in *2006 IEEE International Symposium on Geoscience and Remote Sensing*, IEEE, 2006, p. 1828-1831.
- [19] G. POLAT, R. A. UGAN, E. CADIRCI et Z. HALICI, "Sepsis and septic shock : current treatment strategies and new approaches," *The Eurasian journal of medicine*, t. 49, n° 1, p. 53, 2017.
- [20] T. CHE, Y. LI, A. P. JACOB, Y. BENGIO et W. LI, "Mode regularized generative adversarial networks," *arXiv preprint arXiv :1612.02136*, 2016.
- [21] A. SOUGUIR-AOUANI, "GaN, une alternative au SiC pour les applications domotiques?" In *JCGE*, 2014.
- [22] H. SONG, M. WANG, L. ZHANG, Y. LI, Z. JIANG et G. YIN, "RGAN : sonar-image super-resolution based on generative adversarial network," *The Visual Computer*, t. 37, n° 8, p. 2285-2299, 2021.
- [23] C. ZHENG, X. JIANG, Y. ZHANG, X. LIU, B. YUAN et Z. LI, "Self-normalizing generative adversarial network for super-resolution reconstruction of SAR images," in *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2019, p. 1911-1914.
- [24] N. LIU, J. LIU, L. GONG, X. JIA et D. WANG, "Convolutional Network for Image Steganography With Redundant Embedding," in *Proceedings of the 2nd International Conference on Industrial Control Network And System Engineering Research*, 2020, p. 44-48.
- [25] K. KOJIMA, T. OHTOMO, K.-i. IKEMURA et al., "Determination of absolute value of quantum efficiency of radiation in high quality GaN single crystals using an integrating sphere," *Journal of Applied Physics*, t. 120, n° 1, p. 015 704, 2016.
- [26] H. SHI, J. DONG, W. WANG, Y. QIAN et X. ZHANG, "SSGAN : secure steganography based on generative adversarial networks," in *Pacific Rim Conference on Multimedia*, Springer, 2017, p. 534-544.
- [27] A. DIAMOND, N. KIRKHAM et D. AMSO, "Conditions under which young children can hold two rules in mind and inhibit a prepotent response.," *Developmental psychology*, t. 38, n° 3, p. 352, 2002.
- [28] N. E. BORLAUG, "Ending world hunger. The promise of biotechnology and the threat of antiscience zealotry," *Plant physiology*, t. 124, n° 2, p. 487-490, 2000.
- [29] T. VOS, R. M. BARBER, B. BELL et al., "Global, regional, and national incidence, prevalence, and years lived with disability for 301 acute and chronic diseases and injuries in 188 countries, 1990–2013 : a systematic analysis for the Global Burden of Disease Study 2013," *The lancet*, t. 386, n° 9995, p. 743-800, 2015.

- [30] M. D. S. AINSWORTH, S. M. BELL et L. D. STEINBERG, "5. Attachment, Exploration, and Separation : Illustrated by the Behavior of One-Year-Olds in a Strange Situation," in *The life cycle*, Columbia University Press, 1981, p. 57-71.
- [31] C. WOODHAM et C. WOODHAM-SMITH, *The Great Hunger : Ireland 1845-1849*, 1991.
- [32] G. L. CAREFOOT et E. R. SPROTT, *Famine on the wind : man's battle against plant disease*. Longmans Canada [1967], 1967.
- [33] D. HUGHES, M. SALATHÉ et al., "An open access repository of images on plant health to enable the development of mobile disease diagnostics," *arXiv preprint arXiv :1511.08060*, 2015.
- [34] E.-C. OERKE, U. STEINER, H.-W. DEHNE et M. LINDENTHAL, "Thermal imaging of cucumber leaves affected by downy mildew and environmental conditions," *Journal of experimental botany*, t. 57, n° 9, p. 2121-2132, 2006.
- [35] T. MACIAS, "Working toward a just, equitable, and local food system : The social impact of Community-Based agriculture," *Social science quarterly*, t. 89, n° 5, p. 1086-1101, 2008.
- [36] M. CAMPO, B. LOUVET, F. DOSSEVILLE et al., "Promotion de l'activité physique chez les seniors. Revue systématique des programmes d'intervention centrés sur les barrières affectives," *Staps*, n° 4, p. 115-127, 2015.
- [37] A. FLOOD, "Understanding phenomenology," *Nurse researcher*, t. 17, n° 2, 2010.
- [38] C. ALBER, R. WARE, C. ROCKEN et J. BRAUN, "Obtaining single path phase delays from GPS double differences," *Geophysical Research Letters*, t. 27, n° 17, p. 2661-2664, 2000.
- [39] S. J. NICHOLLS, G. RUOTOLO, H. B. BREWER et al., "Cholesterol efflux capacity and pre-beta-1 HDL concentrations are increased in dyslipidemic patients treated with evace-trapib," *Journal of the American College of Cardiology*, t. 66, n° 20, p. 2201-2210, 2015.
- [40] K. AITELKADI, S. BAKOURI, M. BELBRIK, H. HAJJI et N. CHTAINA, "Expérimentation d'un modèle de détection précoce des maladies de la tomate par apprentissage profond," *Revue Marocaine de Protection des Plantes*, n° 14, 2020.
- [41] C. CHU, A. ZHMOGINOV et M. SANDLER, "CycleGAN, a master of steganography," *arXiv preprint arXiv :1712.02950*, 2017.
- [42] C. BAUR, R. GRAF, B. WIESTLER, S. ALBARQOUNI et N. NAVAB, "SteGANomaly : inhibiting CycleGAN steganography for unsupervised anomaly detection in brain MRI," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, 2020, p. 718-727.
- [43] Y.-H. CAO, V. JAOUEN, V. BOURBONNE et al., "Synthèse de mouvement respiratoire par réseau antagoniste génératif doublement conditionnel en imagerie tomodensitométrie 4D," in *ORASIS 2021*, 2021.
- [44] I. GOODFELLOW, "Nips 2016 tutorial : Generative adversarial networks," *arXiv preprint arXiv :1701.00160*, 2016.
- [45] M. AL-QIZWINI, I. BARJASTEH, H. AL-QASSAB et H. RADHA, "Deep learning algorithm for autonomous driving using googlenet," in *2017 IEEE Intelligent Vehicles Symposium (IV)*, IEEE, 2017, p. 89-96.