

الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Abbes Laghrou de Khenchela

Faculté des Sciences et de La Technologie

Département de Mathématique et Informatique

**Filière :** Informatique



**Spécialité :** GLSD (Génie Logiciel et Système Distribué)

Intitulé

**Autoencodeurs variationnels pour  
l'élimination des poils dans les images  
dermoscopiques**

**Réalisé par :**

- Ghezal Nour-El-Houda
- Hamzaoui Abdeldjalil

**Encadré par :** Dr. Bardou Dalal

**Année universitaire :** 2021 / 2022

## *Remerciement*

*Je tiens à exprimer toute ma reconnaissance à ma directrice de mémoire, Dr. **Bardou Dalal**, qui m'a beaucoup appris sur les défis à relever dans le monde d'Intelligence Artificiel. Elle a partagé ses connaissances et expériences dans ce milieu, tout en m'accordant sa confiance et une large indépendance dans l'exécution de missions valorisantes. Un immense merci pour sa patience, sa disponibilité et surtout ses judicieux conseils, qui ont contribué à alimenter ma réflexion. Je la remercie de m'avoir encadré, orienté et aidé.*

*J'adresse mes sincères remerciements à tous les professeurs de l'université de Abbes Laghror de Khenchela, intervenants et toutes les personnes qui par leurs paroles, leurs écrits, leurs conseils et leurs critiques ont guidé mes réflexions et ont accepté de me rencontrer et de répondre à mes questions durant mes recherches.*

## *Dédicace*

*Nous dédions ce modeste travail, comme preuve de respect, de gratitude, et de reconnaissance à :*

*Nos chers parents : Qui n'ont jamais cessé de nous encourager et nous conseiller*

*Ils nous ont beaucoup aidé tout en long de notre chemin, grâce à leur amour, leur dévouement, leur compréhension et leur patience sans jamais nous quitter des yeux ni baisser les bras et leurs soutien moral et matériel, on ne saurait jamais traduire ce qu'on ressent vraiment envers eux.*

*Nos frères et sœurs : Pour leur indulgence en notre faveur qu'ils touchent ici l'affection la plus intime qu'on ressent à leur égard.*

*Nos amis et collègues : Pour leur compagnie et bons moments passés ensemble*

## Résumé

Le mélanome est un type très dangereux du cancer de la peau qui tue beaucoup de personnes chaque année. Le diagnostic précoce augmente le taux de survie de ce cancer. Donc, récemment plusieurs techniques automatiques qui basent sur le machine learning ont été apparait. Mais, comme les images dermoscopiques utilisées dans l'apprentissage sont couvertes par des poils, le diagnostic ne peut pas être considéré fiable. Pour cela, dans ce travail, nous proposons un modèle qui utilise le deep learning pour l'élimination automatique des poils dans les images dermoscopiques.

Nous allons construire un autoencodeur variationnel qui considère les poils comme un bruit durant la production du latent space. Le modèle proposé se compose d'un encodeur, du latent space et d'un décodeur. L'encodeur passe l'image encodé vers le latent space puis vers le décodeur qui fait la génération d'une image presque identique à celle donnée comme entrée, mais sans poils. Les expériences menées montrent la fiabilité de notre méthode.

**Mots clés :** Le mélanome, le deep learning, Autoencodeurs variationnels, CNN.

## Table des matières

<b>Introduction générale</b> .....	<b>8</b>
<b>Chapitre I : <i>Le Mélanome</i></b> .....	<b>10</b>
I.1 Introduction .....	11
I.2 Le mélanome .....	11
I.3 Symptômes du mélanome .....	12
I.4 Les quatre principaux types de mélanome .....	12
I.5 Les signes d'avertissement de mélanome .....	14
I.6 Conclusion.....	17
<b>Chapitre II : <i>Le Deep Learning</i></b> .....	<b>18</b>
II.1 Introduction .....	19
II.2 L'Intelligence Artificielle (IA).....	19
II.3 Le Machine Learning (Apprentissage Automatique).....	20
II.4 Les différentes techniques de Machine Learning.....	20
II.5 Le Deep Learning (Apprentissage Profond).....	21
II.6 Le fonctionnement de Deep Learning (apprentissage profond).....	21
II.7 Auto-Encodeur (Encodeur Automatique) «AE » .....	23
II.8 Auto-Encodeur Variationnel « VAE ».....	26
II.9 Le réseau neuronal convolutif (CNN).....	27
II.10 Conclusion .....	31
<b>Chapitre III : <i>Développement et Implémentation</i></b> .....	<b>32</b>
III.1 Les outils utilisés .....	33
III.2 DataSet.....	34
III.3 Architecture proposé de VAE.....	35
III.4 Les paramètres d'apprentissage.....	37
III.5 Les résultats .....	38
III.6 Conclusion.....	39
<b>Conclusion générale</b> .....	<b>40</b>

## Liste des figures

Figure 1: le mélanome [2].....	11
Figure 2 : Type A de mélanome [3] .....	14
Figure 3 Type B de mélanome [3].....	15
Figure 4: Type C de mélanome [3] .....	15
Figure 5 : Type D de mélanome [3] .....	16
Figure 6: Type E de mélanome [3].....	16
Figure 7: Trois exemples de Vilain petit canard [3].....	17
Figure 8: représente neurone multipolaire biologique et un réseau de neurones artificiel [8] .	22
Figure 9 : Fonctionnement de Deep Learning [9] .....	23
Figure 10 : Architecture d'un auto-encodeur [10] .....	24
Figure 11 : Architecture d'un VAE [11] .....	27
Figure 12: L'architecture d'un CNN [12] .....	28
Figure 13: Couche Convolutive [5].....	29
Figure 14: La couche ReLU [14] .....	30
Figure 15 : La couche Max-Pooling [15].....	30
Figure 16 : La couche Entièrement Connectée (FC) [16].....	31
Figure 17: Interface de compte sur kaggle [17] .....	34
Figure 18 : Quelques exemples d'images du HAM10000 [18] .....	35
Figure 19 : L'architecture propose du VAE .....	35
Figure 20: Architecture d'encodeur et de décodeur. ....	36
Figure 21 Screenshot pris du kaggle qui détaille le résultat de chaque opération exécutée par l'encodeur. [19].....	37
Figure 22 : Screenshot pris du kaggle qui détaille le résultat de chaque opération exécutée par le décodeur. [19].....	37
Figure 23 : (A) images originales avec poils, (B) images sans poils après avoir utilisé VAE. [18] [19].....	38
Figure 24: Comparaison entre notre modèle et DullRazor [20] [21] .....	39

## Liste des tables

Table 1 : L'architecture détaillée d'encodeur et de décodeur.....	36
---	----

## Introduction générale

La peau est considérée comme l'organe humain le plus important en termes de surface. Elle est composée de plusieurs couches de tissus, et elle forme une barrière de protection de l'organisme contre le milieu extérieur et protège le corps des infections et des rayonnements ultraviolets. Elle facilite aussi le contrôle de la température corporelle et l'élimination des déchets organiques par la transpiration.

Le cancer de la peau est un cancer qui a connu une forte augmentation au cours des dernières années. Il existe différents types de cancer de la peau : le mélanome et le carcinome, Le mélanome cutané est beaucoup plus rare que le carcinome mais c'est le plus grave des cancers de la peau, du fait de son « haut potentiel métastatique », c'est-à-dire de sa capacité à se propager rapidement à d'autres parties du corps. Le mélanome peut se situer n'importe où sur le corps, y compris sur le cuir chevelu. Il peut se manifester de deux façons : par l'apparition d'une petite tache pigmentée sur une peau saine (cas le plus fréquent) ou par la modification d'un grain de beauté préexistant. Il est en général difficile de poser un diagnostic formel de cancer à partir du seul aspect clinique d'une lésion cutanée ou d'un grain de beauté surtout du mélanome de la peau. Toute éventuelle modification de la peau doit faire l'objet d'un examen médical pour un dépistage précoce. En cas de mélanome, d'autres examens diagnostiques sont toutefois nécessaires afin de déterminer le stade d'évolution et d'identifier les éventuelles métastases. Il s'agit notamment d'échographies, de tomographie assistée par ordinateur (CT), d'imagerie par résonance magnétique (IRM) et de scintigraphie osseuse.

Les progrès de la technologie, précisément des techniques d'imagerie, ont permis d'acquérir et de collecter des images de mélanome de la peau de haute qualité. Ces images sont désormais normalisées, ce qui a permis aux chercheurs informaticiens de mener des études et de développer des outils informatiques fiables pour automatiser le diagnostic et apporter une aide aux praticiens.

Il existe plusieurs artefacts qui se présentent sur les images dermoscopiques et qui peuvent impacter le diagnostic automatique tels que les poils. L'apparence des poils sur ces images peut mener à un mauvais diagnostic comme il donne des mauvaises informations sur la lésion et ses propriétés.

Pour résoudre ce problème, plusieurs méthodes d'épilation automatique ont été développées basant sur le traitement d'images ce qui compris deux tâches : la segmentation des poils et la peinture des espaces, mais ces méthodes ne sont pas fiables car leur performance est faible.

Le deep learning, une technique d'apprentissage permettant à un système de créer seul son propre algorithme à partir de l'observation d'une base de données de grande taille, construit un modèle ayant l'aptitude pour détecter des objets ou des anomalies qu'il a appris à reconnaître. Les modèles génératifs, un type de deep learning sont utilisés pour générer des échantillons concrets. Ces modèles ont eu un grand succès dans le cadre de trouver des solutions à plusieurs problèmes.

Dans ce travail, nous suggérons une méthode efficace pour l'épilation automatique des images dermoscopiques, en appliquant un type des modèles génératifs nommé les autoencodeurs variationnels (VAE) qui considèrent les poils comme étant de bruit lors de parcourt de l'apprentissage au niveau de latente puis refaire le rétablissement des images sans poils à travers la structure encodeur-décodeur.

---

---

# Chapitre 1

## *Le Mélanome*

---

---

## I.1 Introduction

Les cancers de la peau figurent en tête de liste des cancers les plus souvent diagnostiqués au monde. Les carcinomes cutanés, qui se développent à partir des cellules de l'épiderme, représentent le type de cancer de la peau le plus fréquent. À eux seuls, ils comptent pour un peu plus de 80 % des cancers cutanés. Le présent texte traite d'un autre type de cancer de la peau : le mélanome.

## I.2 Le mélanome

Le mélanome [1] est une tumeur maligne qui se développe à partir de cellules de la peau appelées mélanocytes. Ces cellules sont situées dans l'épiderme (couche supérieure de la peau) et produisent la mélanine. Le mélanome [1] se développe d'abord à la surface de la peau, grossit et devient plus profond, atteint le derme (couche intermédiaire de la peau), puis peut disséminer et envahir d'autres parties du corps. Il peut survenir à tout âge, avec un âge moyen de 57 ans, et il touche exceptionnellement les enfants. Dans 90 % des cas, il se situe sur la peau, mais peut également se développer dans l'œil ou les muqueuses.




Figure 1: le mélanome [2]

### **I.3 Symptômes du mélanome**

Les mélanomes ne sont habituellement pas douloureux. De plus, ils peuvent se former sur n'importe quelle partie du corps [2]. Cependant, ils apparaissent le plus souvent sur le dos et les jambes.

Parmi les signes de la présence potentielle de mélanomes [2], il y a :

- la modification ou l'apparition d'un grain de beauté ou d'une tache dont la couleur ou la taille change au fil du temps ou dont le contour est irrégulier.
- la formation d'une lésion brun foncé ou noire sur la peau ou sur une muqueuse (bouche, nez, organes génitaux ou anus).

### **I.4 Les quatre principaux types de mélanome**

On distingue quatre principaux types de mélanomes de la peau [3] :

#### **I.4.1 Mélanome superficiel à propagation :**

- La forme la plus courante de mélanome [3].
- Il peut survenir dans un grain de beauté existant ou apparaître comme une nouvelle lésion [3]. Lorsqu'il débute dans un grain de beauté déjà présent sur la peau, il se développe souvent à la surface de la peau pendant un certain temps avant de pénétrer plus profondément. Il peut être trouvé presque n'importe où sur le corps, mais apparaît souvent sur le torse chez les hommes, les jambes chez les femmes et le haut du dos chez les deux.
- Il peut apparaître comme une tache asymétrique plate [3] ou légèrement surélevée et décolorée avec des bordures inégales. Les couleurs incluent des nuances de bronzage, de brun, de noir, de rouge/rose, de bleu ou de blanc. Il peut également manquer de pigment et apparaître comme une lésion rose ou de couleur chair (amélanotique).

#### **I.4.2 Le lentigo malin**

- Ce mélanome se développe souvent chez les personnes âgées. Lorsque ce cancer devient invasif ou se propage au-delà du site d'origine, la maladie est connue sous le nom de mélanome lentigo malin [3].
- Cette forme de mélanome est similaire au type à propagation superficielle [3], se développant d'abord près de la surface de la peau. La tumeur apparaît généralement sur la peau endommagée par le soleil du visage, des oreilles, des bras ou du haut du torse.
- Cela peut ressembler à une tache plate ou légèrement surélevée aux bords inégaux [3]. La couleur est généralement bleu-noir, mais peut varier du bronzage au brun ou au brun foncé.

#### **I.4.3 Le mélanome acral lentigineux :**

- La forme de mélanome la plus courante chez les personnes de couleur [3].
- Il apparaît souvent dans des endroits difficiles à repérer [3], notamment sous les ongles et sur la plante des pieds ou la paume des mains.
- Il peut apparaître comme une zone noire ou brune [3].
- Le musicien Bob Marley a reçu un diagnostic de mélanome lentigineux acral [3]. Lorsqu'une tache sombre est apparue sous son ongle, Marley a pensé qu'il s'agissait d'une blessure au football. Finalement, cette maladie a été diagnostiquée mais n'a pas été traitée. Son mélanome s'est propagé à d'autres parties de son corps et a entraîné sa mort à l'âge de 36 ans.

#### **I.4.4 Le mélanome nodulaire :**

- Le type de mélanome le plus agressif [3]. Il représente 10 à 15 % de tous les cas.
- La tumeur se développe plus profondément [3] dans la peau plus rapidement que les autres types et se trouve le plus souvent sur le torse, les jambes et les bras, ainsi que sur le cuir chevelu chez les hommes plus âgés. Il est généralement invasif au moment où il est diagnostiqué pour la première fois.
- Le mélanome nodulaire [3] est souvent reconnu comme une bosse sur la peau, généralement de couleur bleu-noir, mais peut également apparaître comme une bosse rose à rouge.

## I.5 Les signes d'avertissement de mélanome

Trouver un mélanome à un stade précoce [3] est crucial ; une détection précoce peut considérablement augmenter vos chances de guérison.

Recherchez tout ce qui est nouveau, changeant ou inhabituel sur les zones du corps exposées au soleil et protégées du soleil. Les mélanomes apparaissent [3] généralement sur les jambes pour les femmes et le torse pour les hommes. Mais rappelez-vous que les mélanomes peuvent survenir n'importe où sur la peau, même dans les zones que le soleil n'atteint pas. La plupart des grains de beauté, des taches brunes et des excroissances sur la peau sont inoffensifs, mais pas toujours. Les ABCDE et le signe du Vilain petit canard peuvent vous aider à détecter le mélanome [3]. De fait, il faut se méfier des lésions qui présentent les signes suivants : (règle ABCDE)

### I.5.1 Les 'ABCDE' du mélanome

Les cinq premières lettres de l'alphabet [3] sont un guide pour vous aider à reconnaître les signes avant-coureurs du mélanome.

- **A : pour Asymétrie**

La plupart des mélanomes sont asymétriques [3]. Si vous tracez une ligne à travers le milieu de la lésion, les deux moitiés ne correspondent pas, donc il semble différent d'un grain de beauté commun, de rond à ovale, et symétrique.



Figure 2 : Type A de mélanome [3]

- **B : pour Bord**

Les bords [3] du mélanome sont souvent inégaux et peuvent avoir des bords festonnés ou entaillés, tandis que les grains de beauté communs ont tendance à avoir des bords plus lisses.



Figure 3 Type B de mélanome [3]

- **C : pour Couleur**

Les couleurs [3] multiples sont un signe d'avertissement. Alors que les grains de beauté bénins sont généralement d'une seule nuance de brun, un mélanome peut avoir différentes nuances de brun, de beige foncé ou de noir. Au fur et à mesure de sa croissance, les couleurs rouge, blanc ou bleu peuvent également apparaître.



Figure 4: Type C de mélanome [3]

- **D : pour Diamètre**

Bien qu'il soit idéal de détecter un mélanome lorsqu'il est petit, si une lésion a la taille d'une gomme de crayon (environ 6 mm de diamètre) [3] ou plus, c'est un signe d'avertissement. Certains experts disent qu'il est également important de rechercher toute lésion, quelle que soit sa taille, qui est plus sombre que d'autres. Les mélanomes amélanotiques sont incolores et rares.



Figure 5 : Type D de mélanome [3]

- **E : pour Évolutif.**

Tout changement de taille, de forme, de couleur ou d'élévation d'une tache sur votre peau, ou tout nouveau symptôme, tel qu'un saignement, des démangeaisons ou des croûtes [3], peut être un signe avant-coureur d'un mélanome.




Figure 6: Type E de mélanome [3]

### I.5.2 Le vilain petit canard

Le vilain petit canard [3] est un autre signe avant-coureur du mélanome. La plupart des grains de beauté normaux sur votre corps se ressemblent, tandis que les mélanomes se distinguent comme de vilains petits canards en comparaison. Cela met en évidence l'importance non seulement de vérifier les irrégularités, mais également de comparer tout endroit inhabituel aux grains de beauté environnants pour déterminer s'il est différent des autres. Ces lésions de type Vilain petit canard [3] peuvent être plus grandes, plus petites, plus claires ou plus foncées, par rapport aux grains de beauté environnants. De plus, les lésions isolées sans grains de beauté environnants à des fins de comparaison sont considérées comme de vilains petits canards.

Trois exemples de vilain petit canard [3]:




Figure 7: Trois exemples de Vilain petit canard [3]

### I.6 Conclusion

Une consultation médicale doit être recommandée sans délai dès qu'il existe des signes suspects. En cas de tache suspecte, un dermatologue procède à un examen de l'ensemble de la peau, puis de la lésion à l'aide d'un dermoscopie. Si la suspicion se confirme, cette lésion est retirée sous anesthésie locale puis examinée au microscope. C'est l'examen anatomopathologique qui permet de poser le diagnostic. En cas de mélanome avéré, on détermine alors ses caractéristiques, à savoir son type, son épaisseur et la profondeur de pénétration dans les tissus. Ensuite, d'autres examens permettent de préciser une éventuelle extension de la tumeur à d'autres organes. Sont alors prescrits dans cet objectif une échographie de la région pour détecter des ganglions atteints, une échographie de l'abdomen, une radiographie des poumons, un scanner, une IRM ou une scintigraphie osseuse.

---

---

# **Chapitre 2**

## *Deep Learning*

---

---

## II.1 Introduction

L'Intelligence Artificielle est au cœur des recherches dans le milieu médical et ses applications visent désormais à améliorer la qualité des soins pour la médecine de demain. L'IA se concentre sur le développement des opérations assistées, des traitements personnalisés, le suivi des patients à distance, l'aide dans le traitement du cancer.

L'IA, par les algorithmes, aide donc principalement à l'élaboration de diagnostics. En effet, la machine prescrit le même diagnostic que les médecins dans 99% des cas, et dans 30% des cas, elle propose un traitement plus adapté que celui des spécialistes. Elle réussit à détecter les cancers dans 89% des cas, alors que les spécialistes les détectent dans 73% des cas. Les machines arrivent également à détecter des crises cardiaques par téléphone. Ainsi, la robotique étend sa toile dans de nombreux secteurs de la médecine.

Cependant, l'Intelligence Artificielle ne tend pas à remplacer les médecins, mais vient compléter le jugement du médecin pour lui permettre de modifier ou confirmer son diagnostic. Celui-ci prendra la décision en utilisant ses qualités d'intelligence relationnelle et émotionnelle, aspect de l'intelligence que les machines ne possèdent pas.

## II.2 L'Intelligence Artificielle (IA)

L'Intelligence Artificielle [4] est l'ensemble des technologies de traitement de l'information visant à conférer des capacités cognitives comparables à celle des humains à des ordinateurs, machines ou robots, grâce à des fonctions mathématiques, des algorithmes mais aussi des modes de représentation de l'environnement réel. Cette discipline scientifique s'est structurée dès le début des années 1950, avec l'article séminal d'Alan Turing : " Computing Machinery and Intelligence " dans lequel il considère la question " Les machines peuvent-elle penser ? " ou l'utilisation du terme d'Artificial Intelligence par John McCarty et Marvin Minsky (1956).

Derrière l'intelligence artificielle [4], se cache une multitude d'appareils qui ont un dénominateur commun : le machine learning. Cette technologie permet de stocker une grande quantité de données dans un cerveau ou réseau neuronal virtuel. On distingue l'intelligence artificielle [4] forte de l'intelligence artificielle [4] faible. La première inclut les machines capables d'agir de façon intelligente, mais aussi d'assimiler des concepts abstraits et d'avoir une véritable conscience proche des sentiments éprouvés par les êtres humains. Les machines qui se limitent à résoudre des problèmes entrent dans la catégorie d'intelligence artificielle faible.

L'intelligence artificielle [4] est un secteur qui s'accroît fortement et dont les perspectives sont immenses. Néanmoins, ce domaine ne serait rien sans le machine learning.

### **II.3 Le Machine Learning (Apprentissage Automatique)**

Le Machine Learning [4] ou apprentissage automatique est un domaine scientifique, et plus particulièrement une sous-catégorie de l'intelligence artificielle. Elle consiste à laisser des algorithmes découvrir des " patterns ", à savoir des motifs récurrents, dans les ensembles de données. Ces données peuvent être des chiffres, des mots, des images, des statistiques...

Tout ce qui peut être stocké numériquement peut servir de données pour le Machine Learning. En décelant les patterns dans ces données, les algorithmes apprennent et améliorent leurs performances dans l'exécution d'une tâche spécifique.

Pour résumer, les algorithmes de Machine Learning [4] apprennent de manière autonome à effectuer une tâche ou à réaliser des prédictions à partir de données et améliorent leurs performances au fil du temps. Une fois entraîné, l'algorithme pourra retrouver les patterns dans de nouvelles données.

### **II.4 Les différentes techniques de Machine Learning**

On distingue deux techniques de Machine Learning [5]: l'apprentissage supervisé, l'apprentissage non-supervisé

#### **II.4.1 L'apprentissage supervisé**

Le plus courant, les données sont étiquetées afin d'indiquer à la machine quelles patterns elle doit rechercher [5]. Le système s'entraîne sur un ensemble de données étiquetées, avec les informations qu'il est censé déterminer. Les données peuvent même être déjà classifiées de la manière dont le système est supposé le faire.

Cette méthode nécessite moins de données d'entraînement que les autres, et facilite le processus d'entraînement puisque les résultats du modèle peuvent être comparés avec les données déjà étiquetées. Cependant, l'étiquetage des données peut se révéler onéreux. Un modèle peut aussi être biaisé à cause des données d'entraînement, ce qui impactera ses performances par la suite lors du traitement de nouvelles données.

## II.4.2 L'apprentissage non-supervisé

Les données n'ont pas d'étiquettes [5]. La machine se contente d'explorer les données à la recherche d'éventuelles patterns. Elle ingère de vastes quantités de données, et utilise des algorithmes pour en extraire des caractéristiques pertinentes requises pour étiqueter, trier et classer les données en temps réel sans intervention humaine.

Plutôt que d'automatiser les décisions et les prédictions, cette approche permet d'identifier les patterns et les relations que les humains risquent de ne pas identifier dans les données. Cette technique n'est pas très populaire, car moins simple à appliquer. Elle est toutefois de plus en plus populaire dans le domaine de la cybersécurité.

## II.5 Le Deep Learning (Apprentissage Profond)

Le Deep Learning [6] est un domaine appartenant à l'intelligence artificielle dont l'objectif est l'étude et la construction de systèmes informatiques capables « d'apprendre par l'expérience ». Il s'inspire donc légèrement de certains principes du fonctionnement du cerveau humain.

En général, ces systèmes doivent être formés à partir d'exemples connus de la même manière qu'un jeune enfant apprend à reconnaître des objets ou des sons autour de lui.

Ce type d'apprentissage automatique est appelé deep learning [6] ou apprentissage profond, car il possède une structure hiérarchique qui extrait différents niveaux de détail des données. Par exemple, lors de la reconnaissance d'image, des contours sont extraits qui, lorsqu'ils sont combinés, permettent de détecter des formes qui à leur tour permettent de reconnaître différentes parties de l'objet pour finalement déterminer son identité. Pour ce faire, le deep learning fait appel à des réseaux de neurones artificiels composés d'algorithmes.

## II.6 Le fonctionnement de Deep Learning (Apprentissage Profond)

Au sein du cerveau humain, chaque neurone reçoit environ 100 000 signaux électriques des autres neurones. Chaque neurone en activité peut produire un effet excitant ou inhibiteur sur ceux auxquels il est connecté [7].

Au sein d'un réseau artificiel, le principe est similaire [7]. Les signaux voyagent entre les neurones. Toutefois, au lieu d'un signal électrique, le réseau de neurones assigne un certain poids à différents neurones [7]. Un neurone qui reçoit plus de charge exercera plus d'effet sur les neurones adjacents. La couche finale de neurones émet une réponse à ces signaux [7].

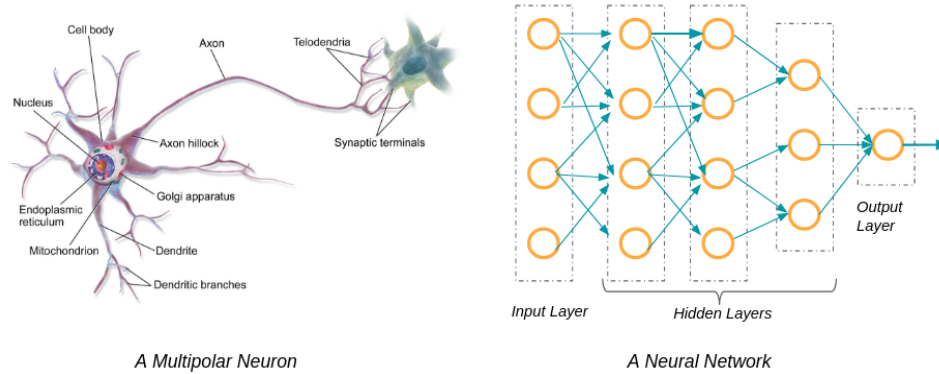


Figure 8: représente neurone multipolaire biologique et un réseau de neurones artificiel [8]

### II.6.1 Exemple : Deep Learning

Afin d’y parvenir, le réseau de neurones doit être entraîné. Pour ce faire, il est nécessaire de compiler un ensemble d’images d’entraînement pour pratiquer le Deep Learning [7]. Cet ensemble va regrouper des milliers de photos de chats différents, mélangés avec des images d’objets qui ne sont pas des chats. Ces images sont ensuite converties en données et transférées sur le réseau. Les neurones artificiels assignent ensuite un poids aux différents éléments. La couche finale de neurones va alors rassembler les différentes informations pour déduire s’il s’agit ou non d’un chat.

Le réseau de neurones va ensuite comparer cette réponse aux bonnes réponses indiquées par les humains. Si les réponses correspondent, le réseau garde cette réussite en mémoire et s’en servira plus tard pour reconnaître les chats. Dans le cas contraire, le réseau prend note de son erreur et ajuste le poids placé sur les différents neurones pour corriger son erreur. Le processus est répété des milliers de fois jusqu’à ce que le réseau soit capable de reconnaître un chat sur une photo dans toutes les circonstances. Cette technique d’apprentissage est appelée « supervised learning » ou apprentissage supervisé.

Une autre technique d'apprentissage est celle de l'« unsupervised learning », ou apprentissage non supervisé. Cette technique repose sur des données qui ne sont pas étiquetées. Les réseaux de neurones doivent reconnaître des patterns au sein des ensembles de données pour apprendre par eux-mêmes quels éléments d'une photo peuvent être pertinents.




Figure 9 : Fonctionnement de Deep Learning [9]

## II.7 Auto-Encodeur (Encodeur Automatique) «AE »

Un auto-encodeur [10] est un type de réseau neuronal artificiel utilisé pour apprendre les encodages de données de manière non supervisée.

L'objectif d'un auto-encodeur [10] est d'apprendre une représentation de dimension inférieure (codage) pour des données de dimension supérieure, généralement pour la réduction de la dimensionnalité, en entraînant le réseau à capturer les parties les plus importantes de l'image d'entrée.

### II.7.1 L'architecture des Auto-Encodeurs

Commençons par un aperçu rapide de l'architecture des auto-encodeurs.

Les encodeurs automatiques se composent de 3 parties [10] :

- Encodeur
- Goulot d'étranglement
- Décodeur

**1. Encodeur** : Un module qui comprime les données d'entrée [10] de l'ensemble train-validate-test en une représentation codée qui est généralement inférieure de plusieurs ordres de grandeur aux données d'entrée.

**2. Goulot d'étranglement** : un module qui contient les représentations de connaissances compressées [10] et qui est donc la partie la plus importante du réseau.

**3. Décodeur** : un module qui aide le réseau à « décompresser » les représentations des connaissances et reconstruit les données [10] à partir de leur forme codée. La sortie est ensuite comparée à une vérité terrain.

L'architecture [10] dans son ensemble ressemble à ceci :

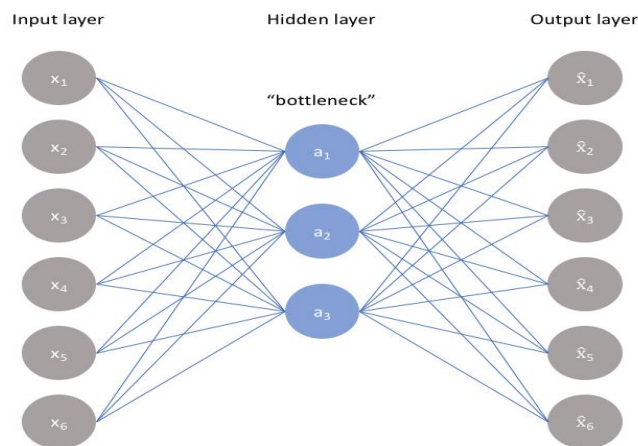


Figure 10 : Architecture d'un auto-encodeur [10]

## II.7.2 La relation entre l'encodeur, le goulot d'étranglement et le décodeur

### ▪ Encodeur

L'encodeur [10] est un ensemble de blocs convolutifs suivis de modules de regroupement qui compressent l'entrée du modèle dans une section compacte appelée goulot d'étranglement [10].

Le goulot d'étranglement [10] est suivi par le décodeur qui se compose d'une série de modules de suréchantillonnage pour ramener la caractéristique compressée sous la forme d'une image. Dans le cas d'auto-encodeurs simples, la sortie devrait être la même que l'entrée avec un bruit réduit.

Cependant, pour les auto-encodeurs variationnels, il s'agit d'une image complètement nouvelle, formée avec des informations que le modèle a fournies en entrée.

- **Goulot**

La partie la plus importante du réseau neuronal, et ironiquement la plus petite, est le goulot d'étranglement [10]. Le goulot d'étranglement existe pour restreindre le flux d'informations vers le décodeur depuis l'encodeur, ne permettant ainsi que le passage des informations les plus vitales.

Étant donné que le goulot d'étranglement est conçu de telle manière que le maximum d'informations détenues par une image  $y$  soit capturé, nous pouvons dire que le goulot d'étranglement nous aide à former une représentation de la connaissance de l'entrée. Ainsi, la structure codeur-décodeur [10] nous aide à extraire le maximum d'une image sous forme de données et à établir des corrélations utiles entre les différentes entrées du réseau.

Un goulot d'étranglement [10] en tant que représentation compressée de l'entrée empêche en outre le réseau neuronal de mémoriser l'entrée et de surajuster les données. En règle générale, souvenez-vous de ceci : plus le goulot d'étranglement est petit, plus le risque de surajustement est faible. Cependant, De très petits goulots d'étranglement restreindraient la quantité d'informations pouvant être stockées, ce qui augmente les risques que des informations importantes glissent à travers les couches de regroupement de l'encodeur.

- **Décodeur**

Enfin, le décodeur [10] est un ensemble de blocs de suréchantillonnage et de convolution qui reconstruit la sortie du goulot d'étranglement. Étant donné que l'entrée du décodeur est une représentation de connaissances compressée, le décodeur [10] sert de "décompresseur" et reconstruit l'image à partir de ses attributs latents.

### **II.7.3 L'entraînement d'un Auto-Encodeur**

On doit définir 4 hyperparamètres avant de former un auto-encodeur [10] :

**Taille du code :** la taille du code ou la taille du goulot d'étranglement est l'hyperparamètre le plus important utilisé pour régler l'auto-encodeur [10]. La taille du goulot d'étranglement détermine la quantité de données à compresser. Cela peut également servir de terme de régularisation.

**Nombre de couches :** comme tous les réseaux de neurones, un hyperparamètre [10] important pour régler les auto-encodeurs est la profondeur de l'encodeur et du décodeur. Alors qu'une profondeur plus élevée augmente la complexité du modèle, une profondeur plus faible est plus rapide à traiter.

**Nombre de nœuds par couche :** Le nombre de nœuds par couche définit les poids que nous utilisons par couche [10]. En règle générale, le nombre de nœuds diminue avec chaque couche suivante dans l'auto-encodeur à mesure que l'entrée de chacune de ces couches devient plus petite à travers les couches.

**Perte de reconstruction :** la fonction de perte que nous utilisons pour entraîner l'auto-encodeur dépend fortement du type d'entrée et de sortie [10] auquel nous voulons que l'auto-encodeur s'adapte. Si nous travaillons avec des données d'image, les fonctions de perte les plus populaires pour la reconstruction sont MSE Loss et L1 Loss. Dans le cas où les entrées et les sorties sont dans la plage  $[0,1]$ , comme dans MNIST, nous pouvons également utiliser l'entropie croisée binaire comme perte de reconstruction.

Enfin, explorons les différents types d'encodeurs automatiques que vous pourriez rencontrer.

## II.8 Auto-Encodeur Variationnel « VAE »

L'Autoencodeur Variationnel [11] a été proposé en 2013 par Knigam et Welling chez Google et Qualcomm. Un autoencodeur variationnel (VAE) [11] fournit une manière probabiliste de décrire une observation dans l'espace latent. Ainsi, plutôt que de construire un encodeur qui génère une valeur unique pour décrire chaque attribut d'état latent. Il a de nombreuses applications telles que la compression de données, la création de données synthétiques, etc.

### II.8.1 Architecture d'un Auto-Encodeur Variationnel

Les Auto-Encodeurs sont un type de réseau de neurones qui apprend les codages de données à partir de l'ensemble de données de manière non supervisée. Il contient essentiellement deux parties [11]: la première est un encodeur qui est similaire au réseau de neurones à convolution [11], à l'exception de la dernière couche.

L'objectif de l'encodeur est d'apprendre un codage de données efficace à partir de l'ensemble de données et de le transmettre à une architecture de goulot d'étranglement. L'autre partie de l'encodeur automatique est un décodeur [11] qui utilise l'espace latent dans la couche de goulot d'étranglement pour régénérer les images similaires à l'ensemble de données. Ces résultats se propagent à partir du réseau de neurones sous la forme de la fonction de perte.

L'Autoencodeur Variationnel [11] est différent de l'autoencodeur en ce sens qu'il fournit une méthode statistique pour décrire les échantillons de l'ensemble de données dans l'espace latent. Par conséquent, dans l'autoencodeur variationnel, l'encodeur produit une distribution de probabilité dans la couche de goulot d'étranglement au lieu d'une seule valeur de sortie.

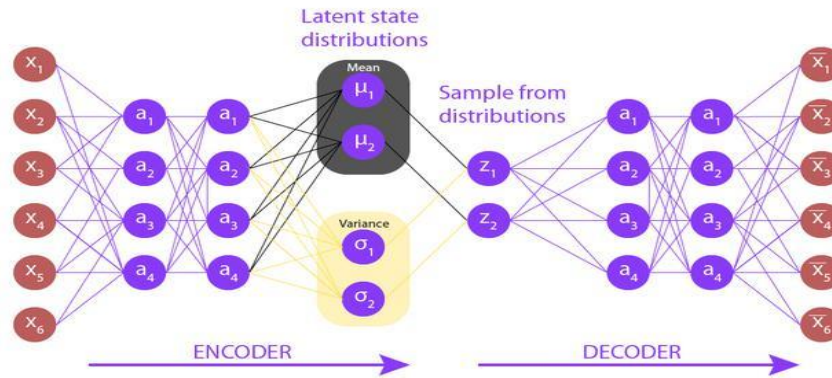


Figure 11 : Architecture d'un VAE [11]

Dans les sections précédentes, on a mentionné que la détection d'anomalies avec des auto-encodeurs simplifiés, ont été appliqués largement au niveau de la réduction des dimensions et la réduction de bruit d'une image. Dans la prochaine section, on va aborder le sujet de la réduction de bruit d'une image via les auto-encodeurs. Pour faire une modélisation des données d'image, il nécessite une approche la plus connue dans le monde des réseaux de neurones, qui s'appelle CNN (le réseau neuronal convolutif).

## II.9 Le Réseau Neuronal Convolutif (CNN)

CNN est un type de modèle de réseau neuronal [12] qui peut extraire des représentations supérieures de l'image. Le prétraitement demandé dans un CNN est considéré beaucoup plus faible par rapport aux autres algorithmes de classification. Alors que dans les méthodes primitives, les filtres sont modélés ou bien créés à la main, avec un entraînement suffisant, les CNN ont l'habilité d'apprendre ces filtres/caractéristiques.

### II.9.1 Le principal fonctionnement de CNN

Les CNN ont besoin de modèles pour s'entraîner et tester [13]. Chaque image d'entrée traverse une série de couches de convolution avec des filtres (Kernels), Pooling, des couches entièrement connectées (FC) et applique la fonction softmax (Généralisation de la fonction

logistique qui "écrase" un vecteur à K dimensions de valeurs réelles arbitraires en valeurs réelles (Kd vector) pour classer un objet avec des valeurs probabilistes entre 0 et 1 [13]. C'est la raison pour laquelle chaque image dans CNN est représentée comme une matrice de valeurs de pixels [13], elle peut être présentée sur deux dimensions si elle est au niveau de gris sinon sur trois dimensions pour faire représenter les trois couleurs essentielles (rouge, vert et bleu) (RVB).

Les couches Convolution + Pooling agissent comme des extracteurs de caractéristiques de l'image d'entrée tandis qu'une couche entièrement connectée agit comme un classificateur.

## II.9.2 L'architecture d'un CNN

Les couches utilisées pour construire des réseaux de neurones convolutifs CNN [13] simple est une séquence de couches, et chaque couche d'un CNN transforme un volume d'activations en un autre grâce à une fonction différentiable.

Les quatre principaux types de couches pour construire nos architectures CNN sont [13]:

- Couche convolutive.
- ReLU.
- Regroupement ou sous-échantillonnage (le Max-Pooling).
- Couche entièrement connectée (FC).

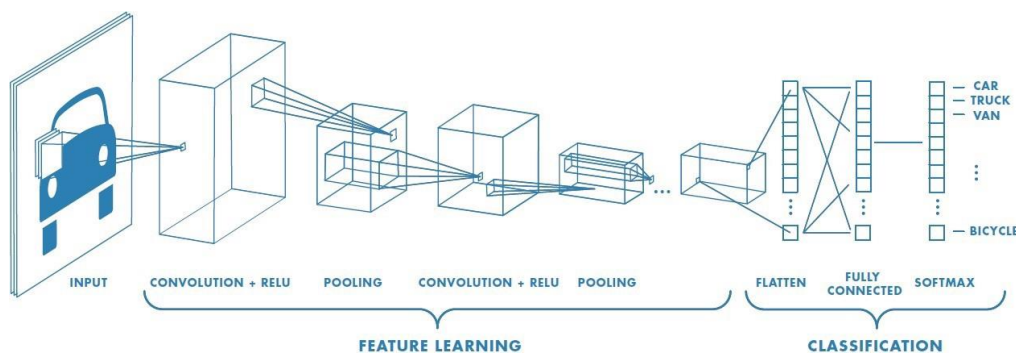


Figure 12: L'architecture d'un CNN [12]

## Couche Convolutive

Cette couche [13] assure la relation spatiale entre les pixels en apprenant les caractéristiques de l'image à l'aide de petits carrés de données d'entrée. La taille de la carte des entités est contrôlée par trois paramètres.

- Profondeur : nombre de filtres utilisés pour l'opération de convolution.
- Stride : nombre de pixels par lequel filtrer la matrice sur la matrice d'entrée.
- Remplissage : Il est bon d'entrer une matrice avec des zéros autour de la bordure, matrice.
- Calcul de l'erreur totale au niveau de la couche de sortie avec sommation sur les 4 classes.
  - ✓ Erreur totale =  $\sum \frac{1}{2} (\text{probabilité cible} - \text{probabilité de sortie})^2$
  - ✓ Calcul de la sortie des neurones connectés aux régions locales de l'entrée. Cela peut entraîner un volume.

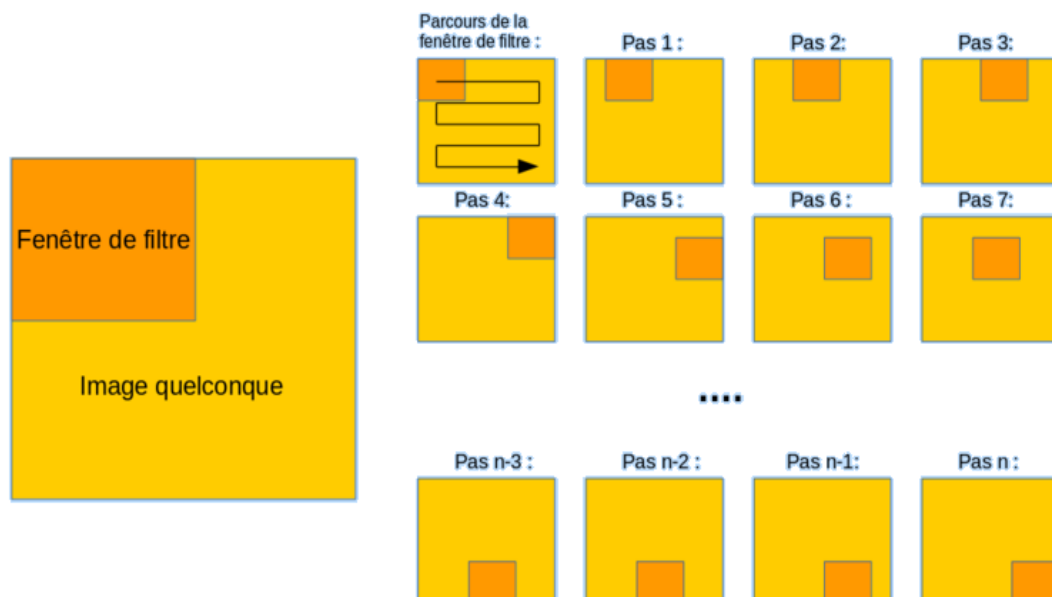


Figure 13: Couche Convolutive [5]

### Couche d'Unité Linéaire Rectifiée (ReLU)

Une opération non linéaire. Cette couche [13] applique une fonction d'activation élément par élément. ReLU est utilisé après chaque opération de convolution. Il est appliqué par pixel et remplace toutes les valeurs de pixel négatives dans la carte des caractéristiques par zéro. ReLU est une opération non linéaire.

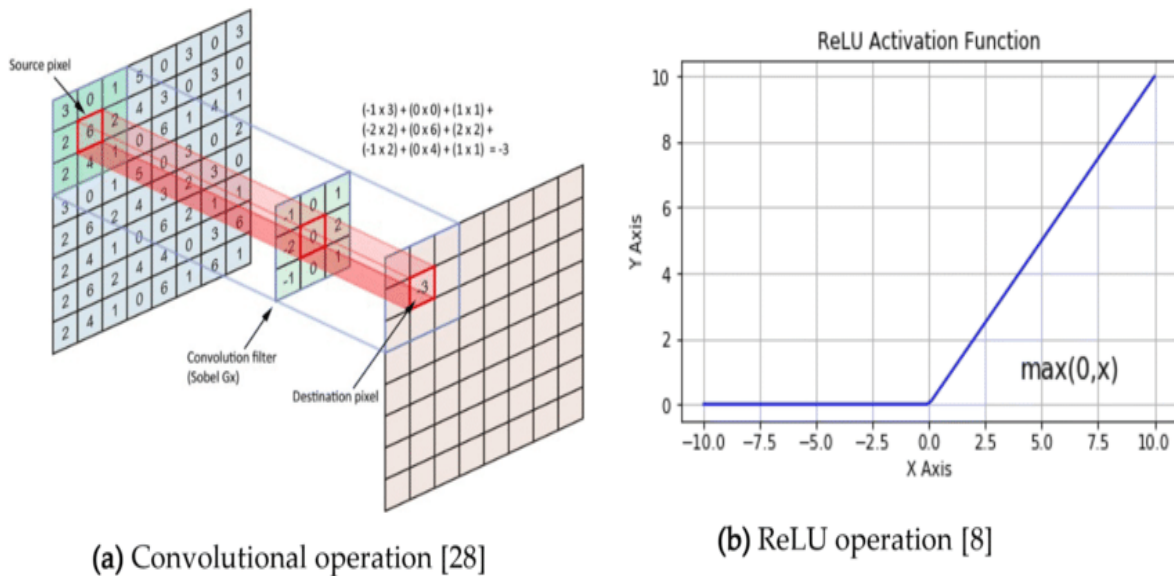


Figure 14: La couche ReLU [14]

### Couche de Regroupement ou sous-échantillonnage (le Max-Pooling).

La couche de regroupement [13] appelé aussi sous-échantillonnage (le Max-pooling) [13] effectue une opération de sous-échantillonnage le long des dimensions spatiales (largeur, hauteur), c'est-à-dire réduit la dimensionnalité de chaque carte d'entités mais conserve les informations les plus importantes.




Figure 15 : La couche Max-Pooling [15]

## Couche Entièrement Connectée (FC)

Cette couche [15] est placée en fin d'architecture de CNN et est entièrement connectée à tous les neurones de sorties (d'où le terme fully-connected). Après avoir reçu un vecteur en entrée, la couche FC applique successivement une combinaison linéaire puis une fonction d'activation **Softmax** dans le but final de classifier l'input image. Elle renvoie enfin en sortie un vecteur de taille  $d$  correspondant au nombre de classes dans lequel chaque composante représente la probabilité pour l'input image d'appartenir à une classe.




Figure 16 : La couche Entièrement Connectée (FC) [16]

## II.10 Conclusion

Dans ce chapitre, nous avons montré que les performances de l'apprentissage profond (deep learning) dépassent les performances des techniques traditionnelles de l'apprentissage automatique (le machine learning).

Nous avons présenté aussi l'utilisation et l'importance des auto-encodeurs Variationnels dans l'apprentissage profond (deep learning) ainsi leur fonctionnalité et leur performance par rapport aux auto-encodeurs simples dans la génération des données.

Les réseaux que nous avons eu choisi pour les auto-encodeurs variationnels et que nous les avons considérés très essentiel dans notre étude c'est les réseaux neuronal convolutifs (CNN) qui sont une classe de réseaux de neurones qui se sont avérés très efficaces dans les domaines de la reconnaissance, du traitement et de la classification des images.

---

# Chapitre 3

## *Développement et Implémentation*

---

Au cours de ce chapitre nous allons décrire étape par étape notre solution proposée. On va détailler notre architecture, les paramètres et les résultats obtenus.

### III.1 Les outils utilisés

Pour développer notre algorithme, nous avons utilisé le langage Python. C'est un langage très utilisé dans le domaine de machine learning, connu pour sa facilité d'apprentissage et sa simplicité d'utilisation. Python permet d'écrire des codes très complexes avec quelques simples lignes. La syntaxe élégante de python et son mode interprété rend la programmation trop amusante, flexible et dynamique.

Pour les bibliothèques utilisées pour implémenter notre modèle génératif, nous avons utilisé deux bibliothèques Tensorflow et keras. Tensorflow est une bibliothèque de Machine Learning, il s'agit d'une boîte à outils permettant de résoudre des problèmes mathématiques extrêmement complexes avec aisance. Elle permet aux chercheurs de développer des architectures d'apprentissages expérimentaux et de les transformer en logiciels. Par contre, Keras s'exécute sur des bibliothèques comme TensorFlow. Il est basé sur une structure minimale qui offre un moyen simple et propre de créer des modèles d'apprentissage en profondeur basés sur TensorFlow

Pour l'implémentation de notre travail, nous avons décidé d'utiliser la plateforme Kaggle. C'est une plateforme web appartenant à Google très répandue et très utilisée pour l'organisation des compétitions dans le domaine des sciences des données. Nous l'avons choisie pour sa facilité à charger les datasets avec grandes tailles et aussi sa vitesse d'exécution performante grâce au mode GPU qu'elle fournit. L'utilisation de Kaggle a besoin d'ouvrir un compte et créer un notebook. Son interface est donnée dans **Figure17**.

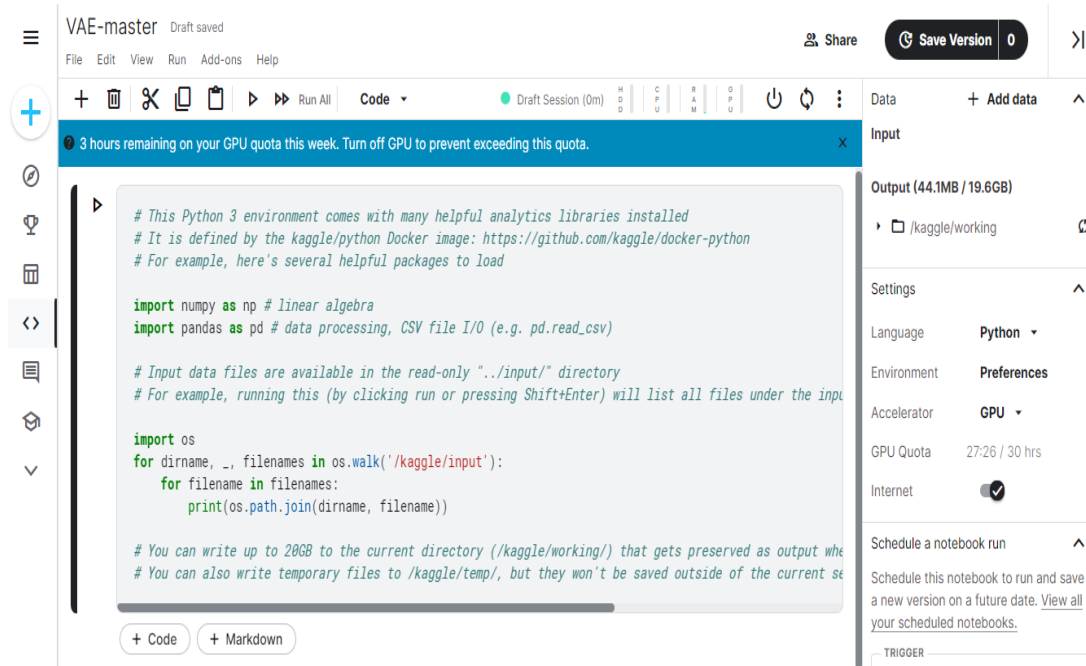


Figure 17: Interface de compte sur kaggle [17]

### III.2 DATA SET

Le dataset joue un rôle primordial dans toute application basée sur l'intelligence artificielle car c'est la ressource utilisée par les différents modèles pour apprendre. Chaque dataset doit se diviser en deux parties : Une partie utilisée pour la construction du modèle dans la phase d'entraînement et une partie pour valider et tester dans la phase du test.

Dans ce travail, nous avons utilisé le dataset HAM10000 ("Human Against Machine with 10 000 training images"), qui est une grande collection d'images de démoscopie multi-sources. Ce dataset est disponible sur l'archive 'The International Skin Imaging Collaboration' (ISIC) et contient des images de différentes lésions cutanées pigmentées. Il a été créé pour surmonter le problème des ensembles de données de petite taille. Nous avons procédé une sélection manuelle des images. Premièrement, nous avons séparé les images avec poils et sans poils dans deux dossiers différents. Puis, nous avons séparé 100 images avec poils pour les employer dans l'étape de validation. Toutes les images ont été redimensionnées en 256\*256. **Figure18** illustre quelques exemples des images avec et sans poils.




Figure 18 : Quelques exemples d'images du HAM10000 [18]

### III.3 Architecture proposé du VAE

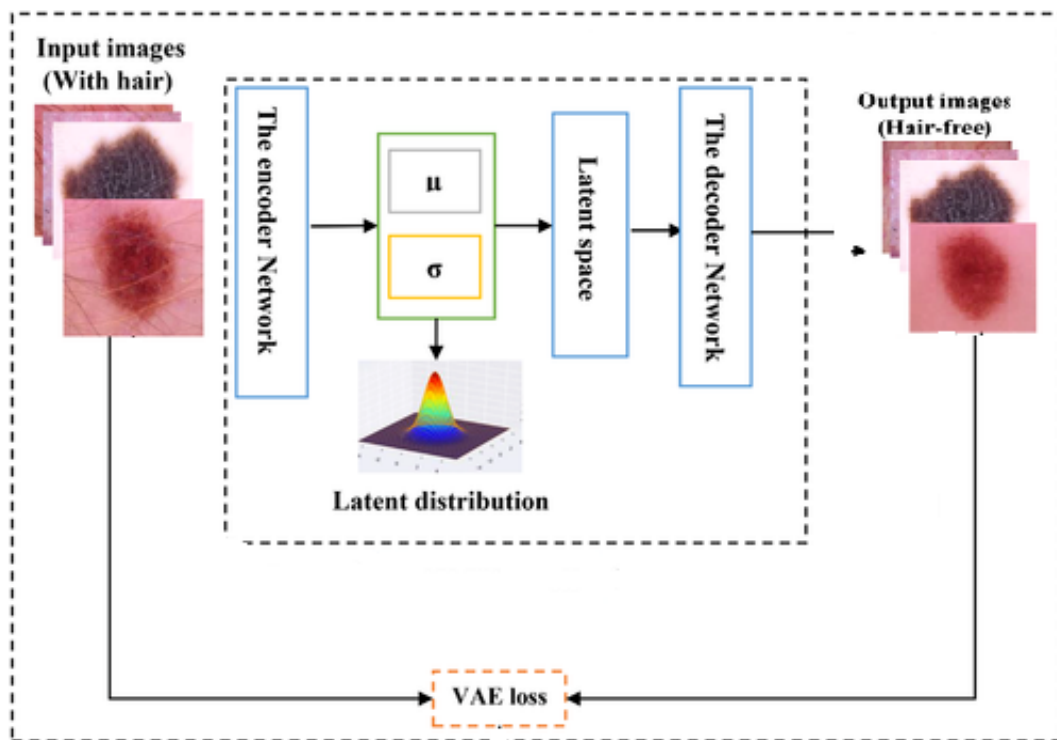


Figure 19 : L'architecture propose du VAE

L'architecture illustrée en **Figure19** décrit le processus utilisé pour construire un modèle fiable qui emploie VAE pour produire des images sans poils. Donc, le modèle prend un ensemble des images comme entrée puis il les passe vers l'encodeur puis vers le latent space et finalement il les décode avec le décodeur. Notre but avec cette architecture est d'apprendre les valeurs optimales d'encodeur, de latent space et de décodeur qui permet de construire des images identiques à celles des entrées en termes de qualité mais sans poils. L'avantage de VAE qu'on a constaté est qu'il considère les poils comme un bruit, et durant la construction du latent space, ils ignorent complètement. Donc quand on échantillonne du latent space, on obtient que des images sans poils.

Pour construire l'encodeur et le décodeur, on a utilisé CNN avec plusieurs couches. Leur architecture est illustre en **Figure20** et détaillé dans la Table ci-dessus.

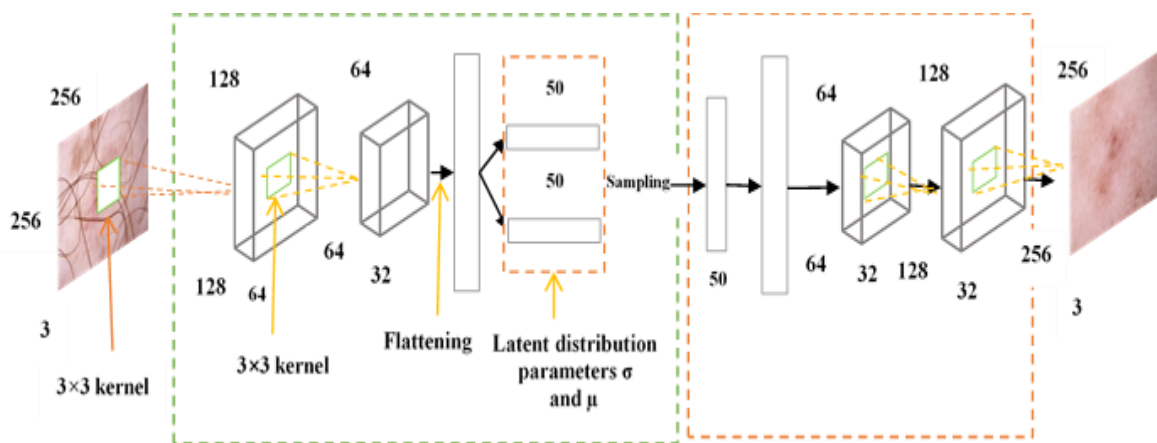


Figure 20: Architecture d'encodeur et de décodeur.

	Encodeur				Decodeur			
	Taille de filtre	Activation	Stride	Nombre de filtres	Taille de filtre	Activation	Stride	Nombre de filtres
Couche 1	3	relu	2	64	3	relu	2	32
Couche 2	3	relu	2	32	3	relu	2	64

Table 1 : L'architecture détaillée d'encodeur et de décodeur

```
Model: "encoder"
```

Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	[(None, 256, 256, 3)]	0	
conv2d (Conv2D)	(None, 128, 128, 64)	1792	input_1[0][0]
conv2d_1 (Conv2D)	(None, 64, 64, 32)	18464	conv2d[0][0]
flatten (Flatten)	(None, 131072)	0	conv2d_1[0][0]
z_mean (Dense)	(None, 50)	6553650	flatten[0][0]
z_log_var (Dense)	(None, 50)	6553650	flatten[0][0]
z (Lambda)	(None, 50)	0	z_mean[0][0] z_log_var[0][0]

Figure 21 Screenshot pris du kaggle qui détaille le résultat de chaque opération exécutée par l'encodeur. [19]

```
Model: "decoder"
```

Layer (type)	Output Shape	Param #
z_sampling (InputLayer)	[(None, 50)]	0
dense (Dense)	(None, 131072)	6684672
reshape (Reshape)	(None, 64, 64, 32)	0
conv2d_transpose (Conv2DTran	(None, 128, 128, 32)	9248
conv2d_transpose_1 (Conv2DTr	(None, 256, 256, 64)	18496
conv2d_transpose_2 (Conv2DTr	(None, 256, 256, 3)	1731

Figure 22 : Screenshot pris du kaggle qui détaille le résultat de chaque opération exécutée par le décodeur. [19]

### III.4 Les paramètres d'apprentissage

Nous avons testé des architectures simples et profondes avec de nombreuses couches mais une architecture décente a conduit aux meilleures performances. La normalisation par lots a également été mise à l'épreuve mais cela n'a eu aucun effet sur les performances d'optimisation. Le modèle a été formé à l'aide de l'optimiseur Adam et le taux d'apprentissage a été fixé à 0,0001. La taille de batch a été fixée au 16 tandis que le nombre d'époques a été réglé sur 200.

### III.5 Les résultats

Après avoir terminé l'entraînement du modèle, nous l'avons testé sur l'ensemble de test. **Figure23** illustre quelques exemples. Comme la figure montre, notre modèle a réussi à éliminer les poils.



Figure 23 : (A) images originales avec poils, (B) images sans poils après avoir utilisé VAE.

[18] [19]

#### III.5.1 Comparaison avec l'état de l'art

Nous allons comparer les résultats obtenus par notre modèle avec **DullRazor**, qui est un ancien outil développé pour éliminer les poils. **Figure24** démontre la différence entre notre modèle et celui de **DullRazor**. Il est très clair que l'efficacité de notre VAE est plus élevée.




Figure 24: Comparaison entre notre modèle et DullRazor [20] [20]

### III.6 Conclusion

Dans ce chapitre, nous avons essayé de bien expliquer les étapes que nous avons suivies pour résoudre le problème des poils dans les images dermoscopiques. Pourtant l'architecture utilisée est très simple mais elle a abouti à ce que nous avons cherché. Il nous reste un problème à traiter avec d'autres techniques dans le futur ce qui apparaît dans la qualité des images générées.

## **Conclusion générale**

Dans ce mémoire, nous avons démontré la pertinence du modèle qui utilise le deep learning pour l'élimination automatique des poils dans les images dermoscopiques. Nous avons conçu un modèle basé sur des méthodes, en mettant l'accent sur les autoencodeurs variationnels qui sont bien adaptées au traitement d'images.

Suite aux expérimentations réalisées, nous sommes en mesure de conclure que notre modèle conçu a prouvé des performances dans le processus d'élimination des poils des images dermoscopiques, et que notre méthode appliquée sur les images avec poils est très efficace, Ceci est démontré dans les résultats obtenus, qui sont comparés aux résultats des méthodes précédentes, utilisées déjà dans des expériences d'épilation.

En tant que travaux futurs, nous visons à utiliser notre approche pour maintenir la qualité des images générées sans poils. Qui va faire aider à résoudre le problème de la segmentation des lésions et à classifier les images du cancer de la peau.

## Bibliographie

- [1] «RamsaySanté,» [En ligne]. Available: <https://www.ramsaysante.fr/vous-etes-patient-en-savoir-plus-sur-ma-pathologie/melanome>.
- [2] «uniprix,» [En ligne]. Available: <https://www.uniprix.com/fr/conseils/1/sante/melanomes-des-tumeurs-malignes>.
- [3] «SkinCancerFoundation,» [En ligne]. Available: <https://www.skincancer.org/international/labcde-du-melanome/>. [Accès le 16 Avril 2022].
- [4] «FICHE PRATIQUE,» [En ligne]. Available: <https://fiches-pratiques.e-marketing.fr/Thematique/data-marketing-1290/FichePratique/est-que-Intelligence-Artificielle-Machine-Learning-Deep-Learning-358567.htm>.
- [5] «DataScientest,» [En ligne]. Available: <https://datascientest.com/machine-learning-tout-savoir>.
- [6] «Je veux etre Data Scientist,» [En ligne]. Available: <https://www.jeveuxetredatascientist.fr/quest-ce-que-le-machine-learning/>.
- [7] «lebigdata.fr,» [En ligne]. Available: [https://www.lebigdata.fr/deep-learning-definition#Deep\\_Learning\\_apprentissage\\_profond\\_fonctionnement](https://www.lebigdata.fr/deep-learning-definition#Deep_Learning_apprentissage_profond_fonctionnement).
- [8] «Datakeen,» [En ligne]. Available: [https://www.datakeen.co/wp-content/uploads/2018/02/S%C3%A9lection\\_107.png](https://www.datakeen.co/wp-content/uploads/2018/02/S%C3%A9lection_107.png).
- [9] «FUTURA TECH,» [En ligne]. Available: <https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/>.
- [10] «V7,» [En ligne]. Available: <https://www.v7labs.com/blog/autoencoders-guide>.
- [11] «acervo lima,» [En ligne]. Available: <https://fr.acervolima.com/encodeurs-automatiques-variationnels/>.
- [12] «tds,» [En ligne]. Available: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>.
- [13] «Vinod Sharma's Blog,» [En ligne]. Available: <https://vinodsblog.com/2018/10/15/everything-you-need-to-know-about-convolutional-neural-networks/>.

- [14] «ResearchGate,» [En ligne]. Available: [https://www.researchgate.net/figure/Functionalities-of-convolution-and-ReLU-layers-of-CNN\\_fig3\\_339342379](https://www.researchgate.net/figure/Functionalities-of-convolution-and-ReLU-layers-of-CNN_fig3_339342379).
- [15] «AI,» [En ligne]. Available: <https://ai.plainenglish.io/pooling-layer-beginner-to-intermediate-fa0dbdce80eb>.
- [16] «tlds,» [En ligne]. Available: <https://towardsdatascience.com/convolutional-neural-network-for-image-classification-with-implementation-on-python-using-pytorch-7b88342c9ca9>. [Accès le 18 MAI 2022].
- [17] «Kaggle,» [En ligne]. Available: <https://www.kaggle.com/>. [Accès le 7 Février 2022].
- [18] «Kaggle,» [En ligne]. Available: <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000>. [Accès le 15 Février 2022].
- [19] «Kaggle,» [En ligne]. Available: <https://www.kaggle.com/code/noorghezal/autoencoder>. [Accès le 2 Juin 2022].
- [20] M. M. M. M.-D. o. C. P. U. B.-8. Dr. S Natarajan Professor of Department of CSE PES University Bangalore-85, «Melanoma Skin Cancer Detection using Image Processing and Machine Learning,» International Journal of Engineering Research & Technology (IJERT), 2019.
- [21] «StockLib,» [En ligne]. Available: <https://www.stocklib.fr/media-34583510/melanoma-or-skin-cancer-this-rare-type-of-skin-cancer-originates-from-melanocytes-layers-of-the-human-skin.html?keyword=skin>. [Accès le 3 Mai 2002].