



UNIVERSITE IBN KHALDOUN - TIARET

MEMOIRE

Présenté à :

FACULTÉ MATHÉMATIQUES ET INFORMATIQUE
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de :

MASTER

Spécialité : **Réseaux et Télécommunication**

Par :

**Mazouzi Mohamed
Senouci Ali**

Sur le thème

**L'apprentissage profond pour la recherche et la
classification des images basé sur le cloud**

Soutenu publiquement le .. / 07 / 2019 à Tiaret devant le jury composé de :

Mr MEZZOUG Karim

MAA Université de Tiaret

Président

Mr MERATI Medjeded

MCB Université de Tiaret

Encadreur

Mr GHAFOUR Yacine

MAA Université de Tiaret

Examineur

Dédicaces

Nous dédions notre travail à :

A tous les membres de la famille et à tous les amis.

Remerciements

- *Nous tenons à remercier tout d'abord notre encadreur : Mr **MERATI Medjeded**, pour tous ses conseils, son soutien, son aide, et son orientation.*
- *Nous remercions les membres de jury Mr **MEZZOUG karim** et Mr **GHAFOUR Yacine** d'avoir accepté de juger notre travail.*
- *Nous remercions tous les enseignants du département d'informatique, et aussi nos camarades de la promotion 2018-2019 Master informatique.*
- *Nous remercions toutes les personnes qui nous ont soutenues de près ou de loin dans la réalisation de ce travail.*

Résumé

La recherche du contenu multimédia est devenue très importante notamment après la profusion de ce dernier dans le réseau Internet. Dans ce contexte, la recherche d'images similaires à une image requête est une problématique connue dans le domaine de la classification des images.

A cet effet, nous avons proposé un système de recherche combinant les mesures de similarité avec la classification des images basée sur l'apprentissage automatique.

Nous avons choisi d'utiliser un modèle de réseau de neurones convolutif (CNN) « Convolutional Neural Networks » dans la classification des images et la distance euclidienne comme mesure de similarité entre l'image requête et les images de la base classées par le CNN comme étant de la même classe que l'image requête.

Nous avons testé notre système sur une base d'images à huit classes dans un environnement Cloud.

Mots clés : Recherche, Classification, Images similaires, CNN, Distance euclidienne, Cloud.

Sommaire

Table des matières

Chapitre I introduction générale	9
I.1. Introduction :.....	11
I.2. L'objectif :.....	11
I.3. Approche proposée :.....	11
I.4. Plan de lecture :.....	11
Chapitre II	13
Classification des Images	13
II.1.Introduction :.....	14
II.2.Définition de la classification :.....	14
II.3.L'objectif de la classification :.....	14
II.4.Les différentes méthodes de la classification et l'apprentissage :.....	14
II.4.1. Méthodes supervisées :.....	14
II.4.2. Méthodes non-supervisées :.....	15
II.5. Classification des images et l'apprentissage automatique :.....	15
II.6. Classification des images et les réseaux de neurones :.....	16
II.7. Conclusion :.....	17
Chapitre III Deep Learning	18
III.1.Introduction :.....	19
III.2.Définition apprentissage profond « Deep Learning » :.....	19
III.3.Domains d'application de l'apprentissage profond :.....	20
III.4.Architectures de réseaux de neurones profonds :.....	21
III.4.1. Architecture d'un CNN :.....	21
III.4.2. Couches de traitement de CNN :.....	22
III.4.2.1La couche de convolution (CONV) :.....	22
III.4.2.2.Couche de Pooling (POOL) :.....	23
III.4.2.3.Couche de correction (ReLU):.....	24
III.4.2.4.Couche entièrement connectée (FC) :.....	25
III.4.2.5.Couche de perte (LOSS) :.....	25
III.5. Exemples de modèles de CNN :.....	25
III.6. Avantages de CNNs :.....	26
III.7. Conclusion :.....	26

Chapitre IV	27
Cloud Computing	27
IV.1. Introduction :.....	28
IV.2. Définition de Cloud Computing :.....	28
IV.3. Types de Cloud Computing :.....	29
IV.3.1. Cloud privé :.....	29
IV.3.2. Cloud de Communauté :.....	29
IV.3.3. Cloud Public :.....	30
IV.3.4. Cloud Hybride :.....	30
IV.4. Modèle d'application de Cloud Computing :.....	30
IV.4.1. La phase stratégique :.....	31
IV.4.1.1.La proposition de calcul de valeur :.....	31
IV.4.1.2.Le Cloud stratégie :.....	32
IV.4.2. La phase de planification :.....	32
IV.4.3. La phase de déploiement :.....	32
IV.5.Les services du Cloud Computing :.....	32
IV.5.1. IaaS :.....	33
IV.5.2. PaaS :.....	33
IV.5.3. SaaS :.....	33
IV.6.Exemples de Cloud Computing:.....	34
IV.6.1.DROPBOX :.....	34
IV.6.2.GOOGLE DRIVE :.....	35
IV.7.Les avantages et les contraintes de Cloud Computing :.....	36
IV.7.1. Les avantages :.....	36
IV.7.2. Contraintes et limites :.....	36
IV.8. Sécurité et confidentialité du Cloud Computing :.....	37
IV.9. Conclusion :.....	38
Chapitre V Conception et implumentation	39
V.1.Introduction :.....	40
V.2.Notre approche proposée :.....	40
V.3.L'environnement Cloud :.....	41
V.3.1. Python :.....	41
V.3.2. Google Colaboratory :.....	42
V.3.3. Google Drive :.....	42

V.4.Base des images :.....	42
V.5.Système proposé :.....	43
V.5.1. Architecture du modèle CNN :.....	43
V.5.2. La distance euclidienne :	44
V.6.Discussion des résultats :.....	45
V.7.Conclusion :.....	46
Bibliographie :	48

Listes des figures :

Figure III.1 : La relation entre l'intelligence artificielle, le ML et le Deep Learning.....	15
Figure III.2 : La différence entre l'apprentissage profond et l'apprentissage automatique.....	16
Figure III.3 : La différence de performance entre le Deep Learning et la plupart Des algorithmes de ML en fonction de la quantité de données.....	16
Figure III.4 : Exemple d'architecture CNN Classification d'images.....	17
Figure III.5 : Illustration de la convolution.....	18
Figure III.6: Pooling avec un filtre 2x2 et un pas de 2.....	19
Figure III.7 : Trois fonctions d'activation.....	20
Figure III.8 : Exemples de modèles de CNN.....	21
Figure I.11 : Infrastructure de cloud computing.....	25
Figure IV.2 : Les types de Cloud Computing.....	26
Figure IV.3 : Modèle d'application de Cloud Computing.....	27
Figure I.1 Les services du Cloud Computing.....	30
Figure IV.5 : DROPBOX.....	31
Figure IV.6: Google Drive.....	31
Figure V.1 : Modèle CNN.....	37
Figure V.2 : Base des images.....	38
Figure V.3 : Architectures CNN.....	40

Listes des tableaux :

Tableau 1 : résultats obtenu par le modèle CNN proposé.....41

Tableau 2 : précision des n premières images en réponse à l'image requête.....41

Chapitre I

Introduction générale.

I.1. Introduction :

Le nombre de bases d'images numériques est actuellement en augmentation rapide, et la taille du contenu multimédia créé et stocké chaque jour croît significativement. En même temps un besoin croissant de partage et d'accès rapide à des informations faiblement structurées (images, musiques, etc.) se précise jour après jour.

Dans ce contexte, le besoin à des systèmes de recherche des images répondant aux demandes des utilisateurs se fait sentir de plus en plus.

A cet effet, la recherche d'images similaires à une image requête de l'utilisateur constitue une problématique très connue dans le domaine de la classification des images.

I.2. L'objectif :

Par conséquent, nous songeons à travers ce travail proposer un système qui soit capable de rechercher des images similaires à une image requête où la recherche d'images se fait dans une base d'images constituée de plusieurs classes.

I.3. Approche proposée :

Notre approche est basée sur une combinaison de la classification des images en utilisant un modèle de réseau basé sur l'apprentissage profond et l'utilisation de la distance euclidienne entre les images de la base classées par le modèle réseau comme étant ayant la même classe que celle de l'image requête. La liste de ces images est triée selon la valeur de la distance et les n premières images seront retournés comme images similaires les plus proches à l'image requête.

I.4. Plan de lecture :

Après un chapitre introductif, notre mémoire est organisé comme suit :

Le chapitre deux sert à donner la définition de la classification des et ses différents types, les réseaux de neurones et l'apprentissage automatique.

Le chapitre trois est consacré à la description de l'apprentissage profond et ses différentes techniques.

Chapitre I : Introduction générale

Le quatrième chapitre, sera consacré à l'explication des notions relatives au Cloud Computing.

Dans le cinquième chapitre, nous détaillons la partie expérimentale de notre travail dans laquelle nous décrivons notre modèle proposé pour la recherche et la classification des images.

Enfin, nous concluons ce mémoire et proposons des perspectives à notre travail dans la conclusion générale.

Chapitre II

Classification des Images

Chapitre II : Classification des Images.

II.1. Introduction :

L'Internet actuel fournit un contenu sous des formes de vidéos, e-mails et des informations servis dans les pages web avec le Cloud Computing qui nous donne la possibilité d'acheter des services informatiques. A partir du web nous serions en mesure de louer par le biais d'une vitrine virtuelle la base nécessaire pour construire un centre des données virtuel tels que le processeur, la mémoire et le stockage, et ajouter au-dessus l'intermédiaire nécessaire tels que les serveurs d'applications Web, bases de données et bus serveur d'entreprise...etc.

II.2. Définition de la classification :

Classifier une image est une tâche ou une série de méthodes qu'une théorie unifiée pour pouvoir utiliser les images pour les analyses complémentaires ou pour la cartographie. Elle consiste à déterminer des procédures permettant de rassembler l'ensemble des pixels de l'image en un nombre limité de classes correspondant aux grands éléments structuraux de l'image [1].

II.3. L'objectif de la classification :

L'objectif de la classification d'images est d'élaborer un système capable d'affecter une classe automatiquement à une image ainsi ce système permet d'effectuer une tâche d'expertise qui peut s'avérer coûteuse à acquérir pour un être humain en raison notamment de contraintes physiques comme la concentration, la fatigue ou le temps nécessaire à allouer pour un volume important d'images.

II.4. Les différentes méthodes de la classification et l'apprentissage :

De nombreuses méthodes classiques ont été consacrées elles peuvent être séparées en deux grandes catégories : les méthodes de classification supervisée et les méthodes de classification non supervisée.

II.4.1. Méthodes supervisées :

L'objectif de la classification supervisée est principalement de définir des règles permettant de classer des objets dans des classes à partir de variables qualitatives ou quantitatives caractérisant ces objets on dispose au départ d'un échantillon dit d'apprentissage dont le classement est connu. Cet échantillon est utilisé pour l'apprentissage des règles de classement. Il

Chapitre II : Classification des Images.

est nécessaire d'étudier la fiabilité de ces règles pour les comparer et les appliquer afin d'évaluer les cas de sous-apprentissage ou de sur-apprentissage (complexité du modèle). On utilise souvent un deuxième échantillon indépendant dit de validation ou de test [2].

II.4.2. Méthodes non-supervisées :

Contrairement aux méthodes supervisées, les méthodes non-supervisées ne nécessitent aucun apprentissage et aucune tâche préalable d'étiquetage manuel. Elle consiste à représenter un nuage des points d'un espace quelconque en un ensemble de groupes appelé **Cluster** lié généralement au domaine de l'analyse des données. Un « **Cluster** » est une collection d'objets qui sont « **similaires** » entre eux et qui sont « **dissemblables** » par rapport aux objets appartenant à d'autres groupes [3].

II.5. Classification des images et l'apprentissage automatique :

Les méthodes manuelles se sont avérées très difficiles à appliquer pour des tâches en apparence très simples comme la classification des images, la reconnaissance d'objets dans les images ou la reconnaissance vocale. Les données venant du monde réel, les échantillons d'un son ou les pixels d'une image sont complexes, variables et entachées de bruit.

Pour une machine, une image est un tableau de nombres indiquant la luminosité (ou la couleur) de chaque pixel, et un signal sonore est une suite de nombres indiquant la pression de l'air à chaque instant [4].

Les systèmes de reconnaissance des images classiques étaient composés de deux blocs : un de caractéristiques, suivi d'un classifieur entraînable simple. L'extracteur de caractéristiques est programmé « à la main », et transforme le tableau de nombres représentant l'image en une série de nombres, un vecteur de caractéristiques, dont chacun indique la présence ou l'absence d'un motif simple dans l'image. Ce vecteur est envoyé au classifieur, dont un type commun est le classifieur linéaire. Ce dernier calcule une somme pondérée des caractéristiques : chaque nombre est multiplié par un poids (positif ou négatif) avant d'être sommé. Si la somme est supérieure à un seuil, la classe est reconnue. Les poids forment une sorte de « prototype » pour la classe à laquelle le vecteur de caractéristiques est comparé. Les poids sont différents pour les classifieurs de chaque

Chapitre II : Classification des Images.

catégorie, et ce sont eux qui sont modifiés lors de l'apprentissage. Les premières méthodes de classification linéaire entraînable datent de la fin des années cinquante et sont toujours largement utilisées aujourd'hui. Elles prennent les doux noms de perceptron ou régression logistique.

Dans l'apprentissage automatique, un programme analyse un ensemble de données afin de tirer des règles qui permettront de tirer des conclusions sur de nouvelles données. L'apprentissage profond est basé sur ce qui a été appelé, par analogie, des « réseaux de neurones artificiels », composés de milliers d'unités (les « neurones ») qui effectuent chacune de petites opérations simples. Les résultats d'une première couche de « neurones » servent d'entrée aux calculs d'une deuxième couche et ainsi de suite.

II.6. Classification des images et les réseaux de neurones :

Le système entraînable est constitué d'une série de modules, chacun représentant une étape de traitement. Chaque module est entraînable, comportant des paramètres ajustables similaires aux poids des classifieurs linéaires. Le système est entraîné de bout en bout : à chaque exemple, tous les paramètres de tous les modules sont ajustés de manière à rapprocher la sortie produite par le système de la sortie désirée. Le qualificatif profond vient de l'arrangement de ces modules en couches successives [5].

Pour pouvoir entraîner le système de cette manière, il faut savoir dans quelle direction et de combien ajuster chaque paramètre de chaque module. Pour cela il faut calculer un gradient, c'est-à-dire pour chaque paramètre ajustable, la quantité par laquelle l'erreur en sortie augmentera ou diminuera lorsqu'on modifiera le paramètre d'une quantité donnée. Le calcul de ce gradient se fait par la méthode de rétropropagation. Dans sa réalisation la plus commune, une architecture profonde peut être vue comme un réseau multicouche d'éléments simples, similaires aux classifieurs linéaires, interconnectés par des poids entraîlables. C'est ce qu'on appelle un réseau neuronal multicouches.

Chapitre II : Classification des Images.

II.7. Conclusion :

Dans ce chapitre nous avons introduit les notions de recherche d'images et donné un aperçu général sur les méthodes de classification (supervisées non supervisées). Dans le chapitre suivant, nous allons décrire en détails notre approche proposée et son application sur un échantillon d'images, ainsi que les outils utilisés pour la réalisation de notre application.

Chapitre III

Deep Learning

Chapitre III : Deep Learning.

III.1. Introduction :

On entend de plus en plus parler en ce moment d'intelligence artificielle le Machine Learning et en particulier d'un de ses techniques à savoir l'apprentissage profond (Deep Learning). C'est grâce à cette technologie que des programmes informatiques sont désormais capables d'apprendre à effectuer des tâches complexes.

Dans ce chapitre nous allons présenter les notions en relation avec l'apprentissage profond.

III.2. Définition apprentissage profond « Deep Learning » :

L'apprentissage profond « *Deep Learning* » est un ensemble de techniques d'apprentissage automatique qui a permis des avancées importantes en intelligence artificielle dans les dernières années. Dans l'apprentissage automatique un programme analyse un ensemble de données afin de tirer des règles qui permettront d'obtenir des conclusions sur de nouvelles données (Figure III.1).




Figure III.1 : La relation entre l'intelligence artificielle, le ML et le Deep Learning

Le Deep Learning s'appuie sur un réseau de neurones artificiels s'inspirant du cerveau humain. Ce réseau est composé de « couches » de neurones ou plus le nombre de couches est élevé plus le réseau est « profond ». Chaque couche recevant et interprétant les informations de la couche précédente.

Chapitre III : Deep Learning.

Dans l'apprentissage automatique un programme analyse un ensemble de données afin de tirer des règles qui permettront de faire des conclusions sur de nouvelles données contrairement aux algorithmes traditionnelles utilisés pour l'étape de l'extraction de caractéristiques qu'est faite manuellement ce qui rend la tâche difficile et coûteuse en temps et requiert un spécialiste en la matière. En Deep Learning cette étape est exécutée automatiquement par l'algorithme, par exemple, pour la reconnaissance visuelle les premières couches d'unités identifient des lignes, des courbes, des angles. Les autres couches supérieures identifient des formes, des combinaisons de formes, des objets, des contextes... etc.

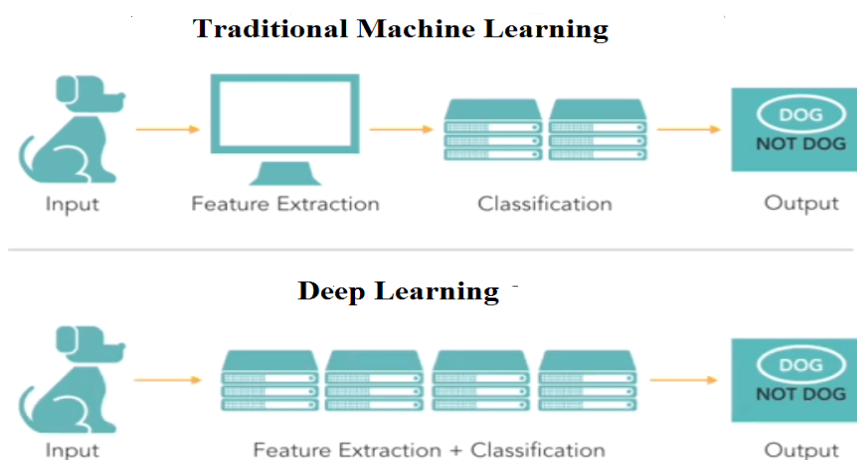


Figure III.2 : La différence entre l'apprentissage profond et l'apprentissage automatique

III.3. Domaines d'application de l'apprentissage profond :

Deep Learning est notamment utilisée pour développer les systèmes de conduite autonome des automobiles, elle est également responsable des améliorations spectaculaires constatées ces dernières années dans la reconnaissance de la parole, à la robotique, à la bio-informatique, dans l'imagerie et dans la traduction des langues. Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données (Figure III .3).

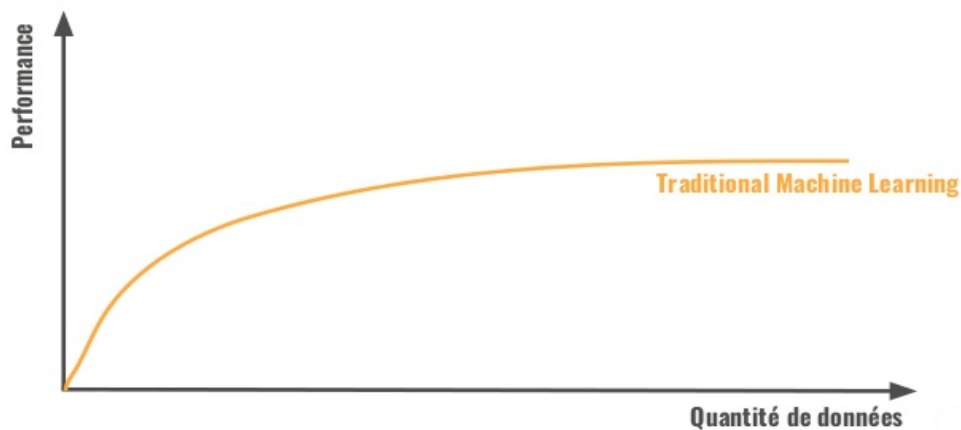


Figure III.3 : La différence de performance entre le Deep Learning et la plupart Des algorithmes de ML en fonction de la quantité de données.

III.4. Architectures de réseaux de neurones profonds :

Il existe un grand nombre de variantes d'architecture profond. La plupart d'entre elles sont dérivés de certaines architectures originales.

III.4.1. Architecture d'un CNN :

Un réseau de neurones convolutifs ou réseau de neurones à convolution est un type de réseau de neurones artificiels très performants dans la classification des images désignés par l'acronyme CNN ou ConvNet (en anglais pour Convolutional Neural Networks). Un CNN est simplement un empilement de plusieurs couches de **convolution**, **pooling**, correction **ReLU** où chaque image reçue en entrée va donc être filtrée, réduite et corrigée plusieurs fois pour finalement former un vecteur qui contient, notamment dans le problème de classification, les probabilités d'appartenance aux classes. Les couches intermédiaires peuvent s'empiler de différentes manières à condition que la sortie d'une couche ait la même structure que l'entrée de la couche suivante (Figure III.4).

Chapitre III : Deep Learning.

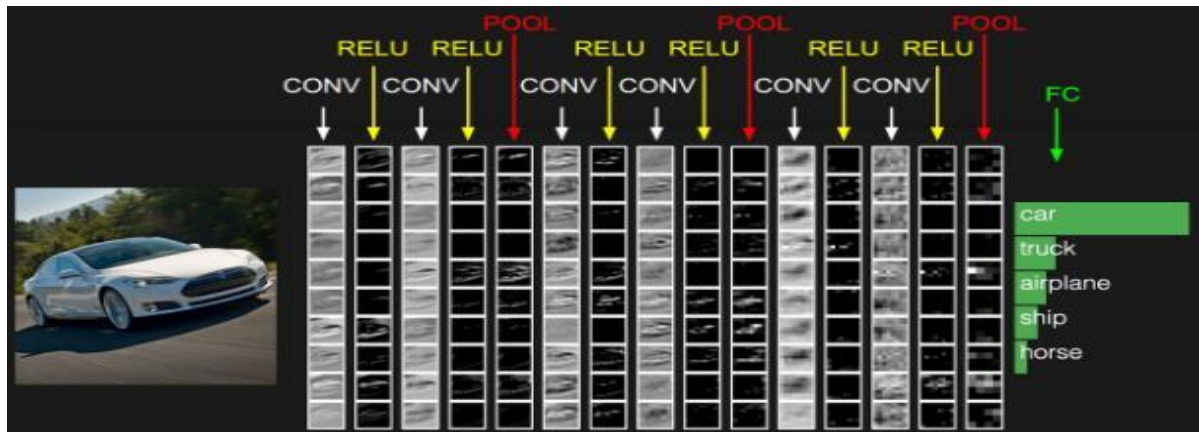


Figure III.4 : Exemple d'architecture CNN Classification d'images.

III.4.2. Couches de traitement de CNN :

CNN est formée d'un empilement de couches de traitement indépendantes :

III.4.2.1. La couche de convolution (CONV) :

La couche de convolution est la composante clé des réseaux de neurones convolutifs et constitue toujours au moins leur première couche. Dans cette couche, au lieu de faire un produit scalaire entre les valeurs internes et les poids de chaque neurone comme dans les réseaux de neurones traditionnel, on applique un produit de convolution. Ce produit de convolution fonctionne comme un extracteur de caractéristiques des images reçues en entrée. Le principe d'un filtrage par convolution est de faire "glisser" une fenêtre représentant la caractéristique sur l'image et de calculer le produit de convolution entre la caractéristique et chaque portion de l'image balayée. Trois hyper paramètres permettent de dimensionner le volume de la couche de convolution (aussi appelé volume de sortie) : la 'profondeur', le 'pas' et la 'marge' [6].

- **Profondeur de la couche** : nombre de noyaux de convolution ou nombre de neurones associés à un même champ récepteur.
- **Le pas** : Contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.
- **La marge à 0 ou zéro padding**: Parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. Cette marge permet de contrôler la dimension spatiale du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée (Figure III.6)




Figure III.6 : Illustration de la convolution.

III.4.2.2. Couche de Pooling (POOL) :

L'image d'entrée est découpée sans chevauchement en une série de rectangles de $N \times N$ pixels. On applique à chacun d'eux l'opération de *pooling*. Ce type de couche est souvent placé entre deux couches de convolution. L'opération de *pooling* consiste à réduire la taille des images tout en préservant leurs caractéristiques importantes réduisant ainsi la quantité de paramètres et de calcul dans le réseau. Il existe plusieurs types de pooling comme MAX pooling (Le Max Pooling renvoie l'élément maximum sur une fenêtre de calcul), AVG pooling (L'Average pooling permet de renvoyer la moyenne des éléments sur une fenêtre de calcul). La méthode la plus utilisée est le "Max Pooling" où une tuile qui se déplace (comme un filtre) sur la surface de l'image. A chaque position de la tuile on extrait la valeur la plus haute. Cela produit une nouvelle image avec uniquement les valeurs remarquables de l'image. On aura une 'feature maps' de 9 par 9 pixels de départ et on utilise souvent une tuile de 2 ou 3 pixels et une valeur de 2 pixels pour le pas. A la fin, on obtient en sortie une image de 7 par 7 pixels (7) (Figure III.7).

Chapitre III : Deep Learning.




Figure III.7: Pooling avec un filtre 2x2 et un pas de 2.

III.4.2.3. Couche de correction (ReLU):

La couche d'unité linéaire rectifiée (en anglais rectified linear unit layer) est une fonction d'activation. Il existe différentes fonctions d'activation permettant la non-linéarité dans les différentes couches des CNN. Parmi les plus connues :

- La correction ReLU (abréviation de Unités Rectifié linéaires) : $f(x)=\max (0,x)$. Cette fonction augmente les propriétés non linéaires de la fonction de décision et de l'ensemble du réseau sans affecter les champs récepteurs de la couche de convolution.
- La correction par tangente hyperbolique $f(x)=\tanh(x)$.
- La correction par la tangente hyperbolique saturante : $f(x)=|\tanh(x)|$.
- La correction par la fonction sigmoïde.

La correction Relu est préférable car il en résulte la formation de réseau neuronal plusieurs fois plus rapide sans faire une différence significative à la généralisation de précision (Figure III.8).




Figure III.8 : Trois fonctions d'activation, (a) La sigmoïde, (b) La tangente hyperbolique, (c) La fonction ReLU.

Chapitre III : Deep Learning.

III.4.2.4. Couche entièrement connectée (FC) :

Après plusieurs couches de convolution et de max-pooling, le raisonnement de haut niveau dans le réseau neuronal se fait via des couches entièrement connectées. Les neurones dans une couche entièrement connectée ont des connexions vers toutes les sorties de la couche précédente. Leurs fonctions d'activations peuvent donc être calculées avec une multiplication matricielle suivie d'un décalage de polarisation.

III.4.2.5. Couche de perte (LOSS) :

La couche de perte spécifie comment l'entraînement du réseau pénalise l'écart entre le signal prévu et réel elle est normalement la dernière couche dans le réseau. Diverses fonctions de perte adaptées à différentes tâches peuvent y être utilisées. La fonction (**Softmax**) permet de calculer la distribution de probabilités sur les classes de sortie.

III.5. Exemples de modèles de CNN :

La forme la plus commune d'une architecture CNN empile quelques couches Conv-ReLU et les suit avec des couches Pool et répète ce schéma jusqu'à ce que l'entrée soit réduite dans un espace d'une taille suffisamment petite à un moment. Il est fréquent de placer des couches entièrement connectées (FC). La dernière couche entièrement connectée est reliée vers la sortie. Voici quelques architectures communes CNN qui suivent ce modèle :

- **INPUT -> CONV -> RELU -> FC**
- **INPUT -> [CONV -> RELU -> POOL] * 2 -> FC -> RELU -> FC** il y a une couche de CONV unique entre chaque couche POOL.
- **INPUT -> [CONV -> RELU -> CONV -> RELU -> POOL] * 3 -> [FC -> RELU] * 2 > FC** il y a deux couches CONV empilées avant chaque couche POOL.

L'empilage des couches CONV avec de petits filtres de pooling (plutôt un grand filtre) permet un traitement plus puissant avec moins de paramètres mais avec l'inconvénient de demander plus de puissance de calcul (pour contenir tous les résultats intermédiaires de la couche CONV).

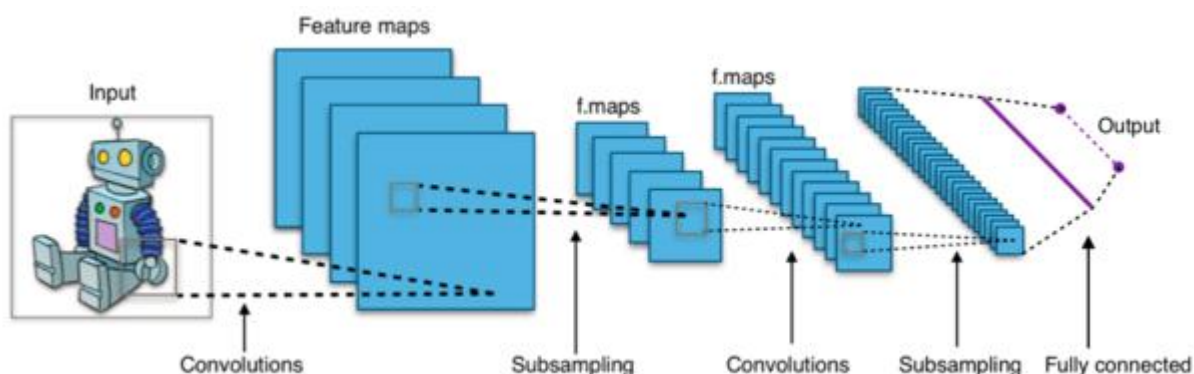


Figure III.9 : Exemples de modèles de CNN

III.6. Avantages de CNNs :

Un avantage majeur des réseaux convolutifs est l'utilisation d'un poids unique associé aux signaux entrant dans tous les neurones d'un même noyau de convolution. Cette méthode réduit l'empreinte mémoire, améliore les performances [8] et permet une invariance du traitement par translation. C'est le principal avantage du CNN par rapport au MLP qui considère chaque neurone indépendant et donc affecte un poids différent à chaque signal entrant lorsque le volume d'entrée varie dans le temps (vidéo ou son). Il devient intéressant de rajouter un paramètre de temporisation (Delay) dans le paramétrage des neurones. On parlera dans ce cas de réseau neuronal à retard temporel (TDNN).

Comparés à d'autres algorithmes de classification des images, les réseaux de neurones convolutifs utilisent relativement peu de pré-traitement. Cela signifie que le CNN est responsable de faire évoluer tout seul ses propres filtres (apprentissage sans supervision) ce qui n'est pas le cas des algorithmes traditionnels. L'absence de paramétrage initial et d'intervention humaine est un atout majeur des CNN.

III.7. Conclusion :

Dans ce chapitre, nous avons abordé le concept de l'apprentissage profond en décrivant ses avantages par rapport aux techniques anciennes. Nous avons aussi décrit deux types de réseaux basés sur l'apprentissage profond à savoir les réseaux de neurones convolutifs et récurrents.

Dans le chapitre suivant, nous allons aborder le Cloud Computing et décrire ses différentes techniques.

Chapitre IV

Cloud Computing

Chapitre IV : Cloud Computing

IV.1. Introduction :

L'Internet actuel fournit un contenu sous des formes de vidéos, e-mails et des informations servis dans les pages web avec le Cloud Computing qui nous donne la possibilité d'acheter des services informatiques. A partir du web nous serions en mesure de louer par le biais d'une vitrine virtuelle la base nécessaire pour construire un centre des données virtuel tels que le processeur, la mémoire et le stockage, et ajouter au-dessus l'intermédiaire nécessaire tels que les serveurs d'applications Web, bases de données et bus serveur d'entreprise...etc.

IV.2. Définition de Cloud Computing :

Le Cloud Computing abrégé en Cloud « **le Nuage** » ou l'informatique en nuage [9] est l'exploitation de la puissance de calcul ou de stockage de serveurs informatiques distants par l'intermédiaire d'un réseau (généralement est le réseau Internet). Ces serveurs sont le plus souvent loués à la demande par tranche d'utilisation selon des critères techniques (**puissance, bande passante, etc.**) mais également au forfait.

On retrouve comme synonymes de Cloud Computing le terme suivant : informatique virtuelle donnant l'accès à la demande et en libre-service via un réseau de télécommunications, à des ressources informatiques partagées configurables. Il s'agit donc d'une délocalisation de l'infrastructure informatique (Figure IV.1).

Chapitre IV : Cloud Computing

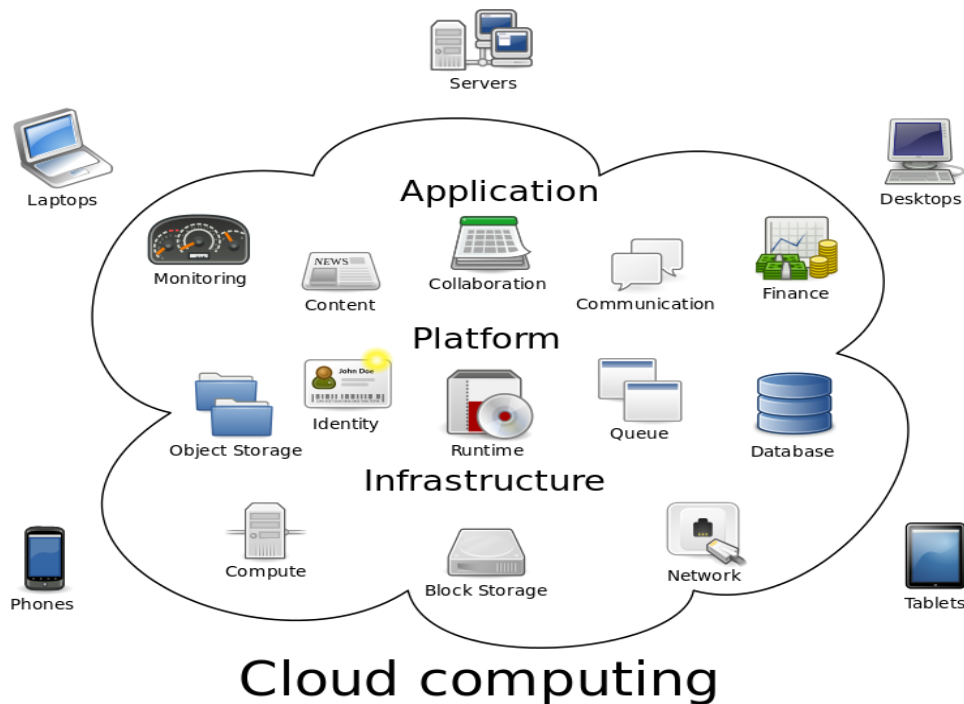


Figure IV.11 : Infrastructure de cloud computing

IV.3. Types de Cloud Computing :

Nous distinguons quatre formes de Cloud Computing (Figure IV.2):

IV.3.1. Cloud privé :

- Expressément pour une organisation donnée.
- Géré par l'organisation.
- Délivré en interne ou en externe.

IV.3.2. Cloud de Communauté :

- Partagé par plusieurs organisations
- Supporte une communauté spécifique
- Géré par l'organisation
- Délivré en interne ou en externe

Chapitre IV : Cloud Computing

IV.3.3. Cloud Public :

- Disponible pour le public en général.
- Détenu par un fournisseur

IV.3.4. Cloud Hybride :

- Composition de différents types de Cloud (privé, communauté, public).
 - Relié entre eux par des technologies standards.




Figure IV.2 : Les types de Cloud Computing

IV.4. Modèle d'application de Cloud Computing :

Le Cloud Computing est un nouveau modèle pour fournir aux entreprises les services informatiques. Ce modèle est basé sur une architecture standard qui contient trois phases : **la phase stratégique, la phase de planification et la phase de déploiement**, chaque phase contient plusieurs étapes comme la figure ci-dessous qui montre la structure générale de ce modèle (**Figure IV.3**).

Chapitre IV : Cloud Computing

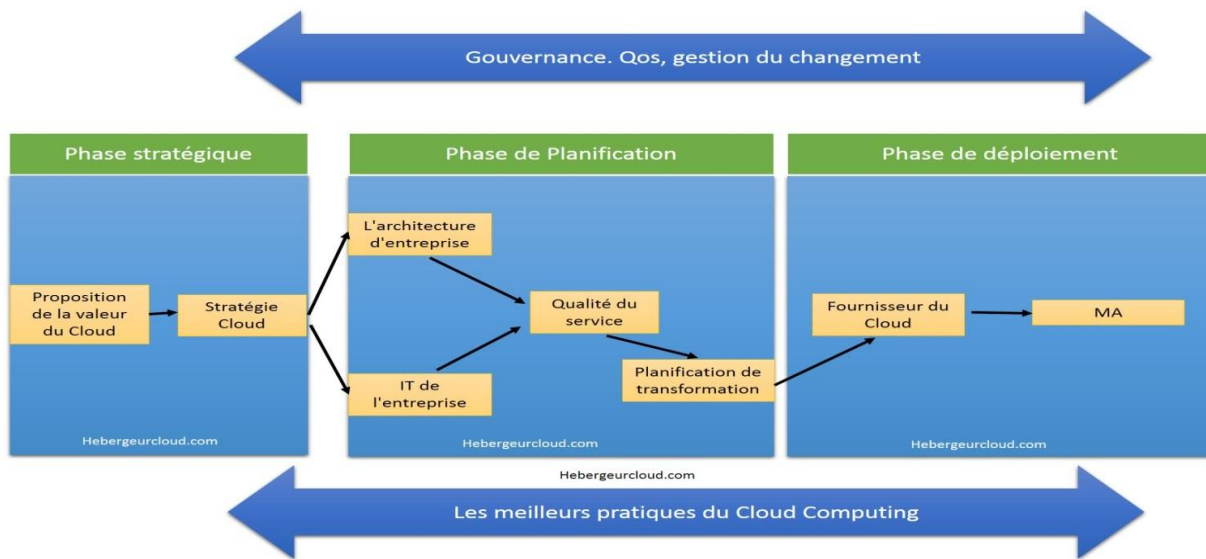


Figure IV.3 : Modèle d'application de Cloud Computing

IV.4.1. La phase stratégique :

La phase stratégique de Cloud Computing assure une analyse complète des problèmes et opère en deux étapes : la proposition de calcul de valeur, et le Cloud stratégique.

IV.4.1.1. La proposition de calcul de valeur :

L'objectif de cette étape est d'analyser la valeur spécifique de l'entreprise. Dans cette analyse nous avons besoin d'identifier la cible principale pour le client et appliquer le mode Cloud Computing et les principaux problèmes qu'elles cherchent à résoudre. Par exemple voici quelques objectifs communs :

- La simplification de la gestion.
- L'exploitation et la réduction des coûts de maintenance
- L'innovation en mode entreprise
- Faible coût de service d'hébergement
- Haute qualité de service d'hébergement, etc.

Chapitre IV : Cloud Computing

IV.4.1.2. Le Cloud stratégie :

Cette étape est la partie la plus importante de la phase stratégique. La mise en place de Cloud stratégie est basée sur le résultat d'analyse de l'étape proposition de calcul de valeur et vise le but d'atteindre l'objectif des clients.

IV.4.2. La phase de planification :

Lors de la phase de planification de Cloud Computing, il est nécessaire de connaître les positions des clients et analyser les problèmes et les risques dans l'application de Cloud Computing après cela des approches concrètes et des plans peuvent être amenés à veiller à ce que les clients peuvent utiliser le Cloud Computing avec succès pour atteindre leurs objectifs d'affaires. Cette phase comprend trois étapes comme suit :

- Développement d'Architecture d'affaires.
- Développement de qualité des services.
- Développement du Plan de Transformation.

IV.4.3. La phase de déploiement :

La phase de déploiement se concentre principalement sur la phase stratégique et la phase de planification. Deux étapes sont mises en évidence dans cette phase.

•Fournisseur de Cloud Computing ou activateur choisi :

Selon les deux phases précédentes, les clients peuvent avoir à choisir un fournisseur de Cloud Computing ou un activateur.

•Service de technique et de maintenance :

Dans cette étape les différents niveaux de normes sont adoptés. Ces normes sont définies par l'exigence de qualité des services faits au préalable.

IV.5. Les services du Cloud Computing :

Les services du Cloud Computing peuvent être divisés en 3 couches (pile) (Figure IV.4):

Chapitre IV : Cloud Computing

IV.5.1. IaaS :

L'IAAS (Infrastructure as à Service) est un modèle qui permet de fournir des infrastructures informatiques en tant que service. Ces infrastructures virtuelles composent un des domaines du « As a Service » en empruntant la même philosophie de fonctionnement et de tarification que la plupart des services du Cloud Computing plutôt que d'acheter des serveurs, des logiciels, et l'espace dans un centre de traitement de données et l'équipement réseau où les clients n'ont plus qu'à louer les ressources auprès des prestataires de service [10].

- ✓ **Hébergement mutualité** : une machine pour plusieurs clientes gérées par un prestataire de service et dont les clients payent le même prix peu importe leur utilisation.
- ✓ **Hébergement dédié** : une machine pour un client géré le plus souvent par le client lui-même et pour laquelle le client paye le même prix chaque mois peu importe son utilisation.
- ✓ **Infrastructure as à Service** : un nombre indéfini de machines pour un nombre indéfini des clients dont les ressources sont combinées et partagées pour tous les clients chaque client paye en fonction de son utilisation de l'architecture.

IV.5.2. PaaS :

Le PAAS qui signifie « Platform as a Service » est une architecture composée de tous les éléments nécessaires pour soutenir la construction, la livraison, le déploiement et le cycle de vie complet des applications et des services exclusivement disponibles à partir d'internet et offre des facilités à gérer le déroulement des opérations lors de la conception du développement, du test, du déploiement et de l'hébergement d'applications web à travers des outils et des services [11] tels que :

- ✓ Le travail collaboratif
- ✓ L'intégration des services web et bases de données.

IV.5.3. SaaS :

Chapitre IV : Cloud Computing

Sa signification est « Software as a Service » c'est un modèle de déploiement d'application dans lequel un fournisseur loue une application clé en main à ses clients en tant que service à la demande au lieu de leur facturer des licences. De cette façon l'utilisateur final n'a plus besoin d'installer tous les logiciels existants sur sa machine de travail cela réduit également la maintenance en supprimant le besoin de mettre à jour les applications. Ce type de modèle transforme les budgets logiciels en dépenses variables et non plus fixes et il n'est plus nécessaire d'acquérir une version du logiciel pour chaque personne au sein de l'entreprise [12].

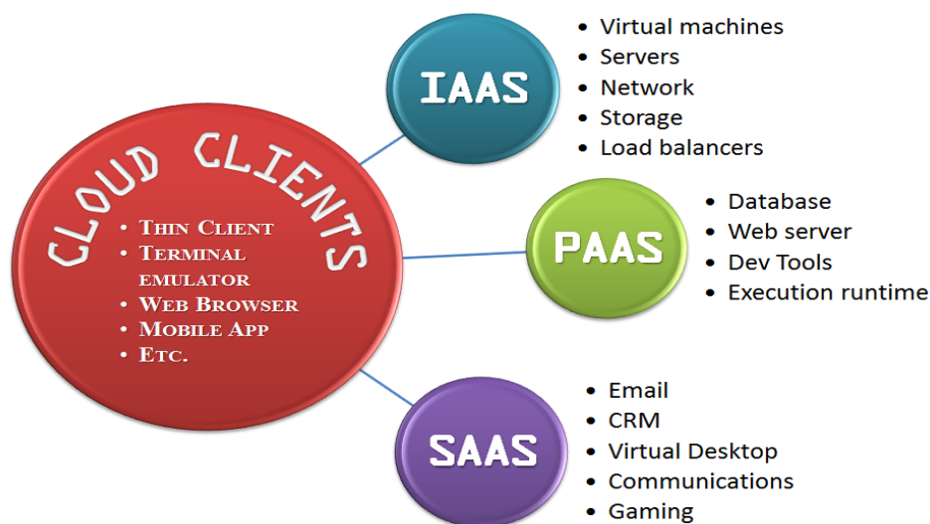


Figure IV.5 Les services du Cloud Computing

IV.6. Exemples de Cloud Computing:

IV.6.1. DROPBOX :

Utilisation de l'application DROPBOX pour synchroniser ses dossiers ainsi que ses sous-dossiers et ses fichiers de préférences dont ceux de certaines applications entre ses ordinateurs distants, sa tablette et son Smartphone (étant tous connectés à Internet ADSL, Wifi (FigureIV.5).

Chapitre IV : Cloud Computing

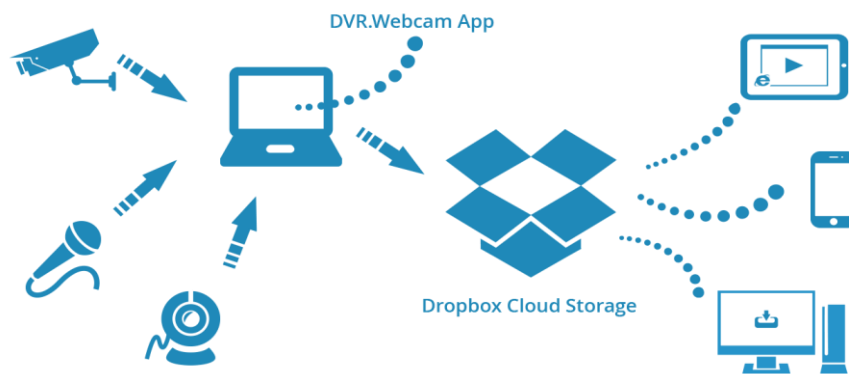


Figure IV.5 : DROPBOX

IV.6.2. GOOGLE DRIVE :

Google Drive est un service de stockage et de partage de fichiers dans le Cloud lancé par la société Google pour partager les fichiers étant tous connecté à internet (Figure IV.6)



Figure IV.6: Google Drive

IV.7. Les avantages et les contraintes de Cloud Computing :

IV.7.1. Les avantages :

- **Gagner en flexibilité :**

Le Cloud Computing repose sur le principe même de flexibilité par opposition au modèle traditionnel dans lequel l'intégration de nouveaux logiciels ou d'éléments d'infrastructure est longue et complexe. La mise en œuvre du Cloud Computing se veut simple et rapide [13].

- **Faciliter la gestion de l'informatique :**

Le Cloud Computing permet de sous-traiter la supervision de son infrastructure à un professionnel de l'hébergement et ainsi de s'assurer de la disponibilité du service 24h/24 et 7j/7 tout en sachant que les coûts d'astreinte de personnel interne pour obtenir la même qualité de service sont bien souvent trop élevés pour de petites structures.

Par ailleurs en cas de panne sur le lieu de stockage des données, le Cloud Computing dispose d'un système de redondance permet le basculement vers un autre site évitant ainsi la rupture de service.

- **Réaliser des économies :**

Un investissement informatique se fonde sur une estimation des besoins à court, moyen et long terme de l'entreprise avec le risque de sous-investir. Grace au Cloud Computing, en ne payant que ce qu'elle consomme réellement, l'entreprise gère son budget au plus près de ses besoins. En plus, le Cloud Computing permet de bénéficier d'un haut niveau de service (24h/24 et 7j/7) pour un prix accessible aux petites structures.

IV.7.2. Contraintes et limites :

- **Dépendance vis-à-vis du prestataire :**

A l'exception du Cloud Computing interne privé l'entreprise confie la gestion de son infrastructure de ses applications ou de ses données à un tiers cette situation crée évidemment une certaine dépendance vis-à-vis de ce tiers. De ce fait, lors du

Chapitre IV : Cloud Computing

choix du prestataire, l'entreprise doit rester vigilante notamment sur la qualité de service offerte et il convient également d'être attentif à la qualité de la connexion Internet de l'entreprise [14].

- **Menaces sur la sécurité et la confidentialité :**

La sécurité des données est l'un des freins les plus couramment évoqués par les entreprises car les données sont hébergées en dehors de l'entreprise dans la majorité des cas de Cloud Computing. Il est important que le prestataire s'engage par contrat à mettre tout en œuvre pour protéger les données de ses clients :

- ✓ Les utilisateurs peuvent choisir le lieu d'hébergement.
- ✓ Sécurisation de la plateforme logicielle en ligne.
- ✓ Données sauvegardées.

- **Disparition de fonctionnalités :**

Pour être en mesure de proposer des prix compétitifs les prestataires de Cloud Computing proposent des produits standards. Une personnalisation est possible mais dans la mesure du possible (sauf dans les Cloud privés où l'entreprise est propriétaire de son infrastructure).

- **Limites de l'élasticité :**

La flexibilité du Cloud Computing se vérifie très facilement lorsque l'entreprise a besoin de plus de ressources. Dans le cas inverse, lorsqu'elle souhaite réduire la voilure, les prestataires s'avèrent plus réticents pour des raisons essentiellement contractuelles. La flexibilité à la baisse est plus compliquée.

IV.8. Sécurité et confidentialité du Cloud Computing :

Une des plus grandes préoccupations des utilisateurs sur le Cloud Computing est sa sécurité. La sécurité des données des utilisateurs peut être réfléchiée dans les règles suivantes :

- Gestion des identifiants (identités).
- Sécurité et confidentialité des données.
- Sécurité physique et personnelle.

Chapitre IV : Cloud Computing

- Disponibilité (garantie à 99 %).
- Contrôle des applications.
- Localisation des données ou des bases de données.

IV.9. Conclusion :

Le Cloud Computing est une nouvelle technologie d'utilisation des services informatiques nous pouvons être beaucoup plus flexibles et productif dans l'utilisation des ressources allouées dynamiquement et pour objectif de décharger l'utilisateur des problématiques serveur et lui permettre de disposer et facilité d'exploitation de ses données et de ses outils où qu'il soit, dès qu'il a une connexion Internet.

Chapitre V

Conception et implémentation

V.1. Introduction :

Dans ce chapitre, nous allons faire la conception de notre programme Nous allons présenter aussi la mise en œuvre de notre programme en utilisant le langage Python. On commençant tout d'abord par une présentation du langage de programmation choisi. Ensuite nous présentons des captures d'écran et après l'exécution.

V.2. Notre approche proposée :

Notre approche de recherche d'images similaires à une image requête est basée d'un côté sur l'utilisation d'une méthode de classification basée sur l'apprentissage automatique (Deep Learning) et de l'autre côté de l'utilisation de la mesure de distance entre les images.

Nous avons choisi d'utiliser les réseaux de neurones convolutifs (CNN) qui sont connus pour leurs performances dans la classification des images. De l'autre côté, nous avons choisi d'utiliser la distance euclidienne entre les images en prenant la moyenne et l'écart-type des images comme attributs caractérisant les images.

En premier temps, la classe de l'image requête est calculée par le modèle CNN ainsi que les images de la base d'images. Sur la base de cette prédiction, les images ayant la même classe que celle l'image requête sont retenues.

En deuxième temps, la moyenne et l'écart type de l'image requête et les images de la base sont calculés et considérés comme les caractéristiques de ces images. Ensuite, la distance euclidienne entre l'image requête et les images de la base en utilisant leurs caractéristiques.

Finalement, une liste d'images triée de manière croissante sur la base de la distance et les premières images sont présentées comme images similaires à l'image requête (Figure V.1).

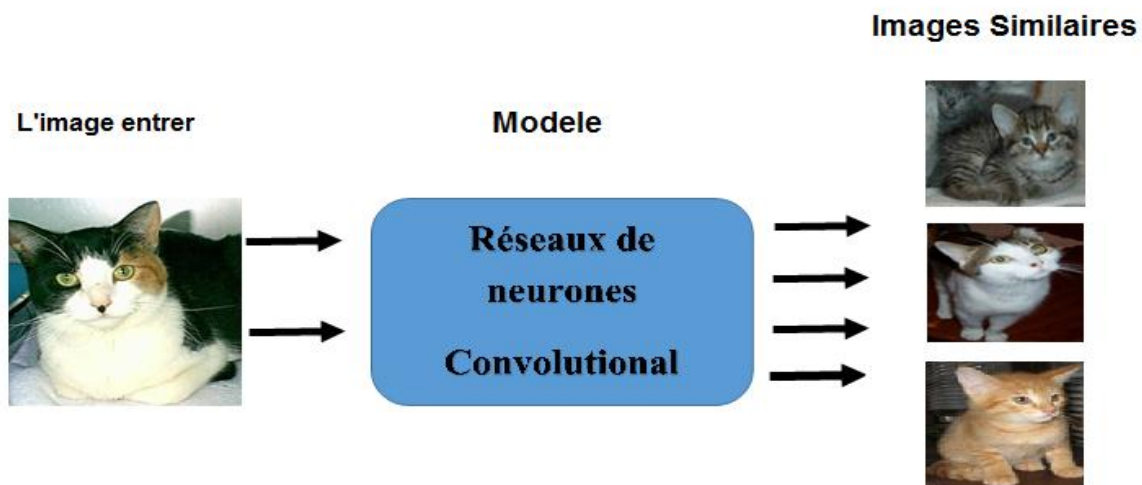


Figure V.1 : Modèle CNN

V.3. L'environnement Cloud :

Pour implémenter notre système de recherche d'images similaires nous avons travaillé dans l'environnement Cloud de Google. Ce dernier est composé de Google Drive pour le stockage des images et Google Colaboratory pour exploiter les capacités de calcul mis en disponibilité gratuitement par Google au profit des travaux de recherches. Nous avons choisi d'utiliser la bibliothèque Keras de Python dans l'implémentation de nos algorithmes.

V.3.1.Python :

Python est un langage de programmation interprété, multi-paradigme et multiplateformes. Il favorise la programmation impérative structurée, fonctionnelle et orientée objet. Il est doté d'un typage dynamique fort d'une gestion automatique de la mémoire. Le langage Python est placé sous une licence libre proche de la licence BSD [15] et fonctionne sur la plupart des plateformes informatiques et peut aussi être traduit en Java ou NET. Il est conçu pour optimiser la productivité des programmeurs en offrant des outils de haut niveau et une syntaxe simple à utiliser.

V.3.2. Google Colaboratory :

Colaboratory est un environnement d'ordinateur portable **Jupyter** gratuit qui ne nécessite aucune installation et qui s'exécute entièrement dans le Cloud pour exécuter du code, enregistrer et partager vos analyses et accéder à de puissantes ressources informatiques, le tout gratuitement à partir de navigateur.

V.3.3. Google Drive :

Google Drive est un service de stockage et de partage de fichiers dans le Cloud lancé par la société Google permettant de modifier des documents, des feuilles de calcul, des présentations, des dessins, des formulaires, etc. Les utilisateurs peuvent rechercher les fichiers partagés publiquement sur Google Drive Lancé le 24 avril 2012 [17], Google Drive a compté 240 millions d'utilisateurs actifs en octobre 2014.

V.4. Base des images :

Nous avons choisi de tester notre système sur une base d'images constituée de 7065 images réparties sur huit classes à savoir : personne, avion, voiture, chat, chien, fleur, fruit et moto qui contiennent respectivement ..., ..., ..., ..., ..., ..., ... et ... (Figure V.2).

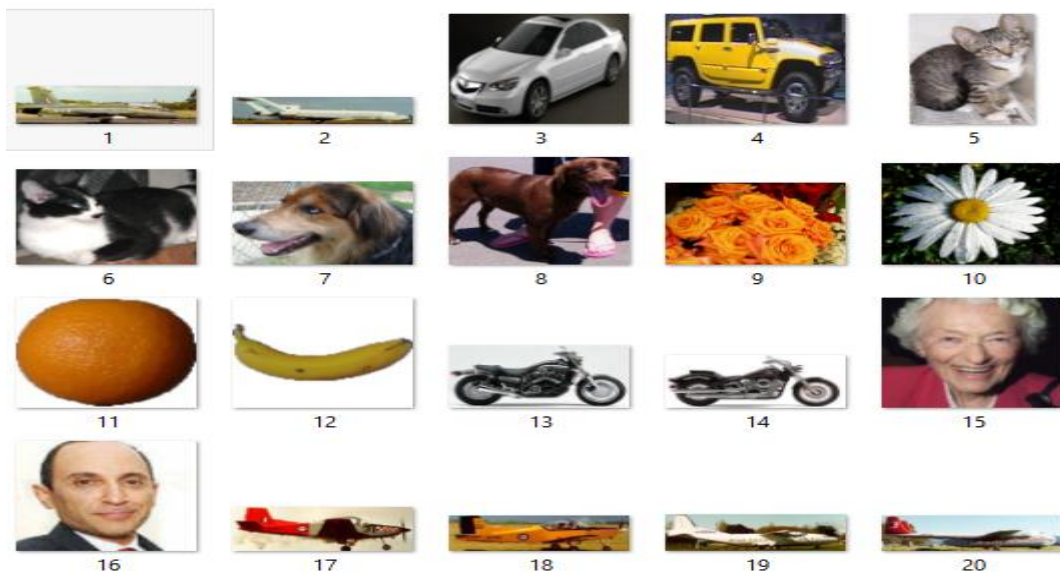


Figure V.2 : Base des images.

V.5. Système proposé :

V.5.1. Architecture du modèle CNN :

Comme illustré à la Figure V.3, La structure du réseau consiste en une série de trois blocs de couches contenant deux couches de Convolution (Conv), une couche Dropout et une couche de MaxPooling (pooling).

Finalement, le réseau enchaine par une couche entièrement connectée (FC) « Fully Connected »

Dans ce qui suit, nous détaillons la description de ces couches :

La couche de convolution extrait les caractéristiques à partir de l'entrée et donne en sortie une carte des pixels. Le nombre de ces pixels en sortie dépend de la valeur (*valid* ou *same*) affectée au paramètre de remplissage de la couche (Padding). Avec le paramètre (*Same*), le volume d'entrée est complété par des zéros et les dimensions spatiales sont préservées. Dans notre cas, nous avons choisi de réduire les dimensions spatiales en choisissant le paramètre (*valid*).

Ainsi, les caractéristiques sont générées en convoluant l'entrée avec 32 noyaux à convolution. de taille 3×3 .

La couche Dropout est utilisée pour aider à prévenir le sur-apprentissage en sélectionnant de manière aléatoire les nœuds à abandonner avec une probabilité de 50% à chaque cycle de mise à jour du poids.

La couche MaxPooling réalise un sous-échantillonnage non linéaire des cartes de caractéristiques en partitionnant les caractéristiques d'entrée en un ensemble de rectangles ne chevauchant pas et pour chaque sous-région (c'est-à-dire avec le pas 2) donne en sortie la valeur maximale. Avec 10 neurones et une fonction d'activation « Relu », la couche entièrement connecté prend en entrée toutes les caractéristiques générées par le réseau.

Enfin, une seconde couche entièrement connectée de huit neurones et une fonction d'activation sigmoïde donne la probabilité si une entrée appartient à l'une des huit classes (c'est-à-dire, personne, avion, voiture, chat, chien, fleur, fruit ou moto).

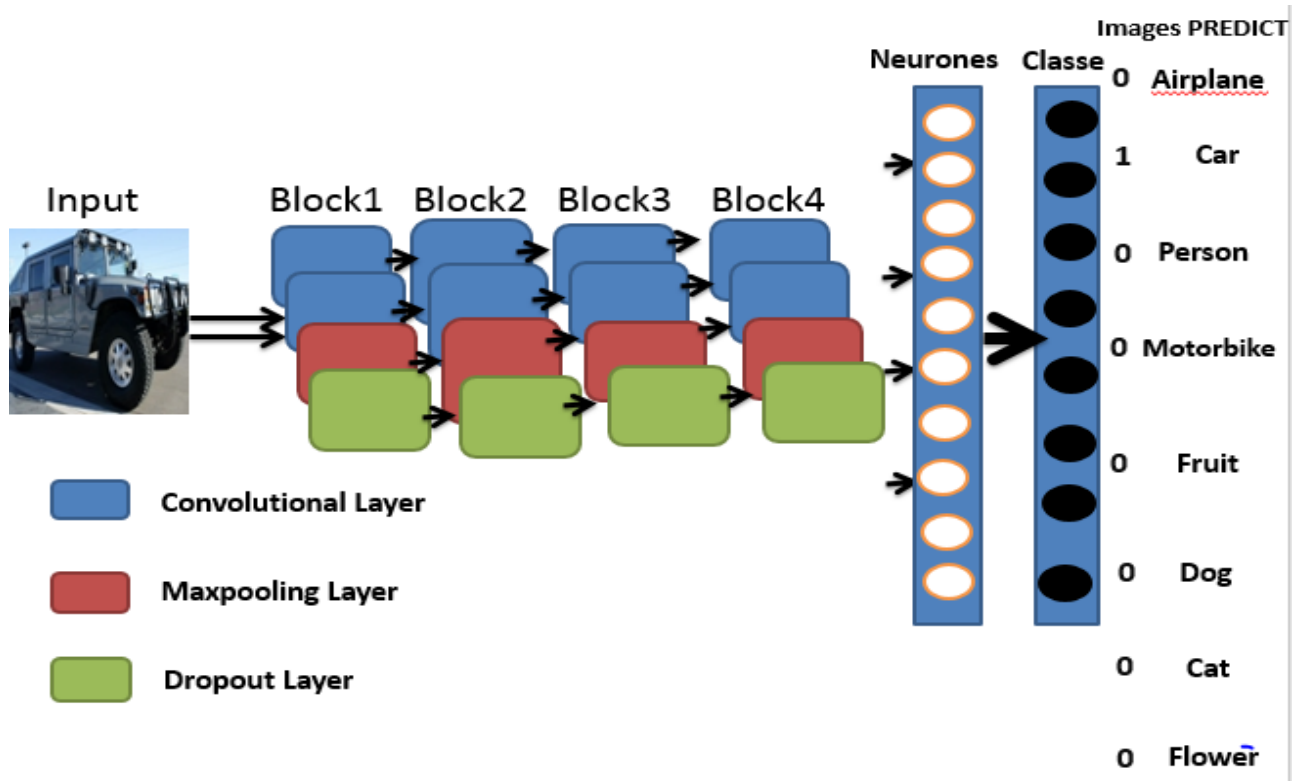


Figure V.3 : Architectures CNN.

V.5.2. La distance euclidienne :

Nous avons choisi d'utiliser la moyenne de l'image et son écart-type comme descripteurs des images. Par la suite, un vecteur de description pour chaque image est construit à partir de la moyenne de l'image et son écart-type.

Par conséquent, on calcule la distance euclidienne entre l'image requête et chaque image de la base des images selon la formule (1).

$$\text{Distance euclidienne (img_req, img_db)} = ((\text{moyenne}(\text{img_req}) - \text{moyenne}(\text{img_db}))^2 + (\text{moyenne}(\text{img_req}) - \text{moyenne}(\text{img_db}))^2)^{1/2} \quad (1)$$

Ainsi, une liste est créée à partir des images de la base estimées par le modèle CNN comme ayant la même classe que l'image requête. Ladite liste est triée en ordre croissant selon la valeur de la

Chapitre V : Conception et implémentation

distance et les premières images de la liste sont retournées comme étant les images similaires à l'image requête.

V.6. Discussion des résultats :

Dans le tableau 1, nous résumons les résultats de test obtenus par le modèle CNN avec diverses structures. Chaque structure représente le nombre de blocs de couches avec lequel le modèle est construit.

Résultats \ nombre de blocks	1	2	3	4
Précision %	59.71%	67.44 %	87.50%	96.85%

Tableau 1 : résultats obtenu par le modèle CNN proposé.

Le tableau 1 montre que la structure du modèle CNN constituée de trois blocks de couches a réalisé le meilleur résultat en l'occurrence. %

Le tableau 2, résume les taux de précision en pourcentage des n premières images retournées en réponse à l'image requête.

N premières images	5	10	50	100
Précision %	86.75%	86.25%	86.20%	85.75%

Tableau 2 : précision des n premières images en réponse à l'image requête.

V.7. Conclusion :

Nous avons présenté dans ce chapitre l'implémentation de notre système de recherche des images similaires à une image requête dans un environnement Cloud en utilisant les réseaux de neurones convolutifs. En effet, nous proposons un système qui combine la classification en utilisant un modèle CNN et l'utilisation de la distance euclidienne entre l'image requête et les images de la base classées par le modèle CNN comme étant de la même classe que celle de l'image requête.

Nous avons testé notre système sur une base d'images constituée de huit classes et les résultats obtenus sont encourageants.

Conclusion générale

Nous avons visé dans ce travail la réalisation d'un système de recherche des images similaires à une image requête. A cet effet, nous avons proposé un système combinant la classification des images basée sur l'apprentissage profond et la distance euclidienne entre l'image requête et les images de la base classées dans la même classe que celle de l'image requête.

Nous avons proposé un modèle CNN dans la classification des images et l'utilisation de la moyenne de l'image et son écart-type comme descripteurs de l'image pour calculer la distance entre l'image requête et les images classées dans la même classe que l'image requête.

Nous avons développé notre système dans un environnement Cloud. Les résultats obtenus dans les différentes expérimentations réalisées sur une base d'images contenant huit classes sont encourageantes.

Comme perspectives, il est possible d'améliorer les en utilisant les modèles CNN pré-entraînés tels que : AlexNet, MobileNet et YOLOv2.

Bibliographie :

- [1] : Classification-floue-des-images.pdf
- [2] : **BORGI A., AKDAG H.** Supervised Learning and Approximate. 2001.
- [3] : **Parrochia.** Classifications, histoire et problèmes formels. Cinquièmes Rencontres de la société Francophone de classification SFC'97. Lyon : s.n., Septembre 1997.
- [4] : Yann LeCun Professeur, New York University Chaire Informatique et Sciences Numériques 2015-2016
- [5] : Yann LeCun Professeur, – Titulaire de la chaire Informatique et Sciences numériques du Collège de France
- [6] : **Krizhevsky, I. Sutskever et G. E. Hinton.** ImageNet Classification with Deep Convolutional Neural Networks », Advances in neural Processing Systems de traitement. 2012.
- [7] : **Graham, Benjamin.** Fractional Max-Pooling. 18 décembre 2014.
- [8] : **LeCun, Yann.** L'apprentissage prédictif est le grand défi scientifique de l'intelligence artificielle
- [9] : Office québécois de la langue française, sur Le grand dictionnaire terminologique (consulté le 18 avril 2018)
- [10] : Brian J.S. Chee, Curtis Franklin Jr., Cloud Computing: Technologies and Strategies of the Ubiquitous Data Center, CRC Press, 2010 (ISBN 9781439806173)
- [11] : Brian J.S. Chee, Curtis Franklin Jr., Cloud Computing: Technologies and Strategies of the Ubiquitous Data Center, CRC Press, 2010 (ISBN 9781439806173)
- [12] : Rajkumar Buyya, James Broberg, Andrzej M. Goscinski, Cloud Computing: Principles and Paradigms, John Wiley & Sons, 2010 (ISBN 9781118002209).
- [13] : Brookings Institution citée par *Regards sur le numérique*, 28 juin 2010, p. 3

[14] : Les risques du cloud computing - David-Julien Rahmil.

[15] : « *Python License* »

[16] : [Download Python for Other Platforms.](#)

[17] : [Introducing Google Drive... yes, really »](#) , Google (consulté le 24 avril 2012).

