

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE MOHAMED BOUDIAF - M'SILA

FACULTE DE TECHNOLOGIE
DEPARTEMENT ELECTRONIQUE



FILIERE : ELECTRONIQUE
OPTION : ELECTRONIQUE DES
SYSTEME EMBARQUE

**Mémoire présenté pour l'obtention
Du diplôme de Master Académique**

Par: BENDJAAFER Abderrahmane

MEDDAH Toufik

Intitulé

**Classification d'image à l'aide d'un réseau
Totalement convolutionnelle**

Soutenu devant le jury composé de:

Nom et prénom Enseignant

Président	Khalfa Ali	Université de M'sila
Rapporteur	Lalaoui Lahouaoui	Université de M'sila
Examineur	Zerdoumi Zohra	Université de M'sila


Année universitaire : 2020/2021



Dédicaces

BENDJAAFER ABDERRAHMANE

Je dédie ce travail à ma petite famille : mes parents, mes sœurs, et mes frères et mes amis MEDDAH TOUFIK et MOHAMED ARBANE et mes enseignants BRIK YUCEF et MOHAMED DJERIOUI



Dédicaces

MEDDAH TOUFIK

Je dédie ce travail à mes parents, à mes frères et sœurs et toute ma famille pour leur grand encouragement et leur sacrifice. Le dévouement ne peut pas être exprimé Mon respect, mon appréciation et mes sentiments profonds envers eux. Je prie Dieu de les protéger et de les bénir, j'espère qu'ils seront toujours fiers de moi.

A tous mes professeurs, en particulier **Dr Youssef Brik** et **Dr Mohamed djerioui** Leur générosité et leur soutien m'obligent à leur montrer mon plus profond respect et ma loyauté. Considération.

A mes amis et collègues,

En particulier **Mohamed Arbane** et **Bendjafer Abderrahmane** Et tous ceux qui me sont chers.

Ils trouveront des expressions de sentiments de loyauté et d'amitié infinies Leur gratitude pour leur soutien continu envers moi

Remerciements

Nous voudrions d'abord remercier Dieu tout-Puissant de nous avoir donné la force et l'opportunité de faire ce travail.

Ensuite, nous tenons à exprimer nos sincères remerciements à notre directeur de thèse, le **Dr : LALAOUI LAHOUAOUI**, qui nous a soutenu tout au long de notre travail et a répondu aux questions que nous lui avons posées. Il continua patiemment et encouragea les nombreuses corrections nécessaires pour compléter cet écrit.

Nous demandons à nos professeurs de trouver ici une expression de notre gratitude pour leurs efforts, leur éducation fructueuse et leur intérêt tout au long de nos études.

Nous ne pouvons pas terminer la tâche sans exprimer nos sincères remerciements à tous ceux qui nous ont aidés à construire ce travail.

• Table des matières

• Liste des figures.....	7
• Liste des tableaux	7
• Liste des abréviations	9
• Introduction générale.....	10
• Chapitre I Notion de base sur le traitement et classification de L'image	
• I.1 Introduction.....	12
• I.2 Définition de l'image	12
• I.3 Définition de l'image numérique	12
• I.4 Caractéristique d'une image numérique.....	13
• I.4.1 pixel de l'image.....	13
• I.4.2 la taille de l'image	13
• I.4.3 dimension	14
• I.4.4 les countour et texture	14
• I.4.5 l'histogramme.....	14
• I.4.6 Luminance.....	15
• I.4.7 Contraste.....	15
• I.4.8 image binaire	15
• I.4.9 image en couleur	15
• I.4.10 image niveau de gris.....	16
• I.4.11 bruit	16
• I.5 classification d'image.....	18
• I.6 la classification binaire.....	18
• I.7 méthodes de classification.....	19
• I.7.1 Méthodes supervisées.....	19
• I.7.2 Méthodes non supervisées.....	19
• I.8 mesures des performances pour la classification	20
• I.8.1 Matrice de confusion.....	20
• I.8.2 Courbe ROC.....	21
• I.8 Conclusion.....	22
• Chapitre II : Les réseaux de neurones convolutionnels.....	
• II.1 Introduction.....	24
• II.2 les réseaux de neurones.....	24

• II.3 Deep learning	25
• II.4 les réseaux de neurones récurant.....	26
• II.5 Les réseaux de neurones Convolutionnels	27
• II.5.1 Couche de convolution	28
• II.5.2 Couche de pooling (POOL).....	29
• II.5.3 Couche de correction (RELU).....	29
• II.5.4 Couche entièrement connectée (FC).....	30
• II.5.5 Couche de perte (LOSS).....	30
• II.6 les auto encodeur.....	30
• II.7 amélioration des performances du réseau de neurone	31
• II.8 technique de Dropout	32
• II.9 technique de early stopping.....	32
• II.10 choix des hyperparamètre	32
• II.11 taux d'apprentissage (learning rate).....	32
• II.12 optimiseur Adam.....	33
• II.13 batch normalisation	33
• II.14 nombre des filters.....	34
• II.15 forme des filters	34
• II.16 Conclusion.....	34
• Chapitre III : Implémentation et resultat.....	
• III.1 Introduction.....	36
• III.2 présentation des outils de développement.....	36
• III.2.1 matériels et méthodes	36
• III.2.2 Python.....	36
• III.2.3 Tensorflow.....	37
• III.2.4 Keras.....	37
• III.3 la base de donnés	37
• III.4 prétraitement et augmentation	38
• III.5 l'architecture	39
• III.6 Résultat	44
• III.7 conclusion.....	46
• Conclusion générale.....	47
• Références bibliographiques.....	48

• Résumé.....	50
---------------	----

Liste des figures

Chapitre I

Figure I.1 représentation d'une image numérique.....	12
Figure I.2 image par pixel	13
Figure I.3 contour d'image	14
Figure I.4 calculé l'histogramme.....	14
Figure I.5 augmenté la luminance	15
Figure I.6 le système RVB	16
Figure I.7 . Une image en niveaux de gris, agrandissement d'une zone de l'image, et affichage des valeurs constituant la matrice image	16
Figure I.8 .image bruité	17
Figure I.9 image sans bruit	17
Figure I.10 .différence entre apprentissage supervisé et non supervisé	20
Figure I.11 Matrice de confusion	20
Figure I.12 Courbe de ROC.....	22

Chapitre II

Figure II.1 la relation entre l'intelligence artificielle , le ML et deep learning	24
Figure II.2 .architecture d'un réseau neurone artificiel	25
Figure II.3 schéma de réseaux de neurones récurrents.....	26
Figure II.4 architecture d'un réseau neurone convolutionelle.....	27
Figure II.5 image représenté architecture deep learning.....	27
Figure II.6 convolution avec plusieurs filtres.....	28
Figure II.7 .source image : https://cs231n.github.io/assets/cnn/weights.jpeg	28

Figure II.8 . Max and moy pooling	29
Figure II.9 allure de la fonction Relu	29
Figure II.10 . Application du relu dans une image	30
Figure II.11 . image représenté auto encodeur	31
Figure II.12 image représente le technique dropout	32
Figure II.13 image représente les déférentes taux d'apprentissage	33

Chapitre III

Figure III.1 echontillon radiographique sans pneumonie.....	38
Figure III.2 echontillon radiographique avec pneumonie	38
Figure III.3 architecture proposé	40
Figure III.4 model de précision	42
Figure III.5. model de perte	42
Figure III.6 model de précision validation	43
Figure III.7 model de perte validation.....	43
Figure III.8 courbe de ROC de notre résultats	44
Figure III.9 image représenté précision vs Recall.....	45

Liste des Tableaux

Chapitre I

Tableau I.1 filtre passe bas	17
Tableau I.2 filtre passe haute.....	18

Chapitre III

Tableau III.1 paramètres pour augmentation des images.....	39
Tableau III.2 résultat du l'architecture du CNN proposé.....	40
Tableau III.2 les résultat dans la pahse de la prédiction.....	44

Liste des abréviations :

NdG : niveaux de gris

ReLU : Unité linéaire rectifiée

SVM : Machines à vecteurs de soutien

ROC : caractéristiques de fonctionnement du récepteur

CNN : réseau de neurones convolutif

AI : intelligence artificiel

Introduction Générale :

Le domaine de traitement d'image dans ces dernières années est énormément développé et il a été utilisé dans plusieurs spécialités comme médical, autonome, satellite et le but de cette domaine est amélioré la qualité de l'image et extraire des informations. La pneumonie est une maladie mortelle qui affecte principalement les personnes âgées et peut parfois mettre leur vie en danger, un diagnostic précoce de la pneumonie prend une importance capitale pour sauver de nombreuses vies humaines, ce travail a pour objectif la détection et la classification des patients atteints de pneumonie à partir de leur radiographie de la poitrine.

Il existe cependant plusieurs domaines pour lesquels la classification de d'image est appliquée avec un succès, dans notre travail nous avons utilisé le Deep Learning basé sur les réseaux de neurones convolutionnels les plus commun pour faire une classification d'image de la maladie pneumonie et pour obtenu des bons résultats et donnés plusieurs avantages.

Après cette introduction, dans le premier chapitre, nous présenterons rapidement les notions de bases du traitement d'images, et surtout la partie de la classification de l'image.

Dans le deuxième chapitre, nous nous intéresserons plus particulièrement au le Deep-Learning qui basé sur les réseaux des neurones convolutionnels.

Dans le troisième chapitre, nous présenterons notre travail sur la classification des images on nous démontre la partie expérimentale avec discussion les différents résultats obtenus.

Chapitre I :

Notion de base sur le traitement et classification de l'image

Introduction:

De nos jours, le traitement d'image fait partie des technologies à croissance rapide, est une méthode pour effectuer certaines opérations sur une image, afin d'obtenir une image améliorée.

La classification des images est un processus de catégorisation d'un ensemble donné de données en classes et utilisé dans plusieurs domaines comme médicaux (détecté les maladies), Identification d'objets, Prédiction de données, etc....., Il existe deux principaux types d'apprentissage : l'apprentissage supervisé et l'apprentissage non-supervisé.

Dans ce chapitre nous allons présenter tout d'abord les notions de base du traitement de l'image et puis nous connaissons la classification de l'image et les techniques

Définition de l'image :

Une image peut être définie comme une fonction bidimensionnelle, $f(x, y)$, où x et y sont des coordonnées spatiales (plan), et l'amplitude de f à n'importe quelle paire de coordonnées (x, y) est appelée l'intensité ou niveau de gris de l'image à ce stade. Lorsque x , y et les valeurs d'intensité de f sont toutes finies.

Définition de l'image numérique :

L'image numérique est l'image dont la surface est divisée en éléments de taille fixe appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs. [1]

Le processus de la numérisation de l'image c'est de convertir l'image d'un état analogique en une image numérique représentée par une matrice bidimensionnelle de valeurs numériques $f(x,y)$ comme la montre la figure suivant :




Figure I.1 représentation d'une image numérique

Où :

x, y : coordonnées cartésiennes d'un point de l'image.

$f(x, y)$: niveau d'intensité.

Pour des raisons de commodité de représentation pour l'affichage et l'adressage, les données images sont généralement rangées sous formes de tableau I de x lignes et y colonnes.

La valeur en chaque point exprime la mesure d'intensité lumineuse perçue par le capteur

Caractéristiques d'une image numérique:

pixel de l'image :

L'image numérique est un ensemble des pixels représenté comme des zones carrées ou par des points, le pixel est la plus petite unité d'une image qui peut être affichée par un ordinateur.

La figure ci-dessous donne un exemple d'image "binaire" représentant un A (noir et blanc) :

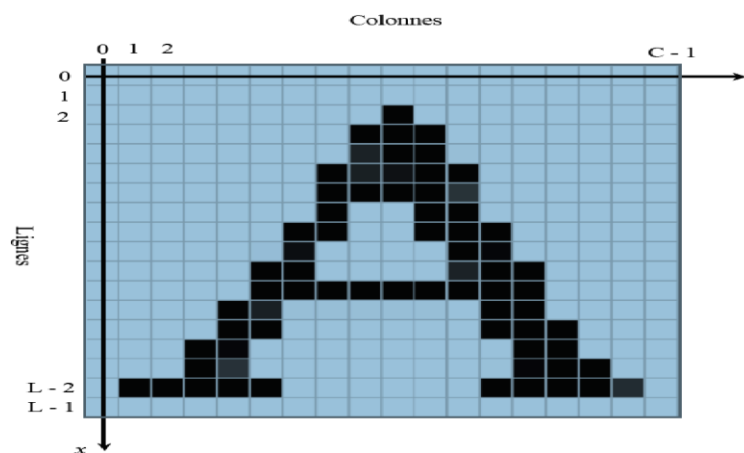


Figure I.2 image par pixel

la taille de l'image :

La taille de l'image est le nombre des pixels qui composent l'image numérique, représentée en colonnes et en lignes, par exemple l'image contient 64×64 et correspond donc à une image de 64 pixels de large et 64 pixels de haut, égal: $64 \times 64 = 4096$ pixels.

Dimension :

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes de cette matrice multiplié par le nombre de colonnes nous donne le nombre total de pixels dans une image. [2]

Les contours et texture :

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux pixels dont les niveaux de gris représentent une différence significative. Les textures décrivent la structure de ceux-ci. L'extraction de contour consiste à identifier dans l'image les points qui séparent deux textures différentes. [3]




Figure I.3 contour d'image

L'histogramme :

L'histogramme de l'image est mesure la distribution des niveaux de gris de l'image(NdG), pour chaque NdG compter le nombre de pixel possédant ce NdG.




Figure I.4 : calculé l'histogramme

Luminance :

La luminance (ou brillance) est définie comme la moyenne de tous les pixels de l'image, et pour augmenter la luminance, il suffit de décaler l'histogramme par l'équation : $I'(i,j)=I(i,j)+b$

Dans la figure les deux images suivantes, seule la luminance différente :




Figure I.5 : augmenter la luminance

contraste :

C'est l'opposition marquée entre deux régions d'une image. Une image contrastée présente une bonne dynamique de la distribution des valeurs de gris sur tout l'intervalle des valeurs possibles, avec des blancs bien clairs et des noirs profonds. Au contraire une image peu contrastée a une faible dynamique, la plupart des pixels ayant des valeurs de gris très proches.

Si L_1 et L_2 sont les degrés de luminosité respectivement de deux zones voisines A_1 et A_2 d'une image, le contraste est défini par le rapport : $c = \frac{|L_1 - L_2|}{L_1 + L_2}$. [4]

Image binaire :

Une image binaire est une matrice rectangulaire dans l'élément valent 0 ou 1, Lorsque l'on visualise une telle image, les 0 sont représentés par du noir et les 1 par du blanc. [5]

Image en couleur :

La représentation d'une image colorée basé sur l'intensité luminance du trois composent : (rouge, vert, bleu), chaque composent codée sur 8 bits.

Le codage de chaque couleur : $R(i,j) = 0 \dots\dots\dots 255$; $V(i,j) = 0 \dots\dots\dots 255$; $B(i,j) = 0 \dots\dots\dots 255$

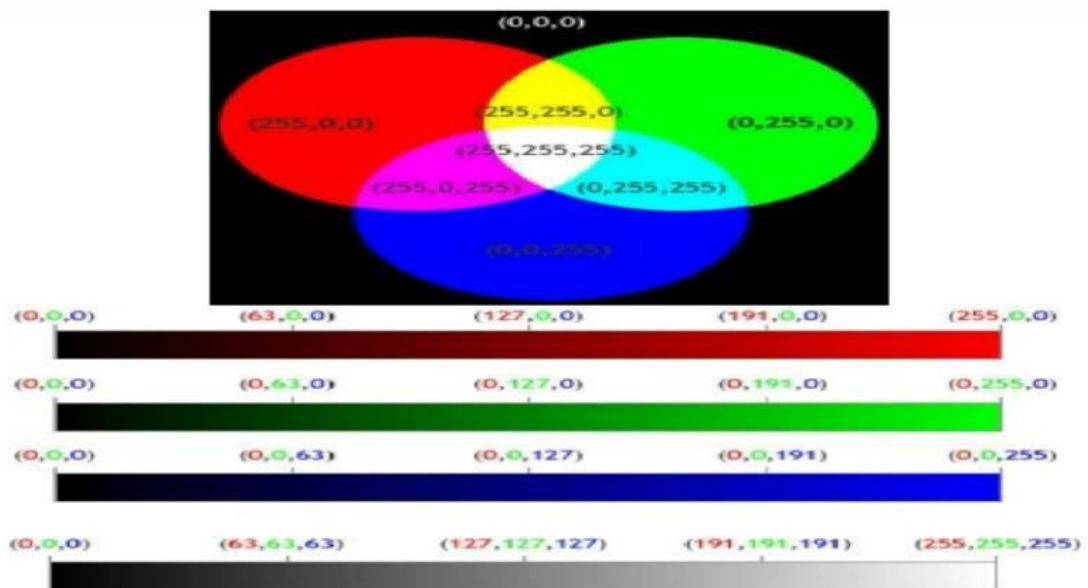


Figure I.6 : Le système RVB

Image Niveau de gris:

Le niveau de gris est la valeur de l'intensité lumineuse en un point. La couleur du pixel peut prendre des valeurs allant du noir au blanc en passant par un nombre fini de niveaux intermédiaires. Donc, pour représenter les images à niveaux de gris, on peut attribuer à chaque pixel de l'image une valeur correspondant à la quantité de lumière renvoyée. Cette valeur peut être comprise par exemple entre 0 et 255. Chaque pixel n'est donc plus représenté par un bit, mais par un octet. Pour cela, il faut que le matériel utilisé pour afficher l'image soit capable de produire les différents niveaux de gris correspondants. [6]




Figure I.7 : Une image en niveaux de gris, agrandissement d'une zone de l'image, et affichage des valeurs constituant la matrice image.

bruit :

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs optiques et

électroniques du capteur, c'est un parasite qui représente certains défauts (poussière, petits nuages, baisse momentanée de l'intensité électrique sur les capteurs, ...etc.). Il se traduit par des taches de faible dimension et dont la distribution sur l'image est aléatoire [8].



Figure I.8: image bruitée



Figure I.9: image sans bruit

Pour limiter le bruit et pour une bonne amélioration de la qualité de l'image on utilise une opération de filtrage appliquée au niveau des pixels d'une image.

Un filtre est une matrice de dimension impaire, qui permet de remplacer la valeur du pixel central par le résultat de l'opération effectuée sur ses voisins.

Il existe plusieurs types de filtres dans deux domaines :

- 1- les filtres non linéaires.
- 2- les filtres linéaires.

Filtre passe bas : est un filtre qui laisse passer les basses fréquences et qui atténue les hautes fréquences.

Filtre passe-bas (Lissage)			
Catégorie	Linéaire		Non- Linéaire
Type	Moyenneur	Gaussien	Médian
Forme	$\frac{1}{5} \begin{bmatrix} 0 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 0 \end{bmatrix}$ $\frac{1}{10} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	$H_{G1} = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$ $H_{G2} = \frac{1}{2025} \begin{bmatrix} 1 & 10 & 22 & 10 & 1 \\ 10 & 106 & 231 & 106 & 10 \\ 22 & 231 & 504 & 231 & 22 \\ 10 & 106 & 231 & 106 & 10 \\ 1 & 10 & 22 & 10 & 1 \end{bmatrix}$	
Avantage	Élimination de bruit additionnel et surtout de type poisson	Élimination de bruit additionnel et surtout de type gaussien	Filtre mieux le bruit impulsionnel (poivre et sel)
Inconvénient	<ul style="list-style-type: none"> - Forte atténuation des contours - Forte influence des pixels isolés 		<ul style="list-style-type: none"> - Supprime le détail qui n'est pas bruit - Détruit les coins - Couteux en temps de calcul

Tableau I.1 filtre passe bas

Filtre passe haute : est un filtre qui laisse passer les hautes fréquences et qui atténue les basses fréquences.

Filtre passe-haut (Détection de Contours)																																																		
Catégorie	Gradient																																																	
Type	Approximation de base	Roberts	Prewitt	Sobel																																														
Forme	$\frac{\partial f}{\partial x}$: <table border="1"><tr><td>-1</td><td>0</td><td>+1</td></tr></table> $\frac{\partial f}{\partial y}$: <table border="1"><tr><td>-1</td><td>0</td><td>+1</td></tr></table>	-1	0	+1	-1	0	+1	<table border="1"><tr><td>0</td><td>1</td></tr><tr><td>-1</td><td>0</td></tr></table> Gradient diagonal	0	1	-1	0	<table border="1"><tr><td>+1</td><td>0</td><td>-1</td></tr><tr><td>+1</td><td>0</td><td>-1</td></tr><tr><td>+1</td><td>0</td><td>-1</td></tr></table> moyennneur/dérivateur pour $\frac{\partial f}{\partial x}$ <table border="1"><tr><td>+1</td><td>+1</td><td>+1</td></tr><tr><td>0</td><td>0</td><td>0</td></tr><tr><td>-1</td><td>-1</td><td>-1</td></tr></table> moyennneur/dérivateur pour $\frac{\partial f}{\partial y}$	+1	0	-1	+1	0	-1	+1	0	-1	+1	+1	+1	0	0	0	-1	-1	-1	<table border="1"><tr><td>+1</td><td>0</td><td>-1</td></tr><tr><td>+2</td><td>0</td><td>-2</td></tr><tr><td>+1</td><td>0</td><td>-1</td></tr></table> gaussien/dérivateur pour $\frac{\partial f}{\partial x}$ <table border="1"><tr><td>+1</td><td>+2</td><td>+1</td></tr><tr><td>0</td><td>0</td><td>0</td></tr><tr><td>-1</td><td>-2</td><td>-1</td></tr></table> gaussien/dérivateur pour $\frac{\partial f}{\partial y}$	+1	0	-1	+2	0	-2	+1	0	-1	+1	+2	+1	0	0	0	-1	-2	-1
-1	0	+1																																																
-1	0	+1																																																
0	1																																																	
-1	0																																																	
+1	0	-1																																																
+1	0	-1																																																
+1	0	-1																																																
+1	+1	+1																																																
0	0	0																																																
-1	-1	-1																																																
+1	0	-1																																																
+2	0	-2																																																
+1	0	-1																																																
+1	+2	+1																																																
0	0	0																																																
-1	-2	-1																																																
Avantage	Rapide et efficace avec les images propres		<ul style="list-style-type: none"> - Absorbe considérablement le bruit - Facile et rapide de leur traitement - Plus robustes 																																															
Inconvénient	<ul style="list-style-type: none"> - Forte sensibilité au bruit - Problème de seuillage 		<ul style="list-style-type: none"> - Ils ne peuvent pas éliminer tout le bruit - Les contours obtenus sont souvent assez larges - Moins précis + Problème de seuillage 																																															

Tableau I.2 filtre passe haute

Classification d'image :

La classification d'image est une méthode de catégorisation et d'étiquetage de groupes de pixels ou de vecteurs dans une image en fonction des règles spécifiques, la loi de catégorisation peut être conçue en utilisant une ou plusieurs caractéristiques spectrales ou texturales, Deux méthodes générales de classification sont « supervisées » et « non supervisées ».

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 par un volume important de données images. [11]

La classification binaire:

La classification binaire consiste à classer un ensemble des données ou des images à deux classes à l'aide d'un classificateur, est abondamment utilisée dans de nombreux domaines, cette section couvre de nombreux algorithmes largement utilisés pour la classification binaire. Chaque algorithme a ses avantages et ses inconvénients et certains algorithmes conviennent à certaines applications.

Méthodes de classification:

Méthodes supervisées :

L'objectif de la classification supervisée est principalement de définir des règles permettant de classer des objets dans des classes à partir des variables qualitatives ou quantitatives caractérisant ces objets, toutes les données sont étiquetées et les algorithmes apprennent à prédire le résultat des données d'entrée.

Il existe les plus importants algorithmes dans l'apprentissage supervisées :

- 1- K-les voisins les proches.
- 2- Régression logistique
- 3- Machines à vecteurs de soutien (SVM)
- 4- Les réseaux de neurones

Méthodes non supervisées :

La classification non supervisée désigne un corpus de méthodes ayant pour objectif de dresser ou de retrouver une typologie existante caractérisant un ensemble de n observations, à partir de p caractéristiques mesurées sur chacune des observations. Par typologie, on entend que les observations, bien que collectées lors d'une même expérience, ne sont pas toutes issues de la même population homogène, mais plutôt de K populations. [12]

Les algorithmes les plus importantes dans l'apprentissage non supervisées sont :

- 1- K-Means.
- 2- C-moyennes floues.
- 3- Fisher

La figure ci-dessous représente la différence entre apprentissage supervisé et non supervisé :

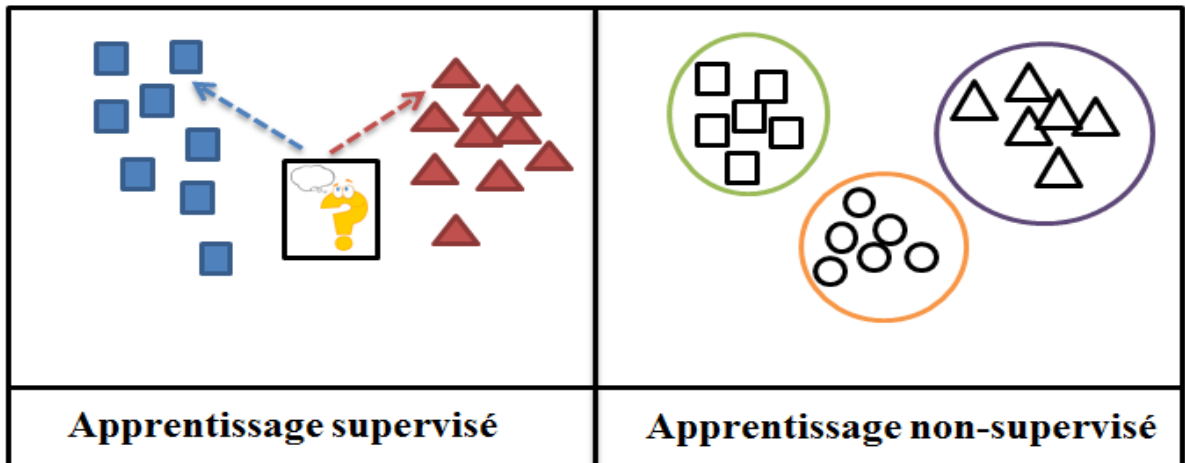


Figure I.10 différence entre apprentissage supervisé et non supervisé

Mesures de performance pour la classification :

Matrice de confusion :

Une matrice de confusion est un tableau souvent utilisé pour décrire les performances d'un modèle de classification (ou "classificateur") sur un ensemble de données de test dont les valeurs réelles sont connues. La matrice de confusion elle-même est relativement simple à comprendre, mais la terminologie qui s'y rapporte peut prêter à confusion.

		Réponse de l'expert	
		p	n
Réponse du classifieur	Y	Vrai Positif	Faux Positif
	N	Faux Négatif	Vrai Négatif

Figure I.11 Matrice de confusion

1. Vrai positif VP : Elément de la classe 1 correctement prédit.
2. Vrai négatif VN : Elément de la classe 0 correctement prédit.
3. Faux positif FP : Elément de la classe 1 mal prédit.
4. Faux négatif FN : Elément de la classe 0 mal prédit.

Il est possible de calculer plusieurs indicateurs résumant la matrice de confusion :

- 1- Accuracy: Il nous indique à quel point la valeur mesurée est proche d'une valeur connue.

$$\text{Accuracy} = \frac{(\square\square + \square\square)}{(\square\square + \square\square + \square\square + \square\square)}$$

- 2- Précision: Il indique la précision du modèle en termes de prédictions positives.

$$\text{Précision} = \frac{\square\square}{(\square\square + \square\square)}$$

- 3- Recall : Il calcule le nombre de positifs réels que le modèle a pu capturer après l'avoir étiqueté comme positif. (True positive)

$$\text{Recall} = \frac{\square\square}{(\square\square + \square\square)}$$

- 4- F1 Score: Il donne un équilibre entre la précision et le rappel.

$$\text{F1} = 2 * \frac{\square\square\square\square\square\square\square\square - \square\square\square\square\square\square}{\square\square\square\square\square\square\square\square + \square\square\square\square\square\square}$$

Courbe de ROC

ROC (receiver operating characteristics) est une courbe de probabilité, et l'AUC (aire sous la courbe) représente le degré de séparabilité, La courbe ROC est le tracé de la sensibilité (taux de vrais positifs) par rapport à la spécificité (taux de faux positifs). [17]

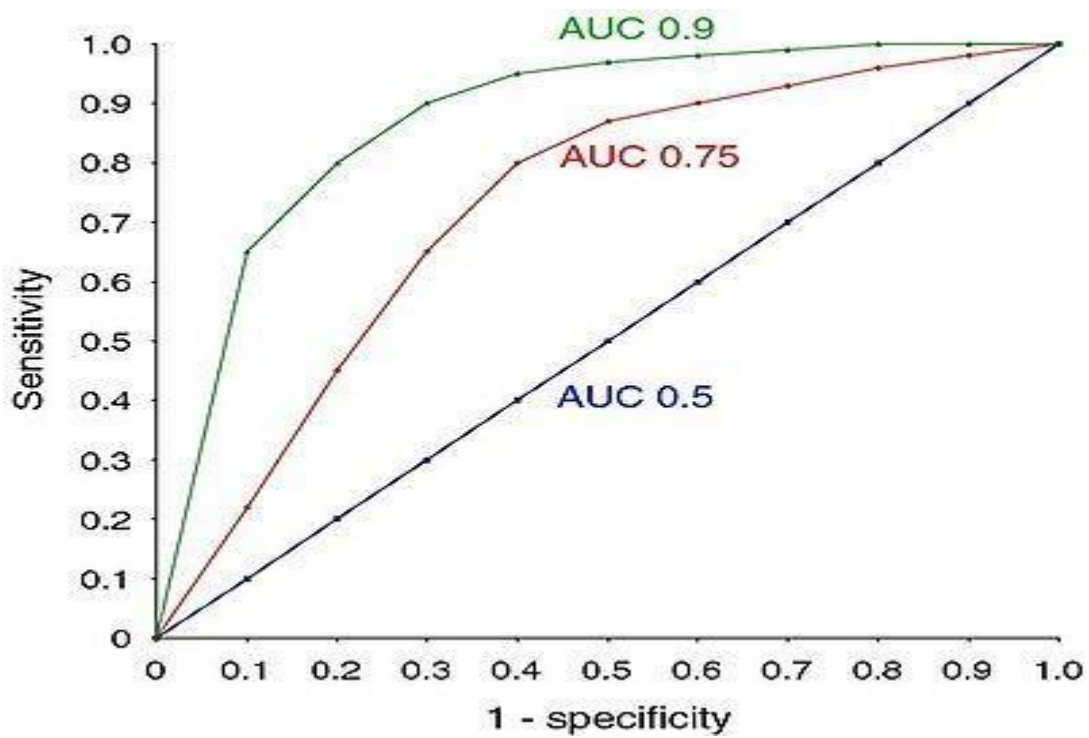


Figure I.12 Courbe de ROC

La courbe ROC est que chaque point de cette courbe prédit la précision du modèle.

conclusion :

Nous avons consacré ce chapitre à la présentation des notions de base de traitement d'image et classification ainsi que leurs intérêts dans plusieurs domaines.

Dans le deuxième chapitre on va bien détailler les réseaux de neurones et plus précisément l'utilisation des réseaux de neurones convolutionnels.

Chapitre II :

Les réseaux de neurones convolutionnels

Introduction:

L'intelligence artificielle (IA) est l'ensemble des théories et des techniques réalisées pour résoudre les problèmes à forte complexité logique ou algorithmique, L'apprentissage profond (Deep-Learning en anglais) est un ensemble des processus d'apprentissage automatique tentant de modéliser avec un haut niveau d'abstraction.

Les algorithmes d'apprentissage profond utilisent ce qu'on appelle un réseau de neurones pour trouver des associations entre un ensemble d'entrées et de sorties, il existe plusieurs types de réseaux de neurones existant pour différentes tâches (par exemple, NN convolutif pour la vision par ordinateur, NN récurrent pour PNL).




Figure II.1 : La relation entre l'intelligence artificielle, le ML et le deep learning

les réseaux de neurones

Les réseaux de neurones, communément appelés réseaux de neurones artificiels, sont inspirés des neurones du cerveau humain pour résoudre des problèmes d'apprentissage automatique

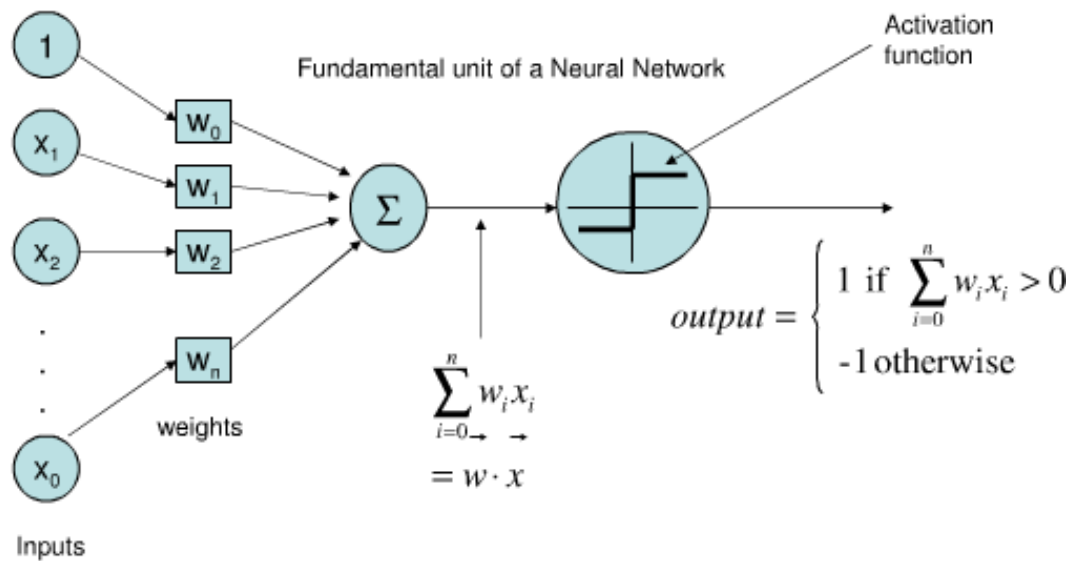


Figure II.2 : architecteur d'un réseau neurone artificiel

Il existe plusieurs domaine d'application des réseaux de neurones :

- 1- La reconnaissance d'image.
- 2- Les classifications de textes ou d'images.
- 3- Identification d'objets.
- 4- Prédiction de données.
- 5- Filtrage d'un set de données.

Deep-Learning :

L'apprentissage en profondeur (Deep-Learning) est un domaine de recherche sur l'apprentissage automatique basé sur un type particulier de mécanisme d'apprentissage.

Il est caractérisé par l'effort de créer un modèle d'apprentissage à plusieurs niveaux, dans lequel les niveaux les plus profonds prennent en compte les résultats des niveaux précédents, les transformant et en faisant toujours plus d'abstraction. Cet aperçu des niveaux d'apprentissage est inspiré par la façon dont le cerveau traite l'information et apprend en réagissant aux stimuli externes. Chaque niveau d'apprentissage correspond, par hypothèse, à l'une des différentes zones qui composent le cortex cérébral. [9]

Il existe plusieurs types d'architectures pour les réseaux de neurones:

1. Les perceptrons multicouches, qui sont les plus anciens et les plus simples.
2. Les Réseaux de Neurones Convolutionnels (CNN), particulièrement adaptés pour l'image En traitement.

3. Les réseaux de neurones récurrents, utilisés pour les données séquentielles telles que le texte ou séries chronologiques.

Pour classer des images avec le Machine Learning, les choix de caractéristiques et de classificateur doivent être effectués manuellement. Avec le Deep Learning, l'extraction de caractéristiques et le processus de modélisation sont automatiques.

Les réseaux de neurones récurrents:

Les réseaux de neurones récurrents sont au cœur de bon nombre d'améliorations substantiels dans des domaines aussi divers que la reconnaissance vocale, la composition automatique de musique, l'analyse de sentiments, l'analyse de séquence ADN, la traduction automatique.

Un réseau récurrent diffère des précédents par le fait qu'il est cyclique. La présence de cycles a un impact profond sur les capacités d'apprentissage du réseau et sur ses performances, notamment rendre le système dynamique. [19] [20]

Le schéma de ce réseau est produit ici:




Figure II.3 schéma de réseaux de neurones récurrents

les réseaux de neurones convolutionnels :

Les réseaux de neurones convolutifs (ConvNets) sont des outils largement utilisés pour l'apprentissage en profondeur (Deep Learning), Ils sont spécifiquement adaptés aux images en tant qu'entrées, bien qu'ils soient également utilisés pour d'autres applications telles que le texte, les signaux et d'autres réponses continues. Ils diffèrent des autres types de réseaux de neurones en quelques points.

Les réseaux de neurones convolutifs sont inspirés de la structure biologique d'un cortex visuel qui contient des arrangements de cellules simples et complexes [7].

Les réseaux de neurones convolutifs il comporte deux parties distinctes, une première partie que l'on appelle la partie convolutif du modèle et la seconde partie, que l'on va appeler la partie classification.

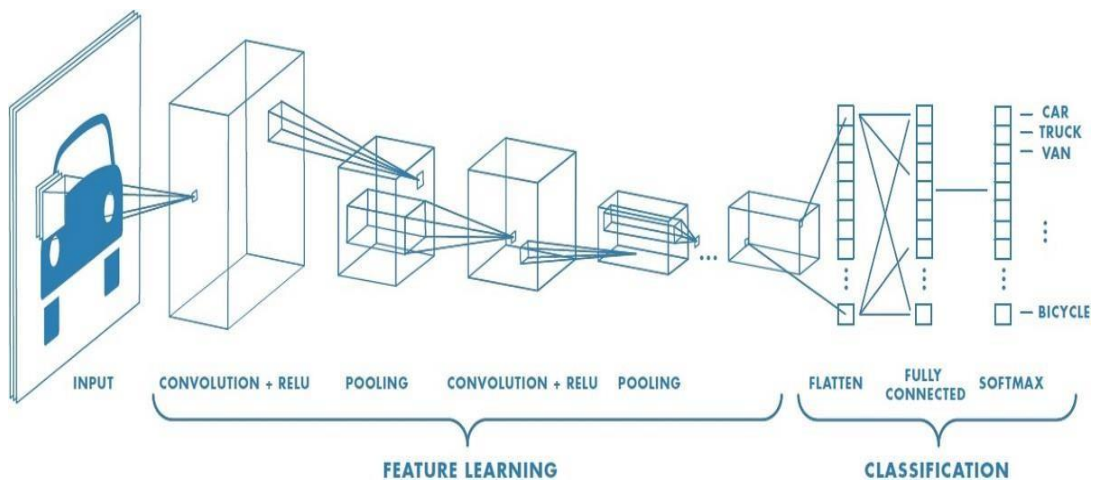


Figure II.4 Architecture d'un réseau de neurone convolutionnel

Un réseau de neurones multicouches et plus justement c'est un réseau profond composé de multiples couches qui en générale sont organisées en trois blocs (CONV → RELU → POOL).

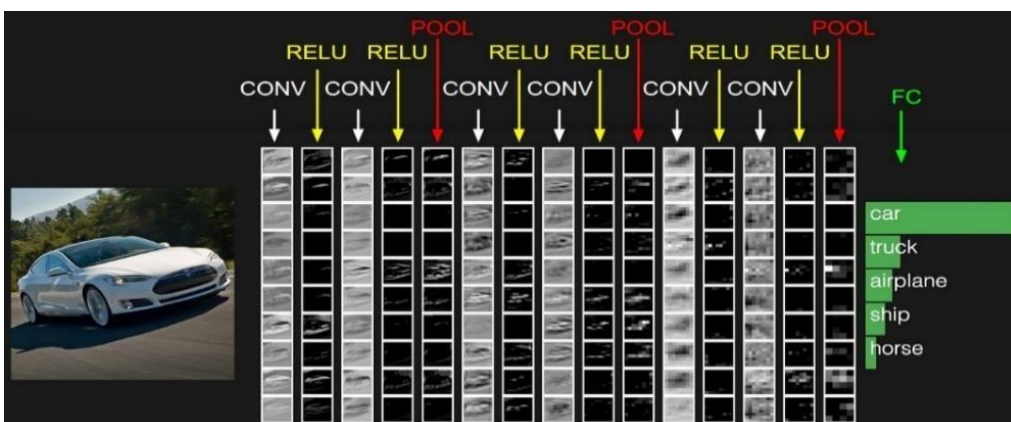


Figure II.5 image représenté architecture Deep-Learning

La couche de convolution :

Une couche convolutive est l'une des composantes les plus fondamentales et les plus importantes d'un réseau neuronal, elle contient plusieurs filtres dont chacun est petit par rapport au volume d'entrée (l'image), par exemple $3 \times 3 \times 3$ pixels (un filtre 3×3 avec 3 canaux), car les images standard ont 3 canaux de couleur).

Lors de la passe avant du réseau les filtres sont déplacés sur l'image d'entrée, à chaque position des filtres sur l'image une convolution est calculée, c'est-à-dire une multiplication matricielle par éléments et une somme sur la matrice résultante.

Le résultat de cette opération est une carte d'activation cette carte est la sortie du réseau convolutionnel couche.

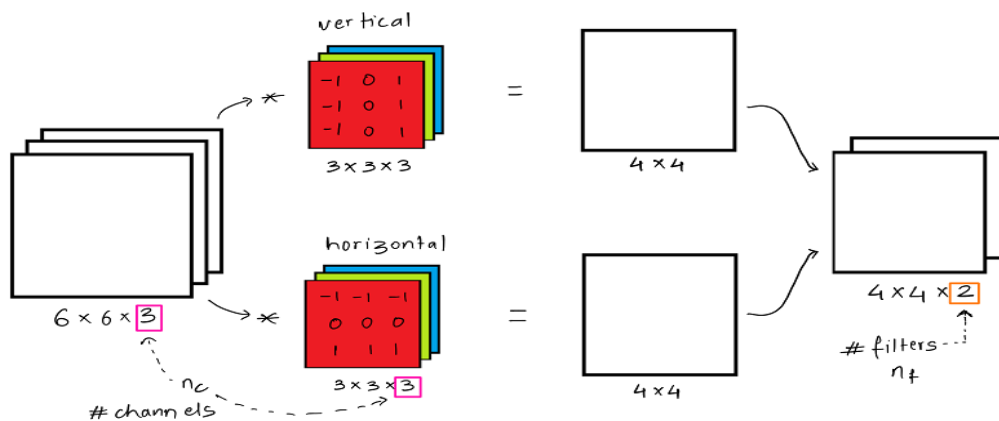


Figure II.6 Convolution avec plusieurs filtres

La taille d'un filtre peut être configurée, ainsi que la taille du pas, le pas (stride) et la quantité de remplissage de zéro autour de l'image d'entrée.



Figure II.7 : <https://cs231n.github.io/assets/cnn/weights.jpeg>

La couche de pooling :

Le pooling est une technique qui permet de réduire la taille d'une image par extraire une valeur unique d'une région de valeurs, la valeur extraite dépend du type de regroupement utilisé, les types de regroupement les plus courants sont au maximum (max) pooling pour extraire la valeur la plus élevée du champ actuel, et pooling moyen (moy) qui extrait la valeur moyenne de la région actuelle.

Une couche de pooling a essentiellement des paramètres avec lesquels elle peut être configurée, d'abord il y a la stride qui est la distance sur laquelle le filtre est déplacé. Deuxièmement, il y a la taille du filtre f qui détermine la largeur et la hauteur du filtre utilisé pour extraire la valeur de l'entrée.

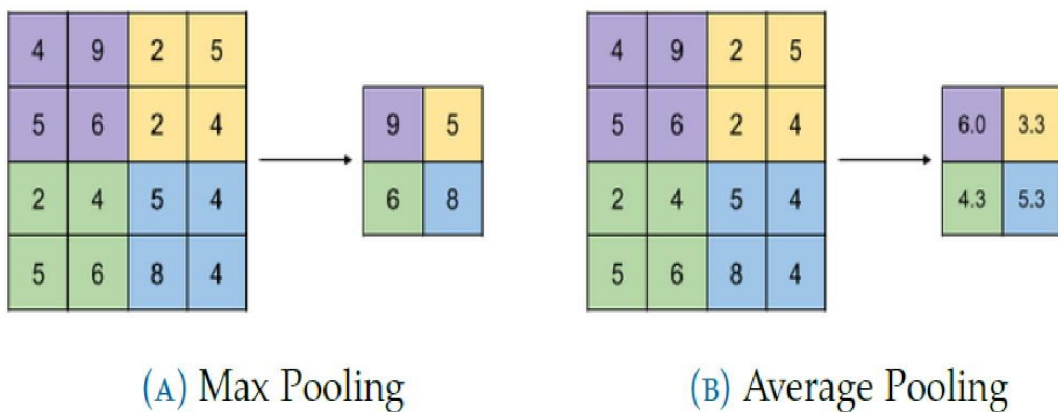


Figure II.8 Max and moy pooling

La couche de correction (Relu) :

ReLU (*Rectified Linear Units*) désigne la fonction réelle non-linéaire définie par la fonction :

$$\text{ReLU}(x) = \max(0, x)$$




Figure II.9: Allure de la fonction ReLU

La couche de correction ReLU remplace donc toutes les valeurs négatives reçues en entrées par des zéros, elle joue le rôle de fonction d'activation.



Figure II.10 Application du relu dans une image

Couche entièrement connectée (fully connecte layer):

Après plusieurs couches de convolution et de max 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. [15]

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 perte « Soft max » est utilisée pour prédire une seule classe parmi K classes mutuellement exclusives. La perte par entropie croisée sigmoïde est utilisée pour prédire K valeurs de probabilité indépendante dans [0,1]. [16]

Les auto encodeur :

Un auto encodeur est un réseau de neurones qui est formé pour répliquer son entrée à sa sortie. Auto-encodeur peut servir d'outils pour apprendre les réseaux neuronaux profond, ce qui a pour objectif de compresser tout en gardant l'erreur $\| \square - \hat{\square} \|^2$ faible ou d'apprendre une représentation des données compacte mais riche en information.

Un auto encodeur de formation n'est pas surveillée en ce sens qu'aucune données étiquetées ne sont nécessaire. Le processus de formation repose toujours sur l'optimisation d'une fonction objectif (aussi appelée fonction de coût ou d'erreur).[10]

L'architecture de notre réseau est le suivant:




Figure II.11 image représenté auto encodeur

Le réseau va donc représenter les données au moyen d'une ou plusieurs couches cachées de sorte à ce qu'en sortie on retrouve les mêmes données qu'en entrée.

L'objectif de retrouver en sortie les mêmes données qu'en entrée est caractéristique des auto-encodeurs (analogue à la fonction identité $f(x)=x$). La phase d'encodage et de décodage n'est-elle pas propre aux auto-encodeurs.

En effet, on les retrouve dans la traduction automatique dans des réseaux de neurones récurrents, après avoir entraîné le réseau avec suffisamment de données il sera possible d'identifier des observations suspectes ou anormales lorsque celles-ci dépassent un certain seuil par rapport à la nouvelle "norme". [24]

Amélioration des performances du réseau de neurones :

Il existe plusieurs techniques pour améliorer les performances des réseaux de neurones, car initialement, ces performances peuvent souvent ne pas être satisfaisantes, les principaux facteurs conceptuels causant la dégradation de performances sont le problème du sur apprentissage et le mauvais choix des hyperparamètres. Nous avons sélectionné certaine techniques d'amélioration de performance pour les tester sur notre modèle. [18]

Technique du Dropout :

L'objectif est d'éteindre et rallumer les neurones aléatoirement, dans le cadre d'entraînements successifs. Une fois les séries d'entraînements terminées, on rallume tous les neurones et on utilise le réseau comme d'habitude. Cette technique a montré non seulement un gain dans la vitesse d'apprentissage, mais en déconnectant les neurones, on a aussi limité des effets marginaux, rendant le réseau plus robuste et capable de mieux généraliser les concepts appris.




Figure II.12 : image représente le technique dropout

Technique du early stopping :

Appelée aussi l'arrêt précoce, cette technique permet d'interrompre l'entraînement avant que les poids ne convergent. Souvent, nous nous arrêtons lorsque la précision cesse d'améliorer pour l'ensemble de validation. [21]

choix des hyperparamètres :

Les hyperparamètres sont les variables qui déterminent la structure du réseau (par exemple : nombre couches cachées, nombre filtre, forme de filtre, etc...) et les variables qui déterminent la façon dont le réseau est formé (par exemple : taux d'apprentissage, optimiseur Adam, Batch normalisation, etc....)

Taux d'apprentissage (Learning rate):

Le taux d'apprentissage est un hyperparamètre qui contrôle dans quelle mesure le modèle doit être modifié en réponse à l'erreur estimée chaque fois que les poids du modèle sont mis à jour. Le choix du taux d'apprentissage est un défi, car une valeur trop petite peut entraîner un long processus d'apprentissage qui peut rester bloqué, tandis qu'une valeur trop grande peut entraîner l'apprentissage trop rapide d'un ensemble sous-optimal de poids ou un processus d'apprentissage instable.

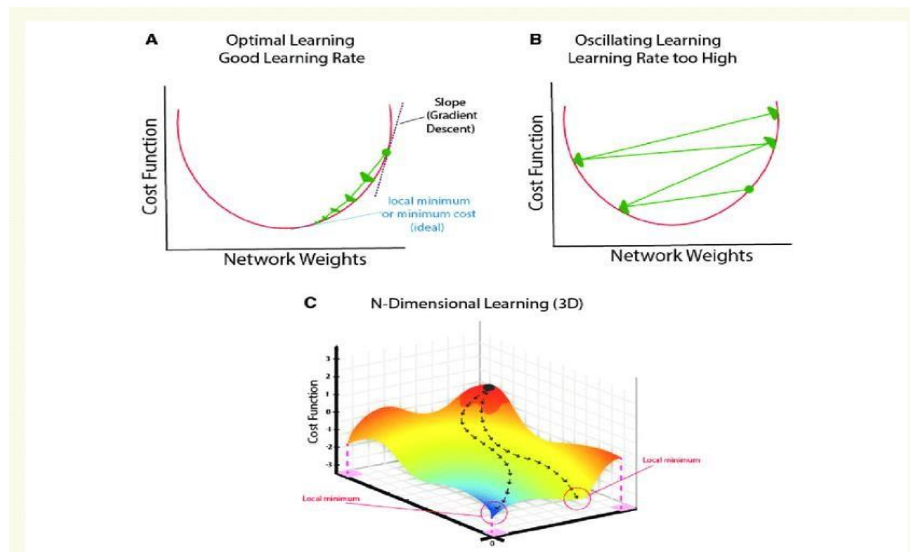


Figure II.13 image représenté les déférentes taux d'apprentissage

Optimiseur Adam :

Adam est un algorithme d'optimisation alternatif qui fournit des poids de réseau neuronal plus efficaces en exécutant des cycles répétés d'"estimation de moment adaptative". Adam s'appuie sur la descente de gradient stochastique pour résoudre les problèmes non convexes plus rapidement tout en utilisant moins de ressources que de nombreux autres programmes d'optimisation. Il est plus efficace dans les ensembles de données extrêmement volumineux en maintenant les gradients "plus serrés" sur de nombreuses itérations d'apprentissage.

Batch normalisation :

Pour faciliter l'apprentissage, nous normalisons généralement les valeurs initiales de nos paramètres en les initialisant avec une moyenne nulle et une variance unitaire. Au fur et à mesure que la formation progresse et que nous mettons à jour les paramètres, nous perdons cette normalisation, ce qui ralentit l'apprentissage et amplifie les changements au fur et à mesure que le réseau s'approfondit. À mesure que le réseau devient plus profond, la normalisation par lot rétablit ces normalisations pour chaque mini-lot et les changements sont également rétro-propagés à travers l'opération.

À travers l'opération également. En faisant de la normalisation une partie de l'architecture du modèle, nous sommes en mesure d'utiliser des taux d'apprentissage plus élevés et de prêter moins d'attention aux paramètres d'initialisation. Lot agit en outre comme un régularisateur, réduisant (et parfois même éliminant) le besoin de Dropout.

nombre de filtres :

Comme la taille des images intermédiaires diminue avec la profondeur du traitement, les couches proches de l'entrée ont tendance à avoir moins de filtres tandis que les couches plus proches de la sortie peuvent en avoir davantage. Pour égaliser le calcul à chaque couche, le produit du nombre de caractéristiques et le nombre de pixels traités est généralement choisi pour être à peu près constant à travers les couches. Pour préserver l'information en entrée, il faudrait maintenir le nombre de sorties intermédiaires (nombre d'images intermédiaire multiplié par le nombre de positions de pixel) pour être croissante (au sens large) d'une couche à l'autre. [19]

forme des filtres :

Comme la taille des images intermédiaires diminue avec la profondeur du traitement, les couches proches de l'entrée ont tendance à avoir moins de filtres tandis que les couches plus proches de la sortie peuvent en avoir davantage. Pour égaliser le calcul à chaque couche, le produit du nombre de caractéristiques et le nombre de pixels traités est généralement choisi pour être à peu près constant à travers les couches. Pour préserver l'information en entrée, il faudrait maintenir le nombre de sorties intermédiaires (nombre d'images intermédiaire multiplié par le nombre de positions de pixel) pour être croissante (au sens large) d'une couche à l'autre.

Le nombre d'images intermédiaires contrôle directement la puissance du système, dépend du nombre d'exemples disponibles et la complexité du traitement. [16]

conclusion :

Dans ce chapitre on a présenté les notions importantes qui sont en relation avec l'apprentissage profond (définition, ...etc.). Aussi qu'une vision générale sur l'apprentissage profond, toute en donnant en détail la méthode choisie dans notre travail de recherche qui est le CNNs.

Le prochain chapitre, traite les détails de la conception, ainsi que la méthode et les outils utilisés pour la réalisation de notre application.

Chapitre III

Implémentation et résultats

III.1 Introduction :

La pneumonie est l'une des maladies les plus dangereuses, c'est une maladie infectieuse qui affecte les poumons et menace la vie humaine.

Elle est généralement causée par une bactérie appelée *Streptococcus pneumoniae* comme documenté en 2017, il affecte environ 450 millions de personnes dans le monde chaque année. Le diagnostic précoce de la pneumonie est d'une importance primordiale Pour sauver la vie de nombreuses personnes.

En raison du succès des algorithmes d'apprentissage en profondeur dans l'analyse des images médicales, les réseaux de neurones convolutifs (CNN) ont attiré beaucoup d'attention pour la classification, et notre travail vise à détecter et à classer les patients atteints de pneumonie sur la base d'images radiographiques thoraciques.

Les résultats statistiques obtenus démontrent que les modèles CNN pré-entraînés utilisés avec des algorithmes de classification supervisés peuvent être très bénéfiques dans l'analyse des radiographies de la poitrine, en particulier pour détecter la pneumonie.

III.2-Présentation des outils de développement :

Matériels et méthodes:

Nous présentons les expériences détaillées et les étapes d'évaluation entreprises pour tester l'efficacité du modèle proposé, nos expériences étaient basées sur un ensemble de données d'images de radiographie thoracique proposé dans [13].

Toutes les expériences ont été réalisées sur un PC HP équipé d'un processeur Intel® Core™ i5-10210U CPU @ 1.60GHz 2.11 GHz et une RAM de 8 Go et un GPU Intel ® UHD Graphics.

python :

Python est un langage de programmation puissant et facile à apprendre. Il possède des structures de données structures de données de haut niveau efficaces et une approche simple mais efficace de la programmation orientée objet. La syntaxe élégante et le typage dynamique de Python, ainsi que sa nature interprétée, en font un langage idéal pour le développement de scripts et d'applications rapides dans de nombreux domaines et sur la plupart des plates-formes. [14]

Python est contient plusieurs bibliothèques de l'intelligence artificiel populaires : (Keras, Tensorflow, Numpy, Pandas, OPENCv, Pytorch, etc....)

TensorFlow :

TensorFlow est un Framework de programmation pour le calcul numérique qui a été rendu Open Source par Google en Novembre 2015. Depuis son release, TensorFlow n'a cessé de gagner en popularité, pour devenir très rapidement l'un des Framework les plus utilisés pour le Deep Learning et donc les réseaux de neurones. Son nom est notamment inspiré du fait que les opérations courantes sur des réseaux de neurones sont principalement faites via des tables de données multidimensionnelles, appelées Tenseurs (Tensor). Un Tensor à deux dimensions est l'équivalent d'une matrice. Aujourd'hui, les principaux produits de Google sont basés sur TensorFlow: Gmail, Google Photos, Reconnaissance de voix.

Keras :

Keras est une API de réseaux de neurones de haut niveau, écrite en Python et capable de fonctionner sur TensorFlow ou Theano. Il a été développé en mettant l'accent sur l'expérimentation rapide. Être capable d'aller de l'idée à un résultat avec le moins de délai possible est la clé pour faire de bonnes recherches. Il a été développé dans le cadre de l'effort de recherche du projet ONEIROS (Open-ended Neuro-Electronic Intelligent Robot Operating System), et son principal auteur et mainteneur est François Chollet, un ingénieur Google.

En 2017, l'équipe TensorFlow de Google a décidé de soutenir Keras dans la bibliothèque principale de TensorFlow. Chollet a expliqué que Keras a été conçue comme une interface plutôt que comme un cadre d'apprentissage end to end. Il présente un ensemble d'abstractions de niveau supérieur et plus intuitif qui facilitent la configuration des réseaux neuronaux indépendamment de la bibliothèque informatique de backend. Microsoft travaille également à ajouter un backend CNTK à Keras aussi.

La base de données :

La base de données utilisée pour tous les diagnostics est basée sur un ensemble de radiographies du thorax qui publié sur le site Web de Kaggle [13], toutes les images sont des radiographies composées du format RGB, le cadre d'apprentissage profond open-source Keras avec le backend TensorFlow est utilisé pour construire et former le Construire et former le réseau neuronal convolutif.

L'ensemble de données obtenu se compose d'images de formation (training), de test et de validation, chacune divisée par les radiographies thoraciques Pneumonie et Normal, Les données sont modifiées dans l'ensemble de formation (training) et de validation pour améliorer le système et augmenter son efficacité, un total d'environ 5216 images sont incluses dans l'ensemble de formation (training) et de même, un total de 624 images est attribué à l'ensemble de validation afin d'améliorer la

précision globale.




Figure III.1: Échantillon radiographique sans pneumonie




Figure III.2 : Échantillon radiographique sans pneumonie

Prétraitement et augmentation :

Nous avons employé plusieurs méthodes d'augmentation des données pour accroître artificiellement la taille et la qualité de l'ensemble de données, ce processus permet de résoudre les problèmes d'overfitting et d'améliorer la capacité de généralisation du modèle pendant la formation. Les paramètres déployés dans l'augmentation des images sont présentés ci-dessous dans le (TableauIII.1).

L'opération de remise à l'échelle représente la réduction ou l'agrandissement de l'image pendant le processus d'augmentation, la plage de rotation indique la plage dans laquelle les images ont été tournées de manière aléatoire pendant la formation, c'est-à-dire 90 degrés. Le décalage en largeur est la translation horizontale des images de 0,1 %, et le décalage en hauteur est la translation verticale des images de 0,1 %. En outre.

La plage de zoom permet de zoomer aléatoirement les images dans un rapport de 0,2 pour cent, et enfin, les images ont été retournées horizontalement et verticalement.

Méthode	Paramètre
remise à l'échelle (rescale)	1/255
la plage de rotation (rotation range)	90 degrés
translation horizontale (Width shift)	0.1 %
translation verticale (Height shift)	0.1 %
la plage de Zoom (Zoom range)	0.2 %
retournées horizontalement (Horizontal flip)	True
retournées verticalement (vertical flip)	True

Tableau III.1 Paramètres pour l'augmentation des images

L'Architecture:

Montre l'architecture globale du modèle CNN proposé qui se compose de deux parties principales, les extracteurs de caractéristiques et un classificateur (fonction d'activation sigmoïde).

Chaque couche de la couche d'extraction de caractéristiques prend en entrée la sortie de la couche qui la précède immédiatement, et sa sortie est transmise comme entrée aux couches suivantes. L'architecture proposée dans la figure 3 se compose des couches de convolution, de maxpooling et de classification combinées ensemble.

Les extracteurs de caractéristiques comprennent des couches de convolution 3×3 , 256 ; 3×3 , 64 ; 3×3 , 16, une couche de max-pooling de taille 2×2 , et un activateur RELU entre elles.

Les sorties des opérations de convolution et de max-pooling sont assemblées en 2 dropout de taille 0,5 deux couches denses de taille 64 et 1 respectivement un RELU entre les deux couches denses et une fonction d'activation sigmoïde qui effectue les tâches de classification des tâches.




Figure III.3 architecture proposé

Il y a trois couches convolutionnelles avec le même nombre de couches de Maxpooling suivies par les couches plates, même nombre de couches de Maxpooling, suivies par la couche flatten de de zéro paramètre et les couches denses d'environ 10000 paramètres.

Ainsi le total des paramètres entraînaables dans le réseau s'élève à 799 791.00 paramètres, ce résumé du modèle donne une information rapide sur le réseau neuronal profond.

Le modèle:

COUCHES	FORME DE SORTIE	PARAMETERS
CONV2D	(NONE, 200, 200, 256)	2560
ACTIVATION	(NONE, 200, 200, 256)	0
MAX_POOLING2D	(NONE, 100, 100, 256)	0
BATCH_NORMALIZ	(NONE, 100, 100, 256)	400
CONV2D_1	(NONE, 100, 100, 64)	147520
ACTIVATION_1	(NONE, 100, 100, 64)	0
MAX_POOLING2D_1	(NONE, 50, 50, 64)	0
BATCH_NORMALIZ_1	(NONE, 50, 50, 64)	200
CONV2D_2	(NONE, 50, 50, 16)	9232
ACTIVATION_2	(NONE, 50, 50, 16)	0
MAX_POOLING2D_2	(NONE, 25, 25, 16)	0
BATCH_NORMALIZ_2	(NONE, 25, 25, 16)	100
FLATTEN	(NONE, 10000)	0
DROPOUT	(NONE, 10000)	0
DENSE	(NONE, 64)	640064
ACTIVATION_3	(NONE, 64)	0
DROPOUT_1	(NONE, 64)	0
DENSE_1	(NONE, 1)	65
ACTIVATION_4	(NONE, 1)	0
Total params: 800,141		
Trainable params: 799,791		
Non-trainable params: 350		

Les figures suivantes présentent les résultats d'apprentissage de l'architecture proposée :

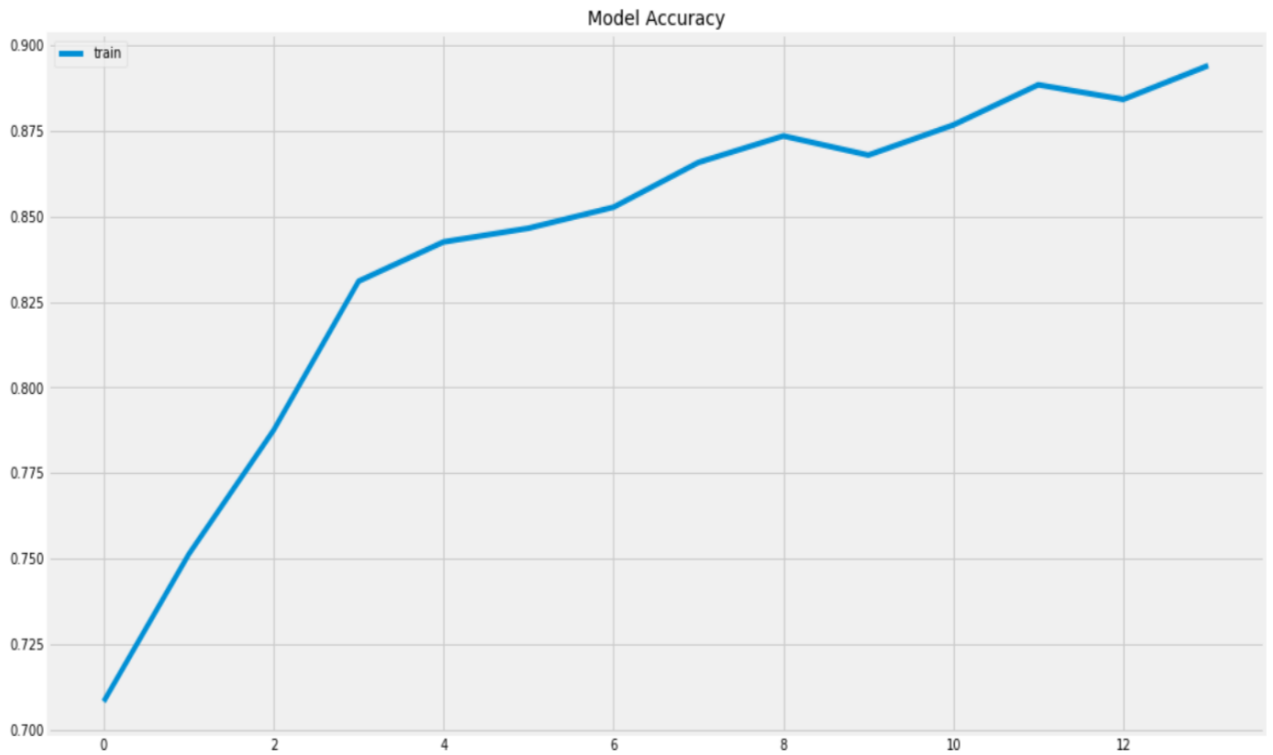


Figure III.4 model de précision

Le Figure III.4 représenté la précision dans l'étape de formation (training) à partir la base des donnée utilisé




Figure III.5 model de perte




Figure III.6 model précision validation




Figure III.7 model perte validation

La figure III.7 montre la détérioration de la perte qui est ce que nous voulons dans notre étude

Résultat :

Pour tester et évaluer les performances du réseau proposé, les paramètres et hyper paramètres ont été réglés pendant la formation, les (figures III.8) montrent les courbes de la précision de l'entraînement et de perte d'entraînement obtenues lors de l'entraînement des modèles pour 15 époques. La précision d'apprentissage du modèle à de **91.63 %**, et la perte d'apprentissage du modèle à de **0.1997**, et une précision correspondante de **91,14 %** et **0.2282** perte pour validation.

Le tableau suivant représente les différents résultats obtenus :

Époque	Precision de formation	Perte de formation	Précision de validation	Perte de validation
1	0.7120	0.6431	0.7407	0.6431
3	0.8044	0.4152	0.7940	0.3886
5	0.8489	0.3489	0.8549	0.3175
10	0.8740	0.2899	0.9114	0.2183
12	0.8793	0.2795	0.9146	0.2160
15	0.8887	0.2651	0.8943	0.2466

Tableau III.2 résultat du l'architecture CNN proposé




Figure III.8 courbe de ROC de notre résultat

Dans la phase de la prédiction nous avons trouvé les résultats dans le tableau :

Seuil/parametre	0.86	0.84	0.80	0.75	0.73	0.70	0.65	0.50
accuracy	0.9189	0.9163	0.9146	0.9087	0.907	0.899	0.86	0.736
recision	0.8358	0.8632	0.8905	0.9331	0.948	0.965	0.979	0.997
recall	0.8702	0.8427	0.8207	0.7881	0.772	0.749	0.672	0.514
f1 score	0.8526	0.8528	0.8541	0.8544	0.851	0.844	0.797	0.678

Tableau III.3 : les résultats dans la phase de la prédiction

D'après le (Tableau III.3), on peut conclure que pour le seuil égal 0.5 on trouve une grande valeur de précision et des petites valeurs pour les autres critères. Et pour la valeur du seuil égale 0.86 on remarque qu'une mauvaise valeur de précision et meilleures valeurs pour les autres critères




Figure III.9 image représenté précision vs Recall

conclusion:

La présence des images de référence (radiologues experts) est la première nécessité pour diagnostiquer correctement tout type de maladie thoracique, le but de ce chapitre est améliorer le diagnostic de maladie pneumonie pour prévenir les conséquences indésirables (la mort), le développement d'algorithmes dans ce domaine peut être très utile pour fournir de meilleurs services de soins de santé.

L'utilisation des CNNs est donnés des bons résultats pour classifiez la maladie de pneumonie, à l'aide d'une base de donnée contient des images des personnes (malade/pas malade) afin pour détecter la présence de la maladie plus rapide et précis.

Conclusion générale:

Dans ce travail nous avons discuté des notions fondamentales de classification d'image et du Deep Learning basé sur les réseaux de neurones convolutionnels en particulier.

Nous avons introduit ces réseaux de neurones convolutionnels en présentant les différents types de couches utilisées dans la classification : La couche convolutionnelle, la couche de Relu, la couche de pooling et la couche entièrement connectée, nous avons parlé aussi sur les méthodes de régularisation (dropout et data augmentation, early stopping, taux d'apprentissage, batch normalisation, etc....) utilisées pour éviter le problème de sur apprentissage.

A fin pour résoudre les problèmes de classification pour détecter de la maladie pneumonie.

Références bibliographiques

- [1] M Sandeli, traitement d'images par des approches bio-inspirées application à la segmentation d'images, université constantine 2. 2014.
- [2] T. Mohamed ,D.Djafar, la découverte des concepts sémantiques cachés avec plusieurs niveaux d'abstraction pour la recherche d'images,université kasdi merbah ouargla.2013
- [3] N MERABET,M MAHLIA, recherche d'images par le contenu, université abou bakrbelkaid–tlemcen.2011
- [4] ATTAF YUCEF, AMOUR HAMIDM,BOUALAM LYES Analyse d'images par filtre de Gabor Application aux images médicales 2010
- [5] Naciri H., Chaoui N, Conception et Réalisation d'un système automatique d'identification des empreintes digitales, Mémoire de PFE, Université de Tlemcen, 2003.
- [6] Jean-Marie Munguakonkwa biringanine, « La liaison automatique de plusieurs images perçues sur un scanner » ISP licencié en pédagogie Informatique de Gestion, 2008.
- [7] Hubel, H. D. and Wiesel, T. N. " Receptive Fields of Single neurones in the Cat's Striate Cortex." Journal of Physiology.1959
- [8] Rafael C.Gonzalez & Richard E.Woods , Digital Image Processing, Pearson Education Inc,2008.
- [9] ZACCONE Giancarlo, MD REZAUL Karim, MENSRAWY Ahmed. Deep learning with tensorflow. 2017
- [10] Sadia ALKAMA, Nacerdine LARBI, Segmentation d'images avec le Deep Learning 2018
- [11] Laurent HEUTTE Classification Automatique d'Images, Application à l'Imagerie du Poumon Profond 2013
- [12] E. Lebarbier, T. Mary-Huard Classification non supervisée AgroParisTech
- [13] <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>
- [14] Van Rossum, G. An introduction to Python ,F. L. Drake (Ed.). Bristol: Network Theory Ltd 2003.

- [15] MALKI NARIMANE Classification automatique des textes par Les réseaux de neurones à convolution 2019
- [16] Boughaba Mohammed et Boukhris Brahim L`apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu .2017
- [17] Hashmi, M. F., Katiyar, S., Keskar, A. G., Bokde, N. D., & Geem, Z. W. Efficient pneumonia detection in chest xray images using deep transfer learning. Diagnostics .2020
- [18] BALAMANE Asma TAKLIT Zina Proposition d'un modèle pour l'optimisation automatique de Boucles dans le compilateur Tiramisu : cas d'optimisation de déroulage. (p.133) (2019)
- [19] PARIZEAU Marc. Réseaux de neurones. 2004
- [20] NAKAMOTO Pat. Neural networks and deep learning : deep learning explained to your granny visual introduction for beginners who want to make their own deep learning neural network. 2017

Résumé : Dans notre mémoire on a utilisé l'apprentissage profond (Deep Learning) et les réseaux de neurones convolutifs (CNNs) pour classifier une base d'images en un ensemble de classes, on a utilisé python et la bibliothèque TensorFlow et keras...etc., on a implémenté une modèle CNN pour classifier la maladie de pneumonie en deux classe (malade/pas malade).

Abstract : In our dissertation we used Deep Learning and Convolutional Neural Networks (CNNs) to classify a database of images into a set of classes, we used python and the TensorFlow library and keras...etc., we implemented a CNN model to classify the pneumonia disease into two classes (sick/not sick)

ملخص : في أطروحتنا ، استخدمنا التعلم العميق والشبكات العصبية التلافيفية (CNN) لتصنيف قاعدة الصور إلى مجموعة من الفئات ، واستخدمنا Python ومكتبة TensorFlow و keras ... إلخ ، وتم تنزيل نموذج CNN لتصنيف مرض الالتهاب الرئوي إلى فئتين (مرضى / غير مرضى).

Mots clés : Deep Learning ,Convolutional Neural Networks (CNNs), classification des images