



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Mohamed Khider – BISKRA
Faculté des Sciences Exactes, des Sciences de la Nature et de la Vie
Département d'informatique

N° d'ordre : **Voir le numéro sur le liste (exemple : IA23, IOD5) /M2/2017**

Mémoire

présenté pour obtenir le diplôme de master académique en

Informatique

Parcours : **nom de l'option, choisir une seule parmi (Images et vie artificielle ou Intelligence artificielle ou Génie logiciel et systèmes distribués ou Informatique décisionnelle et optimisation ou Réseaux et TIC)**

Titre

Par :

NOM & PRENOM

Soutenu le **Mettre la date de la soutenance**, devant le jury composé de :

Nom et prénom

Grade

Président

Nom et prénom

Grade

Rapporteur

Nom et prénom

Grade

Examineur

Remerciement

Je remercie ALLAH le tout puissant qui m'a guidé et qui m'a donné la force et la volonté de réaliser ce travail.

*Je voudrai exprimer mes remerciements les plus sincères à mon encadreur Monsieur
TJBERMACINE AHMED pour son encadrement et sa expérience qu'il à su me faire partager.*

Mes remerciements et ma reconnaissance sont adressés envers mes collègues pour un temps précieux passé ensemble. Mes plus vifs remerciements vont également à tous mes amis avec qui j'ai partagé des moments inoubliables pendant mes études.

Enfin, toute ma gratitude, ma reconnaissance et mes très vifs remerciements à tous ceux qui ont contribué de près ou de loin et en particulier l'ensemble des enseignants du département d'informatique de Biskra, à ma formation d'études de la graduation et de la post graduation.

Dédicace

*Je dédie le présent travail
A mes très chers parents
A ma sœur et mes frères
A l'ensemble de ma famille
A mes amis et mes
Collègues...*

Résumé

Les tremblements de terre se produisent sans avertissement et peuvent dévaster des villes entières en quelques secondes, causant de nombreuses victimes et d'énormes pertes économiques. De grands efforts ont été déployés pour pouvoir prévoir ces catastrophes naturelles et prendre des mesures de précaution. Cependant, prédire simultanément quand, où et l'ampleur du prochain séisme, dans une région et dans un temps limité, semble une tâche presque impossible. Les techniques issues du domaine de l'exploration de données fournissent des informations nouvelles et importantes aux chercheurs. Cet article passe en revue l'utilisation de Deep Learning pour la prévision des tremblements de terre en réponse à la quantité croissante d'ouvrages publiés récemment et présentant des allégations d'efficacité. Sur la base d'une analyse et d'une discussion des résultats récents, les praticiens de l'exploration de données sont encouragés à appliquer leurs propres techniques dans ce nouveau domaine de recherche.

La conception et la réalisation d'une application de prédiction de tremblement de terre à en se basent sur le Deep Learning. Cette étude nous permet de prédire s'il va y'avoir un tremblement de terre dans un endroit précis à une date précise.

Pour sa en va parler de tous ce qui concerne cette application que ça soit côté application ou tremblements de terre.

Table Des matières

Remerciement.....	I
Dédicace	II
Résumé	III
Table Des matières.....	IV
Liste des figures	VII
Liste des tableaux	VIII
Introduction générale.....	1
Chapitre 1 : Réseaux de neurones/ allez plus loin : Le Deep Learning	
1. Introduction	4
2. Réseaux de neurones	4
2.1. Modèle biologique	4
2.2. Du neurone biologique au neurone formel (artificiel).....	5
2.3. Neurone artificiel.....	6
2.3.1. Historique	7
2.3.2. Définition	8
2.3.3. Topologie	8
2.3.3.2. Réseaux de neurones dynamiques ou réseaux bouclés	10
2.3.4. Fonction.....	10
2.3.4.1. Fonction de combinaison	10
2.3.4.2. Fonction d'activation	10
2.3.5. Type de réseau de neurone	13
2.3.5.1. Perceptron	13
2.3.5.2. Perceptron multicouche	14
2.3.5.4. Réseau de neurones RBF	16
2.3.6. Type d'apprentissage.....	17
3. Machine Learning	18
4. Deep Learning	18
4.1. Définition de Deep Learning	18
4.2. Historique	18
4.3. Fonctionnement de Deep Learning.....	19
4.4. Méthode d'utilisation du deep learning	20
4.5. Domaine d'application	21

Table des matières

4.6.	Les avantages de Deep Learning	22
5.	Conclusion.....	23
Chapitre 2 : Les tremblements de terre		
1.	Introduction	25
2.	Définition du tremblement de terre	25
3.	Caractéristiques principales.....	25
4.	Catégorie de tremblement de terre	26
4.1.	Séismes tectoniques.....	26
4.2.	Séismes d'origine volcanique.....	27
4.3.	Séismes d'origine polaire	27
4.4.	Séismes d'origine artificielle.....	27
5.	Magnitude.....	28
6.	Intensités d'un séisme	28
7.	Mesure d'un tremblement de terre selon RICHTER	28
7.1.	Propagation des ondes sismiques	29
	Ondes de volume :	29
	Ondes de surface :	29
8.	Statistique sur les tremblements de terre	30
9.	Méthode de Détection	31
9.1.	Ancienne méthode chinoise.....	31
9.2.	Méthode moderne	31
10.	Méthode de prédiction.....	32
10.1.	Prédiction à long terme (sur plusieurs années)	32
10.2.	Prédiction à moyen terme (sur plusieurs mois).....	33
10.3.	Prédiction à court terme (inférieur à quelques jours) :.....	34
10.3.1.	La magie de L'informatique dans la prédiction de tremblement de terre.....	35
10.3.1.1.	L'utilisation du big data pour prédire les tremblements de terre	36
10.3.1.2.	La machine learning à la rescousse pour donner plus de précision	36
11.	Conclusion.....	38
Chapitre 3 : conception et implémentation		
1.	Introduction	40
2.	Conception	40
2.1.	Conception globale du système	40
2.2.	Conception détaillée du système	41
2.2.1.	L'acquisition des données	41

Table des matières

2.2.2.	L'apprentissage et le test	42
2.2.2.1.	Etape de propagation.....	42
2.2.3.	Phase d'utilisation	43
3.	Implémentation.....	43
3.1.	Environnement du développement	43
3.2.	Bibliothèques et outils utilisées	44
3.2.1.	Tensorflow	44
3.2.2.	Pandas.....	44
3.2.3.	Time	45
3.2.4.	Matplotlib	45
3.3.	Détails de l'implémentation.....	45
3.3.1.	Les entrées.....	45
3.3.2.	L'apprentissage	46
3.3.3.	L'utilisation	47
4.	Conclusion.....	48
	Conclusion Générale	49
	Table de références.....	50

LISTE DES FIGURES

Figure 1: Un Neurone Biologique	5
Figure 2: Le Neurone Artificiel Et Le Neurone Biologique	6
Figure 3: Composition D'un Neurone Artificiel.....	7
Figure 4: Topologie Des Rna.	9
Figure 5: La Fonction Sigmoidé.....	11
Figure 6 : La Fonction Tanh.....	12
Figure 7 : La Fonction Heaviside	12
Figure 8 : Schema De Perceptron Simple	14
Figure 9 : Schema Du Perceptron Multicouche	15
Figure 10 : Schema De Reseau De Neurones Hopfield	16
Figure 11 : Architecture Generale D'un Rna	17
Figure 12: Schema Illustratif De Fonctionnement De Dl Avec Plusieurs Couches.....	20
Figure 13 : Epicentre, Hypocentre (Foyer) Et Faille.....	26
Figure 14 : Les Trois Grands Types De Failles	27
Figure 15: Architecture General Du Systeme De Prediction	41
Figure 16: Organigramme De Retro Propagation	43
Figure 17: Logo De Tensorflow	44
Figure 18: Logo De Pandas	44
Figure 19: Logo Matplotlib	45
Figure 20 : Une Partie De La Dataset	45
Figure 21: Notre Modele De Reseau De Neurone	46
Figure 22: La Partie Responsable Du Calcul De Propagation De Notre Rna	47
Figure 23: Resultat D'apprentissage	47
Figure 24: La Partie Du Programme Qui Affiche La Valeur De La Precision	48
Figure 25: Resultat De L'utilisation Du Systeme	48

LISTE DES TABLEAUX

TABLEAU 1. MODELISATION DU NEURONE FORMEL A PARTIR DU NEURONE BIOLOGIQUE	6
TABLEAU 2. TREMBLEMENTS DE TERRE LES PLUS PUISSANTS ENREGISTRE DEPUIS 1900.....	30
TABLEAU 3. TREMBLEMENTS DE TERRE LES PLUS MEURTRIERS ENREGISTRE DEPUIS 1900	31

Introduction générale

Les tremblements de terre sont une véritable menace pour l'Homme. Quelques 10.000 personnes meurent chaque année dans des tremblements de terre. Plus de 2200 personnes sont mortes et 10 000 blessés dans le séisme de magnitude 6.8 qui a frappé Boumerdes en 2003, Plus de 200 000 morts en Haïti en 2010 après que le pays ait été touché par un tremblement de terre de magnitude 7 sur l'échelle de Richter. Et on estime que plus de 800.000 chinois sont morts dans un tremblement de terre en 1556. Voilà pourquoi disposer d'un moyen de prévoir des tremblements de terre serait extrêmement précieux.

Dans notre travail, nous croyons que l'utilisation de l'un des technique de l'intelligence artificielle qui utilise l'apprentissage automatique comme un processus pour résoudre des problème complexe nous permet de Prédire les tremblements de terre. Dans notre projet de recherche, nous allons utiliser les réseaux de neurones artificiels 'RNA' comme un outil de prédiction de tremblement de terre. Les RNA ont été développés dans les années 80 pour résoudre des problèmes d'ingénierie : estimation, approximation des fonctions, prédiction, élimination d'échos, égalisation des canaux, etc.... Les réseaux de neurones sont des assemblages d'unités de calcul appelés neurones formels, et dont l'inspiration original était le fonctionnement cérébral de l'être humain. Les réseaux de neurones artificiels (RNA) on fait l'objet d'un intérêt soutenu et de nombreux travaux depuis plus d'une vingtaine d'années à cause de leur capacité à résoudre des problèmes non linéaires par apprentissage. Ce sont donc des méthodes numériques qui appartiennent au domaine des méthodes non paramétriques, en ce sens qu'ils ne reposent pas sur un modèle explicite des données [1]. Dans notre travail, nous allons pouvoir observer une utilisation « avancée » ou tout du moins particulière de ce genre de réseaux de neurones : à savoir le Deep Learning. Ce type d'algorithme a largement dépassé tous les critères de référence précédents pour la classification des images, du texte et de la voix. Il fait partie d'une famille de méthodes d'apprentissage automatique fondées sur l'apprentissage de modèles de données. Il alimente également certaines des applications les plus intéressantes au monde, comme les véhicules autonomes et la traduction en temps réel. Le Deep Learning est l'un des algorithmes aujourd'hui très utilisé dans le monde de l'apprentissage automatique. Le présent mémoire est organisé en Trois chapitres dont les thèmes sont donnés ci-dessous : Dans un premier temps, nous définissons la notion du réseau de neurones et ses caractéristiques et nous introduisons ses composants. Nous apportons ensuite ses avantages. Ainsi, nous présentons quelques types de RNA les plus répandus et qui ayant un lien avec notre travail de

recherche. Le deuxième chapitre, nous définissons le tremblement de terre et ses caractéristiques et nous introduisons ses différentes catégories et Nous apportons ensuite les différentes techniques adoptées pour prédire le tremblement de terre. Dans le troisième et dernier chapitre nous présentons l'architecture conceptuelle de notre système de prédiction de tremblement de terre développé. ainsi l'implémentation de notre système de prédiction et l'analyse des résultats obtenus. En conclusion, nous établissons le bilan de notre travail avec des perspectives possibles.

Chapitre 1 :
**Réseaux de neurones/
allez plus loin : Le Deep
Learning**

1. Introduction

Lors de l'émergence d'une nouvelle technique, l'informaticien se demande naturellement en quoi elle peut lui être utile. S'elle est dotée d'un nom plus métaphorique que scientifique, ce qui est évidemment le cas pour les réseaux de neurones.

Dans ce premier chapitre préliminaire, nous définissons la notion du réseau de neurones et ses caractéristiques et nous introduisons ses composants. Nous apportons ensuite ses avantages. Ainsi, nous présentons quelques types de RNAs les plus répandus et qui ayant un lien avec notre travail de recherche.

2. Réseaux de neurones

2.1. Modèle biologique

Un neurone est une cellule nerveuse constituant la base du système nerveux spécialisée dans le traitement des signaux électriques. C'est en 1881 que le terme de neurone fut inséré dans le vocabulaire médical par l'anatomiste allemand Heinrich Wilhelm Waldeyer. En biologie, le cerveau humain contient un grand nombre de neurones fortement interconnectés constituant des réseaux de neurones [1]. Chaque neurone est une entité autonome au sein du cerveau. Un neurone comprend un corps cellulaire ou cellule somatique ou soma, centre de contrôle de celui-ci, qui fait la somme des informations qui lui parviennent. Il traite ensuite l'information et renvoie le résultat sous forme de signaux électriques, du corps cellulaire à l'entrée des autres neurones au travers de son axone. Les axones reliant les neurones entre eux jouent donc un rôle important dans le comportement logique de l'ensemble. Le neurone est également constitué de plusieurs branches nommées dendrites, qui sont les récepteurs principaux du neurone, par lesquelles transite l'information venue de l'extérieur vers le corps cellulaire. Les synapses du neurone quant à eux reçoivent les informations des autres neurones via l'axone et permettent donc aux neurones de communiquer entre eux [1]. En simplifier le neurone biologique dans la figure 1 :




Figure 1: un neurone biologique

Les neurones reçoivent des signaux (impulsions électriques) par les dendrites et envoient l'information par les axones.

Les contacts entre deux neurones (entre axone et dendrite) se font par l'intermédiaire des synapses.

Les signaux n'opèrent pas de manière linéaire : effet de seuil [2].

2.2. Du neurone biologique au neurone formel (artificiel)

Les réseaux de neurones biologiques qui constituent le cerveau humain réalisent simplement de nombreuses applications telles que la reconnaissance de formes, le traitement du signal, la mémorisation, la généralisation, l'apprentissage par l'exemple, etc. Or ces applications sont actuellement à la limite de leurs possibilités actuelles, même en tenant compte de tous les efforts déployés en algorithmique ou en intelligence artificielle. C'est à partir de l'hypothèse que le comportement intelligent humain est le résultat de la structure et des éléments de bases du système nerveux central (que sont les neurones), que l'on a développé les réseaux de neurones artificiels. Cette inspiration à partir du modèle biologique provient du fait que le cerveau humain est un système apprenant basé sur une structure contenant environ 100 milliards de neurones reliés entre eux par 10000 contacts synaptiques ce qui représente un million de milliards de synapses. Les réseaux de neurones artificiels sont donc un moyen de modéliser le mécanisme d'apprentissage et de traitement de l'information qui se produit dans le cerveau humain [1].

On peut résumer la modélisation du neurone formel à partir du neurone biologique à l'aide du tableau suivant :

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

Neurone biologique	Neurone formel
Axones	Signal de sortie
Dendrites	Signal d'entrée
Synapses	Poids de la connexion

Tableau 1. Modélisation du neurone formel à partir du neurone biologique

Comme on peut aussi résumer la modélisation du neurone formel à partir du neurone biologique à l'aide de la figure ci-dessous :




Figure 2: Le neurone artificiel et le neurone biologique

2.3.Neurone artificiel

Chaque neurone faisant partie du réseau est une machine élémentaire. Il reçoit un certain nombre de variables d'entrées provenant de neurones en amont. À chacune de ces entrées, est associé un poids qui représente la force de la connexion entre les deux neurones. Chaque neurone est doté d'une unique sortie qui se ramifie ensuite pour représenter les entrées qui alimenteront d'autres neurones en aval. Pour résumer, chaque neurone calcule une sortie unique en se basant sur les informations qui lui sont données [1].

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

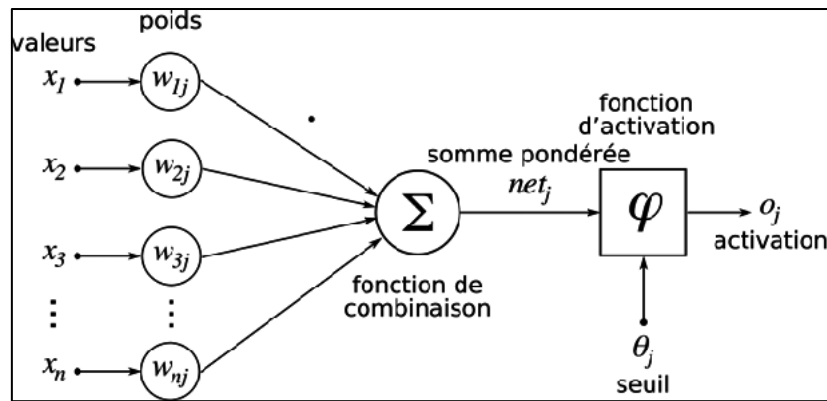


Figure 3: composition d'un neurone artificiel

Le neurone en tant qu'unité élémentaire agit de la façon suivante :

1ère phase : Le neurone fait le calcul de la somme pondérée des entrées (en fonction de la force des connexions). L'apprentissage ayant été réalisé auparavant, le poids des connexions est ici déjà déterminé et fixe.

2° phase : À partir de la valeur obtenue, une fonction d'activation ou de transfert va calculer la valeur de l'état du neurone. Le neurone compare la somme pondérée des entrées à une valeur de seuil et fournit alors une réponse en sortie.

La majorité des fonctions sont continues et offrent donc une infinité de valeurs possibles comprises dans les intervalles $[0;+1]$ ou $[-1;+1]$. Il existe différents types de fonctions de transfert pour le neurone artificiel [1]:

2.3.1. Historique

Le champ des réseaux neuronaux va démarrer par la présentation en 1943 par W.MCCulloch et W. Pitts du neurone formel qui est une abstraction du neurone physiologique. Le retentissement va être énorme. Par cette présentation, ils veulent démontrer que le cerveau est équivalent à une machine de Turing, la pensée devient alors purement des mécanismes matériels et logiques. Il déclara en 1955 "Plus nous apprenons de choses au sujet des organismes, plus nous sommes amenés à conclure qu'ils ne sont pas simplement analogues aux machines, mais qu'ils sont machine. La démonstration de McCulloch et Pitts sera un des facteurs importants de la création de la cybernétique.

En 1949, D. Hebb présente dans son ouvrage "The Organization of Behavior" une règle d'apprentissage. De nombreux modèles de réseaux aujourd'hui s'inspirent encore de la règle de Hebb.

En 1958, F. Rosenblatt développe le modèle du Perceptron. C'est un réseau de neurones inspiré du système visuel. Il possède deux couches de neurones : une couche de perception et une couche liée à la prise de décision. C'est le premier système artificiel capable d'apprendre par

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

expérience. Dans la même période, Le modèle de L'Adaline (ADaptive LINar Element) a été présenté par B. Widrow, chercheur américain à Stanford. Ce modèle sera par la suite le modèle de base des réseaux multi-couches.

En 1969, M. Minsky et S. Papert publient une critique des propriétés du Perceptron. Cela va avoir une grande incidence sur la recherche dans ce domaine. Elle va fortement diminuer jusqu'en 1972, où T. Kohonen présente ses travaux sur les mémoires associatives et propose des applications à la reconnaissance de formes.

C'est en 1982 que J. Hopfield présente son étude d'un réseau complètement rebouclé, dont il analyse la dynamique.

Aujourd'hui, les réseaux neuronaux sont utilisés dans de nombreux domaines (entre autres, vie artificielle et intelligence artificielle) à cause de leur propriété en particulier, leur capacité d'apprentissage, et qu'ils soient des systèmes dynamiques [3].

2.3.2. Définition

Un réseau de neurones artificiels, est un système dont la conception est à l'origine schématiquement inspirée du fonctionnement des neurones biologiques, et qui par la suite s'est rapproché des méthodes statistiques [4]. Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire (neurone artificiel) calcule une sortie unique sur la base des informations qu'il reçoit.

2.3.3. Topologie

Les neurones d'un réseau de neurone artificiel sont connectés entre eux de diverses manières. De la figure. 4 on peut distinguer deux familles de réseaux de neurones : non bouclés ou statiques (a) et (b) et bouclés (dynamiques) (c) et (d).

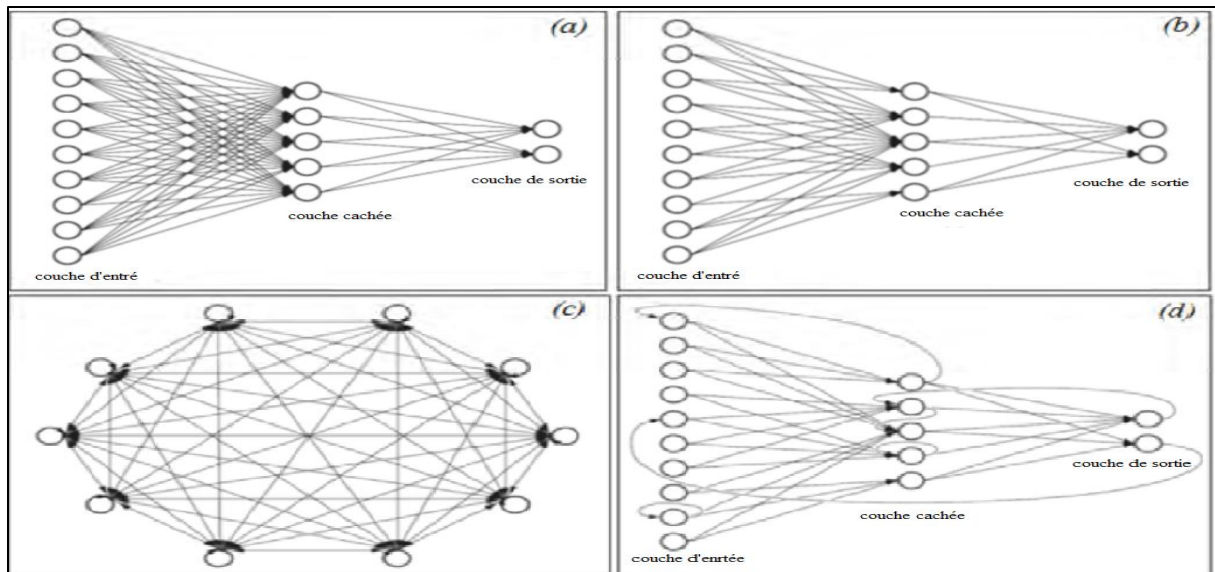


Figure 4: topologie des RNA.

(a) Réseaux multicouches à connexions Totales, (b) à connexions locales, (c) réseau à connexions complexes et (d) réseau multicouche à connexions récurrentes [1].

2.3.3.1. Réseaux de neurones statiques

L'exemple le plus simple de réseau de neurones statique est donné par le perceptron multicouche chaque couche contenant un ou plusieurs neurones. Afin d'illustrer ces propos, voici le rôle de chacune des couches dans un perceptron à trois couches. La première couche est appelée couche d'entrée. Elle recevra les données source que l'on veut utiliser pour l'analyse. Sa taille est donc directement déterminée par le nombre de variables d'entrées.

La deuxième couche est la couche cachée. Dans cette couche, les fonctions d'activation sont en général non linéaires. Le choix de sa taille (nombre de neurones) n'est pas automatique et doit être ajusté. Il sera souvent préférable pour obtenir la taille optimale, d'essayer le plus de tailles possibles.

La troisième couche est appelée couche de sortie. Elle donne le résultat obtenu après compilation par le réseau des données entrée dans la première couche. Sa taille est directement déterminée par le nombre de variables dont on a besoin en sortie. C'est le réseau statique non bouclé qu'on va utiliser dans cette étude, car les paramètres recherchés dans le présent projet de recherche sont indépendants du temps [5].

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

2.3.3.2. Réseaux de neurones dynamiques ou réseaux bouclés

L'architecture la plus générale, pour un réseau de neurones, est celle des « réseaux bouclés », dont le graphe des connexions est cyclique : lorsque l'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ un tel chemin est désigné sous le terme de « cycle ». La sortie d'un neurone du réseau peut donc être fonction d'elle-même ; ceci n'est évidemment concevable que si la notion de temps est explicitement prise en considération [5].

2.3.4. Fonction

2.3.4.1. Fonction de combinaison

Considérons un neurone quelconque. Il reçoit des neurones en amont un certain nombre de valeurs via ses connexions synaptiques, et il produit une certaine valeur en utilisant une fonction de combinaison. Cette fonction peut donc être formalisée comme étant une fonction vecteur-à-scalaire, notamment :

Les réseaux de type MLP (MultiLayer Perceptron) calculent une combinaison linéaire des entrées, c'est-à-dire que la fonction de combinaison renvoie le produit scalaire entre le vecteur des entrées et le vecteur des poids synaptiques.

Les réseaux de type RBF (Radial Basis Function) calculent la distance entre les entrées, c'est-à-dire que la fonction de combinaison renvoie la norme euclidienne du vecteur issu de la différence vectorielle entre les vecteurs d'entrées [4].

2.3.4.2. Fonction d'activation

La fonction d'activation (ou fonction de seuillage, ou encore fonction de transfert) sert à introduire une non-linéarité dans le fonctionnement du neurone.

Les fonctions de seuillage présentent généralement trois intervalles :

En dessous du seuil, le neurone est non-actif (souvent dans ce cas, sa sortie vaut 0 ou -1) ;

Aux alentours du seuil, une phase de transition ;

Au-dessus du seuil, le neurone est actif (souvent dans ce cas, sa sortie vaut 1).

Des exemples classiques de fonctions d'activation sont [4]:

➤ La fonction sigmoïde

La fonction sigmoïde (aussi appelée fonction logistique ou fonction en S) est définie par :

$$f_{sig}(x) = \frac{1}{1 + e^{-x}}$$

Elle possède plusieurs propriétés qui la rendent intéressante comme fonction d'activation.

Elle n'est pas polynômiale

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

Elle est indéfiniment continûment dérivable et une propriété simple permet d'accélérer le calcul de sa dérivée. Ceci réduit le temps calcul nécessaire à l'apprentissage d'un réseau de neurones.

On a en effet

$$\frac{d}{dx} f_{sig}(x) = f_{sig}(x) (1 - f_{sig}(x)).$$

On peut donc calculer la dérivée de cette fonction en un point de façon très efficace à partir de sa valeur en ce point.

Voici une figure qui représente un graphe de la fonction sigmoïde




Figure 5: La fonction sigmoïde

Comme vous pouvez le voir dans la Figure qui précède la fonction sigmoïde renvoie des valeurs dans l'intervalle $[0;1]$, ce qui permet d'interpréter la sortie du neurone comme une probabilité. Elle est aussi liée au modèle de régression logistique et apparaît naturellement quand on considère le problème de la séparation optimale de deux classes de distributions gaussiennes avec la même matrice de covariance [4].

➤ La fonction tangente hyperbolique

La fonction tangente hyperbolique, définie par

$$\mathbf{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Est aussi très utilisée en pratique, car elle partage avec la fonction sigmoïde certaines caractéristiques pratiques :

- Non polynomiale
- Indéfiniment continûment dérivable

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

- Calcul rapide de la dérivée par la formule

$$\frac{d}{dx} \tanh(x) = 1 - (\tanh(x))^2$$

On ne peut pas cependant lui donner une interprétation probabiliste aussi claire [4].

Voici une figure qui représente un graphe de la fonction tanh




Figure 6 : La fonction tanh

- La fonction de Heaviside

la fonction de Heaviside est la fonction indicatrice de \mathbb{R}^+ .

C'est donc la fonction H (discontinue en 0) prenant la valeur 1 pour tous les réels positifs et la valeur 0 pour les réels strictement négatifs [4]:

$$\forall x \in \mathbb{R}, H(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0. \end{cases}$$

Voici une figure qui représente un graphe de la fonction heaviside



Figure 7 : La fonction heaviside

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

Propagation de l'information :

Ce calcul effectué, le neurone propage son nouvel état interne sur son axone. Dans un modèle simple, la fonction neuronale est simplement une fonction de seuillage : elle vaut 1 si la somme pondérée dépasse un certain seuil ; 0 sinon. Dans un modèle plus riche, le neurone fonctionne avec des nombres réels (souvent compris dans l'intervalle $[0,1]$ ou $[-1,1]$). On dit que le réseau de neurones passe d'un état à un autre lorsque tous ses neurones recalculent en parallèle leur état interne, en fonction de leurs entrées [4].

2.3.5. Type de réseau de neurone

2.3.5.1. Perceptron

Le perceptron peut être vu comme le type de réseau de neurones le plus simple. Le Perceptron simple est caractérisé par :

- ❖ Il est constitué d'un unique neurone qui répond à l'équation proposée plus haut.
- ❖ La fonction de transfert est une fonction de seuil ou toute autre fonction du même type.
- ❖ La différence avec le modèle de neurone formel est que le neurone peut « apprendre » en utilisant les règles de Hebb/Rosenblatt [6].

Les travaux de McCulloch et Pitts n'ont pas donné d'indication sur une méthode pour adapter les coefficients synaptiques. Cette question au cœur des réflexions sur l'apprentissage a connu un début de réponse grâce aux travaux du physiologiste canadien Donald Hebb sur l'apprentissage en 1949 . Hebb a proposé une règle simple qui permet de modifier la valeur des coefficients synaptiques en fonction de l'activité des unités qu'ils relient. « règle de Hebb ».

À partir de cet article, l'idée germa dans l'esprit de Frank Rosenblatt en 1957 avec le modèle du perceptron. C'est le premier système artificiel capable d'apprendre par expérience, y compris lorsque son instructeur commet quelques erreurs.

En 1969, Marvin Lee Minsky et Seymour Papert publièrent un ouvrage mettant en exergue quelques limitations théoriques du perceptron, et plus généralement des classifieurs linéaires, Paraissant alors dans une impasse, la recherche sur les réseaux de neurones perdit une grande partie de ses financements publics. Cependant, les solides qualités de certains réseaux de neurones en Voimatière adaptative (e.g. Adaline), leur permettant de modéliser de façon évolutive des phénomènes eux-mêmes évolutifs, utilisés dans le domaine des télécommunications ou celui du contrôle de processus industriels [4].

En 1982, John Joseph Hopfield, physicien reconnu, donna un nouveau souffle au neuronal en publiant un article introduisant un nouveau modèle de réseau de neurones (complètement récurrent). Cet article eut du succès pour plusieurs raisons, dont la principale était de teinter la théorie des réseaux de neurones de la rigueur propre aux physiciens. Le neuronal redevient un

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

sujet d'étude acceptable, bien que le modèle de Hopfield souffrît des principales limitations des modèles des années 1960, notamment l'impossibilité de traiter les problèmes non linéaire [4].

Voici une figure qui montre le schéma du perceptron




Figure 8 : Schéma de perceptron simple

2.3.5.2. Perceptron multicouche

Le problème du Perceptron simple sont ses limitations que nous allons essayer de dépasser avec le Perceptron multicouche.

Le perceptron multicouche (multilayer perceptron MLP) est un type réseau neuronal formel organisé en plusieurs couches au sein desquelles une information circule de la couche d'entrée vers la couche de sortie uniquement ; il s'agit donc d'un réseau à propagation directe (feedforward). Chaque couche est constituée d'un nombre variable de neurones, les neurones de la dernière couche (dite « de sortie ») étant les sorties du système global [4].

Le Perceptron multicouche se caractérise par :

- ❖ Il est basé sur le modèle du Perceptron
- ❖ Il a plusieurs couches de neurones liées entre elles
- ❖ Chaque couche a un ou plusieurs neurones

Le Perceptron simple ne pouvait classifier que des données séparées par un hyperplan. Le perceptron multi couche va passer à des données plus complexes séparables par des hyper-surfaces.

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

Il va donc travailler avec une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées. En pratique un réseau 3 couches suffit presque toujours. Le théorème de Cybenko assure en effet que :

N'importe quelle fonction peut être approximée avec une précision quelconque à l'aide d'un réseau 3 couches.

Les mathématiques du Perceptron multicouche sont similaires à celles du Perceptron. La phase d'entraînement également.

On présente donc un essai à la couche d'entrée et on calcule les sorties de chaque neurone jusqu'à la couche de sortie en utilisant la formule suivante :

$$S = b + w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n = b + \sum_{i=1}^n w_i \cdot x_i$$

Dans laquelle b représente un biais. Il est parfois pratique de considérer le biais comme une entrée dont la valeur vaut toujours 1 affectée du poids b .

On dispose d'une série d'entrées $x_1 \dots x_2$, chacune associées à un poids $w_1 \dots w_2$. Les entrées sont l'équivalent des dendrites. On calcule la somme S [6].

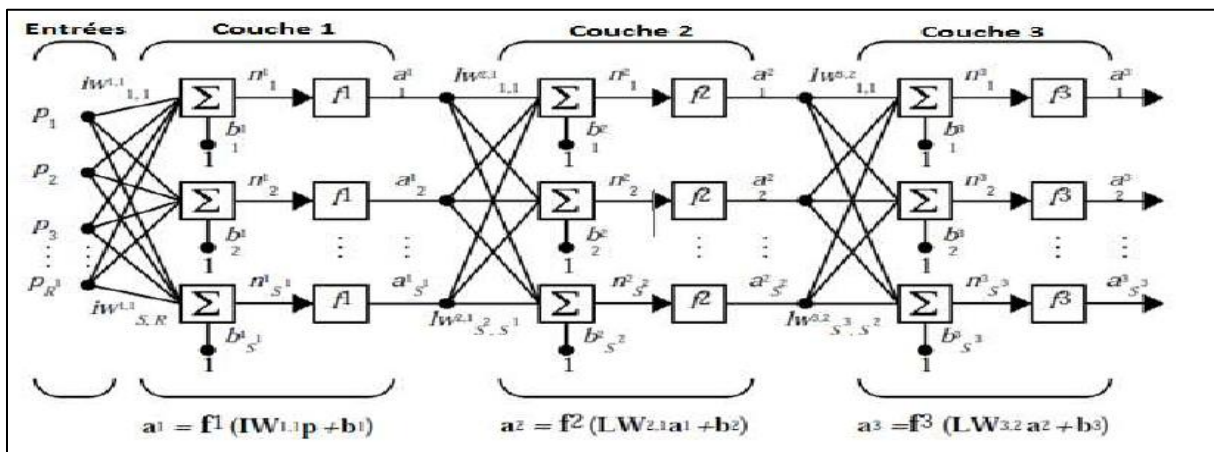


Figure 9 : schéma du Perceptron Multicouche

2.3.5.3. Réseau de neurones hopfield

Le réseau de neurones d'Hopfield est un modèle de réseau de neurones récurrents à temps discret dont la matrice des connexions est symétrique et nulle sur la diagonale et où la dynamique est asynchrone (un seul neurone est mis à jour à chaque unité de temps). Il a été découvert par le physicien John Hopfield en 1982. Sa découverte a permis de relancer l'intérêt dans les réseaux de neurones qui s'était essoufflé durant les années 1970 à la suite d'un article de Marvin Minsky et Seymour Papert.

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

Un réseau de Hopfield est une mémoire adressable par son contenu : une forme mémorisée est retrouvée par une stabilisation du réseau, s'il a été stimulé par une partie adéquate de cette forme.

Ce modèle de réseau est constitué de N neurones à états binaires (-1, 1 ou 0, 1 suivant les versions) tous interconnectés. L'entrée totale d'un neurone i est donc :

$$I_i = \sum_j w_{ij} V_j$$

où :

- W_{ij} est le poids de la connexion du neurone i à j
- V_j est l'état du neurone j

L'état du réseau peut être caractérisé par un mot de N bits correspondant à l'état de chaque neurone [4].

Voici une figure qui montre un schéma de réseau de neurones hopfield




Figure 10 : Schéma de réseau de neurones hopfield

2.3.5.4. Réseau de neurones RBF

Les réseaux à fonctions de base radiales (RBF) sont des modèles connexionnistes simples à mettre en œuvre et assez intelligibles, et sont très utilisés pour la régression et la discrimination. Leur propriétés théoriques et pratiques ont été étudiées en détail depuis la fin des années 80 ; il s'agit certainement, avec le Perceptron multicouche, du modèle connexionniste le mieux connu.

Une fonction de base radiale (RBF) est une fonction ϕ symétrique autour d'un centre μ_j : $\phi_j(x) = \phi(kx - \mu_j k)$, où k est une norme [BUH 03]. Par exemple, la fonction gaussienne est une RBF avec la norme euclidienne et $\phi(r) = e^{-r^2/2\sigma^2}$. En général, les RBF sont paramétrées par σ qui correspond à la « largeur » de la fonction [7]:

$$\phi_j(x) = \phi(\|x - \mu_j\|, \sigma_j)$$

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

Un modèle ou réseau RBF calcule une combinaison linéaire de fonctions radiales de centres μ_j :

$$y(x) = \sum_{j=1}^N w_j \varphi(\|x - \mu_j\|, \sigma_j)$$




Figure 11 : Architecture générale d'un RNA

2.3.6. Type d'apprentissage

L'objectif de la phase d'apprentissage des RNA est de trouver, parmi toutes les fonctions paramétrées par les poids synaptiques, celle qui s'approche le plus possible de l'optimum.

L'apprentissage consiste, donc à minimiser une fonction de coût à l'aide des algorithmes d'optimisation [5]. Il existe trois types d'apprentissage :

L'apprentissage supervisé : Le superviseur, ou professeur, fournit au réseau des couples d'entrée-sortie. Il fait apprendre au réseau l'ensemble de ces couples, par une méthode d'apprentissage, comme la Rétropropagation du gradient de l'erreur [4] en comparant pour chacun d'entre eux la sortie effective du réseau et la sortie désirée. L'apprentissage est terminé lorsque tous les couples entrée-sortie sont reconnus par le réseau. Ce type d'apprentissage se retrouve également dans le perceptron [5].

L'apprentissage non-supervisé : Cet apprentissage consiste à détecter automatiquement des régularités qui figurent dans les exemples présentés et à modifier les poids des connexions pour que les exemples ayant les mêmes caractéristiques de régularité provoquent la même sortie. Les réseaux auto-organiseurs de Kohonen et réseaux de neurone Hopfield sont parmi les réseaux à apprentissage non supervisé les plus connus [4].

L'apprentissage par renforcement : L'apprentissage par renforcement fait référence à une classe de problèmes d'apprentissage automatique, dont le but est d'apprendre, à partir d'expériences, ce qu'il convient de faire en différentes situations, de façon à optimiser une récompense quantitative au cours du temps. Un paradigme classique pour présenter les problèmes d'apprentissage par renforcement consiste à considérer un agent autonome, plongé au sein d'un environnement, et qui doit prendre des décisions en fonction de son état courant. En retour, l'environnement procure à l'agent une récompense, qui peut être positive ou négative.

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

L'agent cherche, au travers d'expériences itérées, un comportement décisionnel (appelé stratégie ou politique, et qui est une fonction associant à l'état courant l'action à exécuter) optimal, en ce sens qu'il maximise la somme des récompenses au cours du temps [4].

3. Machine Learning

Le terme de Machine Learning ML (apprentissage automatique) décrit un processus de fonctionnement d'un système d'intelligence artificielle par lequel le système est doté d'un système d'apprentissage. Il concerne la conception, l'analyse, le développement et l'implémentation de méthodes permettant à une machine (au sens large) d'évoluer par un processus systématique, et ainsi de remplir des tâches difficiles ou problématiques par des moyens algorithmiques plus classiques [4]. Dans de nombreux domaines l'effet d'apprentissage est obtenu par une proposition d'évaluation humaine portant sur le « travail » de l'intelligence artificielle on parle alors d'apprentissage supervisé [8].

4. Deep Learning

4.1. Définition de Deep Learning

Maintenant que nous venons de voir le concept de réseaux de neurones, nous allons pouvoir observer une utilisation « avancée » ou tout du moins particulière de ce genre de réseaux de neurones : à savoir le Deep Learning (DL).

Le Deep Learning ou l'apprentissage profond est une forme d'intelligence artificielle, dérivée du Machine Learning. C'est un ensemble de méthodes d'apprentissage automatique tentant de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires, Ces techniques ont permis des progrès importants et rapides dans les domaines de l'analyse du signal sonore ou visuel et notamment de la reconnaissance faciale, de la reconnaissance vocale, de la vision par ordinateur, du traitement automatisé du langage [9].

4.2. Historique

L'idée du Deep Learning n'est pas une idée récente mais elle date en réalité des années 1980, plus particulièrement suite aux travaux de réseaux de neurones multi-couches et aux travaux de certains pionniers du machine learning et du Deep learning comme le français Yann Le Cun. En collaboration avec deux autres informaticiens, Kunihiko Fukushima et Geoffrey Hinton, ils mettent au point un type d'algorithme particulier appelé Convolutional neural network.

Bien que cette approche donne des résultats, ses progrès et son évolution sont limités par les progrès technologiques en matière de micro-processeurs, de puissance de calculs, et du manque d'accessibilités à des données afin de pouvoir entraîner les neurones. Cependant certains

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

chercheurs ont continué à travailler sur ce modèle pendant environ deux décennies et, avec l'aide des évolutions en matière de technologies mais surtout avec la disponibilité toujours plus grande de données, ont pu améliorer cette technique.

Afin de développer un système d'apprentissage performant, il faut pouvoir l'exercer et cela requiert un nombre important de donnée à tester. C'est dans ce contexte qu'en 2007 le STANFORD VISION LAB, avec Fei-Fei Li à sa tête, développent un agrégateur d'images où sont consignés et étiquetés quelques millions de photos : ImageNet. En 2010, ImageNet regroupe 15 000 000 d'images toutes catégorisés en fonction de leurs caractéristiques propres (véhicules, animaux, ...) [10].

En 2012, le Deep Learning est remis au goût du jour avec un succès retentissant au ImageNet Large Scale Visual Recognition Challenge (ILSVRC) qui est un concours annuel de reconnaissance d'image fondé par l'université de Stanford, dans le cadre de son laboratoire STANFORD VISION LAB [10]. Plusieurs équipes de chercheurs en informatique s'affrontent dans ce concours tous les ans afin de décerner la victoire au programme ayant eu le plus faible taux d'échec. Et alors que les algorithmes d'apprentissage profond sont absents de la compétition, en 2012 c'est bel et bien un algorithme de Deep Learning qui va remporter l'édition 2012 à la surprise générale [1].

4.3.Fonctionnement de Deep Learning

La plupart des méthodes de Deep Learning utilisent des architectures de réseaux de neurones, le terme « profond » se rapporte généralement au nombre de couches cachées du réseau de neurones. Les réseaux de neurones classiques ne comportent que 2 à 3 couches cachées, tandis que les réseaux profonds peuvent en compter jusqu'à 150. L'entraînement des modèles s'effectue à l'aide de vastes ensembles de données labellisées et d'architectures de réseaux de neurones qui apprennent des caractéristiques directement depuis les données, sans avoir à effectuer une extraction manuelle [11].

La figure 12 montre un schéma illustratif de fonctionnement de DL avec plusieurs couches.




Figure 12: Schéma illustratif de fonctionnement de DL avec plusieurs couches

4.4.Méthode d'utilisation du deep learning

Voici les trois méthodes d'utilisation du Deep Learning les plus répandues pour la classification d'objets :

L'entraînement à partir de zéro

Pour entraîner un réseau profond à partir de zéro, vous devez réunir un volume de données labellisées très important et concevoir une architecture de réseau qui apprendra les caractéristiques et le modèle. C'est une méthode adaptée aux nouvelles applications, ou à celles qui obtiendront de nombreuses catégories de résultats. Ce n'est pas une approche très répandue car, en raison du grand volume de données et du rythme d'apprentissage, l'entraînement des réseaux peut facilement s'étaler sur plusieurs jours, voire sur plusieurs semaines.

Transfer Learning « Apprentissage par transfert »

La plupart des applications de Deep Learning utilisent la méthode d'apprentissage par transfert qui consiste à mettre au point un modèle pré-entraîné. Le processus commence avec un réseau existant, tel qu'AlexNet ou GoogLeNet, qu'il faut enrichir avec de nouvelles données contenant des classes auparavant inconnues du réseau. Une fois quelques ajustements effectués au réseau, vous pouvez effectuer une nouvelle tâche, telle que la catégorisation de chiens ou de chats uniquement, plutôt que de 1 000 objets différents. Cette technique présente également l'avantage de nécessiter un volume de données beaucoup plus faible (il faut traiter des milliers d'images, plutôt que des millions), faisant du calcul une affaire d'heures ou de minutes.

Extraction de caractéristiques

Une approche de Deep Learning moins fréquente et plus spécialisée consiste à utiliser le réseau en tant qu'extracteur de caractéristiques. Puisque toutes les couches sont chargées

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

d'apprendre certaines caractéristiques à partir d'images, nous pouvons récupérer ces caractéristiques depuis le réseau à n'importe quel moment du processus d'entraînement. Il est ensuite possible d'utiliser ces caractéristiques en tant que données d'entrée pour un modèle de Machine Learning tel que des machines à vecteurs de support [11].

4.5. Domaine d'application

Des applications de Deep Learning sont utilisées dans divers secteurs, de la conduite automatisée aux dispositifs médicaux.

- ❖ Conduite automatisée : Les chercheurs du secteur automobile ont recours au Deep Learning pour détecter automatiquement des objets tels que les panneaux stop et les feux de circulation. Le Deep Learning est également utilisé pour détecter les piétons [11], comme en trouve dans la Golf 7 ou la nouvelle polo l'argus et dans pas mal de voiture comme la volvo S60 qu'est la première voiture qui a disposé d'un détecteur de piétons évitant ainsi nombre d'accidents. Et le deep learning promis aussi des bons résultats prochainement comme la première voiture "intelligente" aura des capacités limitées. L'Audi A8 qui vient d'être présentée met en œuvre des mécanismes de deep learning et une puissance de 750 giga-flops "comparable à celle d'un avion de ligne, en incluant les systèmes de secours" précise Rubert Stadler, qui dirige la marque. Encore plus impressionnant ? La flotte de Volvo XC90 déployés dans le cadre du projet Drive Me en Suède, et équipés de l'architecture Nvidia Drive PX2. Aussi performant que 150 MacBook Pro d'Apple, et avec une puissance de 24 000 giga-flops annoncés pour le deep learning, ce système reste encore réservé aux prototypes du fait d'un coût unitaire de 15 000 \$ [12].
- ❖ Le système de reconnaissance faciale : Dévoilé au mois de juin 2014, DeepFace de Facebook se révèle très impressionnant. Le réseau social, qui possède la plus importante galerie photo en ligne du monde (250 milliards de photos !), a développé un réseau de neurones capable de reconnaître le visage d'une personne sur une photo avec un taux de réussite de 97,25 %, qu'elle soit de profil ou que les conditions d'éclairage soient trop sombres ou trop lumineuses [13].
- ❖ La traduction en temps réel : La firme de Redmond a développé l'une des applications basées sur le deep learning et le machine learning les plus impressionnantes. Lancée en version preview au mois de décembre 2014, Skype Translator est un système de traduction à la volée de conversations. L'application traduit les appels audio et vidéo quasiment en temps réel dans six langues : anglais, espagnol, français, allemand, italien, et mandarin. Pour les messages écrits, Skype Translator prend en charge 50 langues. Pour l'heure, le système ne fonctionne pas sur les terminaux mobiles, mais uniquement sur PC. Les premiers

Chapitre 1 : Réseaux de neurones/ Allez plus loin : le Deep Learning

utilisateurs ne tarissent pas d'éloges à son propos sur les réseaux sociaux. Très simple d'utilisation, il suffit d'installer la nouvelle version de Skype disponible sur le Windows Store, choisir la langue de l'autre personne, sélectionner le mode de traduction automatique et le tour est joué [13].

- ❖ Recherche médicale : À l'aide du Deep Learning, les chercheurs en cancérologie peuvent dépister automatiquement les cellules cancéreuses. Des équipes de l'Université de Californie à Los Angeles (UCLA) ont conçu un microscope qui génère un ensemble de données de grande dimension afin d'entraîner une application de Deep Learning à identifier avec précision des cellules cancéreuses. Grâce au deep learning, DreamQuark est une start-up française qui exploite cette technologie pour proposer des applications dans le domaine de la santé. Elle a développé notamment un outil permettant aux ophtalmologistes de prévenir les risques de rétinopathie chez leurs patients diabétiques. Cette maladie qui est la première cause de cécité chez les diabétiques peut être évitée si elle est détectée à temps. Grâce aux technologies du deep learning, la start-up a développé un programme pour les médecins capables de détecter les cellules défaillantes sur des photographies en haute définition de rétines. Les débuts de l'intelligence artificielle dans la médecine sont particulièrement prometteurs [13].

4.6. Les avantages de Deep Learning

Le Deep Learning nous offre plusieurs avantages que les autres méthodes, parmi ces avantages on trouve les avantages suivants qui nous facilite notre projet de recherche :

- ❖ Capacité de représenter n'importe quelle fonction, linéaire ou pas, simple ou complexe.
- ❖ Faculté d'apprentissage à partir d'exemples représentatifs, par "rétropropagation des erreurs". L'apprentissage (ou construction du modèle) est automatique.
- ❖ Résistance au bruit ou au manque de fiabilité des données.
- ❖ Simple à manier, beaucoup moins de travail personnel à fournir que dans l'analyse statistique classique. Aucune compétence en mathématiques, informatique statistique requise. Comportement moins mauvais en cas de faible quantité de données.
- ❖ Pour l'utilisateur novice, l'idée d'apprentissage est plus simple à comprendre que les complexités des statistiques multi-variables.

5. Conclusion

Ce chapitre nous a montré que les réseaux de neurones artificiels sont inspirés du comportement du cerveau humain. Ils permettent d'envisager des applications dans presque tous les domaines y compris dans le domaine de la classification et que les réseaux de neurones ont une histoire relativement jeune (environ 50 ans) et les applications intéressantes des réseaux de neurones n'ont vu le jour que depuis une vingtaine d'année (développement de l'informatique), et ils ont un futur très prometteur.

Chapitre 2 :

Les tremblements de terre

Chapitre 2 : Les tremblements de terre

1. Introduction

Le tremblement de terre est à ce jour la catastrophe naturelle la plus meurtrière. Ce phénomène entraîne des conséquences inimaginables d'un point de vue humain, environnemental et économique. Imprévisibles et dévastateurs, les séismes et leurs effets secondaires (comme les tsunamis), font chaque décennie de nombreuses victimes. Ainsi, près de 850 000 personnes ont trouvé la mort durant ces terribles et impitoyables phénomènes.

Nous avons donc choisi d'étudier ce sujet pour de nombreuses raisons : bien que nous vivions dans une zone faiblement menacée par les séismes, nous avons tout de même été énormément touchés par les dernières catastrophes.

Ceci nous a fait réfléchir sur comment prévenir les humains et prédire les tremblements de terres, éviter les accidents corporels et protéger les édifices contre les risques sismiques dans le monde ? [14].

Pour répondre à cette problématique, nous définirons, en premier lieu, qu'est-ce qu'un séisme et son fonctionnement et ces caractéristiques ainsi un petit historique de c'est dégâts. Nous étudierons, par la suite, l'intensité d'un séisme et comment mesuré sa puissance et la propagation des ondes sismique. Et pour finir, nous évoquerons les différents moyens de prédiction contre ce fléau [14].

2. Définition du tremblement de terre

Un séisme ou tremblement de terre se traduit en surface par des vibrations du sol. Il provient de la fracturation des roches en profondeur; celle-ci est due à l'accumulation d'une grande énergie qui se libère, créant des failles, au moment où le seuil de rupture mécanique des roches est atteint. Les dégâts observés en surface sont fonction de l'amplitude, la fréquence et la durée des vibrations. On distingue les séismes : d'origine tectonique, les plus dévastateurs (secousses, raz-de-marée...), d'origine volcanique et d'origine humaine (remplissage de retenues de barrages, exploitation des sous-sols, explosions dans les carrières...) [15].

3. Caractéristiques principales

Le point d'origine d'un séisme est appelé hypocentre ou foyer sismique. Il peut se trouver entre la surface et jusqu'à sept cents kilomètres de profondeur (limite du manteau supérieur) pour les événements les plus profonds. On parle de l'épicentre du séisme pour désigner le point de la surface de la terre qui se trouve directement au-dessus de l'hypocentre [16].




Figure 13 : Épicentre, hypocentre (foyer) et faille

4. Catégorie de tremblement de terre

Un tremblement de terre est une secousse plus ou moins violente du sol qui peut avoir quatre origines : rupture d'une faille ou d'un segment de faille (séismes tectoniques) ; intrusion et dégazage d'un magma (séismes volcaniques) ; « craquements » des calottes glaciaires se répercutant dans la croûte terrestre ; explosion, effondrement d'une cavité (séismes d'origine naturelle ou dus à l'activité humaine). En pratique on classe les séismes en quatre catégories selon les phénomènes qui les ont engendrés [4] :

4.1. Séismes tectoniques

Les séismes tectoniques sont de loin les plus fréquents et dévastateurs. Une grande partie des séismes tectoniques a lieu aux limites des plaques, où se produit un glissement entre deux milieux rocheux. Une autre partie a lieu sur le long d'un plan de fragilité existant ou néoformé. Ce glissement, localisé sur une ou plusieurs failles, est bloqué durant les périodes intersismiques (entre les séismes) de déplacement asismique des deux blocs séparés par la zone de rupture potentielle (la faille est alors inactive), et l'énergie s'accumule par la déformation élastique des roches⁵. Cette énergie et le glissement sont brusquement relâchés lors des séismes⁶. Dans les zones de subduction, les séismes représentent en nombre la moitié de ceux qui sont destructeurs sur la Terre, et dissipent 75 % de l'énergie sismique de la planète. C'est le seul endroit où on trouve des séismes profonds (de 300 à 645 kilomètres). Au niveau des dorsales médio-océaniques, les séismes ont des foyers superficiels (0 à 10 kilomètres), et correspondent à 5 % de l'énergie sismique totale. De même, au niveau des grandes failles de décrochement, ont lieu des séismes ayant des foyers de profondeur intermédiaire (de 0 à 20 kilomètres en moyenne) qui correspondent à 15 % de l'énergie. Le relâchement de l'énergie accumulée ne se fait généralement pas en une seule secousse, et il peut se produire plusieurs réajustements avant de retrouver une configuration stable. Ainsi, on constate des répliques à la suite de la secousse principale d'un séisme, d'amplitude décroissante, et sur une durée allant de

Chapitre 2 : Les tremblements de terre

quelques minutes à plus d'un an. Ces secousses secondaires sont parfois plus dévastatrices que la secousse principale, car elles peuvent faire s'écrouler des bâtiments qui n'avaient été qu'endommagés, alors que les secours sont à l'œuvre. Il peut aussi se produire une réplique plus puissante encore que la secousse principale quelle que soit sa magnitude. Par exemple, un séisme de 9,0 peut être suivi d'une réplique de 9,3 plusieurs mois plus tard même si cet enchaînement reste extrêmement rare [4].




Figure 14 : Les trois grands types de failles

4.2. Séismes d'origine volcanique

Les séismes d'origine volcanique résultent de l'accumulation de magma dans la chambre magmatique d'un volcan. Les sismographes enregistrent alors une multitude de microséismes (trémor) dus à des ruptures dans les roches comprimées ou au dégazage du magma. La remontée progressive des hypocentres (liée à la remontée du magma) est un indice prouvant que le volcan est en phase de réveil et qu'une éruption est imminente [4].

4.3. Séismes d'origine polaire

Les glaciers et la couche de glace présentent une certaine élasticité, mais les avancées différenciées et périodiques (rythme saisonnier marqué) de coulées de glace provoquent des cassures dont les ondes élastiques génèrent des tremblements de terre, enregistrés par des sismographes loin du pôle à travers le monde. Ces « tremblements de terre glaciaires » du Groenland sont caractérisés par une forte saisonnalité. Une étude publiée en 2006 a conclu que le nombre de ces séismes avait doublé de 2000 à 2005, tendance temporelle suggérant un lien avec une modification du cycle hydrologique et une réponse glaciaire à l'évolution des conditions climatiques. Si l'on considère qu'une part du réchauffement climatique est d'origine humaine, une part des causes de ces séismes pourrait être considérée comme induits par l'Homme [4].

4.4. Séismes d'origine artificielle

Les séismes d'origine artificielle ou « séismes » de faible à moyenne magnitude sont dus à certaines activités humaines telles que barrages, pompes profonds, extraction minière,

Chapitre 2 : Les tremblements de terre

explosions souterraines ou nucléaires, ou même bombardements. Ils sont fréquents et bien documentés depuis les années 1960-1970 [4].

5. Magnitude

La puissance d'un tremblement de terre peut être quantifiée par sa magnitude, notion introduite en 1935 par le sismologue Charles Francis Richter. La magnitude se calcule à partir des différents types d'ondes sismiques en tenant compte de paramètres comme la distance à l'épicentre, la profondeur de l'hypocentre, la fréquence du signal, le type de sismographe utilisé, etc. La magnitude est une fonction continue logarithmique: lorsque l'amplitude des ondes sismiques est multipliée par 10, la magnitude augmente d'une unité. Ainsi, un séisme de magnitude 7 provoquera une amplitude dix fois plus importante qu'un événement de magnitude 6, cent fois plus importante qu'un de magnitude 5 [4].

6. Intensités d'un séisme

La magnitude d'un séisme ne doit pas être confondue avec l'intensité macrosismique qui se fonde sur l'observation des effets et des conséquences du séisme en un lieu donné : vibration des fenêtres, nombre de personnes qui ressentent les secousses, ampleur des dégâts, etc. Les échelles d'intensité comportent des degrés notés en nombres romains, de I à XII pour les échelles les plus connues (Mercalli, MSK ou EMS). Parmi les différentes échelles, on peut citer: L'échelle Rossi-Forel (aussi notée RF) ; L'échelle Medvedev-Sponheuer-Karnik (aussi notée MSK) ; L'échelle de Mercalli (notée MM dans sa version modifiée) ; L'échelle de Shindo de l'agence météorologique japonaise ; L'échelle macrosismique européenne (aussi notée EMS98).

Les relations entre magnitude et intensité sont complexes. L'intensité dépend du lieu d'observation des effets. Elle décroît généralement lorsqu'on s'éloigne de l'épicentre en raison de l'atténuation introduite par le milieu géologique traversé par les ondes sismiques, mais d'éventuels effets de site (écho, amplification locale par exemple) peuvent perturber cette loi moyenne de décroissance [16].

7. Mesure d'un tremblement de terre selon RICHTER

L'échelle de Richter a été instaurée en 1935. Elle nous fournit ce qu'on appelle la magnitude d'un séisme, calculée à partir de la quantité d'énergie dégagée au foyer. Elle se mesure sur une échelle logarithmique ouverte ; à ce jour, le plus fort séisme a atteint 9,5 sur l'échelle de Richter (Chili). Cette fois, il s'agit d'une valeur qu'on peut qualifier d'objective : il n'y a qu'une seule valeur pour un séisme donné [16].

Chapitre 2 : Les tremblements de terre

7.1. Propagation des ondes sismiques

Un tremblement de terre correspond à une vibration transitoire du sol provoquée par les ondes sismiques émises lors d'un déplacement de sol (rupture) le long d'une faille active, à partir du foyer. La rupture cesse de se propager lorsque l'énergie potentielle de déformation est épuisée. Dans une région éprouvée par un grand séisme, vont se succéder pendant un certain temps des séismes plus petits, les répliques. Ces répliques achèvent souvent de détruire les constructions endommagées par la secousse principale. On distingue deux types d'ondes : les ondes de volume c'est-à-dire celles qui se propagent à l'intérieur de la terre et les ondes de surface [16].

Ondes de volume :

Elles prennent naissance dans le foyer et se propagent à l'intérieure de la terre sous deux formes :

Ondes primaires P: Ou ondes longitudinales, ces types d'ondes font basculer les ouvrages d'avant en arrière dans la même direction que leur propagation, elles induisent donc, un mouvement vertical dans les ouvrages ce mouvement sera d'autant plus important que l'ouvrage se trouve à proximité de l'épicentre ; elles se propagent dans la croûte terrestre avec une vitesse de 6 à 8km/s et s'accompagnent d'un changement de volume (compression et dilatation alternées).

Ondes secondaires S: Ou ondes de cisaillement, elles se propagent dans la croûte terrestre, avec une vitesse d'environ 3 à 5km/s et s'accompagnent d'une distorsion dans le plan perpendiculaire à la direction de propagation, provoquant un cisaillement sans changement de volume. C'est bien ce type d'ondes qui produit un mouvement horizontal dans les ouvrages.

Les ondes P se propagent toujours à plus grande vitesse que les ondes S ; ainsi, quand un tremblement de terre se produit, les ondes P sont les premières à se manifester et à être enregistrées [16].

Ondes de surface :

Les ondes de volume qui arrivent à la surface de la terre donnant naissance à des ondes de surface ne concernant le sol que sur une profondeur extrêmement faible ; les ondes de surface les plus importantes sont les suivantes :

Ondes de Rayleigh: ce sont des ondes pour lesquelles les points du sol décrivent des ellipses dans le plan vertical et dans le sens rétrograde. Ce mouvement entraîne des compressions ou des tractions, ainsi que des cisaillements dans le sol.

Chapitre 2 : Les tremblements de terre

Ondes de Love: Ce sont des ondes pour lesquelles les points du sol se déplacent dans un plan tangent à la surface et perpendiculairement à la propagation. Leur mouvement n'engendre que des contraintes de cisaillement [16].

8. Statistique sur les tremblements de terre

Le tableau ci-dessous résume le tremblement de terre les plus puissants enregistré depuis 1900 :

Pays	Ville/Zone	Magnitude	Date	Nombre de mort	Nombre de blessés
Chili	Valdivia	9.5	22/05/1960	3000	\
Indonésie	Iles andaman	9.4	24/12/2004	227 898	125 000
Etats-unis	Alaska	9.2	27/12/1964	131	\
Union soviétique	Kamtchatka	9.0	04/11/1952	\	\
Japon	Sendai	9.0	11/03/2011	15 776	5929
Equateur	\	8.8	1906	\	\
Chili	Concepcion	8.8	27/02/2010	497	\
Etat-unis	Alaska	8.7	1965	\	\
Indonésie	Ile de nias	8.7	28/03/2005	905	\
Océan indien	Entre l'inde et Thaïlande	8.7	11 /04/2012	\	\
Tibet	Tibet	8.6	15/08/1950	\	\
Etats-unis	Alaska	8.6	09/03/1957	\	\
Indonésie	Mer de banda	8.5	01/02/1938	\	\
Pérou	Arequipa	8.4	23/06/2001	250	1000
Japon	Kanto	8.3	01/09/1923	141 720	\
Chili	Chillàn	8.3	24/01/1939	28 000	58 000
Tonga	\	8.3	03/05/2005	\	\
Russie	Iles kouriles	8.3	15/11/2006	\	\
Russie	Iles kouriles	8.3	13/01/2007	\	\
Russie	Mer d'okhotsk	8.3	24/05/2013	\	\
Chili	Océan pacifique	8.3	16/09/2015	\	\
Etats-unis	Sans francisco	8.2	18 avril 1906	3000	\
Chili	Valparaiso	8.2	17/08/1906	20 000	20 000
Chili	Cuya	8.2	01/04/2014	5	\
Mexique	Mexico	8.1	19/09/1985	10 000	\
Pérou	Ica,lima	8.0	15/08/2007	387	1050

Tableau 2. Tremblements de terre les plus puissants enregistré depuis 1900 [4].

Le tableau ci-dessous résume le tremblement de terre les plus meurtriers enregistré depuis 1900 :

Pays	Ville/Zone	Date	Magnitude	Nombre de morts
Indonésie	Sumatra	26/12/2004	8.4	227 898
Japon	Tohoku	11/03/2011	8.3	15 776
Chili	Santiago	17/08/1906	8.6	20 000
Inde	Kangra	04/04/1905	8.6	19 000

Chapitre 2 : Les tremblements de terre

Chine	Gansu	16/12/1920	8.6	200 000
Chine	Xining	22/05/1927	8.3	200 000
Japon	Tokyo	01/09/1923	8.3	143 000
Chili	Chillàn	24/01/1939	8.3	28 000
Chine	Tangshan	27/07/1976	8.2	240 000
Indonésie	Bali	21/01/1917	8.2	15 000
Mexique	Michoacan	19/09/1985	8.1	20 000
Turquie	Erzincan	26/12/1939	8.0	30 000
Pérou	Chimbote	31/05/1970	8.0	66 000
Chine	Sichuan	12/08/2008	7.9	87 149
Iran	Zangan	20/06/1990	7.7	45 000
Inde	Bhuj	26/01/2001	7.7	20 085
Pakistan	Muzaffarabad	08/10/2005	7.6	79 410
Chine	Gansu	25/12/1932	7.6	70 000
Pakistan	Quetta	30/05/1935	7.5	45 000
Italie	Messine	28/12/1908	7.5	100 000
Italie	Avezanois	13/01/1915	7.5	29 980
Guatemala		04/02/1976	7.5	23 000
Turquie	Kocaeli	17/08/1999	7.4	17 118
Iran	Khorāsān	31/08/1968	7.3	16 000
URSS	Achgabat	05/10/1948	4.3	110 000
Haïti	Port-au-Prince	12/01/2010	7.2	230 000
Chine	Yibin	10/08/1974	6.8	20 000
Iran	Bam	26/12/2003	6.6	26 271

Tableau 3. Tremblements de terre les plus meurtriers enregistré depuis 1900 [4].

9. Méthode de Détection

9.1. Ancienne méthode chinoise

L'ancienne méthode chinoise consistait en un vase de bronze comportant huit dragons sur le contour, le Houfeng Didong Yi du chinois Zhang Heng, mis au point en l'an 132 de l'ère commune. Une bille était placée dans la gueule de chaque dragon, prête à tomber dans la gueule d'un crapaud. Lorsqu'un séisme se produisait, la bille d'un des dragons (dépendant de l'endroit où se produisait le séisme) tombait dans la gueule d'un des crapauds. Cela indiquait la direction de l'épicentre du tremblement de terre, et vers où il fallait envoyer les secours [4].

9.2. Méthode moderne

La localisation de l'épicentre par des moyens modernes se fait à l'aide de plusieurs stations sismiques (3 au minimum), et un calcul tridimensionnel. Les capteurs modernes permettent de détecter des événements très sensibles, tels qu'une explosion nucléaire.

Le Centre sismologique euro-méditerranéen a quant à lui développé un processus de détection sismique basé sur l'analyse du trafic web et des contenus sur Twitter. La collecte de témoignages et de photos permet en outre de connaître l'intensité des séismes ressentis, et d'apprécier et géolocaliser les dégâts matériels [4].

10. Méthode de prédiction

Les méthodes de prédiction reposent sur une prévision qui spécifie, avec leur incertitude, la position, la taille, la date du séisme, et donne une estimation de la probabilité de son propre succès. La possibilité de la prédiction sismique repose sur l'existence, et la reconnaissance des « précurseurs », signes avant-coureurs d'un séisme. En l'absence de précurseurs fiables, ces méthodes sont accompagnées de non-détections qui entraînent des procès pour les spécialistes et des fausses alarmes qui provoquent une perte de confiance des populations alertées.

On peut distinguer trois types de prévisions : la prévision à long terme (sur plusieurs années), à moyen terme (sur plusieurs mois) et à court terme (inférieur à quelques jours) [4].

10.1. Prédiction à long terme (sur plusieurs années)

Des méthodes permettent d'établir des prédictions à long terme. Dans ce cas, les scientifiques ne font pas une prédiction précise mais déterminent plutôt un risque sismique. Le plus simple consiste à étudier la récurrence des séismes en un lieu précis ainsi que leur périodicité dans le temps. Cette périodicité est expliquée par la théorie générale de la tectonique des plaques. Les plaques se déplacent à la surface de la Terre. Elles s'éloignent ou se rapprochent les unes des autres de quelques centimètres par an. Ces mouvements engendrent des contraintes qui fracturent la roche de la croûte terrestre quand elles deviennent trop fortes : c'est un séisme. Ainsi, comme le déplacement des plaques se déroule à vitesse constante à notre échelle ou à l'échelle historique, le temps séparant deux séismes et leur magnitude sont grossièrement constants, si on suppose que la roche se comporte toujours de la même façon. On définit une lacune sismique comme une zone de faille n'ayant pas connu de séisme depuis plus longtemps que la période observée sur cette faille. Par exemple, si en un lieu il y a habituellement un séisme de magnitude 5 tous les 20 ans et qu'il n'y en a pas eu depuis 30 ans, le risque est grand et on parle de lacune sismique. Les scientifiques recensent donc les séismes affectant une région, ou l'ayant affecté par le passé, afin d'établir cette période de récurrence. C'est une méthode assez efficace mais pas assez précise pour permettre une évacuation : elle permet surtout de définir les zones à risques [17].

On peut aussi essayer d'évaluer directement les contraintes qui s'appliquent sur une faille du fait des mouvements tectoniques. Il existe différentes techniques en géophysique. On repère les failles de la région étudiée grâce à des images satellites puis on mesure la position de ces failles très précisément grâce au système de positionnement satellitaire, le GPS, qui permet de mesurer le mouvement relatif des bords de la faille au centimètre près. On détermine ainsi les contraintes subies par la roche à cause de ce mouvement et on peut en déduire le lieu et la magnitude d'un séisme à venir sur cette faille ainsi que le moment approximatif où se produira le séisme. C'est

Chapitre 2 : Les tremblements de terre

une méthode intéressante car elle permet d'évaluer précisément le risque en un endroit donné, ce qui permet de prendre des précautions en matière d'implantation d'usine ou de constructions. Cependant elle ne permet pas non plus de déterminer précisément la date du séisme à venir, c'est donc plutôt une méthode de prédiction à long terme comme la méthode des lacunes sismiques [17].

10.2. Prédiction à moyen terme (sur plusieurs mois)

Les scientifiques ont aussi élaboré des méthodes de prédictions à plus court terme utilisant des éléments précurseurs à un séisme. Dès les années 1960, des scientifiques soviétiques ont remarqué que la vitesse des ondes P diminuait de 10% environ avant un séisme alors que celle des ondes S était constante. Ils remarquèrent ensuite que la vitesse des ondes P redevenait « normale » juste avant le séisme. Lorsque des roches sont soumises à des contraintes suffisamment fortes, elles se fissurent. Comme les ondes P ne se propagent pas bien dans l'air, leur vitesse diminue à cause de ces fissures. Lorsque la fracturation atteint une valeur limite et s'y maintient quelque temps avant la rupture finale, l'eau souterraine inonde ces fractures, rétablissant la pression initiale, ce qui permet aux ondes P de retrouver leur valeur initiale. Cette méthode, appelé méthode de la dilatance, a suscité beaucoup d'espoir mais le phénomène n'est pas observé systématiquement. Enfin, si ce phénomène dure quelques jours pour un séisme de magnitude 3, il peut durer jusqu'à 40 ans pour un séisme de magnitude 8 ! [17].

Les scientifiques ont étudié la concentration en radon des eaux souterraines proches d'une faille active. Le radon est un gaz radioactif naturel (donc dû à une réaction nucléaire naturelle) dont la concentration varie en fonction de la nature du sol ou encore des variations météorologiques. Ils ont observé que la teneur en radon augmentait dans les eaux à l'approche d'un séisme. Ceci serait dû aux frictions dans la roche à cause des contraintes à l'approche de la rupture provoquant le séisme. Ces frictions provoqueraient la fracturation de la roche, entraînant une remontée vers la surface, grâce à ces fractures, du radon piégé dans les roches profondes. Il a été établi de façon formelle qu'il existait une relation entre la teneur en radon et l'activité sismique. Il est cependant délicat d'utiliser cette technique seule car on ne sait pas précisément déterminer les fluctuations de la teneur en radon dues à d'autres activités naturelles comme les variations climatiques. Il est donc difficile de donner une alerte fiable avec ce seul élément. Mais on utilise fréquemment cette technique couplée à d'autres éléments de prédiction [17].

Il y'a d'autres phénomènes à l'approche d'un séisme. Des scientifiques japonais ont remarqué que dans certaines régions, le sol (ou le niveau marin) se « soulevait » de plusieurs dizaines de centimètres à l'approche d'un séisme, comme s'il « gonflait » avant le choc. Ce phénomène peut en particulier être observé en relevant le niveau d'eau dans les puits ou en mesurant

Chapitre 2 : Les tremblements de terre

l'inclinaison du sol. En étudiant la surface de la zone surélevée, on peut estimer la magnitude du séisme à venir. Cependant, là aussi, cette surélévation du sol n'est pas systématique. De plus, ce phénomène a été observé dans des régions où aucun séisme n'a eu lieu, ce qui rend ce phénomène difficilement utilisable, en tous cas s'il est utilisé seul, pour prévoir des séismes [17].

Dans de nombreux cas, un séisme violent est aussi précédé d'une multitude de petits séismes. Ainsi dans une zone de lacune sismique particulièrement calme, une soudaine activité, même de faible magnitude, peut indiquer l'imminence d'un séisme plus important. Cette méthode a permis de prévoir plusieurs séismes mais est assez imprécise et aléatoire car on ne connaît pas a priori la durée de cette phase de faible activité qui peut être entrecoupée de longues phases de calme. De plus, de nombreux séismes ne sont pas précédés de ces séismes précurseurs et il existe des périodes d'activité faible qui ne sont pas suivies de séismes importants [17].

10.3. Prédiction à court terme (inférieur à quelques jours) :

Une méthode a été élaborée par trois scientifiques grecs. Cette méthode, appelée méthode VAN du nom de ses inventeurs, Varotsos, Alexopoulos et Nomicos date des années 1980. Elle consiste à enregistrer les courants électriques naturels circulant dans le sous-sol. Ces scientifiques ont remarqué que de quelques jours à quelques heures avant un séisme, il existait des anomalies dans ces enregistrements qu'ils ont appelés SES (Signaux Electro-Sismique). Comme la Grèce est sismiquement très active, ils ont pu construire empiriquement une méthode de prédictions grâce à un réseau de stations. Ils pouvaient ainsi déterminer le lieu (en utilisant les enregistrements des stations réparties sur le territoire), l'heure (quelques heures après l'enregistrement de la SES) et la magnitude du séisme à venir (qui est proportionnelle à l'amplitude de la SES). Des dizaines de prédictions ont été faites mais il est très difficile de connaître l'efficacité véritable de cette méthode qui a été très critiquée et au centre d'une vive polémique entre spécialistes. Le principal problème est que l'on explique mal l'origine de ces signaux et que l'on connaît mal leur propagation dans la croûte où il existe beaucoup de signaux parasites naturels et artificiels. Les « inventeurs » de la méthode expliquent ces courants en faisant appel à la propriété bien connue de piézoélectricité du quartz : une contrainte appliquée sur du quartz crée un courant électrique. Ainsi, lorsqu'il existe des contraintes dans la roche à l'approche d'un séisme, il y a création d'un courant électrique car les roches de la croûte contiennent beaucoup de quartz. De nombreuses études ont été faites sur ce sujet et les résultats ne sont pas concluants. À ces questions de validité de la méthode en Grèce s'ajoute le problème d'utiliser cette méthode ailleurs. Il ne savait pas expliquer le phénomène physique qui entre en jeu, on ne peut donc pas prévoir l'importance du phénomène dans une région donnée. De plus,

Chapitre 2 : Les tremblements de terre

il faut attendre que de nombreux séismes aient lieu dans une région pour étalonner le système et prédire les séismes touchant ensuite la région, ce qui est plutôt gênant pour une méthode de prédiction.

Il existe enfin ce que beaucoup ont appelé la « méthode chinoise ». La Chine est régulièrement frappée par des séismes très violents. Il est très important de trouver des techniques de prédictions fiables en Chine car c'est un pays très peuplé où les habitations sont constituées de petites maisons individuelles peu solides : ils ne peuvent pas utiliser de coûteuses constructions parasismiques pour protéger la population mais ils peuvent en revanche organiser une évacuation en regroupant les gens sans trop paralyser l'activité économique. Le gouvernement chinois lança à la fin des années 1960 un programme de prédiction des séismes destructeurs affectant le pays. Pour cela ils ont décidé d'impliquer la population en enseignant à plus de 100000 chinois des rudiments de sismologie. Les physiciens chinois se mirent à chercher tous les signes précurseurs « scientifiques » identifiés jusqu'alors mais aussi à surveiller d'autres signes comme le comportement des animaux ou la formation de bulles dans les puits, tous ces signes étant relevés par cette population formée. Ce n'est pas une méthode spécifique mais plutôt une utilisation d'un ensemble de méthodes. Cette méthode connut un succès retentissant avec la prédiction du séisme du 4 février 1975 à Haicheng de magnitude 7,3, la seule prédiction réussie d'un séisme très destructeur, il est vrai précédé d'un grand nombre de signes précurseurs. Mais elle connut un échec non moins retentissant avec la prédiction ratée du séisme suivant à Tangshan en 1976 de magnitude 7,8, le plus meurtrier depuis 400 ans, qui fit environ 240 000 victimes [17].

Des satellites pour prédire les tremblements de terre ??

Certains scientifiques pensent pouvoir prédire les tremblements de terre en analysant les petites variations de champ magnétique terrestre. Cette hypothèse va être testée par deux nouveaux satellites. Le premier, Quakesat, construit par la société privé Quakefinder a été lancé le 30 juin 2003 et vient de passer en mode opérationnel. Le deuxième, Demeter, beaucoup plus ambitieux, construit par le CNES (Centre National d'Études Spatiales), était lancé en avril 2004. D'après la théorie, la compression des roches cristallines et le mouvement des eaux souterraines feraient varier le champ magnétique local. Ces variations pourraient être observées depuis l'espace [18].

10.3.1. La magie de L'informatique dans la prédiction de tremblement de terre

Maintenant après avoir vu ce que les scientifiques de divers domaines ont fait pour essayer de prévoir les tremblements de terre (les méthodes précédentes) en va voir maintenant ce que les informaticiens ou le domaine d'informatique a pu offrir comme solution à ce problème.

Chapitre 2 : Les tremblements de terre

10.3.1.1. L'utilisation du big data pour prédire les tremblements de terre

Le Big Data peut collecter bien plus facilement qu'avant des informations provenant de différents événements pour déterminer la probabilité de la fréquence d'un tremblement de terre. La Nature donne toujours des signaux lorsque l'un de ces événements va se produire et il faut les comprendre afin de pouvoir agir en conséquence. Puisque ces indices sont éparpillés, la meilleure solution est d'utiliser le Big Data afin de les collecter et de les regrouper dans un site central pour obtenir d'eux des résultats plus précis.

Ces indices peuvent provenir des mouvements des animaux ou bien des conditions atmosphériques qui précèdent un séisme, comme ce fut le cas pour le tremblement de terre qui a eu lieu en Chine de l'Est en 1975, les températures et la pression étaient anormalement élevées. De plus, des serpents et des rongeurs étaient sortis de terre, fuyant la future catastrophe. Lorsque des facteurs liés aux tremblements de terre sont surveillés et analysés constamment avec le Big Data, même le plus petit changement qui pourrait envoyer des signaux d'alertes, peut être capturé d'une grande précision avec ce procédé. Des sociétés comme "Terra Seismic" travaillent d'ores et déjà sur la prédiction de tremblement de terre à l'aide du Big Data. Ils affirment pouvoir les prédire avec 90% de fiabilité grâce aux données satellites et aux autres signaux provenant de la nature. Par exemple, ils avaient prédit le 22 février 2015 la probabilité d'un tremblement de terre d'une magnitude de 6,5 à Sumatra, qui a eu bien eu lieu dans cette ville le 3 mars 2015 et d'une magnitude de 6,4 sur l'échelle de Richter [19].

10.3.1.2. La machine learning à la rescousse pour donner plus de précision

Prédire le tremblement de terre en utilisant le machine learning pour écouter le séisme et le prévoir ??

Le Laboratoire national de Los Alamos aux États-Unis a mis au point une technique d'analyse du signal acoustique des failles qui permet d'anticiper un tremblement de terre. La méthode a été validée en laboratoire [20].

SISMOLOGIE :

Écouter le mouvement des plaques tectoniques pour prévoir les séismes, le procédé est connu. Il consiste la plupart du temps à récolter des données sur le signal sonore de failles réelles ou de séismes reconstitués en laboratoire pour constituer des catalogues et mener des analyses historiques. Mais une équipe du Laboratoire national de Los Alamos, au Nouveau-Mexique, a mis au point une autre méthode à base d'apprentissage automatique (machine learning) sur des séismes de laboratoire. Et les résultats, publiés dans la revue *Geophysical Research Letters* le 30 août dernier, sont plus que prometteurs [20]

Chapitre 2 : Les tremblements de terre

“L'approche habituelle revient à laisser de côté la plupart du signal acoustique. Celle-là est rendue possible par la parallélisation d'algorithmes de machine learning sur de puissants ordinateurs, et permet de ne rien omettre du signal sonore”, explique Bernard Rouet-Leduc, chercheur spécialiste des données et de l'intelligence artificielle au département de sciences des matériaux à l'université de Cambridge, au Royaume-Uni [20].

Un simulateur qui reproduit des failles sismiques

Les données émanent d'un modèle réduit de faille sismique qui sert de simulateur en laboratoire. Il consiste en deux couches de très petites billes de verre entre trois blocs d'acier. Deux blocs extérieurs soumis à une force perpendiculaire provoquent une compression des billes et d'un bloc central, lequel subit une force parallèle. “À mesure que le bloc central avance, des séismes de laboratoire ont lieu, pendant lesquels le matériau granulaire cède et se réarrange brusquement. Cette machine est très étudiée par la communauté géo scientifique depuis des dizaines d'années, et reproduit bien des aspects des vrais failles sismiques”, continue Bernard Rouet-Leduc [20].

Un accéléromètre enregistre et mesure les vibrations émanant des billes. Ce sont ces données qui constituent le signal acoustique. En leur appliquant leurs algorithmes de machine learning, les chercheurs ont découvert un motif sonore qui n'était pas pris en compte par les autres méthodes parce qu'il ressemble au bruit de fond du mouvement des plaques de laboratoire et non à un événement sismique. “Il s'est révélé être un marqueur très précis de l'état de tension de la faille et du temps restant avant qu'elle ne cède.” Cette découverte intervient dans un contexte où il est globalement admis que la rupture d'une faille dans un état critique n'est pas prévisible. Elle peut arriver à tout moment. Les expériences de laboratoire à Los Alamos ont montré l'inverse [20].

Des prédictions justes à 2,5 % près

“Concrètement, pendant la première moitié de l'expérience, l'algorithme apprend à reconnaître le lien entre signal sonore et stress de la faille ou le temps restant avant qu'elle ne cède. Pendant la deuxième moitié, il demande à l'algorithme de faire ses prédictions à partir du son uniquement. Juste après un séisme de laboratoire, il peut déterminer le temps restant avant le prochain séisme à 10 % près. À mesure que le séisme approche, les prédictions deviennent de plus en plus précises, jusqu'à être justes à 2,5 % près.” Le chercheur cite

L'exemple de cycles sismiques de 10 secondes en moyenne : deux secondes avant le prochain séisme, l'algorithme prédit un temps restant entre 1,9 et 2,1 secondes [20].

Chapitre 2 : Les tremblements de terre

Comment en a pu le constater la prédiction des tremblements de terre avec l'utilisation d'informatique (machine learning surtout) et plus fiable que l'utilisation d'autre méthode d'autre domaine.

11. Conclusion

Au terme de ce chapitre, en a vu que les tremblements de terre et l'un des catastrophes les plus meurtrières et qui cause le plus de dégâts que ça soit dégâts matériels ou humains ainsi les causes des tremblements de terre et les avancées scientifiques qui concerne ce sujet.

Dans l'état actuel des connaissances, on ne peut pas prédire les séismes à court terme, c'est-à-dire déterminer la date et l'heure exacte d'un événement sismique. D'autres moyens ont été cités : par exemple, certains animaux semblent détecter les tremblements de terre : serpents, porcs, chiens...

Pour essayer de combattre cette catastrophe naturelle les architectures contre les tremblements de terre seul n'ont pas suffi à lutter, aussi elles sont très couteuses surtout pour les villes ou en trouve beaucoup d'habitant comme la chine ou le japon.

Comme en a vu dans ce chapitre dans le cas de tremblement de terre l'intelligence artificielle a fait mieux que l'intelligence humaine en détectant des corrélations passées jusque-là inaperçues entre les signaux enregistrés et l'occurrence d'un séisme. C'est pour ça qu'on demande de donner plus d'importance au chercheur informaticien vu de ce qu'ils ont fait en si peu de temps avec leurs algorithmes et leur technologie surtout que maintenant grâce au Deep learning en peut avoir encore des meilleurs résultats que les recherche qui ont précédé.

Chapitre 3 :

Conception et implémentation

Chapitre 3 : Conception et implémentation

1. Introduction

La conception c'est le processus qui consiste à représenter les diverses fonctions du système. C'est certainement la partie la plus importante de notre travail. En effet, c'est à cette étape que nous déterminons notre objectif principal et nous affinons notre analyse en introduisant la structure opérationnelle des composantes de notre système, ce qui va nous aider à l'étape de l'implémentation de notre système de prédiction.

Dans les chapitres précédents nous avons présenté le Deep Learning et le tremblement de terre. Le but de notre projet est d'essayer de prédire le tremblement de terre en utilisant le Deep Learning. Dans ce qui suit, nous allons clarifier les phases de conception de notre système, ainsi qu'une conception par affinement successif du système en donnant son architecture générale, puis nous détaillons en étudiant séparément chacun de ses composants.

Dans la deuxième partie de ce chapitre nous allons présenter en premier temps, l'environnement du développement avec les différentes bibliothèques utilisées. Ensuite, on va présenter les algorithmes utilisés et on va introduire et analyser les résultats obtenus.

2. Conception

2.1. Conception globale du système

Le système de prédiction de tremblement de terre est constitué de 3 étapes :

- Etape 1 est l'acquisition des données (latitude, longitude, date).

Dans cette étape le système utilise la DataSet qu'on obtient à partir du USGS (United States Geological Survey).

- Etape 2 est l'apprentissage avec le test.

Le processus de cette phase se déroule principalement en deux étapes : une phase d'entraînement et une phase de test. L'apprentissage est supervisé, c'est-à-dire qu'on associe une configuration d'entrée à une configuration de sortie. Le système reçoit en entrée des données d'entraînement en utilisant la base de données sur laquelle il va s'entraîner et nous donner des résultats qu'on va observer et si les résultats ne sont pas bons le système va effectuer une deuxième phase d'apprentissage en changeant les valeurs de poids synaptiques de réseau de neurones, liés à la couche cachée jusqu'à obtenir les résultats attendus et après le système va sauvegarder le modèle

- Etape 3 L'utilisation du programme.

La phase d'utilisation est la phase très importante dans laquelle notre système va être évalué. Après avoir sauvegardé le modèle construit dans la phase précédente (phase d'entraînement) le système a pour option d'appliquer le modèle sur les données entrées par

Chapitre 3 : Conception et implémentation

l'utilisateur (L'attitude, longitude, Date) pour prédire si l'endroit indiqué par l'utilisateur va avoir un tremblement de terre a la date indiquée.

Le système va prédire la magnitude de l'endroit précisé par l'utilisateur a la date précisée aussi par l'utilisateur et s'il trouve la magnitude =0 il va donc afficher à l'utilisateur qu'il ne va pas avoir de tremblement de terre sinon si la magnitude >0 alors il va lui afficher qu'il va y'avoir un tremblement de terre en affichant au même temps la magnitude du tremblement de terre qu'il va y'avoir.

La figure ci-dessous présente l'architecture général de notre système de prédiction de tremblement de terre.

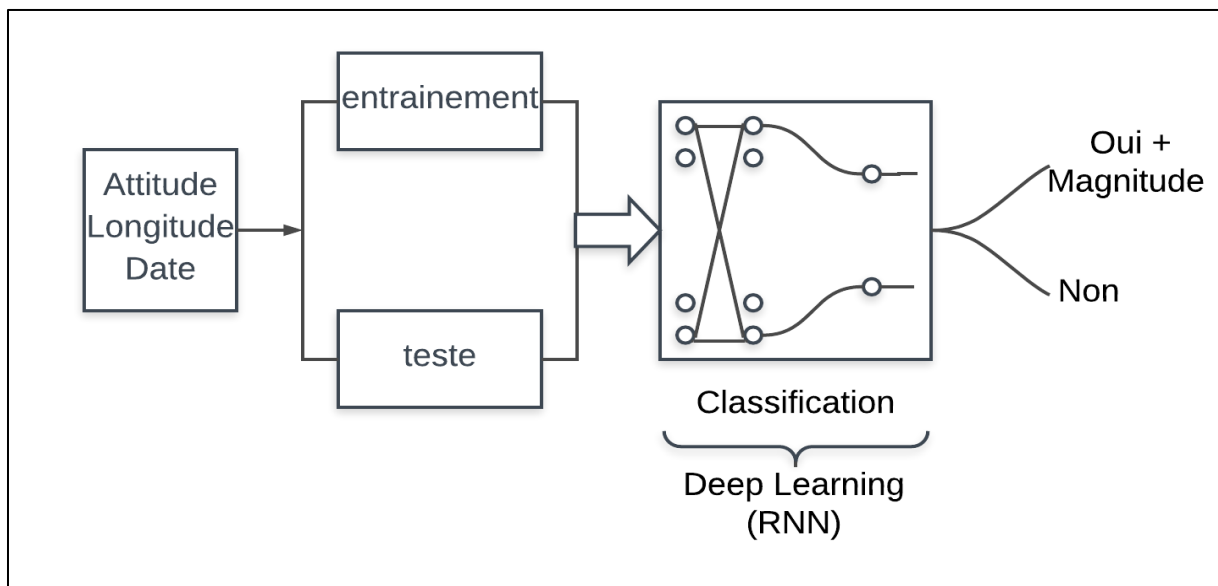


Figure 15: Architecture général du système de prédiction

2.2. Conception détaillée du système

2.2.1. L'acquisition des données

Cette phase consiste à accueillir la DataSet obtenu à partir du USGS.

Le United States Geological Survey « Institut d'études géologiques des États-Unis » est un organisme gouvernemental américain qui se consacre aux sciences de la Terre. Il est notamment chargé de la surveillance de l'activité sismique sur son territoire et à travers le monde. Son activité se rapproche de celle du Bureau de recherches géologiques et minières en France.

Après avoir accueillez la DataSet par le système il va effectuer une tâche appelé la normalisation. La normalisation est utile pour empêcher la saturation des neurones lorsque les entrants peuvent avoir une échelle variable, et pour aider à la généralisation.

Chapitre 3 : Conception et implémentation

2.2.2. L'apprentissage et le test

Dans cette phase le système de détection de tremblement de terre va faire un apprentissage sur la DataSet obtenu dans la phase précédente. L'apprentissage se fait en plusieurs étapes :

2.2.2.1. Etape de propagation

Cette étape commence par fournir la DataSet (ligne par ligne) à notre système. Après il calcule la fonction sigmoïde pour chaque neurone dans le réseau jusqu'au neurone de sortie :

$$\sigma(z) \equiv \frac{1}{1 + e^{-z}}.$$

Tel que :

$$Z = \sum (x * w) + b$$

- x : est l'entrée
- w : est le poids synaptique
- b : est le biais

La fonction sigmoïde a pour objectif d'activer le neurone.

2.2.2.2. Rétropropagation

En calcule le coût avec la fonction coût

$$C(w, b) \equiv \frac{1}{2n} \sum_x \|y(x) - a\|^2.$$

Tel que :

- w désigne la collecte de tous les poids dans le réseau.
- b tous les biais.
- n est le nombre total d'entrées d'apprentissage.
- a est le vecteur des sorties du réseau lorsque x est entré.

La sortie a dépendu de x et w et b mais pour garder l'équation simple j'ai évité d'indiquer la dépendance.

L'objectif de la fonction coût et de savoir si le système doit faire l'apprentissage ou non. Si le système doit faire l'apprentissage alors il le fait en utilisant l'algorithme AdamOptimizer [21].

Chapitre 3 : Conception et implémentation

La figure ci-dessous représente l'organigramme du rétro propagation

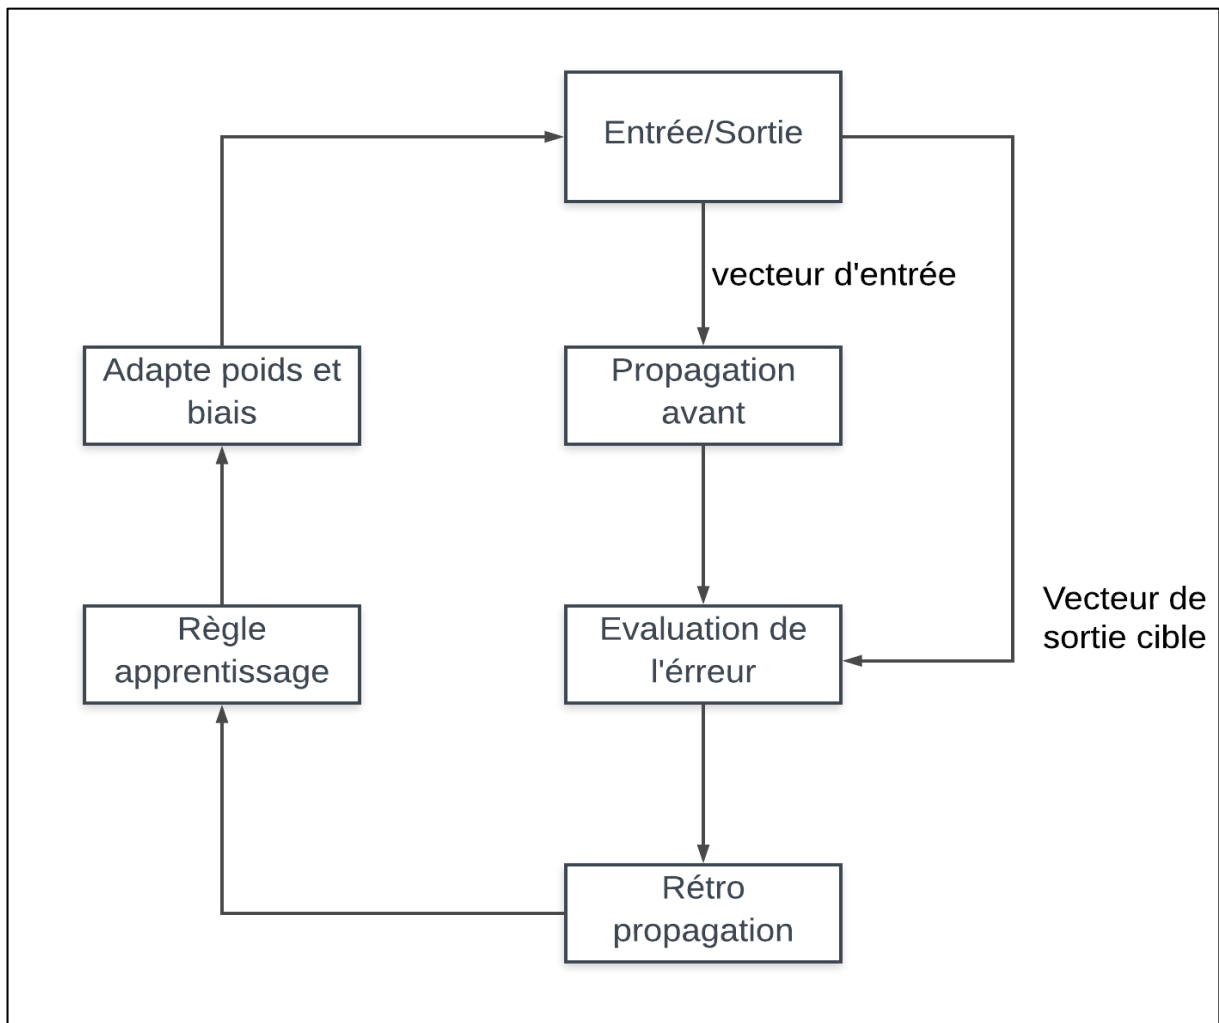


Figure 16: organigramme de rétro propagation

2.2.3. Phase d'utilisation

Cette phase commence par afficher un message à l'utilisateur pour lui demander de rentrer les données (Latitude, Longitude, Date) après sa le système va lire les données et utilisé le modèle obtenu a partir de l'entraînement pour prédire s'il va y'avoir un tremblement de terre ou non.

3. Implémentation

3.1. Environnement du développement

Notre système était développé sur un ordinateur de processeur Core I5 avec une RAM de 8 Go sous Windows 10, Et le langage utilisé est Python, son avantage que l'on travaille sur la plupart des systèmes d'exploitation et qu'il est facile à utiliser grâce à ces bibliothèques.

Chapitre 3 : Conception et implémentation

3.2. Bibliothèques et outils utilisés

3.2.1. Tensorflow




Figure 17: Logo de tensorflow

TensorFlow est un outil open source d'apprentissage automatique développé par Google. Le code source a été ouvert le 9 novembre 2015 par Google et publié sous licence Apache. Il est basé sur l'infrastructure DistBelief, initiée par Google en 2011, et est doté d'une interface Python. TensorFlow est l'un des outils les plus utilisés en IA dans le domaine de l'apprentissage machine [4].

3.2.2. Pandas




Figure 18: Logo de pandas

Pandas est une bibliothèque écrite pour le langage de programmation Python permettant la manipulation et l'analyse des données. Elle propose en particulier des structures de données et

Chapitre 3 : Conception et implémentation

des opérations de manipulation de tableaux numériques et de séries temporelles [4]. Pandas est un logiciel libre sous licence BSD [22].

3.2.3. Time

Ce module fournit diverses fonctions liées au temps. Pour les fonctionnalités connexes, voir également les modules datetime et calendar [4].

3.2.4. Matplotlib



Figure 19: Logo matplotlib

Matplotlib est une bibliothèque du langage de programmation Python destinée à tracer et visualiser des données sous formes de graphiques. Elle peut être combinée avec les bibliothèques python de calcul scientifique NumPy et SciPy [4].

3.3. Détails de l'implémentation

Dans ce qui suit on va présenter les différents modules de notre système, en spécifiant leurs implémentations, tout en illustrant quelques détails sur les différents algorithmes implémentés.

Notre système peut être divisé en trois sous-systèmes : Les entrées, Apprentissage et classification(utilisation).

3.3.1. Les entrées

La figure suivante représente une partie de notre base de données qu'on a obtenu du USGS :

```
Date,Time,Latitude,Longitude,Type,Depth,Magnitude,NormalizedLat,NormalizedLong,NormalizedDepth,NormalizedMag,
23744.00,0.5724,19.246,145.616,Earthquake,131.6,6,0.590649048,0.904493118,0.189273998,0.138888889,,min,-77.6
23746.00,0.4790,1.863,127.352,Earthquake,80,5.8,0.484060459,0.85375908,0.115675367,0.083333333,,max,86.005,1
23747.00,0.7541,-20.579,-173.972,Earthquake,20,6.2,0.346451237,0.016736344,0.030095564,0.194444444,,,,,
23750.00,0.7845,-59.076,-23.557,Earthquake,15,5.8,0.110396419,0.434561591,0.022963914,0.083333333,,,,,
23751.00,0.5645,11.938,126.427,Earthquake,15,5.8,0.54583806,0.8511896,0.022963914,0.083333333,,,,,
23752.00,0.5670,-13.405,166.629,Earthquake,35,6.7,0.390440568,0.962863373,0.051490515,0.333333333,,,,,
23754.00,0.5642,27.357,87.867,Earthquake,20,5.9,0.640383849,0.744077001,0.030095564,0.111111111,,,,,
23757.00,0.9706,-13.309,166.212,Earthquake,35,6,0.391029218,0.961705024,0.051490515,0.138888889,,,,,
23758.00,0.4810,-56.452,-27.043,Earthquake,95,6,0.126486188,0.424878123,0.137070318,0.138888889,,,,,
23759.00,0.4467,-24.563,178.487,Earthquake,565,5.8,0.322022258,0.995802719,0.807445443,0.083333333,,,,,
23759.00,0.8734,-6.807,108.988,Earthquake,227.9,5.9,0.430897998,0.80274726,0.326629582,0.111111111,,,,,
```

Figure 20 : Une partie de la DataSet

Chapitre 3 : Conception et implémentation

3.3.2. L'apprentissage

Le réseau de neurone qu'on a constitué se compose de 3 couches cachées et chaque couche contient 3 neurones. La couche d'entrée est composée de 3 neurones qui sont (Latitude, Longitude et la Date). La couche de sortie se compose d'un seul neurone. La figure ci-dessous présente le modèle de réseau de neurone qu'on a constitué.




Figure 21: notre modèle de réseau de neurone

La figure 22 montre la partie du programme qui effectue la propagation de réseau de neurones :

Chapitre 3 : Conception et implémentation

```
82 ## Parametres de Réseaux
83 L1 = 3 #Nombre de neurones dans la 1er couche
84 L2 = 3 #Nombre de neurones dans la 2eme couche
85 L3 = 3 #Nombre de neurones dans la 3eme couche
86
87 stddev = 0.3
88 with tf.device("/cpu:0"):
89     with tf.name_scope('FeedForward_layer_1'):
90         # Les Poids de 1er couche
91         W_fc1 = tf.Variable(tf.random_normal([Xfeatures,L1],stddev=stddev),name="FeedForward_layer_1_weights") # [input_features,Number of neurons]
92         b_fc1 = tf.Variable(tf.random_normal([L1],stddev=stddev),name="FeedForward_layer_1_bias")
93         # Couche 1
94         matmul_fc1=tf.matmul(X, W_fc1) + b_fc1
95         h_fc1 = tf.nn.relu(matmul_fc1) #ReLU activation
96         summ_W_fc1 = tf.summary.histogram("FC_Layer_1_Weights",W_fc1)
97         summ_b_fc1 = tf.summary.histogram("FC_Layer_1_biases",b_fc1)
98
99     with tf.name_scope('FeedForward_layer_2'):
100        # Les Poids de 2eme couche
101        W_fc2 = tf.Variable(tf.random_normal([L1,L2],stddev=stddev),name="FeedForward_layer_2_weights") # [Number of neurons in preceding layer,Number of neurons]
102        b_fc2 = tf.Variable(tf.random_normal([L2],stddev=stddev),name="FeedForward_layer_2_bias")
103        # Couche 2
104        matmul_fc2=tf.matmul(h_fc1, W_fc2) + b_fc2
105        h_fc2 = tf.nn.relu(matmul_fc2) #ReLU activation
106        summ_W_fc2 = tf.summary.histogram("FC_Layer_2_Weights",W_fc2)
107        summ_b_fc2 = tf.summary.histogram("FC_Layer_2_biases",b_fc2)
108
109     with tf.name_scope('FeedForward_layer_3'):
110        # Les Poids de 3eme couche
111        W_fc3 = tf.Variable(tf.random_normal([L2,L3],stddev=stddev),name="FeedForward_layer_3_weights") # [Number of neurons in preceding layer,Number of neurons]
112        b_fc3 = tf.Variable(tf.random_normal([L3],stddev=stddev),name="FeedForward_layer_3_bias")
113        # Couche 3
114        matmul_fc3=tf.matmul(h_fc2, W_fc3) + b_fc3
115        h_fc3 = tf.nn.relu(matmul_fc3) #ReLU activation
116        summ_W_fc3 = tf.summary.histogram("FC_Layer_3_Weights",W_fc3)
117        summ_b_fc3 = tf.summary.histogram("FC_Layer_3_biases",b_fc3)
118
119     with tf.name_scope('Output_layer'):
120        # Les Poids de Couche sortie
121        W_fc0 = tf.Variable(tf.random_normal([L3,Yfeatures],stddev=stddev),name="Output_layer_weights") # [Number of neurons in preceding layer,output_features]
122        b_fc0 = tf.Variable(tf.random_normal([Yfeatures],stddev=stddev),name="Output_layer_bias")
123        # couche Sortie
124        matmul_fc4=tf.matmul(h_fc3, W_fc0) + b_fc0
125        output_layer = matmul_fc4 #linear activation
126        summ_W_fc0 = tf.summary.histogram("Output_Layer_Weights",W_fc0)
127        summ_b_fc0 = tf.summary.histogram("Output_Layer_biases",b_fc0)
128
```

Figure 22: La partie responsable du calcul de propagation de notre RNA

Après la propagation de notre RNA voici une figure qui montre le résultat de notre apprentissage :

```
Initial training loss: 34.636158
Initial validation loss: [34.704998]
Training loss is: [34.6354] at iteration: 0
Validation loss is: [34.70482] at iteration: 0
Training loss is: [15.167888] at iteration: 200000
Validation loss is: [15.219362] at iteration: 200000
Training loss is: [3.670267] at iteration: 400000
Validation loss is: [3.7035267] at iteration: 400000
Training loss is: [0.17661847] at iteration: 600000
Validation loss is: [0.19281541] at iteration: 600000
Training loss is: [0.17661853] at iteration: 800000
Validation loss is: [0.19281551] at iteration: 800000
```

Figure 23: Résultat d'apprentissage

3.3.3. L'utilisation

Après l'apprentissage le système va faire un teste sur un autre ensemble d'entrée pour obtenir la valeur de précision qu'on obtient à partir de la sortie désiré avec la sortie obtenue

La figure 24 montre la précision obtenue à partir du système

Chapitre 3 : Conception et implémentation

```
[[ -0.38836926 ]
 [ -0.3883719 ]
 [ -0.3883721 ]
 ...
 [ -0.3883688 ]
 [ -0.38837516 ]
 [ -0.38836882 ]
Time taken: 0.02179551124572754
Number of summaries: 10
.\code.py:218: FutureWarning: Method .as_matrix will be removed in a future version. Use .values instead
  InputX = col1.as_matrix()
.\code.py:219: FutureWarning: Method .as_matrix will be removed in a future version. Use .values instead
  InputY = col2.as_matrix()

Précision : 0.820154
```

Figure 24: la partie du programme qui affiche la valeur de la précision

Après avoir obtenu la valeur de précision le système va demander à l'utilisateur de donner Latitude, la Longitude et la Date comme entrée, après sa le système va tester ces entrées à partir de modèle obtenu et après afficher le résultat (la sortie) s'il y'aura un tremblement de terre ou non dans la localisation indiquée par l'utilisateur. La figure ci-dessous nous montre l'opération.

```
Entrer la Longitude :-107.8694
Entrer la Latitude' :-34.9886
Entrer la Date (d-m-Y) : 20-01-2002
La result obtenu est : 5.5
PS C:\Users\Zedster\Documents\Earthquake_predict-master> python .\utilisation.py
Entrer la Longitude :83.5301
Entrer la Latitude' :-23.7021
Entrer la Date (d-m-Y) : 20-05-2007
La result obtenu est : 0.013
```

Figure 25: résultat de l'utilisation du système

4. Conclusion

Dans la partie conception de ce chapitre, nous avons présenté et expliquée la conception de notre système de prédiction de tremblement de terre et son principe de fonctionnement. Ce dernier est basé fortement sur l'algorithme AdamOptimizer. Nous nous avons introduis ensuite en détail le rôle de chaque phase séparément.

Dans la partie implémentation, nous avons introduis la réalisation de notre système, pour cela, nous avons décrit les outils utilisé pour l'implémentation de notre système de prédiction de tremblement de terre ; en commençant par la présentation de l'environnement du travail, ainsi que les structures de données et les outils utilisées. Les résultats obtenus et leur analyse et décrit également dans cette deuxième partie

Conclusion Générale

Notre objectif de ce mémoire est de développer un logiciel de prédiction de tremblement de terre à base de Deep Learning afin d'automatiser cette tâche pour atteindre le but principal qui est la prédiction du tremblement de terre dans un temps précis.

Nous avons vu en premier temps le processus de réseaux des neurones en expliquant ces types ainsi que les types d'apprentissage. Ensuite, nous avons présenté une brève étude sur les tremblements de terre, nous avons illustré les caractéristiques et les catégories ainsi quelque statistique de cette catastrophe naturelle et quelque méthode utiliser pour la prédiction.

Pour présenter ce système, nous avons besoin d'une méthode de classification, une méthode qui nous a convenu pour notre travail. Pour atteindre cet objectif nous avons choisi l'utilisation de la méthode AdamOptimizer que nous avons déjà expliqué son fonctionnement.

Dans la phase de conception, nous avons proposé une architecture pour implémenter notre système, nous avons introduis le principe de fonctionnement du système et son architecture globale, ensuite chaque composant a été décrit de façon indépendante avec une description de son rôle. La deuxième partie de ce chapitre donne une vue de fond sur notre système, à travers les outils de programmation aussi que les algorithmes utilisés.

Table de référence

Table de références

- [1] www.fr.wikiversity.org/.
- [2] www.lrde.epita.fr/~sigoure/cours_ReseauxNeurones.pdf.
- [3] www.futura-sciences.com/tech/dossiers/robotique-presentation-historique-reseaux-neuronaux-31/.
- [4] www.fr.wikipedia.org.
- [5] www.bu.umc.edu.dz/theses/gcivil/BEN6585.pdf.
- [6] www.amethyste16.wordpress.com.
- [7] www.hal.archives-ouvertes.fr/hal-00085092/document.
- [8] www.memoireonline.com/04/12/5750/m_Identification-et-commande-des-systemes-non-lineaires21.html.
- [9] [www.fr.linkedin.com/pulse/apprentissage-profond-et-vision-par-ordinateur-bayoudh-khaled.
- [10] www.image-net.org.
]
- [11] www.fr.mathworks.com/discovery/deep-learning.html.
]
- [12] www.news.autojournal.fr/news/1520929/voiture-autonome-intelligence-artificielle-deep-learning-s%C3%A9curit%C3%A9-routi%C3%A8re-technologie.
]
- [13] www.clubic.com/technologies-d-avenir/intelligence-artificielle/deep-learning/article-783038-2-promesses-deep-learning.html.
]
- [14] www.tpeseisme-architectureprevention.weebly.com/introduction.html.
]
- [15] www.actu-environnement.com/ae/dictionnaire_environnement/definition/seisme_tremblement_de_terre.php4.
- [16] B. Allaoua, «SIMULATION NUMERIQUE DE L'EFFET DE TREMBLEMENT DE TERRE SUR LES BARRAGES EN TERRE,» UNIVERSITÉ de biskra.
- [17] www.musee-sismologie.unistra.fr/comprendre-les-seismes/notions-pour-petits-et-grands/le-risque-sismique/methodes-de-prediction-sismique/.
- [18] www.futura-sciences.com/planete/actualites/geologie-intelligence-artificielle-peut-elle-predire-seismes-2389/.

Table de référence

[19 [En ligne]. Available: www.lebigdata.fr/utiliser-le-big-data-pour-predire-les-tremblements-de-terre.
]

[20 [En ligne]. Available: www.sciencesetavenir.fr/fondamental/quand-le-machine-learning-ecoute-les-seismes-pour-les-prevoir_116106.
]

[21 J. B. Diederik P. Kingma, A Method for Stochastic Optimization.
]

[22 [En ligne]. Available: www.pandas.pydata.org/pandas-docs/stable/overview.html#license.
]

[23 [En ligne]. Available: www.image-net.org/challenges/LSVRC/2012/.
]