

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

**UNIVERSITE M'HAMED BOUGARA-BOUMERDES**



**Faculté des Sciences**

**Thèse de Doctorat**

Présentée par :

**OUADFEUL Sid-Ali**

En vue de l'obtention du diplôme de **DOCTORAT Science** en :

**Filière : Sciences Physique**

**Option : Traitement du Signal**

**TITRE : Analyse Non-linéaire de la Physique du Plasma. Application aux données Ionosphériques.**

**Devant le jury composé de :**

|            |                 |            |                  |                    |
|------------|-----------------|------------|------------------|--------------------|
| M.AITOUCHE | Mohand-Amokrane | Professeur | UMBB             | Président          |
| M.BADDARI  | Kamel           | Professeur | Univ. M'Sila     | Examineur          |
| M.SHOUT    | Hocine          | Professeur | Uiv. Constantine | Examineur          |
| M.DJARFOUR | Nouredine       | Professeur | Univ. Adrar      | Examineur          |
| M.BOUDELLA | Amar            | Professeur | USTHB            | Examineur          |
| M.ELADJ    | Said            | Professeur | UMBB             | Directeur de thèse |

*Un grand hommage est rendu à Mon Directeur de Thèse le D efunt Professeur Tourtchine Victor, sans lui ce travail de th ese n'aura jamais lieu. Un grand merci pour son soutien moral et ses conseils pr ecieux, surtout durant les moments difficiles de pr eparation et recherche. Merci Professeur Tourtchine.*

## Remerciements

Au terme de cette modeste thèse, je voudrais exprimer ma profonde gratitude et mes sincères remerciements à toutes celles et tous ceux qui ont contribué à ce travail de thèse

En premier lieu, je tiens à remercier Monsieur Said Eladj, Professeur à l'UMBB, d'avoir accepté de continuer diriger mes travaux après le décès de Mon promoteur le Professeur Victor Tourchine. Je remercie Monsieur Aitouche Mohand Amokrane, Professeur à l'UMBB, d'avoir accepté de présider le jury de ma thèse.

Je remercie, sincèrement, Messieurs Baddari Kamel , Professeur à l'université de M'Sila , d'avoir accepté de juger ce travail de thèse.

Je tiens à remercier, également, Messieurs Boudella Amar, Professeur à l'USTHB et Shout Hocine Professeur à l'université de Constantine qui m'ont fait honneur d'accepter d'examiner mes travaux.

Mes remerciements s'adressent, aussi, à Monsieur Djarfour Nouredine, Professeur à l'université d'Adrar, d'avoir accepté de faire partie du jury de thèse.

Que ma femme et collègue Madame Leila Ouadfeul (Aliouane), Professeur à l'UMBB, trouve ici l'expression de ma profonde gratitude et reconnaissance pour son aide moral et dans la rédaction de cette thèse.

Je remercie, aussi, Monsieur Michel Parrot, Professeur au CNRS, pour l'autorisation d'accès aux données du satellite DEMETER

.

## **Résumé :**

L'analyse fractale est devenue un outil très puissant pour l'analyse des signaux en physique. En effet beaucoup de signaux sont à caractère chaotique fractal. Les signaux du plasma ionosphériques sont aussi à caractère très complexe et nécessite cette analyse fractale.

Les réseaux de neurones artificiels sont aussi des outils très robustes qui ont montré leurs capacités de prédiction et de modélisation de plusieurs phénomènes en physique.

Dans ce travail de thèse, les réseaux de neurones artificiels et l'analyse fractale combinée avec la transformée en ondelettes continue sont utilisés pour prédire les paramètres ionosphériques enregistrés par le satellite DEMETER. Les signaux de deux instruments installés à bord de ce satellite sont pris en considération à savoir l'instrument Analyseur du Plasma (IAP) et l'instrument de Langmuir (ISL).

Deux Machines neuronales de type Multilayer Perceptron (MLP) ont été implémentées pour prédire les futures séries chronologiques enregistrées par ces instruments, les résultats obtenus à partir de l'analyse des données enregistrées deux jours avant le la secousse principale du séisme Italien de L'Aquila montrent clairement que ces machines ont une bonne capacité de prédiction mais à très court terme.

La méthode des Maxima du Module de la Transformée en Ondelettes (MMTO) a été appliquée aux données de l'instrument ISL enregistrés deux jours avant le séisme de L'Aquila, elle montre clairement le caractère multifractal de la réponse physique du plasma ionosphérique. L'analyse MMTO des données enregistrées par le même instrument deux mois après le choc principale de ce séisme montre un caractère monofractal.

**Mots clés :** Analyse fractale, réseaux de neurones, DEMETER, Ionosphère, plasma, monofractal, multifractal.

**Abstract:**

Fractal analysis has become a very powerful tool of signal analysis in physics. Indeed many signals are of a fractal chaotic character. Ionospheric plasma signals are also very complex in nature and require this fractal analysis. Artificial neural networks are also very robust tools which have shown their ability to predict and model several phenomena in physics.

In this thesis work, the artificial neural networks and the fractal analysis combined with the continuous wavelet transform are used to predict the ionospheric parameters recorded by the French DEMETER satellite. The signals from two instruments installed on board this satellite are taken into consideration, namely the Instrument Analyzer of Plasma (IAP) and the Langmuir instrument (ISL).

Two Multilayer Perceptron (MLP) neural machines have been implemented to predict future time series recorded by these instruments, the obtained results by analyzing recorded data two days before the main earthquake of the Italian L'Aquila earthquake clearly show that these machines have the capacity of prediction but in the very short term.

The Wavelet Transform Modulus Maxima Lines (MMTO) method was applied to ISL instrument data recorded two days before the L'Aquila earthquake, the obtained results clearly show the multifractal behavior of the physical response of ionospheric plasma. MMTO analysis of data recorded by the same instrument two months after the main shock of this earthquake exhibit a monofractal character.

**Keywords:** Fractal analysis, neural networks, DEMETER, Ionosphere, plasma, monofractal, multifractal.

## الملخص:

أصبح التحليل الفركتلي أداة قوية جدًا لتحليل الإشارات في الفيزياء. في الواقع ، العديد من الإشارات ذات طابع فركتلي. إشارات البلازما الأيونوسفيرية معقدة للغاية بطبيعتها وتتطلب هذا التحليل الفركتلي. الشبكات العصبية الاصطناعية هي أيضًا أدوات قوية جدًا أظهرت قدرتها على التنبؤ بالعديد من الظواهر ونمذجتها في الفيزياء.

في هذا البحث ، تم استخدام الشبكات العصبية الاصطناعية والتحليل النمطي هندسيًا مع التحويل المويجي المستمر للتنبؤ بمعلمات الغلاف الأيوني المسجلة بواسطة القمر الصناعي DEMETER. يتم أخذ الإشارات الصادرة من جهازين مثبتين على متن هذا القمر الصناعي في الاعتبار ، وهما جهاز تحليل البلازما (IAP) وجهاز (ISL) Langmuir.

تم تنفيذ اثنين من الآلات العصبية متعددة الطبقات (MLP) للتنبؤ بالسلسلة الزمنية المستقبلية التي سجلتها هذه الأدوات ، والنتائج التي تم الحصول عليها من تحليل البيانات المسجلة قبل يومين من الزلزال الرئيسي لأكويلا الإيطالي تظهر بوضوح أن هذه الآلات لديها قدرة تنبؤ جيدة ، ولكن على المدى القصير جدًا.

تم تطبيق طريقة Wavelet Transform Modulus Maxima Lines (WTMM) على بيانات أداة ISL المسجلة قبل يومين من زلزال لأكويلا ، مما يُظهر بوضوح الطبيعة متعددة الفركتلات للاستجابة الفيزيائية للبلازما الأيونوسفيرية. يُظهر تحليل WTMM للبيانات المسجلة بواسطة نفس الأداة بعد شهرين من الصدمة الرئيسية لهذا الزلزال شخصية أحادية الفركتل.

**الكلمات المفتاحية:** التحليل النمطي الهندسي المتكرر ، الشبكات العصبية ، ديميتير ، الأيونوسفير ، البلازما ، الفركتل الأحادي ، متعدد الفركتلات

# **Sommaire**

|   |     |
|---|-----|
| <b>Introduction générale</b>  | P3  |
| <b>Chapitre I : Invariance d'échelle et Analyse Multifractale</b>   |     |
| I.1) Introduction   | P6  |
| I.2) Processus multifractals  | P8  |
| I.4) Formalisme multifractal  | P9  |
| I.2) Méthode des Maxima du Module de la Transformée en Ondelettes (MMTO)  | P11 |
| I.2.1) La transformée en ondelettes continue  | P12 |
| Définition  | P12 |
| Ondelette de Morlet   | P13 |
| I.2.2) Analyse des singularités par la transformée en ondelettes continue (TOC)   | P13 |
| - Régularité locale et exposant de Hölder d'une distribution  | P13 |
| - Analyse en ondelette de la régularité locale de Hölder  | P13 |
| I.2.) Détection et identification des singularités avec la transformée en ondelette (maximum du module et ligne maximale de le T.O.C) | P14 |
| Definition  | P14 |
| I.2.4) Transformée en ondelettes des mesures multifractales   | P15 |
| I.2.5) Le formalisme multifractals pour des mesures singulières analysées par les ondelettes  | P15 |
| I.2.6) La méthode des maxima du module de la transformée en ondelette MMTO  | P16 |
| I.2.7) Algorithme de la méthode MMTO  | P17 |
| I.2.8) Puissance de la méthode MMTO de distinction entre monofractal et multifractal  | P17 |
| <br>  |     |
| <b>Chapitre II : Réseaux De Neurones Artificiels</b>  |     |
| II.1) Introduction  | P18 |
| II.2) Généralités Sur Les Réseaux De Neurones   | P18 |
| II.2.1) Historique  | P18 |
| II.2.2) Utilité des RNA   | P21 |
| II.2.3) Limites de réseaux de neurones  | P22 |
| II.3) La neurophysiologie   | P22 |
| II.3.1) Le neurone physique et leurs caractéristiques principales   | P22 |
| II.3.2) Réseaux neuronaux   | P23 |
| II.3.3) L'activation d'un neurone   | P24 |

---

---

## Sommaire

---

|  |     |
|--|-----|
| II.4) Les Réseaux De Neurones Artificiels -RNA                             | P23 |
| II.4.1) Définitions  | P24 |
| II.4.2) Principe de fonctionnement de RNA                                  | P24 |
| II.4) L'apprentissage  | P31 |
| II.5) Classification des RNA selon le mode de propagation                  | P37 |
| II.5.1) Fonction représentable par un perceptron                           | P39 |
| II.5.3) Les perceptrons multicouches par l'algorithme de rétro-propagation | P39 |
| II.5.4) Réseaux de Kohonen   | P41 |
| II.5.5) Réseaux de Hopfield  | P42 |

### **Chapitre III : Prédiction des perturbations ionosphériques par utilisation des réseaux de neurones artificiels. Application aux données des instruments ISL et IAP du satellite DEMETER.**

|   |     |
|---|-----|
| III.1) Introduction   | P44 |
| III.2) Le tremblement de terre de L'Aquila  | P44 |
| III.3) Instrument Langmuir et le satellite DEMETER (ISL)  | P44 |
| III.4) Instrument Analyseur du Plasma (IAP)   | P45 |
| III.5) Analyse des données de l'instrument ISL par réseaux de neurones  | P46 |
| III.6) Analyse des données de l'instrument IAP  | P48 |
| -Prediction of Ionospheric Perturbations Using Artificial Neural<br>Network.Application to ISL Instrument Data- DEMETER Mission | P48 |
| -Ionospheric Data Analysis of Demeter Sattelite Using Neural Network: Application<br>to IAP Instrument                          | P56 |

### **Chapitre IV : Analyse Multifractale par transformée en ondelettes des données du satellite DEMETER avant le séisme de L'Aquila de 2009**

|   |     |
|---|-----|
| IV.1) Introduction  | P57 |
| IV.2) Analyse MMTO  | P61 |
| IV.3) Interprétation des résultats  | P62 |
| IV.4) Conclusion  | P76 |
| Wavelet-Based Multifractal Analysis of DEMETER Satellite Data Before the<br>L'Aquila Earthquake of 2009 | P77 |

---

## Sommaire

---

|   |     |
|---|-----|
| <b>Conclusions générales et Recommandations</b> | P79 |
| <b>Bibliographie</b>                            | P80 |
| <b>Annexe</b>                                   | P81 |

---

# **Introduction générale**

## Introduction générale :

L'étude de la physique du plasma ionosphérique demeure un axe de recherche primordial pour la compréhension de cette composante très importante du globe terrestre. L'ionosphère est une région de l'atmosphère située entre la mésosphère et la magnétosphère, c'est à dire entre 60 et 800 km d'altitude. Elle est constituée de gaz fortement ionisés à très faible pression (entre  $2 \cdot 10^{-2}$  mb et  $1 \cdot 10^{-8}$  mb) et des températures (-20 à +1000°C).

On distingue généralement 3 couches ionosphériques qui se différencient par des propriétés particulières vis-à-vis de la propagation des ondes électromagnétiques, à savoir :

a-Couche D : altitude de 60 à 90 km, pression 2 Pa, température -76°C densité électronique  $10^{10}$  e/m<sup>3</sup>, elle est constituée d'ions polyatomiques. Absorbante pour les ondes de fréquence inférieure à quelques MHz, elle disparaît immédiatement après le coucher du Soleil.

b-Couche E : altitude de 90 à 120 km, pression 0,01 Pa, température -50°C densité électronique  $10^{11}$  e/m<sup>3</sup>. Elle est constituée d'oxygène et monoxyde d'azote moléculaires ionisés et d'ions météoritiques. Diurne et présente tout au long du cycle solaire. Elle réfléchit les ondes de quelques MHz jusqu'à une fréquence limite qui dépend de l'angle d'incidence de l'onde sur la couche et de la densité de celle-ci. Au moment du solstice d'été (mai à août) apparaissent parfois pendant quelques dizaines de minutes, voire quelques heures, des "nuages" fortement ionisés dans la couche E (on parle de "sporadique E" ou "Es")

c-Couche F : altitude de 120 à 800 km, pression  $1 \cdot 10^{-4}$  Pa, température 1000°C densité électronique  $10^{10}$  e/m<sup>3</sup>. Elle est constituée d'atomes d'oxygène, d'azote ainsi que d'hydrogène. Très dépendante de l'activité solaire. Elle est particulièrement présente pendant les maxima du cycle solaire. Son altitude fluctue en fonction du rayonnement solaire et se décompose pendant la journée en deux sous-couches F1 et F2. Elle s'atténue et disparaît la nuit plusieurs heures après le coucher du Soleil mais il arrive qu'elle persiste toute la nuit lors des maxima d'activité solaire. Comme pour la couche E, son rôle est essentiel pour la propagation des ondes courtes.

Un séisme ou tremblement de terre est une secousse du sol résultant de la libération brusque d'énergie accumulée par les contraintes exercées sur les roches. Cette libération d'énergie se fait par rupture le long d'une faille, généralement préexistante. Plus rares sont les séismes dus à l'activité volcanique ou d'origine artificielle (explosions par exemple). Le lieu de la rupture des roches en profondeur se nomme le foyer ; la projection du foyer à la surface est l'épicentre du séisme. Le mouvement des roches près du foyer engendre des vibrations élastiques qui se propagent, sous la

forme de trains d'ondes sismiques, autour et au travers du globe terrestre. Il produit aussi un dégagement de chaleur par frottement, au point de parfois fondre les roches le long de la faille (pseudotachylites).

Il se produit de très nombreux séismes tous les jours mais la plupart ne sont pas ressentis par les humains. Environ cent mille séismes sont enregistrés chaque année sur la planète<sup>1</sup>. Les plus puissants d'entre eux comptent parmi les catastrophes naturelles les plus destructrices. La grande majorité des séismes se produisent à la limite entre les plaques tectoniques (séismes inter-plaques) de la terre, mais il peut aussi y avoir des séismes à l'intérieur des plaques (séismes intra-plaques). Les séismes les plus importants modifient la période de rotation de la Terre et donc la durée d'une journée (de l'ordre de la microseconde).

#### Effet des tremblements de terre sur l'ionosphère :

Cicerone et al., (2009) décrivent 3 papiers historiques concernant les premières mesures satellitaires (Larkina et al., 1989 ; Serebryaskova et al., 1992 ; Parrot, 1994). Ces résultats ont conduit le CNRS et le CNES à mettre en orbite le satellite DEMETER, dont l'objectif premier est d'étudier les perturbations de la haute atmosphère et de l'ionosphère, associées aux phénomènes géophysiques naturels. Cette mission s'est particulièrement penchée sur les émissions électromagnétiques et les perturbations du plasma ionosphérique qui pourraient être engendrées par l'activité sismique ou volcanique et avant les séismes (CNRS & CNES, 2004). L'étude des précurseurs ionosphériques a débuté dans les années soixante (Davies & Baker, 1965) et a été sérieusement investiguée depuis, grâce notamment aux ionogrammes des stations ionosphériques et aux données satellitaires (ISSb, Japon ; DEMETER, France). Les anomalies reportées sont pré-sismiques et co-sismiques. Elles concernent des paramètres aussi variés que :

- La variation de la valeur de la fréquence critique des couches de l'ionosphère, notamment la couche F2 (Chi-Chi, M7.3, 21/09/99 ; étudié par Chuo et al., 2002; Hachinohe, M8.3, 16/05/1968 Hobara et Parrot, 2005 ; et Dabas et al., 2007) ou la couche E-sporadique (Asie Centrale, Liperovsky et al., 2000 ; Hyogo-ken Nanbu, M7.2, 17/01/1995 in Ondoh 2003 et 2004) ;
- L'altitude virtuelle des couches, par exemple de la couche F (Hokkaido, M7.8, 1998, in Ondoh, 1998) ;
- La phase et l'amplitude des ondes VLF/LF sub-ionosphériques (Rozhnoi et al., 2003). Deux méthodes existent : analyse des anomalies de phase et d'amplitude nocturnes pour les longs parcours (Sumatra, 26/12/2004, M9.0 in Horie et al., 2007a et 2007b) ; méthode TT (Terminator Time) d'analyse des minima caractéristiques des variations quotidiennes de phase et d'amplitude au cours du trajet à l'aube et au crépuscule (Kobe M7.2 17/01/1995 in Molchanov et al., 1998) ;

- L'intensité de certaines ondes VLF/LF pouvant circuler dans la partie supérieure de l'ionosphère (signaux dits en « whistler-mode »). Les signaux sont analysés à l'aide du satellite DEMETER (CNRS & CNES, 2004 ; Sarkar et al., 2007 ; Muto et al., 2008) ;

- Les flux brutaux de particules chargées de haute énergie (Aleksandrin et al., 2002 ; Sgrigna et al., 2005) causés par les émissions électromagnétiques ULF d'origine sismique se propageant jusque dans la magnétosphère. Les anomalies ont été observées par des spectromètres magnétiques embarqués à bord des stations MIR, SALYUT-7 et satellites INTERCOSMOS-BULGARIA1300 et METEOR-3 à partir de la fin des années 80. Tous ces phénomènes ont été décrits comme pouvant se produire jusqu'à plusieurs jours avant l'événement (He et al., 2009).

Le travail de cette thèse de Doctorat consiste à faire une analyse non-linéaire des données ionosphériques enregistrées par le satellite DEMETER, la première analyse est une tentative de la prédiction des données enregistrées par ce satellite deux jours le séisme Italien de L'Aquila, la deuxième analyse est une démonstration du comportement multifractal de ces données avant le choc principale du même tremblement de terre et la démonstration du comportement monofractal de ces données ionosphériques dans les jours calmes. Le premier chapitre explique l'analyse fractale et multifractale en combinaison avec la transformée en ondelettes continues, le deuxième chapitre contient la théorie des réseaux de neurones artificiels et le réseau de neurones multicouches, le troisième chapitre montre deux tentatives de prédiction des paramètres ionosphériques enregistrés par deux instruments installés à bord du satellite DEMETER, deux procedings publiés dans la revue Lecture Notes on Computer Sciences ont été dégagées. Le chapitre suivant montre l'apport de la transformée en ondelettes continue et l'analyse fractale dans l'analyse des données ionosphériques deux jours avant le choc principal du séisme de L'Aquila et deux mois après le séisme, une publication dans le revue Arabian Journal of Sciences and Engineering a été dégagée. Nous terminons ce travail de thèse par une conclusion générale et des recommandations

# **Chapitre I : Invariance d'échelle et Analyse Multifractale**

## Introduction

La complexité de certains phénomènes physiques peut contraindre à une description probabiliste et non déterministe de ceux-ci. En effet, même si les équations fondamentales les caractérisant sont connues, le nombre de degrés de liberté qu'elles impliquent ne permet pas une résolution analytique. C'est le cas par exemple du fameux mouvement Brownien, i.e. le mouvement aléatoire d'une particule immergée dans un fluide et soumise à des chocs avec les molécules du fluide environnant. Ainsi, plutôt que de chercher à décrire de façon déterministe la trajectoire (hautement irrégulière) de la particule, une alternative consiste à décrire l'ensemble des trajectoires que la particule pourrait emprunter, par un processus (ou une fonction) aléatoire. Afin d'étudier les systèmes complexes très irréguliers qui impliquent une grande hiérarchie d'échelles (de temps et/ou d'espace), nous allons nous intéresser aux processus, qualifiés de *fractales* depuis Mandelbrot, qui possèdent des propriétés d'autosimilarité (i.e. similarités quand on observe le processus à différentes échelles).

### I.1 Processus fractal

Pour caractériser les propriétés statistiques d'un processus  $X(t)$  à différentes échelles, on étudie ses variations ou incréments à l'échelle  $\ell$  :

$$\delta_\ell X(t) = X(t + \ell) - X(t) \quad (\text{I.1})$$

Notons que nous considérons ici le cas d'un processus temporel (1D) mais toutes les notions introduites ci-après s'étendent naturellement au cas de processus dépendant de plusieurs variables (par exemple une variable d'espace  $\vec{r}$ ). Le processus  $\delta_\ell X(t)$  sera supposé stationnaire (ce qui n'est pas forcément le cas du processus  $X(t)$ ), ses propriétés statistiques ne dépendant donc pas de  $t$  mais uniquement de  $\ell$ .

L'*invariance d'échelle* d'un processus suppose que celui-ci n'est caractérisé par aucune échelle de temps (ou de longueur) privilégiée. Pour de tels processus, on s'attend donc à ce que les fonctions statistiques qui décrivent la dépendance des moments des incréments en fonction de l'échelle soient des lois de puissance. On définit ainsi le spectre des exposants  $\zeta(q)$  à partir du comportement des moments absolus des incréments:

$$\Upsilon(q, \ell) = \langle |\delta_\ell X|^q \rangle \sim \ell^{\zeta(q)} \quad (\text{I.2})$$

Où  $\langle |\delta_\ell X|^q \rangle$  représente l'espérance (quand elle existe) de la quantité  $|\delta_\ell X|^q$ . L'espérance mathématique ci-dessus est souvent (pour des raisons expérimentales évidentes) remplacée par une moyenne temporelle. On définit alors les fonctions de structure d'ordre  $q$  et l'exposant  $\zeta_0(q)$  :

$$S(q, \ell) = \int_{[o, \mathcal{E}]} |\delta_\ell X(t)|^q dt \sim \ell^{\zeta_o(q)} \quad (\text{I.3})$$

où  $[o, \mathcal{E}]$  représente l'intervalle total sur lequel le processus est observé. Notons que bien que  $\langle S(q, \ell) \rangle = Y(q, \ell)$ , nous verrons que les fonctions  $\zeta(q)$  et  $\zeta_o(q)$  ne sont pas forcément identiques, la notation  $\zeta_o(q)$  étant alors justifiée.

On introduit parfois d'autres fonctions qui caractérisent le comportement des incréments dans les échelles; ce sont les fonctions de partition  $Z(q, \ell)$  qui consistent simplement à remplacer la somme continue (intégrale) de l'Eq. (I.3) par une somme discrète sur une partition de  $[o, \mathcal{E}]$  en intervalles de taille  $\ell$ :  $I_\ell(k) = [(k-1)\ell, k\ell], k = 1, \dots, \mathcal{E}/\ell$ . On définit ainsi le spectre  $\tau_o(q)$  par :

$$Z(q, \ell) = \sum_{k=1}^{\mathcal{E}/\ell} |\delta_\ell X((k-1)\ell)|^q \sim \ell^{\tau_o(q)} \quad (\text{I.4})$$

D'après les Eqs. (5.3) et (5.4)  $S(q, \ell) \simeq Z(q, \ell)$ . Ainsi, on montre que les spectres  $\tau_o(q)$  et  $\zeta_o(q)$  sont simplement reliés par:

$$\tau_o(q) = \zeta_o(q) - 1 \quad (\text{I.5})$$

De la même façon, on définit  $\tau(q)$  tel que  $\tau(q) = \zeta(q) - 1$ . Notons que dans le cas où le processus  $X(t)$  est non décroissant, on le dénote en général  $M(t)$  et on le considère comme une *mesure*. Rappelons qu'une mesure  $M(t)$  peut être vue comme une quantité positive (de l'énergie ou de la "masse" par exemple) distribuée dans le temps ou l'espace. Ses incréments sont positifs et peuvent s'écrire :

$$\delta_\ell M(t) = M(t+\ell) - M(t) = \int_t^{t+\ell} dM = M([t, t+\ell]) \quad (\text{I.6})$$

où la quantité  $M(I) \geq 0$  représente la mesure de l'intervalle  $I$ .

Mentionnons pour terminer que le formalisme basé sur les incréments a été généralisé par le groupe d'Arneodo (Arneodo et al, 1995) dans le cadre de l'analyse en ondelettes. L'outil "ondelettes" permet de décomposer un signal temporel sur deux dimensions: le temps et l'échelle. Ainsi un signal  $X(t)$  est décrit par sa transformée en ondelettes qui est définie à l'échelle  $\ell$  et au point  $t$  par:

$$T_\psi[\ell, t] = \frac{1}{\ell} \int_{-\infty}^{+\infty} \bar{\psi}\left(\frac{u-t}{\ell}\right) X(u) du \quad (\text{I.7})$$

$\overline{\psi}$  : est le conjugué.

Où la fonction  $\psi(t)$  est appelée l'ondelette "mère". Sous certaines conditions, cette transformation est inversible et existe dans une version de bases orthogonales discrètes. Dans le cas où  $\psi(t) = \delta(t+1) - \delta(t)$ ,  $\delta(t)$  étant la fonction de Dirac, on retrouve simplement les incréments de  $X(t)$ , soit  $T_\psi[\ell, t] = \delta_\ell X(t)$

Un des principes de l'analyse multifractale en ondelettes consiste donc à remplacer les fonctions de partition (ou de structure) définies dans l'Eq. (I.3) ou (I.4) par les fonctions de partition calculées sur la transformée en ondelettes. Un formalisme fondé sur les maximas de cette transformée (on parle de la méthode "MMTO") permet même d'étendre les fonctions  $Z(q, \ell)$  aux valeurs de  $q$  négatives.

## I.2 Processus multifractals

Un processus  $X(t)$  est *auto-similaire* d'exposant  $H$  si les processus  $X(t)$  et  $s^{-H}(st)$  sont identiques en loi et ce quel que soit le paramètre de dilatation  $s > 0$ . Notons que comme  $X(o)$  et que les incréments de  $X(t)$  sont stationnaires, cela implique

$$\delta_\ell X(t) = s^{-H} \delta_{s\ell} X(t) \quad (\text{I.8})$$

Si l'on note  $\rho_\ell(\delta X)$  la densité de probabilité des incréments de  $X(t)$  à l'échelle  $\ell$ , alors l'égalité précédente se réécrit:

$$\rho_\ell(\delta X) = s^{-H} \rho_{s\ell}(s^{-H} \delta X) \quad (\text{I.9})$$

Autrement dit, si l'on normalise à chaque échelle les incréments afin qu'ils aient une variance unité, dans le cas d'un processus auto-similaire (au sens strict), les lois de probabilité des incréments ne dépendent pas de l'échelle considérée.

Notons que le mouvement Brownien (ou la famille de processus Browniens fractionnaires) est l'exemple le plus connu de processus auto-similaires d'exposant de Hurst  $H = 1/2$  (ou  $0 < H$  dans le cas du Brownien fractionnaire) (Arnéodo et Bacry, 1995). Les densités de probabilité sont des Gaussiennes centrées à toute échelle (il est bien connu que la densité de probabilité des variations d'un mouvement Brownien à l'échelle  $\ell$  est Gaussienne d'espérance nulle et de variance proportionnelle à  $\ell$ ).

Si l'on calcule les moments  $\Upsilon(q, \ell)$  tels que définis dans l'Eq. (I.2), alors d'après l'Eq. (I.8) on voit directement que, dans le cas d'un processus auto-similaire, on a:

$$\zeta(q) = qH \quad (\text{I.10})$$

Un processus sera qualifié de *monofractal* si la fonction  $\zeta(q)$  (ou  $\tau(q)$ ) est une fonction linéaire de  $q$ . Sa pente, notée  $H$ , est alors appelée exposant de Hurst du processus. Nous voyons donc que les processus auto-similaires sont des processus monofractals.

Un objet multifractal est plus complexe dans le sens où la fonction  $\zeta(q)$  qui le caractérise est non linéaire. Comme les moments  $\Upsilon(q, \ell)$  (ou les fonctions de structure) demeurent des fonctions qui se comportent en loi de puissance, on s'attend à ce que le processus  $X(t)$  soit aussi, dans ce cas, caractérisé par des propriétés d'autosimilarité mais dans un sens plus large. En effet, il est facile de voir que si  $\zeta(q)$  est strictement concave, alors les lois de probabilité ne peuvent pas, comme dans le cas monofractal, conserver la même forme à toute échelle.

### I.3 Formalisme multifractal

Le formalisme multifractal a été introduit par Parisi et Frisch (1985) dans le but d'interpréter la multifractalité telle qu'introduite précédemment en termes de propriétés de régularité ponctuelle d'un processus. Cette régularité est quantifiée par l'exposant de Hölder au point  $t_o$ . Sans soucis de rigueur mathématique, l'exposant de Hölder  $h(t_o)$  de la fonction  $X(t)$  au point  $t_o$  est défini à partir du comportement local des incréments dans la limite des petites échelles :

$$\delta_\ell X(t_o) \sim \ell^{h(t_o)} \quad (\text{I.11})$$

$\ell \rightarrow 0$

Notons que dans le cadre de l'étude des mesures, l'exposant de régularité locale est souvent noté  $\alpha(t_o)$  et défini par:

$$M(I_\ell(t_o)) \sim \ell^{\alpha(t_o)} \quad (\text{I.12})$$

$\ell \rightarrow 0$

Considérons une trajectoire de  $X(t)$  et définissons  $A(h)$  comme l'ensemble des points  $t_o$  d'exposant iso-Hölder  $h: A(h) = \{t_o, h(t_o) = h\}$ . On appelle *spectre des singularités* la fonction  $D_o(h)$  qui donne la dimension fractale (la dimension de Hausdorff) de  $A(h)$  en fonction de  $h$ . Pour les mesures, le spectre des singularités est en général noté  $f_o(\alpha)$ .

Remarquons que, le spectre des singularités étant une dimension fractale d'un ensemble contenu dans un espace de dimension 1, on a  $0 \leq D_o(h) \leq 1$ . On appellera  $h_*$ , la singularité la plus forte et  $h^*$  la singularité la plus faible:

$$h_* = \min \{h, D_o(h) \geq 0\} \quad (\text{I.13})$$

$$h^* = \max \{h, D_o(h) \geq 0\} \quad (\text{I.14})$$

On supposera enfin que  $D_o(h)$  est une fonction concave et dérivable de  $h$ .

L'idée de Frish et Parisi est d'expliquer la non-linéarité de  $\zeta_o(q)$ , tel que définie dans l'Eq. (I.3), en termes de distribution des singularités. L'heuristique est la suivante : si  $D_o(h)$  est la dimension fractale de  $A(h)$ , alors à l'échelle  $\ell$ , il faut  $\ell^{-D_o(h)}$  intervalles de taille  $\ell$  pour recouvrir  $A(h)$  et donc, dans la somme (I.3) il y aura une fraction  $\ell^{-D_o(h)}$  des  $\ell^{-1}$  incréments de taille  $\ell$  qui correspondra à un exposant de Hölder  $h$ . Leur nombre est donc  $N_h(\ell) \sim \ell^{1-D_o(h)}$ . On peut ainsi réécrire la fonction de structure :

$$S_{q,\ell} \simeq \int_{h \in [h_*, h^*]} \ell^{qh+1-D_o(h)} dh \quad (\text{I.15})$$

Si on considère le comportement asymptotique de cette fonction dans la limite  $\ell \rightarrow 0$ , alors, par une méthode de Laplace d'approximation de l'intégrale et d'après la définition de  $\zeta_o(q)$ , on a :

$$\zeta_o(q) = 1 + \min_h \{qh - D_o(h)\} \quad (\text{I.16})$$

Autrement dit le spectre  $\zeta_o(q)$  est la transformée de Legendre du spectre des singularités  $D_o(h)$ . Compte tenu de l'hypothèse de concavité de  $D_o(h)$ , la relation (I.16) s'inverse et exprime  $D_o(h)$  comme une transformée de Legendre de  $\zeta_o(q)$  :

$$D_o(h) = 1 + \min_q \{qh - \zeta_o(q)\} \quad (\text{I.17})$$

En supposant  $D_o(h)$  et  $\zeta_o(q)$  différentiables, les deux équations précédentes se réécrivent sous la forme paramétrique suivante, plus classique en thermodynamique :

$$\zeta_o(h) = h \frac{dD_o(h)}{dh} - D_o(h) \text{ et } q = \frac{dD_o(h)}{dh} \quad (\text{I.18})$$

$$D_o(q) = q \frac{d\zeta_o(q)}{dq} - \zeta_o(q) \text{ et } h = \frac{d\zeta_o(q)}{dq} \quad (\text{I.19})$$

Remarquons que dans le cas monofractal, on a  $\zeta_o(q) = qH$ , ce qui conduit directement à  $D_o(h = H) = 1$  avec  $h_* = h^* = H$ . Autrement dit, la régularité du processus est constante, un seul exposant de Hölder  $h = H$  caractérise ses trajectoires et le spectre des singularités est supporté par un seul point.

Les Eqs. (I.16) et (I.17) ou (I.18) et (I.19), qui relie la non-linéarité de  $\zeta_o(q)$  aux fluctuations des exposants de singularité ponctuelle du processus, sont appelées *formalisme multifractal*. La validité du formalisme multifractal a été établi pour une grande classe de fonctions multifractales ainsi que pour les modèles de cascades discrètes et continues tels que définis dans la section suivante. Il existe une description alternative introduite par Mandelbrot (1974) qui implique non pas un spectre des singularités défini en termes de dimension d'ensemble d'iso-singularité mais qui met en jeu la probabilité d'observer en un point fixé  $t_o$  un exposant de Hölder  $h$  à une échelle donnée. Le processus étant à incréments stationnaires, cette probabilité ne dépend pas de  $t_o$ . On définit ainsi  $D(H)$  par :

$$D(H) = \text{Pr ob} \left\{ \delta_\ell X(t_o) \sim \ell^h \right\} \sim \ell^{1-D(H)} \quad (\text{I.20})$$

$\ell \rightarrow 0$

#### I.4 Méthode des Maxima du Module de la Transformée en Ondelettes (MMTO)

La transformée en ondelettes est introduite en 1983 par le géophysicien François Morlet dans les études des signaux sismiques. Morlet a montré que la transformée de Fourier courte (avec fenêtre glissante) est non adaptée pour analyser les signaux avec différentes échelles. Il a construit une nouvelle transformation qui effectue une représentation espace-échelle du signal.

Cette transformation consiste à décomposer le signal en somme de fonctions élémentaires  $\Psi_{a,b}$  obtenues par translation et dilatation d'une ondelette mère  $\Psi$  et qui est une fonction simple

$$\Psi_{a,b} = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right)$$

En 1984 Grossman, Morlet formalisent cette nouvelle transformation et montrent que le signal peut se décomposer effectivement si et seulement si la fonction mère est oscillante donc ressemble à une ondelette.

### I.4.1 La transformée en ondelettes continue

On considère une fonction  $S(x) \in L^2(R, dx)$ , dont  $L^2$  est l'espace de Hilbert d'ordre 2. La transformée en ondelettes de la fonction  $S(x)$  est la décomposition de  $S$  en termes de fonctions élémentaires obtenues par dilatation et translation de l'ondelette mère  $\Psi(x)$ .

On définit la famille d'ondelette  $\Psi_{a,b}(x)$  par :

$$\Psi_{a,b}(x) = a^{-1/2} \Psi\left(\frac{x-b}{a}\right)$$

La transformée en ondelette (TO) de  $S(x)$  est définie par :

$$T_\Psi[S](b, a) = \langle \Psi_{b,a} / S \rangle_{L^2(R, dx)} = \frac{1}{\sqrt{a}} \int_R \overline{\Psi\left(\frac{x-b}{a}\right)} S(x) dx \quad (I.21)$$

Dont  $\langle \cdot / \cdot \rangle_{L^2(R, dx)}$  est le produit scalaire dans  $L^2(R, dx)$ .

$\overline{\Psi}$  : Est le conjugué.

Le paramètre  $b$  est la valeur réelle de l'espace ou du temps et  $a$  est un paramètre d'échelle ( $a \in R^{*+}$ ).

Dans le domaine des fréquences l'ondelette transformée est écrite sous la forme :

$$T_\Psi[S](b, a) = \frac{1}{\sqrt{a}} \int_R \overline{\hat{\Psi}(a\omega)} \hat{S}(x) e^{ib\omega} d\omega \quad (I.22)$$

Avec  $\hat{S}(\omega) = \int_R S(x) e^{ib\omega} dx$  représente la TF de la fonction  $S(x)$  ; donc a une dilatation  $a$  fixe la transformée en ondelette correspond au filtrage de la fonction  $S$  par le filtre passe bande  $\overline{\hat{\Psi}(a\omega)}$ .

#### - Ondelette de Morlet

Un exemple historique d'ondelette analysante est celle de Morlet et ses collaborateurs, elle est définie comme une gaussienne translatée dans le domaine fréquentiel (Arneodo et Bacry, 1995):

$$\hat{g}_\Omega(\omega) = \exp(-(\omega - \Omega)^2) - \exp(-\Omega^2/4) \exp(-(\omega - \Omega)^2/4)$$

Sa transformée de Fourier inverse est la suivante :

$$g_\omega(t) = \exp(i\omega t) \exp(-t^2/2) - \sqrt{2} \exp(-\Omega^2/4) \exp(i\omega t) \exp(-t^2) \quad (I.23)$$

Cette fonction est appelée ondelette de Morlet. Notons que si  $\Omega$  est très grand

$$g_\omega(t) \approx \exp(i\Omega t) \exp(-t^2/2)$$

### I.4.2) Analyse des singularités par la transformée en ondelettes continue (TOC)

#### - Régularité locale et exposant de Hölder d'une distribution

Le coefficient de singularité au point  $x_0$  peut s'exprimer par un exposant appelé exposant de Hölder. Cet exposant est défini comme suit :

L'exposant de Hölder de la distribution  $f$  au point  $(x_0)$  est le plus grand  $h$ , dont  $f$  est lespshitizienne d'exposant  $h$  au point  $(x_0)$ . C'est-à-dire il existe une constante  $C$  et un polynôme  $P_n(x)$  d'ordre  $n$  tel que pour tout  $x$  appartenant au voisinage de  $x_0$  on a :

$$|f(x) - P_n(x - x_0)| \leq |x - x_0|^h \quad (\text{I.24})$$

Si  $h(x_0) \in ]n, n+1[$  on peut montrer facilement que :  $f(x) \in C^n$  et  $f(x) \notin C^{n+1}$  au point  $x_0$ .

Le polynôme  $P_n(x)$  correspond à la série de Taylor de  $f$  au point  $x_0$ .  $h(x_0)$  mesure comment la distribution  $f$  est irrégulière au point  $x_0$ , c'est-à-dire :

$h(x_0)$  est très élevé  $\Leftrightarrow f$  est régulière.

Il faut noter que si  $h$  est l'exposant de Hölder de  $f$  au point  $x_0$ , dans la plupart des cas  $h(x_0) = h+1$  pour la primitive de  $f$ , et  $h(x_0) = h-1$  pour la dérivée.

#### - Analyse en ondelette de la régularité locale de Hölder

On suppose que l'exposant de Hölder de la distribution  $f(x)$  autour du point  $x=x_0$  est  $h(x_0) \in ]n, n+1[$ . Le développement de  $f(x)$  autour de  $x=x_0$  est donné par :

$$f(x) = C_0 + C_1(x - x_0) + \dots + C_n(x - x_0)^n + C|x - x_0|^{h(x_0)} \quad (\text{I.25})$$

La transformée en ondelette de  $f$  est le produit scalaire de  $f$  avec la famille d'ondelettes

$\Psi_{a,b}(x) = a^{-1/2} \overline{\Psi}\left(\frac{x-b}{a}\right)$ . Si on suppose que l'ondelette analysante est à  $n_\Psi > n$  moments ; alors

$\Psi_{a,b}(x)$  est orthogonale avec tout polynôme de degré  $n$ , donc la transformée en ondelettes quand  $a \rightarrow 0$  est donnée par :

$$\begin{aligned} T_\Psi[f](x_0, a) &= Ca^{1/2} \int_R \overline{\Psi}\left|\frac{x-b}{a}\right|^{h(x_0)} dx \\ &= a^{h(x_0)+1/2} CT_\Psi[f_0](x_0, a) \end{aligned}$$

Pour simplifier le calcul on définit la TOC par

$$T_a[f](b, a) = 1/a \int_R \overline{\Psi}\left(\frac{x-b}{a}\right) f(x) dx$$

Ce qui implique :  $T\psi_a[f](x_0, a) \approx a^{h(x_0)}$  ;  $a \mapsto 0$  (I.26)

Donc le terme de singularité  $|x - x_0|^{h(x)}$  de  $f$  autour de  $x=x_0$  est caractérisé par un exposant  $h(x)$ , pour des petites échelles  $a \xrightarrow{+} 0$ , si  $f \in C^\infty$  au point  $x_0$

$$\psi_a[f](x_0, a) \approx a^n \psi, \quad a \mapsto 0^+$$

### I.4.3 Détection et identification des singularités avec la transformée en ondelette (maximum du module et ligne maximale de le T.O.C)

On appelle maximum du module de la transformée en ondelette en n'importe quel point  $(x_0, a_0)$  du demi plan espace-échelle la valeur correspondant au maximum local de  $T_\psi[f]$  que l'on considère comme une fonction de  $x_0$ , c'est-à-dire :  $|T_\psi[f](x_0, a_0)| > |T_\psi[f](x, a_0)|$  pour tout  $x$  au voisinage de  $x_0$ . On appelle ligne maximale n'importe quelle connexion dans le demi-plan espace-échelle des modules maximaux. Mallat et Hwang (1992) ont montré que le développement singulier de la distribution autour d'un point  $x_0$  implique qu'il existe une ligne maximale qui converge vers  $x_0$  quand  $(a \mapsto 0)$ . Maintenant s'il n'existe pas des lignes maximales. Alors la distribution est uniformément Lipshitzienne avec un coefficient de Lipshitz  $n_\psi$  au voisinage de  $x_0$  (c'est-à-dire  $h(x) \geq n_\psi$  au voisinage de  $x_0$ ). Les lignes maxima de la transformée en ondelettes donne une information sur la position des singularités de la distribution  $f$ .

#### Remarque

Pour calculer l'exposant de singularité de Hölder au point  $x_0$  on représente  $T_\psi[f](x_0, a) = g(Ln(a)) = h(x_0)Ln(a)$  qui a l'allure d'une ligne avec une pente égale à  $h(x_0)$ .

### I.4.4 Transformée en ondelettes des mesures multifractales

On considère  $M(x)$  une mesure multifractale, singulière au point  $x_0$ , une singularité est caractérisée toujours par un exposant  $\alpha(x_0)$ :

On a vu déjà que  $\mu(B_{x_0}(\varepsilon)) \approx \varepsilon^{\alpha(x_0)}$ ; dont  $(B_{x_0}(\varepsilon))$  est une boule de taille  $\varepsilon$  centré à  $x_0$ . Si  $S(x)$  est la fonction de distribution associée à la mesure,  $\mu[S(x)] = \mu([0, x])$

On peut prouver que  $h(x_0) = \alpha(x_0)$ , car la transformée en ondelette  $T_\psi[M](x_0, a)$  est définie par :

$$T_\psi[\mu](x_0, a) \approx a^{\alpha(x_0)} \quad a \mapsto 0$$

Avec la transformée en ondelettes de la mesure  $\mu$  définie comme suit :

$$T_\psi[\mu](b, a) = \int_R \Psi\left(\frac{x-b}{a}\right) d\mu \quad (\text{I.27})$$

#### I.4.5 Le formalisme multifractal pour des mesures singulières analysées par les ondelettes

L'exposant de Hölder  $h(x_0)$  est un paramètre qui permet de mesurer la force de singularité du spectre  $D(h)$  qui est défini par

$$D(h) = d_F(\{x_0 \in R / h(x_0) = h\}) \quad (\text{I.28})$$

où  $d_F$  : la dimension fractale. C'est un spectre qui mesure l'histogramme des singularités.

La partition associée à la nouvelle fonction de partition qu'on va définir doit satisfaire deux conditions :

- Elle ne doit couvrir que les parties singulières du signal.
- Chaque élément doit mesurer localement l'exposant de Hölder.

Les maxima du module de la TOC vérifient parfaitement ces deux exigences. A une échelle donnée et à un maximum local à la position  $x_0$  ces maxima reflètent un changement brusque dans le signal et donc un comportement singulier.

D'autre part le comportement de la TOC le long d'une ligne de maxima pointe vers  $x_0$  de plus elle se comporte comme  $a^{h(x_0)}$  si  $a \mapsto 0^+$ .

Il est donc nécessaire de définir la fonction de partition du signal à une échelle  $a$  donnée avec les ondelettes de taille  $a$  et positionnée aux endroits des maxima locaux du module. La fonction de partition est donc définie par :

$$Z(q, a) = \sum_{b_i} |T_\psi[S](b, a)|^q \quad (\text{I.29})$$

Dont  $\{(b_i, a)\}_i$  est l'ensemble des maxima locaux à l'échelle  $a$  et  $q \in R$ , l'exposant  $\tau(q)$  est défini alors par :

$$Z(q, a) \approx a^{\tau(q)}, \quad a \mapsto 0^+ \quad (\text{I.30})$$

Le spectre  $D(h)$  des singularités d'une fonction  $S$  est défini comme la transformée de Legendre de  $\tau(q)$  :

$$D(h) = \min_q (qh - \tau(q)) \quad (\text{I.31})$$

Les équations (I.29), (I.30) et (I.31) constituent la généralisation aux distributions singulières du formalisme multifractal. Le spectre  $D(h)$  des singularités permet en effet de décrire aussi bien les mesures multifractales que les signaux multifractals.

L'approche qui consiste à estimer  $D(h)$  à partir de la transformée de Legendre de  $\tau(q)$  est généralement appelée la méthode MMT (Maxima des Modules de la Transformée en Ondelettes).

### I.4.6 La méthode des maxima du module de la transformée en ondelettes MMTO

La méthode MMTO est un formalisme introduit par Arneodo et ses collaborateurs (1998) dans les études de la turbulence. Elle est représentée par les équations (I.29), (I.30) et (I.31). Les études faites sont consacrées essentiellement à la classe des fonctions fractales qui s'écrivent sous la forme :

$$f(x) = \int_0^x dM + r(x)$$

où  $r(x) \in C^\infty$  représente la partie régulière du signal fractal.

$\delta(x) = \int_0^M dM$ , modélise la partie singulière de la fonction  $f(x)$ .

### I.4.7 Algorithme de la méthode MMTO

La méthode MMTO est décomposée en deux parties :

1. Calcul de la transformée en ondelettes et calcul des maxima locaux de son Module.
2. Calcul des fonctions de partitions, mesure des exposants  $\tau(q)$  et transformation de Legendre.

Le calcul des maxima locaux est effectué à l'aide du calcul de la première et de la seconde dérivée des coefficients d'ondelette,  $T_\psi$  admet un maximum au point  $x_0$  si elle vérifie les deux conditions suivantes :

$$\begin{aligned} \frac{\partial T}{\partial x} &= 0 & \text{si : } x = x_0 \\ \frac{\partial^2 T_\psi}{\partial^2 x} &< 0 & \text{si : } x = x_0 \end{aligned}$$

Dans la seconde partie de l'algorithme le point délicat concerne le calcul de la transformée de Legendre car le calcul de cette dernière peut entraîner dans certains cas un biais dans la détermination du spectre  $D(h)$ . Le calcul s'effectue à l'aide du calcul des fonctions suivantes (Arnéodo et Bacry, 1995) :

$$\begin{cases} \langle h \rangle (q, a) = \sum_{(b_i, a)} \hat{T}_\psi [S](q, b_i, a) \text{Ln} |T_\psi [S](b_i, a)| \\ D(q, a) = \sum_{(b_i, a)} \hat{T}_\psi [S](q, b_i, a) \text{Ln} |T_\psi [S](q, b_i, a)| \end{cases} \quad (\text{I.32})$$

Dont  $\hat{T}$  est le poids de « Boltzmann » défini par :

$$\hat{T}_\psi[S](q, b, a) = |T_\psi[S](b_i, a)|^q / Z(q, a)$$

$$h(q) = \lim_{a \rightarrow 0^+} \frac{1}{\text{Ln}(a)} h(q, a) \quad (\text{I.33})$$

$$D(q) = \lim_{a \rightarrow 0^+} \frac{1}{\text{Ln}(a)} D(q, a)$$

Le spectre  $D(h)$  est obtenu en représentant  $D(q)$  en fonction de  $h(q)$  pour différentes valeurs de  $q$ .

#### I.4.8 Puissance de la méthode MMTO de distinguer entre monofractal et multifractal

Parmi les points forts les plus importants de la MMTO est la distinction entre le caractère monofractal et multifractal des signaux, en effet le calcul du spectre des singularités a permis de vérifier la nature du signal car il donne l'ensemble des exposants de singularités (Arnéodo et al, 2002).

# **Chapitre II : Théorie des Réseaux de Neurones Artificiels**

## Introduction

Un réseau de neurones artificiels est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement des neurones biologiques. Les réseaux de neurones sont généralement optimisés par des méthodes d'apprentissage de type probabiliste, en particulier Bayésiens. Ils sont placés d'une part dans la famille des applications statistiques, qu'ils enrichissent avec un ensemble de paradigmes permettant de générer des classifications rapides (réseaux de Kohonen en particulier), et d'autre part dans la famille des méthodes de l'intelligence artificielle.

En modélisation des circuits biologiques, ils permettent de tester quelques hypothèses fonctionnelles issues de la neurophysiologie, ou encore les conséquences de ces hypothèses pour les comparer au réel. Le neurone biologique est une cellule vivante spécialisée dans le traitement des signaux électriques. Les neurones sont reliés entre eux par des liaisons appelées axones. Ces axones vont eux-mêmes jouer un rôle important dans le comportement logique de l'ensemble. Ils transmettent les signaux électriques de la sortie d'un neurone vers l'entrée (synapse) d'un autre neurone. Les neurones font une sommation des signaux reçus en entrée et en fonction du résultat obtenu, vont fournir un courant en sortie.

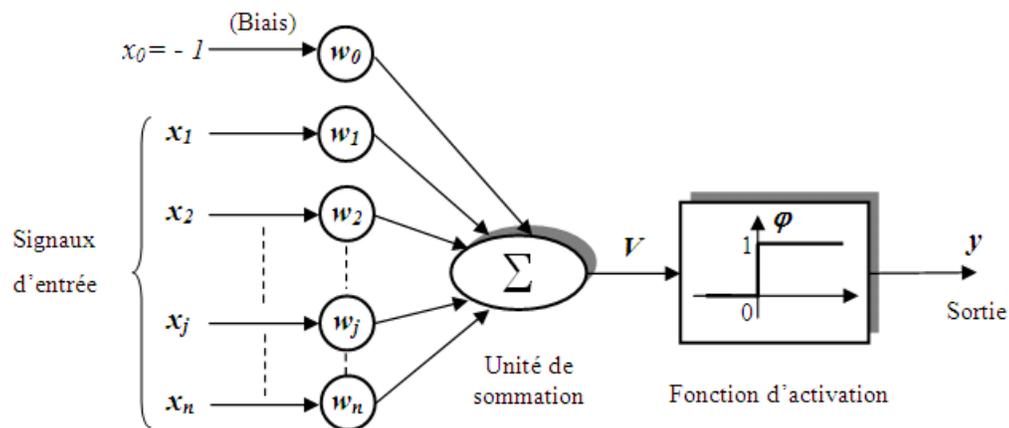
Les réseaux de neurones biologiques réalisent un certain nombre d'applications telles que la reconnaissance des formes, le traitement du signal, l'apprentissage par l'exemple et la mémorisation. C'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau que les réseaux de neurones artificiels, désigné dans ce travail par RNA, se sont développés. Il est nécessaire de mettre en œuvre des réseaux de neurones pour toute application nécessitant de trouver, par apprentissage, une relation non linéaire entre des données numériques. Le réseau de neurones artificiels est basé sur un modèle simplifié du neurone biologique. Les RNA sont donc des modèles et à ce titre, ils peuvent être décrits par leurs composantes, leurs variables descriptives et les interactions des composantes.

## II.1 Généralités Sur Les Réseaux de Neurones

### II. 1.1.Historique

Les neurologues Warren Mc Culloch et Walter Pitts publièrent dès la fin des années 1950 les premiers travaux sur les réseaux de neurones. Ils constituèrent ensuite un modèle simplifié de neurone biologique communément appelé neurone formel. Ils montrèrent que des réseaux de neurones formels simples peuvent théoriquement réaliser des fonctions logiques, arithmétiques et symboliques complexes.

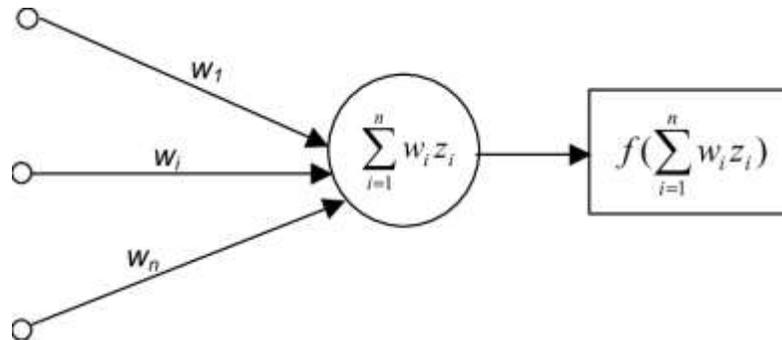
Le neurone formel est conçu comme un automate doté d'une fonction de transfert qui transforme ses entrées en sortie selon des règles précises. Par exemple, un neurone somme ses entrées, compare la somme résultante à une valeur seuil, et répond en émettant un signal si cette somme est supérieure ou égale à ce seuil. Enfin, l'efficacité de la transmission des signaux d'un neurone à l'autre peut varier : on parle de "poids synaptique", et ces poids peuvent être modulés par des règles d'apprentissage (voir fig II.1).



**Fig. II.1.** Modèle du neurone formel de Mac Culloch et Pitts (1943).

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 décrits dans son ouvrage *The Organization of Behaviour*. 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. Cette règle aujourd'hui connue sous le nom de « règle de Hebb » est presque partout présente dans les modèles actuels.



**Fig. II.2.** Modèle d'un réseau de neurone, perceptron (Benahmed, 2002).

L'idée se sema au fil du temps dans les esprits, et elle germa dans l'esprit de Franck 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 (Fig II.2).

En 1969, un coup grave fut porté à la communauté scientifique gravitant autour des réseaux de neurones : Marvin Lee Minsky et Seymour Papert publièrent un ouvrage mettant en exergue quelques limitations théoriques du Perceptron, et plus généralement des classifieurs linéaires, notamment l'impossibilité de traiter des problèmes non linéaires ou de connexité. Ils étendirent implicitement ces limitations à tous modèles de réseaux de neurones artificiels.

En 1982, le physicien John Joseph Hopfield, 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 redevint un 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-linéaires. En 1984, c'est le système de rétropropagation du gradient de l'erreur qui est le sujet le plus débattu dans le domaine.

Une révolution survient alors dans le domaine des réseaux de neurones artificiels : une nouvelle génération de réseaux de neurones, capables de traiter avec succès des phénomènes non-linéaires. Ces systèmes reposent sur la rétropropagation du gradient de l'erreur dans des systèmes à plusieurs couches, chacune de type Adaline de Bernard Widrow, proche du Perceptron de Rumelhart (1962).

Les réseaux de neurones ont par la suite connu un essor considérable, et ont fait partie des premiers systèmes à bénéficier de l'éclairage de la théorie de la « régularisation statistique » introduite par Vladimir Vapnik en Union soviétique et popularisée en occident depuis la chute du mur. Nous présentons dans ce qui suit un bref historique des réseaux de neurone artificiels.

### **II.1.2. Utilité des RNA**

Grâce à leur capacité de classification et de généralisation, les réseaux de neurones sont généralement utilisés dans des problèmes de nature statistique, tels que la classification automatique de codes postaux ou la prise de décision concernant un achat boursier en fonction de l'évolution des cours.

Le réseau de neurones ne fournit pas toujours de règle exploitable par un humain. Le réseau reste souvent une boîte noire qui fournit une réponse quand on lui présente une donnée, mais le réseau ne fournit pas de justification facile à interpréter.

Les réseaux de neurones sont réellement utilisés, par exemple :

- Pour la classification d'espèces animales par espèce étant donnée une analyse ADN.
- Reconnaissance de motif ; par exemple pour la reconnaissance optique de caractères (OCR), et notamment par les banques pour vérifier le montant des chèques, par La Poste pour trier le courrier en fonction du code postal, etc. ; ou bien encore pour le déplacement automatisé de robots mobiles autonomes.
- Approximation d'une fonction inconnue.
- Modélisation accélérée d'une fonction connue mais très complexe à calculer avec exactitude ; par exemple certaines fonctions d'inversions utilisées pour décoder les signaux de télédétection émis par les satellites et les transformer en données sur la surface de la mer.

- Estimations boursières : Apprentissage de la valeur d'une entreprise en fonction des indices disponibles.
- Tentatives de prédiction sur la périodicité des cours boursiers.
- Modélisation de l'apprentissage et amélioration des techniques de l'enseignement.
- En météorologie, pour la classification de conditions atmosphériques et la prévision statistique du temps.

### **II. 1.3.Limites de réseaux de neurones**

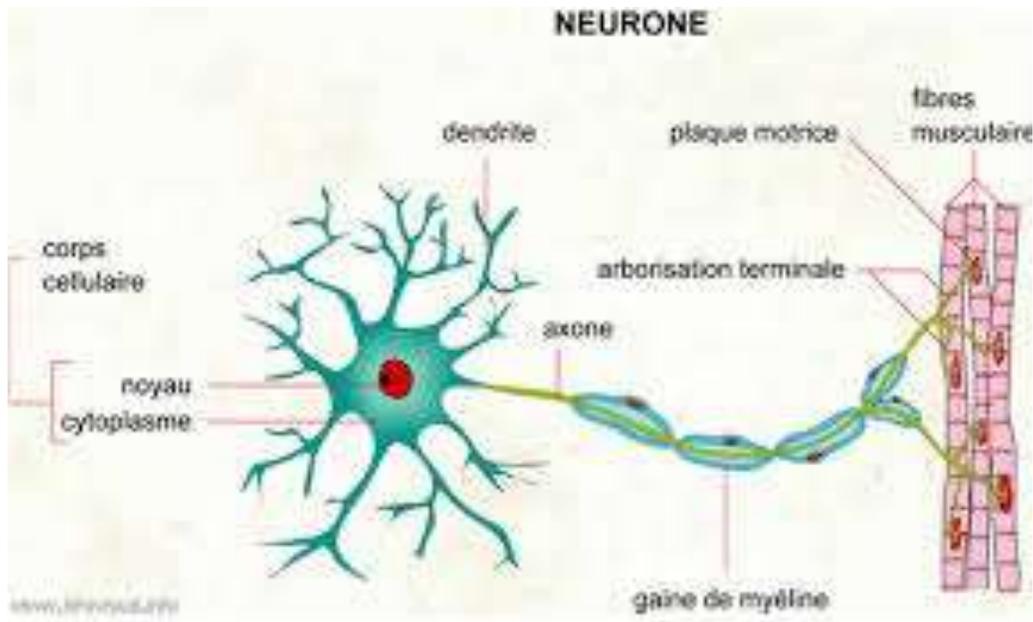
- Les réseaux de neurones artificiels ont besoin de cas réels servant d'exemples pour leur apprentissage (on appelle cela la base d'apprentissage). Ces cas doivent être d'autant plus nombreux que le problème est complexe et que sa topologie est peu structurée.
- Il y a des problèmes qui se traitent bien avec les réseaux de neurones, en particulier ceux de classification en domaines convexes (c'est-à-dire tels que si des points A et B font partie du domaine, alors tout le segment AB en fait partie aussi). Des problèmes comme "Le nombre d'entrées à 1 (ou à zéro) est-il pair ou impair ?" se résolvent en revanche très mal : pour affirmer de telles choses sur 2 puissance N points, si on se contente d'une approche naïve mais homogène, il faut précisément N-1 couches de neurones intermédiaires, ce qui nuit à la généralité du procédé.

## **II.2 La Neurophysiologie**

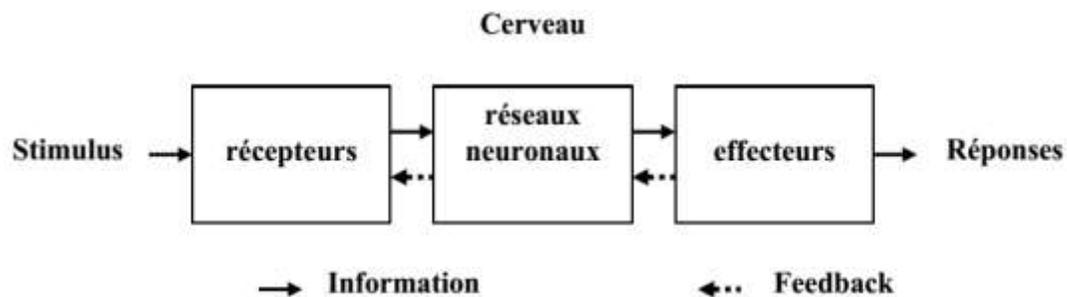
### **II. 2.1. Le neurone physique et leurs caractéristiques principales**

Le neurone est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former ce que l'on nomme les dendrites. C'est par les dendrites que l'information est acheminée de l'extérieur vers le soma, corps du neurone. L'information traitée par le neurone chemine ensuite le long de l'axone pour être transmise aux autres neurones. La transmission entre deux neurones n'est pas directe. Il existe un espace intercellulaire de quelques dizaines d'Angström ( $10^{-9}$  m) entre l'axone du neurone afférent et les dendrites du neurone efférent. La jonction entre deux neurones est appelée la synapse (Fig. II.3).

Les réseaux de neurones sont utilisés pour résoudre des cas complexes en optimisation non linéaire. Les techniques utilisées sont basées sur le fonctionnement des neurones du cerveau. Le système nerveux est un système à trois étages (Fig. II.4).



**Fig. II.3.** Schéma synoptique simplifié d'un neurone biologique (Abdallah et Bouzzgarou, 2012).



**Fig. II.4.** Principe de fonctionnement du système nerveux

## II. 2.2. Réseaux neuronaux

Nous avons vu que chaque neurone est une unité autonome au sein du cerveau. Le neurone reçoit en continu des entrées. Le corps cellulaire du neurone, centre de contrôle, concentre les informations reçues pour ensuite être interprétées. La réponse, unique, à ces

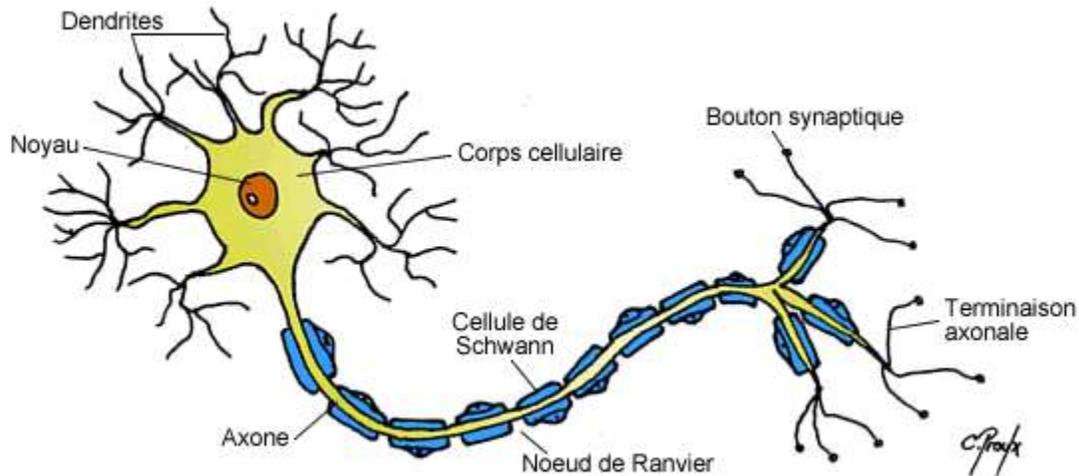
signaux est envoyée au travers de l'axone. L'axone transmet le message aux autres neurones. Le signal transmis peut avoir un effet excitateur ou inhibiteur. Le traitement très simple réalisé par chaque neurone indique que l'information n'est pas stockée dans les neurones, mais est plutôt le résultat du comportement de toute la structure interconnectée. L'information est, principalement, dans l'architecture des connexions et dans la force de ces connexions.

### **II.2.3. L'activation d'un neurone**

L'ensemble des signaux d'entrée (excités et inhibés) est moyenné. Si cette moyenne est suffisamment importante sur un laps de temps très court, la cellule délivre un signal électrique aux cellules suivantes par l'intermédiaire de son axone. Les impulsions délivrées (ou potentiel d'action) sont du type tout ou rien. Cela signifie que les neurones communiquent entre eux en langage binaire. Les réseaux neuronaux sont basés sur cette logique.

### **II.3 Les Réseaux de Neurones Artificiels (RNA) :**

Un réseau de neurones artificiels basé sur un modèle simplifié du neurone. Ce modèle permet de réaliser certaines fonctions du cerveau. Parmi ces fonctions la mémorisation associative, l'apprentissage par l'exemple, le travail en parallèle. Cependant le neurone formel ne possède pas toutes les capacités des neurones biologiques (comme le partage de synapses, l'activation membranaire ou la structuration prénatale des neurones). Par conséquent les réseaux de neurones artificiels actuels sont loin d'intégrer toutes les possibilités du cerveau). Le neurone artificiel s'inspire largement du neurone naturel. Il est donc constitué d'entrées et d'une sortie qui peut être dédoublée. La valeur de sortie est une fonction pondérée des valeurs d'entrée qui est modulée par une autre fonction généralement sigmoïde. On obtient donc un intégrateur dont la sortie se déclenche si la somme des entrées est supérieure à un seuil (Figure II.6).

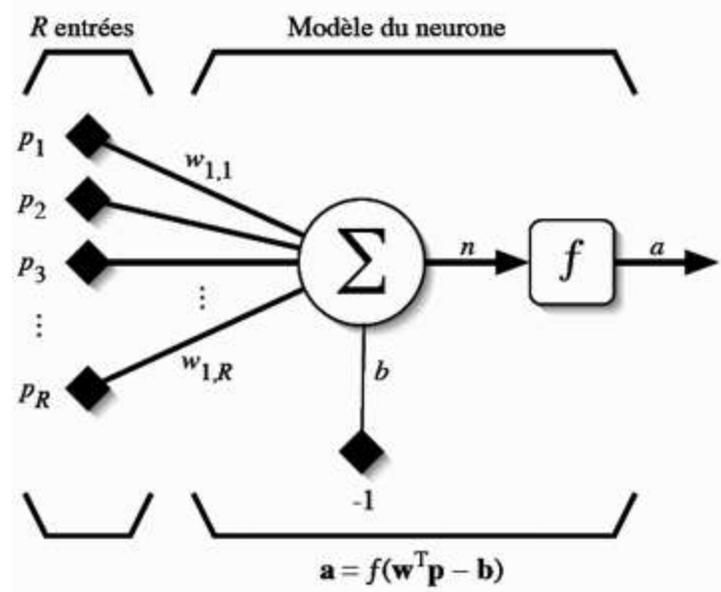


**Fig. II.5.** Modèle d'un neurone formel (Balti, 2016)

### II.3.1 Principe de fonctionnement de RNA

Un neurone se compose généralement d'une entrée formée des variables sur lesquelles opèrent ce neurone et une sortie représentant la valeur de la fonction réalisée (fonction d'activation). La sortie du neurone est une fonction non linéaire d'une combinaison des entrées  $X_i$  (signaux d'entrées) pondérées par les paramètres  $W_i$  (poids synaptiques). Graphiquement le neurone est présenté sous la forme indiquée sur la figure (figure. II.6). Le neurone est modélisé par deux opérateurs :

- \* Un opérateur de sommation qui élabore un potentiel égale à la somme pondérée des entrées de la cellule.
- \* Un opérateur calculant l'état de la sortie du neurone en fonction de son potentiel (fonction d'activation).



**Fig. II.6.** Représentation graphique d'un neurone (.

Mathématiquement le neurone est une fonction algébrique non linéaire, paramétrée, à valeurs bornées [8]. La sortie du neurone est donnée par l'expression suivante :

$$y_k = \varphi \left( \sum_{j=1}^p W_{kj} \cdot X_j - \theta_k \right) \quad (\text{II.1})$$

Ou :  $X_1, X_2, X_3, \dots, X_p$  : entrées.

$W_{k1}, W_{k2}, W_{k3}, \dots, W_{kp}$  : Poids synaptiques du neurone  $k$  .

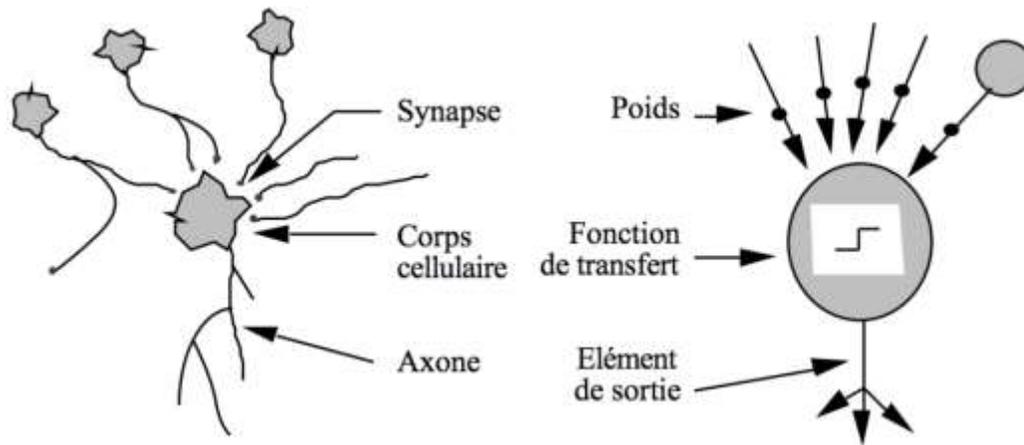
$y_k$  : est la sortie d'activation.

$\theta_k$  : Le seuil.

$\varphi(.)$  : La fonction d'activation.

Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones en amont ou des capteurs composant la machine dont il fait partie. A chacune de ces entrées est associé un poids représentatif de la force de la connexion [41]. Chaque processeur élémentaire est doté d'une sortie unique, qui se

ramifie ensuite pour alimenter un nombre variable de neurones en aval. A chaque connexion est associé un poids [20]. Tout d'abord on additionne les entrées avec leurs poids respectifs, puis une fonction de transfert calcule la valeur de l'état du neurone (Figure. II.7).

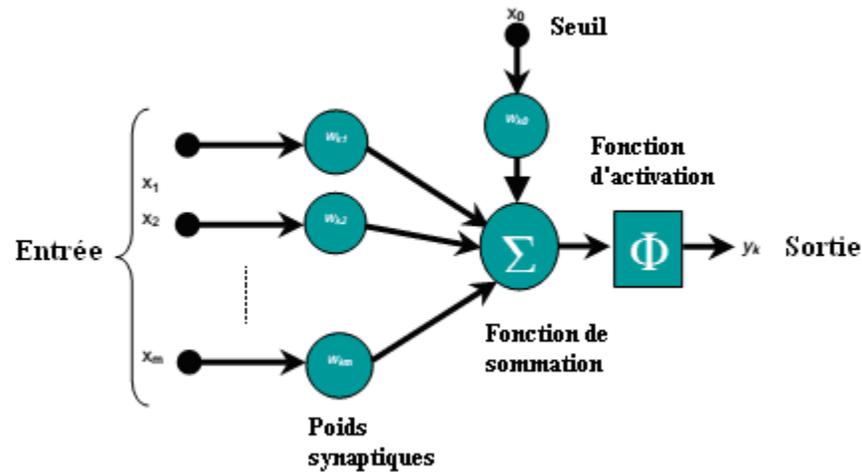


**Fig. II.7.** Comparaison entre le neurone biologique et le neurone artificiel (Liu, 2013).

Un réseau de neurones est en général composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. Chaque couche (i) est composée de  $N_i$  neurones, prenant leurs entrées sur les  $N_{i-1}$  neurones de la couche précédente. À chaque synapse est associé un poids synaptique, de sorte que les  $N_{i-1}$  sont multipliés par ce poids, puis additionnés par les neurones de niveau i, ce qui est équivalent à multiplier le vecteur d'entrée par une matrice de transformation. Mettre l'une derrière l'autre, les différentes couches d'un réseau de neurones reviendraient à mettre en cascade plusieurs matrices de transformation et pourrait se ramener à une seule matrice, produit des autres, s'il n'y avait à chaque couche, la fonction de sortie qui introduit une non-linéarité à chaque étape. Ceci montre l'importance du choix judicieux d'une bonne fonction de sortie.

Au-delà de cette structure simple, le réseau de neurones peut également contenir des boucles qui en changent radicalement les possibilités mais aussi la complexité [41]. De la même façon que des boucles peuvent transformer une logique combinatoire en logique séquentielle, les boucles dans un réseau de neurones transforment un simple dispositif de

reconnaissance d'entrées en une machine complexe capable de toutes sortes de comportements.



**Fig. II.8.** Structure d'un neurone artificiel (Djeddou, 2014).

Le neurone calcule la somme de ses entrées puis cette valeur passe à travers la fonction d'activation pour produire sa sortie

### A. 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 (Multi-Layer 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 [19].
- 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.

## B. Fonction d'activation

La fonction d'activation définit la valeur de la sortie d'un neurone en termes des niveaux d'activité de ses entrées. La fonction d'activation (ou fonction de seuillage, ou encore fonction de transfert) sert à introduire une non-linéarité dans le fonctionnement du neurone [20]. Les fonctions de seuillage présentent généralement trois intervalles :

1. En dessous du seuil, le neurone est non-actif (souvent dans ce cas, sa sortie vaut 0 ou -1) ;
2. Aux alentours du seuil, une phase de transition ;
3. Au-dessus du seuil, le neurone est actif (souvent dans ce cas, sa sortie vaut 1).

Des exemples classiques de fonctions d'activation sont :

1. La fonction sigmoïde.
2. La fonction tangente hyperbolique.
3. La fonction de Heaviside.

La logique Bayésienne, dont le théorème de Cox-Jaynes formalise les questions d'apprentissage, fait intervenir

$$ev(p) = 10 \log\left(\frac{p}{1-p}\right) \quad (\text{II.2})$$

La fonction d'activation considère différentes formes selon l'utilisation du réseau et selon sa nature, continue ou discrète. La plupart des neurones formels utilisés actuellement sont des variantes du neurone de McCulloch et Pitts dans lesquels la fonction de Heaviside est remplacée par une autre fonction d'activation. Les fonctions les plus utilisées sont :

- ✓ La fonction sigmoïde.
- ✓ La fonction tangente hyperbolique.
- ✓ Fonction à seuil (fonction échelon).
- ✓ Fonctions linéaires par parties.

Ces choix sont motivés par des considérations théoriques et pratiques. Les propriétés de la fonction d'activation influent en effet sur celles du neurone formel et il est donc important de bien choisir celle-ci pour obtenir un modèle utile en pratique [41]. Quand les neurones sont combinés en un réseau de neurones formels, il est important par exemple que la fonction d'activation de certains d'entre eux ne soit pas un polynôme sous réserve de limiter la puissance de calcul du réseau obtenu. Les fonctions de type sigmoïde sont généralement bornées.

Il est aussi utile en pratique que la fonction d'activation présente une certaine forme de régularité. Pour calculer le gradient de l'erreur commise par un réseau de neurones, lors de son apprentissage, il faut que la fonction d'activation soit dérivable.

### ➤ La fonction sigmoïde

La fonction sigmoïde, définie par la formule (II.3), possède les propriétés importantes évoquées précédemment (elle n'est pas polynomiale et est indéfiniment continûment dérivable).

$$\varphi(v) = \frac{1}{1 + e^{-v}} \quad (\text{II.3})$$

En outre, une propriété simple permet d'accélérer le calcul de sa dérivée, ce qui réduit le temps de calcul nécessaire à l'apprentissage d'un réseau de neurones. On a en effet

$$\frac{d\varphi(v)}{dv} = \varphi(v)(1 - \varphi(v)) \quad (\text{II.4})$$

On peut donc calculer la dérivée de cette fonction en un point de façon très efficace à partir de sa valeur en ce point. De plus, la fonction sigmoïde est à 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 logique et apparaît naturellement quand on considère le problème de la séparation optimale de deux classes de distributions gaussiennes avec la même matrice de covariance.

### C. 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.

### II.4 L'apprentissage

Une caractéristique des réseaux de neurones est leur capacité à apprendre, mais cette connaissance n'est pas acquise dès le départ. La plupart des réseaux de neurones apprennent par l'exemple.

On appelle "phase d'apprentissage " des réseaux de neurones la procédure qui consiste à estimer les paramètres des neurones du réseau. Afin que celui-ci remplisse au mieux la tâche qui lui est affectée. La phase de l'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré.

La notion d'apprentissage, bien que connue déjà depuis Sumer, n'est pas modélisable dans le cadre de la logique déductive : celle-ci en effet procède à partir de connaissances déjà établies dont on tire des connaissances dérivées , or il s'agit ici de la démarche inverse : par observations limitées, tirer des généralisations plausibles : c'est un procédé par induction.

La notion d'apprentissage recouvre deux réalités souvent traitées de façon successive :

- Mémorisation : le fait d'assimiler sous une forme dense des exemples éventuellement nombreux.
- Généralisation : le fait d'être capable, grâce aux exemples appris, de traiter des exemples distincts, encore non rencontrés, mais similaires.

Dans le cas des systèmes d'apprentissage statistique, utilisés pour optimiser les modèles statistiques classiques, réseaux de neurones et automates markoviens, c'est la généralisation qui est l'objet de toute l'attention. Cette notion de généralisation est traitée de façon plus ou moins complète par plusieurs approches théoriques.

- La généralisation est traitée de façon globale et générique par la théorie de la régularisation statistique introduite par Vladimir Vapnik. La théorie de la régularisation statistique s'est diffusée très largement parmi ceux qui étudient les réseaux de neurones en raison de la forme générique des courbes d'erreurs résiduelles d'apprentissage et de généralisation issues des procédures d'apprentissage itératives telles que les descentes de gradient utilisées pour l'optimisation des perceptrons multicouches. Ces formes génériques correspondent aux formes prévues par la théorie de la régularisation statistiques ; cela vient du fait que les procédures d'apprentissage par descentes de gradient, partant d'une configuration initiale des poids synaptiques explorent progressivement l'espace des poids synaptiques possibles.
- La généralisation est aussi au cœur de l'approche de l'inférence Bayésienne, enseignée depuis plus longtemps. Le théorème de Cox-Jaynes fournit ainsi une base importante à un tel apprentissage, en nous apprenant que toute méthode d'apprentissage est soit isomorphe aux probabilités munies de la relation de Bayes, soit incohérente. C'est l'un résultat extrêmement fort, et c'est pourquoi les méthodes Bayésiennes sont largement utilisées dans le domaine.

#### **A. Les types d'apprentissage :**

Selon le critère d'apprentissage ; les réseaux de neurones se subdivisent en deux classes, les réseaux à apprentissage supervisé (Supervised learning) et les réseaux à apprentissage non supervisé (Unsupervised learning).

- ❖ Pour les réseaux à apprentissage supervisé, on présente au réseau des entrées et au même temps les sorties que l'on désirerait pour cette entrée. Le réseau doit alors se

reconfigurer. C'est-à-dire calculer ses poids afin que la sortie qu'il donne corresponde bien à la sortie désirée.

- ❖ Pour les réseaux à apprentissage non supervisé, on présente une entrée au réseau et on le laisse évoluer librement jusqu'à ce qu'il se stabilise.

Il existe aussi des réseaux à apprentissage dit semi supervisé qui ne tiennent compte que d'une évaluation partielle ou qualitative des sorties.

## B. Applications des RNA

Les réseaux à apprentissage supervisé servent à :

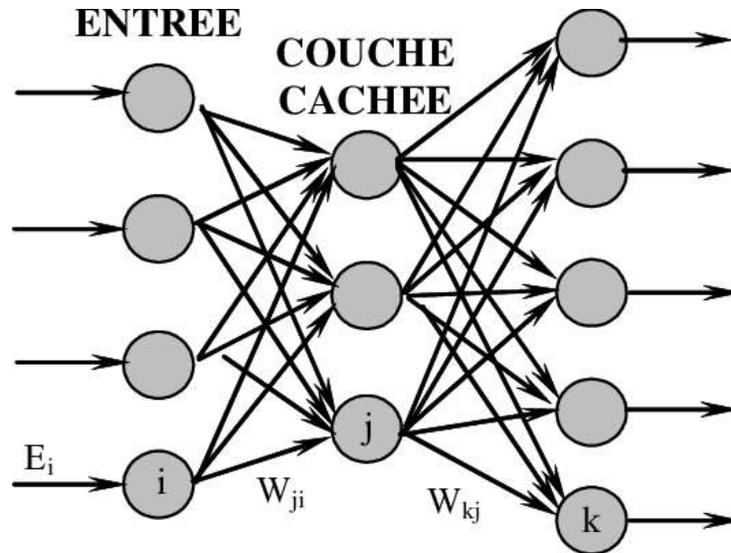
- ✓ La modélisation statique des processus non linéaires décrits par des équations algébriques.
- ✓ La modélisation dynamique des processus décrits par des équations récurrentes.
- ✓ La commande de processus ; ils servent aussi à imposer une dynamique de réponse à une sollicitation.
- ✓ Les réseaux à apprentissage non supervisé permettent l'analyse, la classification et la visualisation des données.

Si un neurone isolé a un comportement prévisible, la complexité d'un réseau naît de ses nombreuses possibilités d'interconnexion. L'adaptation d'un réseau à un problème donné passe par un choix de la topologie et des poids de liaison entre les neurones. La topologie des réseaux de neurones peut être très variée. On peut concevoir plusieurs types de réseaux seulement en modifiant les règles de connexion.

- ❖ **Réseau à une couche (Figure. II.9):**

$$O_i = \begin{cases} 1 & \text{si } \sum_k W_{ik} X_k \succ 0 \\ 0 & \text{sinon} \end{cases} \quad (\text{II.5})$$

$O_i$  : représente la sortie du réseau.



**Fig. II.9.** Exemple d'un réseau à une couche (Brousseau, 2006)

❖ **Réseaux multicouches ``Feedforward`` :**

Notons les couches cachées par la lettre 'c' et les couches de sorties par la lettre 'o'. On appelle :

- Couche d'entrée : l'ensemble des neurones d'entrée,
- Couche de sortie : l'ensemble des neurones de sortie.
- Couches cachées : l'ensemble des couches intermédiaires, elles n'ont aucun contact avec l'extérieur.

Couche cachées :

$$c_j = \begin{cases} 1 & \text{si } \sum_k W_{jk} X_k \succ 0 \\ 0 & \text{sinon} \end{cases} \quad \text{avec: } j = 1, \dots, n_{ne} \quad (\text{II.6})$$

Couches de sortie :

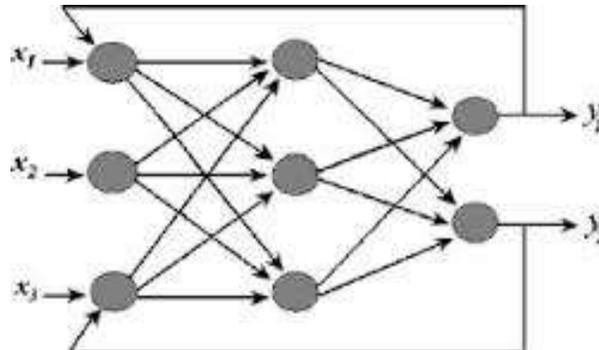
$$o_i = \begin{cases} 1 & \text{si } \sum_k W_{ik} C_k \succ 0 \\ 0 & \text{sinon} \end{cases} \quad \text{avec: } i = 1, \dots, n_{ns}$$

(II.7)

$n_e$  : indique les neurones de la couche d'entrée et ( $n_s$ ) indique les neurones de la couche de sortie.

### ❖ Réseaux récurrents :

L'idée des connexions récurrentes est que le réseau est capable de « se rappeler » des valeurs des états précédents par l'intermédiaire de leurs poids synaptiques (voir Fig II.8).



**Fig. II.10.** Exemple d'un réseau récurrent

La sortie du réseau à un instant donné est une fonction non linéaire de l'entrée externe et de la sortie des neurones cachés à l'instant précédent. Chaque unité  $i$  est connectée à chaque autre unité  $j$  par un poids  $W_{ij}$ . Les poids sont supposés symétriques :  $W_{ij} = W_{ji}$ .

#### ➤ Mode supervisé

Un apprentissage est dit supervisé lorsque l'on force le réseau à converger vers un état final précis, en même temps qu'on lui présente un motif.

À l'inverse, lors d'un apprentissage non-supervisé, le réseau est laissé libre de converger vers n'importe quel état final lorsqu'on lui présente un motif.

#### ➤ Sur-apprentissage

Il arrive souvent que les exemples de la base d'apprentissage comportent des valeurs approximatives ou bruitées. Si on oblige le réseau à répondre de façon quasi parfaite relativement à ces exemples, on peut obtenir un réseau qui est biaisé par des valeurs erronées. Par exemple, imaginons qu'on présente au réseau des couples  $(x_i, f(x_i))$  situés sur une droite d'équation  $y = ax + b$ , mais bruités de sorte que les points ne soient pas

exactement sur la droite. S'il y a un bon apprentissage, le réseau répond  $ax + b$  pour toute valeur de  $x$  présentée. S'il y a sur-apprentissage, le réseau répond un peu plus que  $ax + b$  ou un peu moins, car chaque couple  $(x_i, f(x_i))$  positionné en dehors de la droite va influencer la décision. Pour éviter le sur-apprentissage, il existe une méthode simple : il suffit de partager la base d'exemples en 2 sous-ensembles. Le premier sert à l'apprentissage et le 2<sup>e</sup> sert à l'évaluation de l'apprentissage. Tant que l'erreur obtenue sur le 2<sup>e</sup> ensemble diminue, on peut continuer l'apprentissage, sinon on arrête.

### ➤ **Rétropropagation**

La rétropropagation consiste à rétropropager l'erreur commise par un neurone à ses synapses et aux neurones qui y sont reliés. Pour les réseaux de neurones, on utilise habituellement la rétro-propagation du gradient de l'erreur, qui consiste à corriger les erreurs selon l'importance des éléments qui ont justement participé à la réalisation de ces erreurs : les poids synaptiques qui contribuent à engendrer une erreur importante se verront modifiés de manière plus significative que les poids qui ont engendré une erreur marginale.

### ➤ **Élagage**

L'élagage (" pruning ", en anglais) est une méthode qui permet d'éviter le sur-apprentissage tout en limitant la complexité du modèle. Elle consiste à supprimer des connexions (ou synapses), des entrées ou des neurones du réseau une fois l'apprentissage terminé.

### ➤ **Différents types de réseaux de neurones**

L'ensemble des poids des liaisons synaptiques détermine le fonctionnement du réseau de neurones. Les motifs sont présentés à un sous-ensemble du réseau de neurones : la couche d'entrée. Lorsqu'on applique un motif à un réseau, celui-ci cherche à atteindre un état stable. Lorsqu'il est atteint, les valeurs d'activation des neurones de sortie

constituent le résultat. Les neurones qui ne font ni partie de la couche d'entrée ni de la couche de sortie sont dits neurones cachés.

Les types de réseau de neurones diffèrent par plusieurs paramètres :

- ✓ La topologie des connexions entre les neurones.
- ✓ La fonction d'agrégation utilisée (somme pondérée, distance pseudo-euclidienne...).
- ✓ La fonction de seuillage utilisée (sigmoïde, échelon, fonction linéaire, fonction de Gauss, ...).
- ✓ L'algorithme d'apprentissage (rétropropagation du gradient, cascade corrélation).
- ✓ D'autres paramètres, spécifiques à certains types de réseaux de neurones, tels que la méthode de relaxation pour les réseaux de neurones (e.g. réseaux de Hopfield) qui ne sont pas à propagation simple (e.g. Perceptron Multicouche).

Le réseau ADALINE est proche du modèle Perceptron, seule sa fonction d'activation est différente puisqu'il utilise une fonction linéaire. Afin de réduire les parasites reçus en entrée, les réseaux ADALINE utilisent la méthode des moindres carrés.

Le réseau réalise une somme pondérée de ses valeurs d'entrées et y rajoute une valeur de seuil prédéfinie. La fonction de transfert linéaire est ensuite utilisée pour l'activation du neurone. Lors de l'apprentissage, les coefficients synaptiques des différentes entrées sont modifiés en utilisant la loi de Widrow-Hoff (en). Ces réseaux sont souvent employés en traitement de signaux, notamment pour la réduction de bruit.

## **II.5) Classification des RNA selon le mode de propagation**

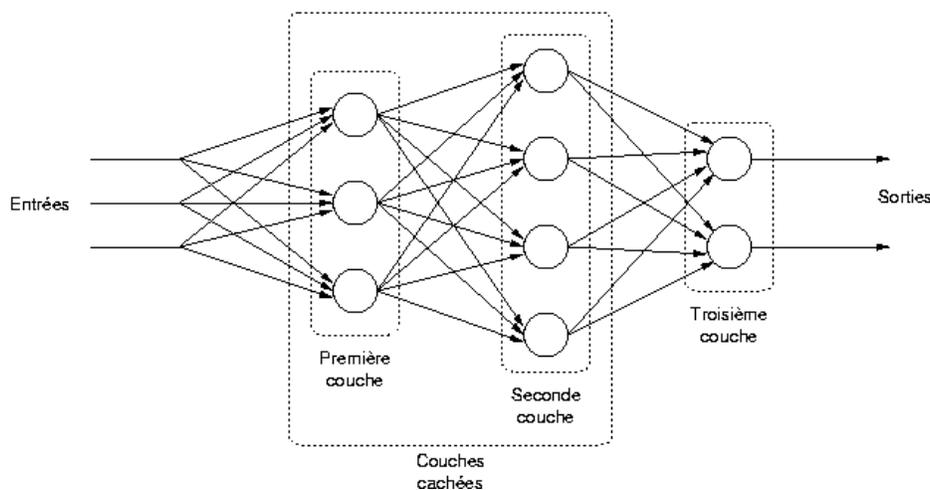
Par définition, un réseau de neurones est constitué d'un assemblage d'éléments, d'unités ou de nœuds processeurs pour lequel un sous-groupe effectue un traitement indépendant et transmet le résultat à un deuxième sous-groupe et ainsi de suite. Les capacités de traitement du réseau dépendent des poids  $W_i$  auxquels sont affectées des valeurs produisant un filtre affectant la capacité d'apprentissage du réseau.

Dans un réseau de neurones, les neurones sont regroupés en couches. Habituellement, chaque neurone dans une couche est connecté à tous les neurones dans la couche précédente et la couche suivante.

L'information donnée à un réseau de neurones est propagée couche par couche de la couche d'entrée à la couche de sortie en passant par une ou plusieurs couches intermédiaires (couches cachées).

### II.5.1 Fonction représentable par un perceptron :

Le perceptron est un réseau de neurones très simple. Il est linéaire et monocouche, acceptant uniquement des valeurs d'entrées et de sorties binaires (0 ou 1). Il est inventé par le psychologue Frank Rosenblatt et inspiré du système visuel. Le procédé d'apprentissage est supervisé et le réseau est capable de résoudre des opérations logiques simples comme les opérations "ET logique" ou "OU logique". Ces réseaux sont efficaces pourvu que les données traitées soient des vecteurs orthogonaux ou linéairement indépendants. Ce que l'on entend par méthode d'apprentissage supervisé est que les sorties du réseau sont comparées avec des sorties cibles. Ce type de réseau est aussi utilisé pour la classification. L'algorithme d'apprentissage est la règle d'apprentissage de Hebb qui affecte le changement des poids en multipliant l'entrée d'un neurone par sa sortie et le taux d'apprentissage du réseau.



**Fig. II.12.** Architecture d'un perceptron (Tertois, 2003).

Un réseau "feedforward" à une seule couche (perceptron) peut uniquement représenter des fonctions linéairement séparables. C'est-à-dire celles pour lesquelles la surface de décision séparant les cas positifs des cas négatifs est un (hyper-)plan. La sortie du perceptron dépend de la somme des composantes  $X_i$  du vecteur d'entrée, pondérées par des poids réels  $W_i$ . Conformément aux notations utilisées, nous appellerons un potentiel, la somme pondérée notée par 'net suivante :

$$net_k = \sum_{i=0}^n W_{ki} X_i \quad (\text{II.8})$$

La sortie du réseau sera désignée par 'O'. Elle sera de la forme suivante :

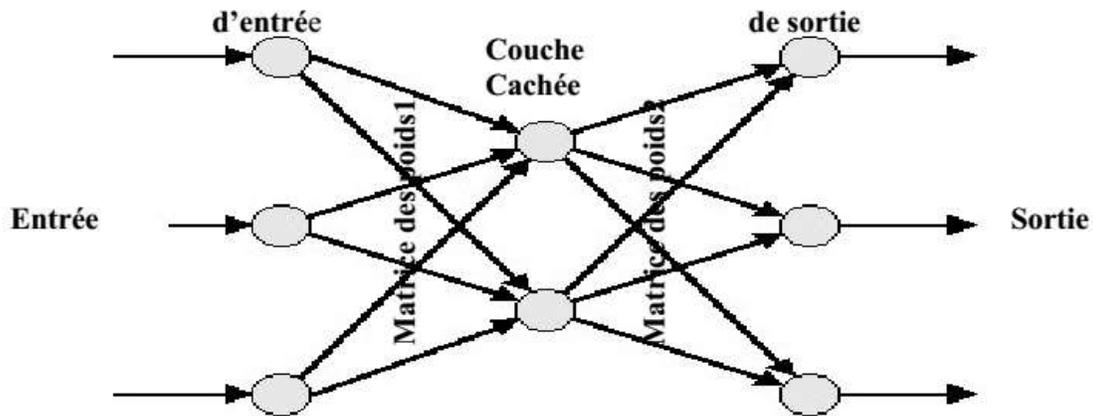
$$O_k = \begin{cases} 1 & \text{si } net_k \geq \theta_k \\ 0 & \text{si } net_k < \theta_k \end{cases} \quad (\text{II.9})$$

$W_{ji}$  : Coefficients synaptiques de j vers i,

$X_i$  : sortie(ou état) de j , et  $\theta_k$  : seuil

### II.5.2 Perceptron multicouche avec et sans l'algorithme de retro-propagation

Les réseaux multicouches sont actuellement les plus employés, plusieurs couches de traitement leur permettent de réaliser des associations non linéaires entre l'entrée et la sortie. Le perceptron à niveaux multiples (perceptron multi couche MLP) est une extension du perceptron qui a une ou plusieurs sous-couches cachées entre ses couches d'entrée et de sortie. A cause de sa structure étendue, un perceptron à niveaux multiples est capable de résoudre toute opération logique. La méthode d'apprentissage est supervisée, l'algorithme d'apprentissage est la règle d'apprentissage delta ( $\Delta$ ) qui affecte le changement des poids en multipliant l'entrée d'un neurone par la différence entre la sortie réelle et la sortie désirée et le taux d'apprentissage du réseau.



**Fig. II.13.** Architecture du perceptron Multicouche

Le perceptron a les caractéristiques suivantes :

- ✓ Le perceptron multicouches est une suite de couches contenant chacune des neurones formels.
- ✓ Les entrées de la couche  $n$  sont les sorties de la couche  $n-1$ .
- ✓ Les neurones de la première couche sont reliés à l'extérieur et reçoivent tous la même entrée (vectorielle).
- ✓ La sortie du perceptron multicouches est un vecteur constitué des sorties des neurones de la dernière couche.

Pour la couche de sortie, on peut appliquer l'apprentissage du perceptron, mais comment modifier les poids pour les connexions qui ne sont pas en relation avec un neurone de sortie? Le problème est l'obtention d'une estimation de la valeur désirée pour chaque neurone de la couche cachée. Ils utilisent pour modifier leurs poids, un algorithme de rétropropagation du gradient (back propagation). Il s'agit toujours de minimiser l'erreur quadratique.

### II.5.3) Les perceptrons multicouches par l'algorithme de rétro-propagation

Ce type de réseau est l'un des plus puissants réseaux de neurones (Figure. II.14). Il a la même structure que le perceptron à niveaux multiples et utilise l'algorithme de rétropropagation (back propagation). La méthode d'apprentissage est sous contrôle

supervisé. On utilise fréquemment des neurones avec une caractéristique entrée-sortie de type sigmoïde.

Les perceptrons multicouches agissent comme un séparateur non linéaire et peuvent être utilisés pour la classification, le traitement de l'image ou l'aide à la décision.

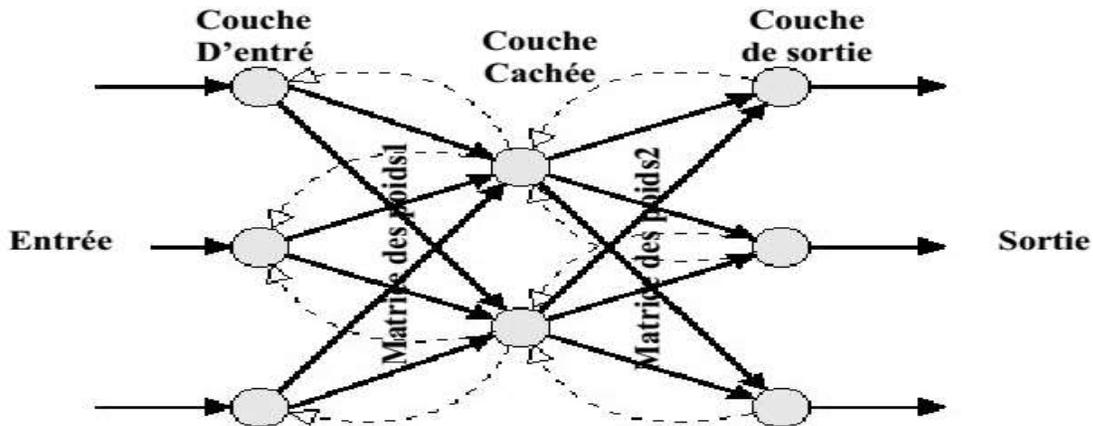
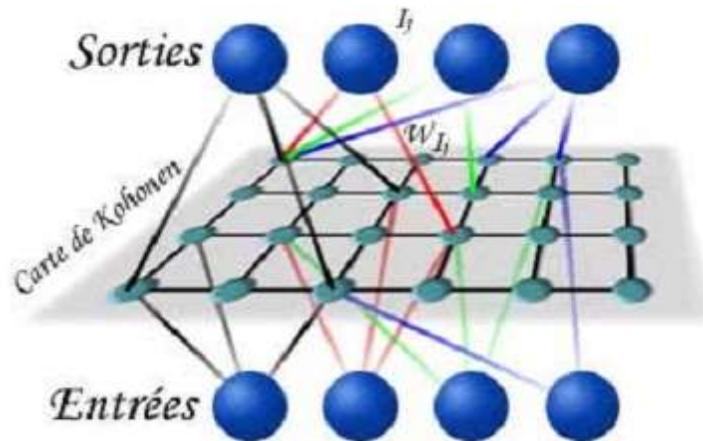


Fig. II.14. Architecture d'un modèle de Rétropropagation

#### II.5.4) Réseaux de Kohonen

Les phénomènes d'auto-organisation sont bien connus dans le système nerveux des vertébrés, particulièrement au niveau cortical. L'organisation corticale est non supervisée [9]. Elle est pilotée par la structure des stimulations extérieures. Des modèles d'auto-organisation, inspirés de l'organisation corticale des vertébrés, ont été proposés des les années 70. Au début ces modèles ont pour objectif de représenter des données complexes dans un espace discret dont la topologie est limitée à un, deux, voire trois dimensions. Il s'agit donc de modèles de quantification vectorielle qui seront dotés de propriétés topologiques particulières. Le type le plus connu de la carte auto-organisatrice est celui de Kohonen. C'est probablement le type de réseau de neurones le plus utilisé quant à sa ressemblance simulé du processus d'apprentissage du cerveau humain. Le cœur de ce type de réseau est une organisation applicative où les neurones s'organisent eux-mêmes par rapport à certaines données se trouvant à l'entrée (Figure : II.15). Il fait l'objet de l'une des applications des réseaux de neurones dans l'exploration pétrolière et exactement dans le domaine du traitement des données sismiques.



**Fig. II.15.** Architecture d'un modèle de Kohonen (Kohonen, 2002).

### II.5.5) Réseaux de Hopfield

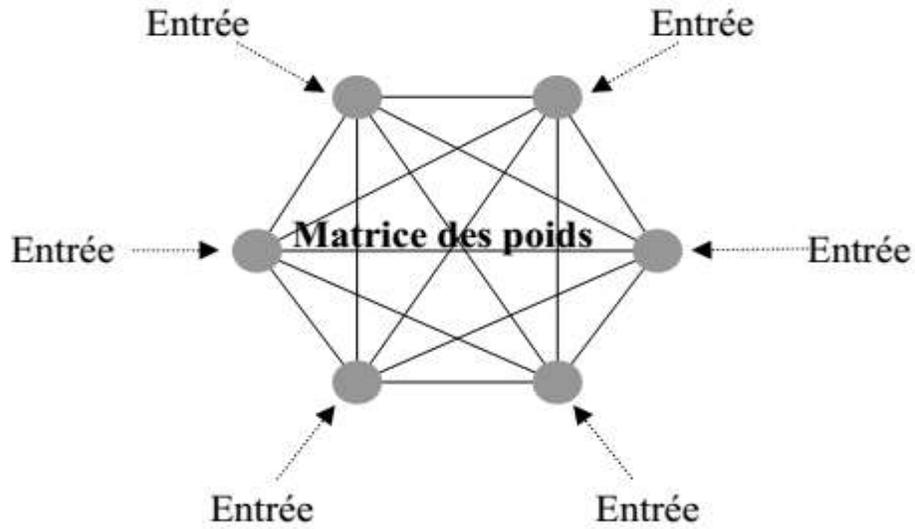
Pour présenter les spécificités de ces réseaux, il est intéressant de comparer les divers aspects du formalisme et de la terminologie entre le traitement de signal et la physique. Là où le traitement de signal cherche à minimiser les fonctions de corrélation, la physique cherche à minimiser les fonctions d'énergie. Si le traitement du signal analyse la convergence d'un système, la physique étudie le phénomène de relaxation. Dans les deux cas, les matrices ont les mêmes valeurs propres et les mêmes vecteurs propres. La différence est plus subtile : en plus de sa terminologie propre, la physique a apporté toute une classe de problèmes liés à l'optimisation, ainsi que des méthodes d'approche de ces problèmes.

Ce modèle a été développé en 1982 selon une analogie formelle avec des réseaux de particules orientées et en interaction. Sa propriété fondamentale réside dans le fait qu'il existe une grandeur homologe à une énergie qui décroît au cours des itérations.

Ce type de réseau est un ensemble de neurones, où chacun de ces derniers est connecté à chaque autre neurone. Il n'y a aucune différenciation entre les neurones d'entrées et de sorties. La loi d'apprentissage est la règle de Hebb, qui stipule qu'une synapse améliore son activité si et seulement si l'activité de ses deux neurones est corrélée d'une autre

façon cela signifie que le poids  $w_{ij}$  d'une connexion entre un neurone  $i$  et un neurone  $j$  augmente quand Les deux neurones sont activés en même temps (Figure. II.16).

L'application principale d'un réseau Hopfield est la collecte des données, la reconnaissance des formes et l'optimisation des images.



**Fig. II.16.** Architecture d'un model de Hopfield.

**Chapitre III : Prédiction des perturbations ionosphériques par utilisation des réseaux de neurones artificiels. Application aux données des instruments ISL et IAP du satellite DEMETER**

### III.1) Introduction

Les réseaux de neurones artificiels (ANN) ont été largement utilisés en physique (Peterson, 1992, Lynch et al 2001, Ouadfeul et Aliouane, 2013). Dans la physique du plasma les ANNs sont utilisés par de nombreux auteurs. Teng et al (2010) ont utilisé un algorithme de perceptron multicouches et un algorithme à fonction de base radiale, afin de prédire la densité du plasma dans un système à plasma, l'efficacité des deux modèles des réseaux neuronaux artificiels est démontrée. Wei et al (2009) ont mis en place un réseau de neurones artificiels (ANN) en utilisant un algorithme de type Back-propagation afin de prédire la distribution spatiale du plasma dans un système à résonance cyclotron électronique (ECR) - dépôt chimique en phase de vapeur assisté par plasma (PECVD). Dans ce chapitre, nous testons l'efficacité du réseau Multilayer Perceptron (MLP) pour la prédiction des paramètres ionosphériques enregistrées par les instruments IAP et ISL du Satellite DEMETER. Nous commençons par décrire ces instruments et les données enregistrées, puis nous décrivons le réseau neuronal MLP, la technique est appliquée aux données réelles enregistrées deux jours avant le choc principal du tremblement de terre de L'Aquila du 06 Avril 2009. Nous finalisons le chapitre par l'interprétation des résultats et une conclusion.

### III.2) Le tremblement de terre de L'Aquila

Le tremblement de terre de L'Aquila 2009 a eu lieu dans la région des Abruzzes, en Italie centrale (voir Fig. III.1). Le choc principal a eu lieu à 03h32 CEST (01 :32 UTC) le 6 Avril 2009, et a été évalué 5,8 ou 5,9 sur l'échelle de Richter ; son épicerne était près de L'Aquila, la capitale des Abruzzes, qui, avec les villages environnants a subi plus de dégâts. Il y a eu plusieurs de milliers d'activités pré-séismiques et répliques depuis Décembre 2008, plus de trente qui avaient une magnitude supérieure à 3,5 sur l'échelle de Richter. Le séisme a été ressenti dans toute l'Italie centrale; 297 personnes sont mortes, ce qui le fait le tremblement de terre le plus meurtrier qui a frappé l'Italie depuis le tremblement de terre 1980 de Irpinia. Dans une enquête ultérieure, sept membres de la Commission nationale Italienne pour la prévision et la prévention des risques majeurs ont été accusés de donner des informations "inexactes, incomplètes et contradictoires" sur le danger des microséismes avant le séisme principal. Le 22 Octobre 2012, six scientifiques et un fonctionnaire de l'ex-gouvernement ont été reconnus coupables d'homicide multiple pour minimiser la probabilité d'un séisme majeur six jours avant qu'il a eu lieu. Ils ont été condamnés chacun à une peine d'emprisonnement de six ans.

### **III.3) Instrument Langmuir et le satellite DEMETER (ISL)**

Le satellite DEMETER est conçu pour étudier les perturbations ionosphériques liées au tremblement de terre, les volcans et l'activité humaine, et de détecter l'environnement électromagnétique à l'échelle mondiale (Lebreton, 2012). Le satellite a quasi orbite solaire synchrone circulaire avec une inclinaison de  $98,23^\circ$ , un poids de 130 kg et une hauteur de 710 km (ce qui a diminué à 660 km au milieu de Décembre 2005). Sa longévité était censée être deux ans. Cependant, elle est étendue jusqu'à 2011. La sonde de Langmuir est en principe un instrument de diagnostic du plasma, simple et très polyvalent pour les mesures in situ. Une sonde de Langmuir classique utilise un seul capteur, qui peut être de géométrie différente (cylindrique ou sphérique). L'instrument Langmuir Probe (ISL: Instrument de sonde de Langmuir) comprend deux capteurs de Langmuir Probe. Il comprend un capteur classique, un est cylindrique (5 cm de longueur, un diamètre de 6 mm) et un sphérique de 4cm de diamètre (Lebreton, 2012, Zhang et al, 2009). Un ensemble d'instruments ont été déployés sur le satellite, y compris ICE pour détecter le champ électrique de courant continu à 3,5 MHz; IMSC pour mesurer le champ magnétique de quelques Hz à 20 kHz; IAP pour détecter la densité d'ions et de la température et ainsi de suite; ISL, sonde de Langmuir pour mesurer la densité et la température des électrons. Deux types de données avec différents modes de fonctionnement sont proposés : mode Burst avec un faible pas d'échantillonnage lorsque le satellite survole les zones sismiques et le mode Survey avec un pas d'échantillonnage élevé. Le centre de mission de DEMETER fournit les données qui peuvent être téléchargés (Zhang et al, 2009). Pour plus de détails nous vous invitons à consulter la page web du satellite DEMETER, [http:// demeter.cnrs-orleans.fr](http://demeter.cnrs-orleans.fr).

La sonde de Langmuir est en principe un instrument de diagnostic du plasma spatial simple et très polyvalent pour les mesures in situ. Une sonde de Langmuir classique utilise un seul capteur, qui peut être de géométrie différente (cylindrique ou sphérique).

### **III.4) Instrument Analyseur du Plasma (IAP)**

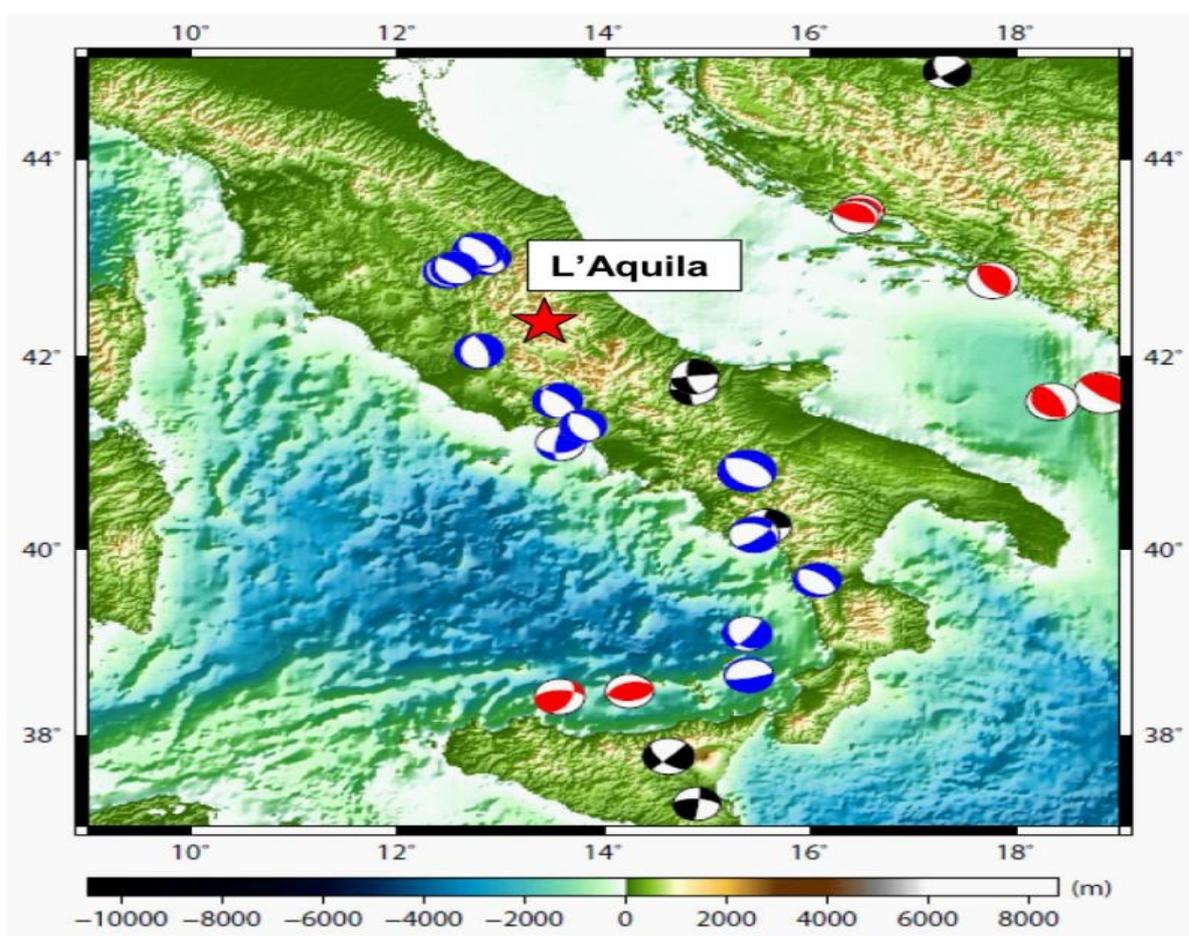
IAP (Instrument Analyseur de plasma) est un instrument installé à bord du satellite DEMETER, composé de deux analyseurs : APR (Analyseur à Potentiel Retardateur, Retarding Potential Analyzer) et ADV (Analyseur des Directions des Vitesses). L'analyseur ADV effectue l'analyse de l'énergie des ions, par contre l'analyseur APR permet de déterminer la densité, la température et l'énergie des ions ionosphériques. L'instrument IAP enregistre les données en deux modes Burst et Survey. IAP au mode Survey a une résolution moyenne pour fournir un ensemble complet de paramètres du plasma tous les 720 ms fournissant un ensemble complet de mesures.

Le mode Burst fonctionne avec une haute énergie et une haute résolution temporelle avec l'ensemble complet des paramètres du plasma tous les  $\sim 360$  ms. L'objectif de l'instrument IAP est

de caractériser l'état du plasma ionosphérique, afin de détecter les perturbations qui peuvent être associés à l'activité sismique et de fournir les paramètres du plasma qui sont nécessaires pour analyser les données du plasma. Les données IAP comportent la densité d'hydrogène ( $NH^+$ ), la densité d'Hélium ( $NHe^+$ ), la densité d'oxygène ( $NO^+$ ), la température des Ions ( $Ni^+$ ), le Potentiel du satellite ( $VS^+$ ), la vitesse des ions suivant l'axe des Z ( $VZ^+$ ) ainsi que les angles ( $VOX$ , suivant  $OX$ ) et ( $VOZ$  suivant  $Z$ ).

### III.5) Analyse des données de l'instrument ISL par réseaux de neurones

Les données de l'instrument Langmuir ISL enregistrées deux jours avant le choc principal du tremblement de terre de L'Aquila sont analysées par le perceptron multicouche, l'objectif est de vérifier l'efficacité du réseau MLP pour prédire les séries chronologiques futures. Les paramètres à prédire sont : Densité des électrons, Densité des Ions, température des électrons et le potentiel du plasma. Une machine de réseau de neurones à trois couches est implémentée, la couche d'entrée est composée de quatre neurones, la couche cachée est composée de 10 neurones et la couche de sortie de quatre neurones.



**Fig. III.1.** Carte de l'Italie centrée autour de la région de L'Aquila

Les 640 premiers échantillons enregistrés par l'instrument ISL sont utilisés comme entrée (voir la figure III.2). Les seconds 640 échantillons sont utilisés comme sortie désirée de la machine MLP (voir figure III.3). Durant la phase d'apprentissage les poids de connexion sont optimisés pour minimiser l'erreur quadratique moyenne entre la sortie désirée et la sortie calculée par la machine MLP. Afin de vérifier l'efficacité de la machine MLP, les deuxièmes 640 échantillons sont utilisés comme une entrée de la machine MLP, l'objectif est de prédire une future série de 300 échantillons.

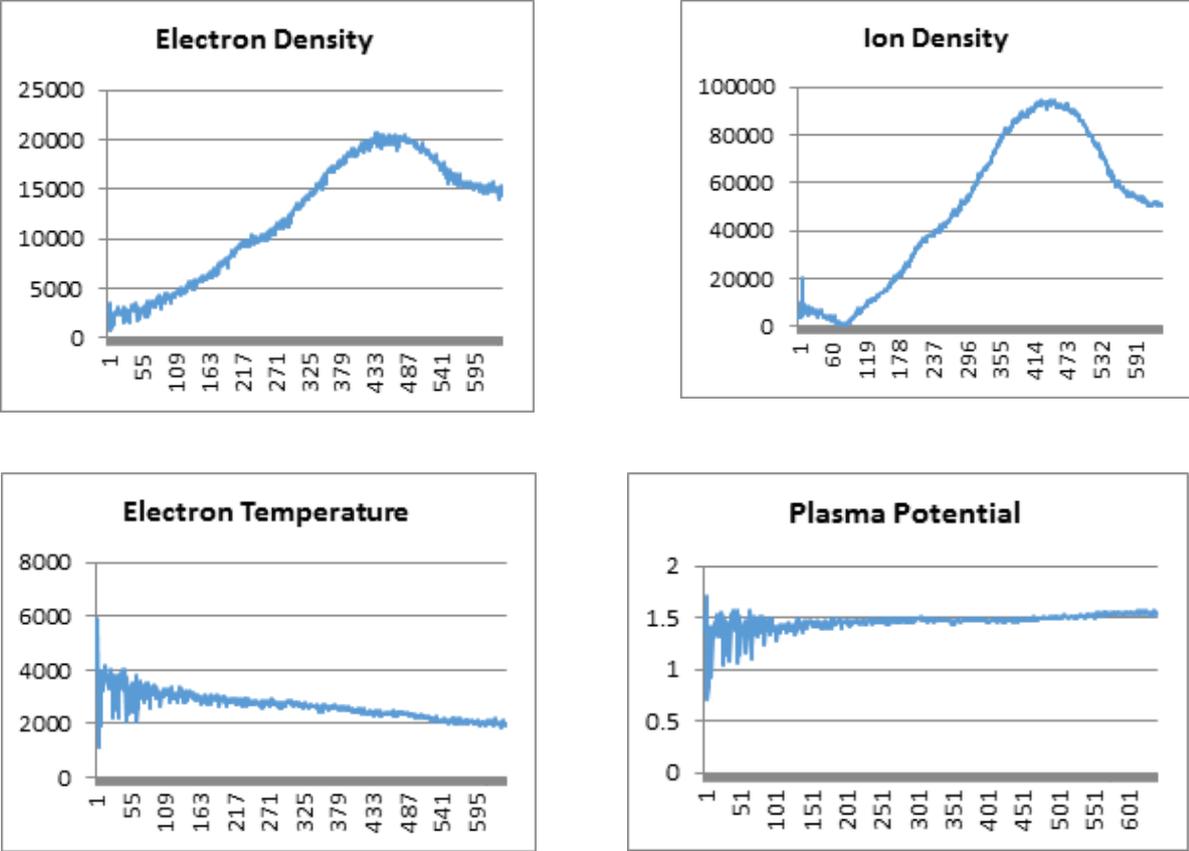


Fig. III.2. Entrée de la machine neuronale Perceptron multicouches.

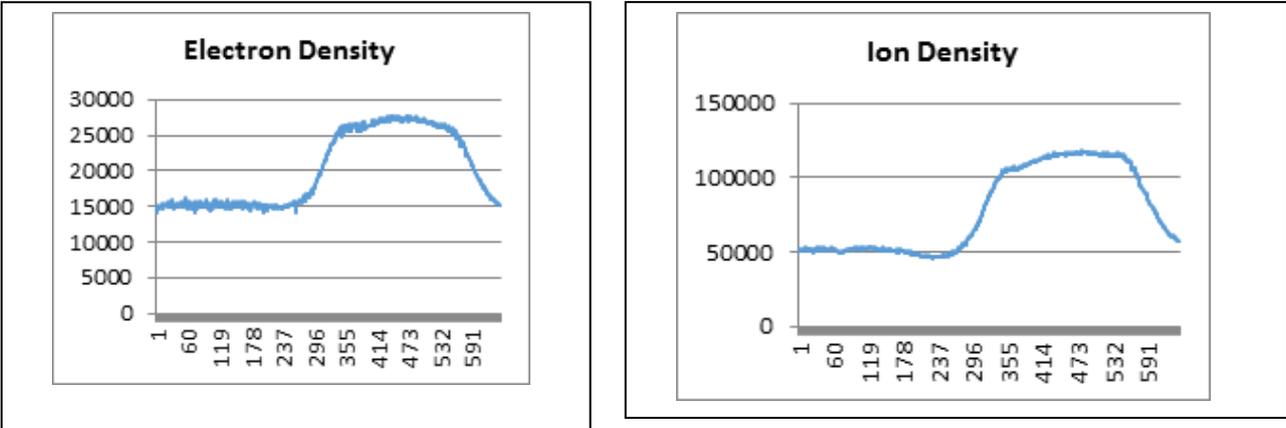
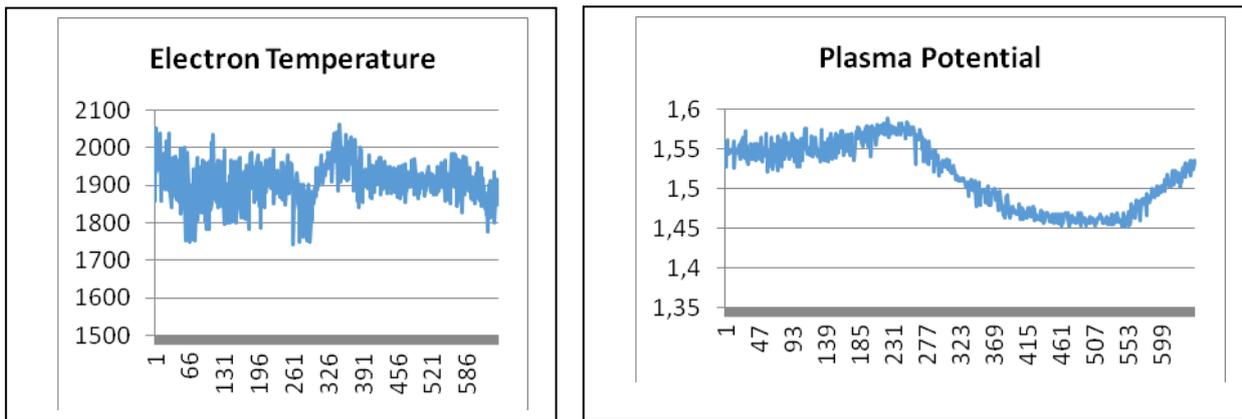


Fig.III.3. Sortie désirée de la machine MLP



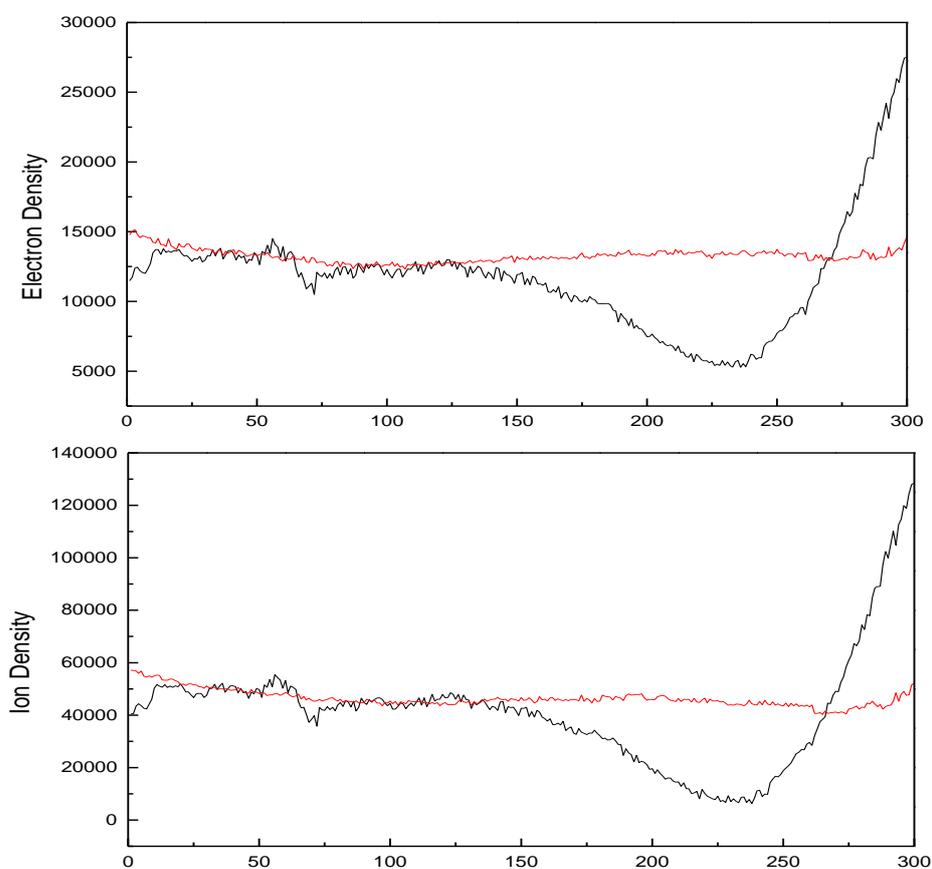
**Fig.III.3.** La suite

La figure III.4 représente les graphes des paramètres du plasma prédits par réseaux de neurones (couleur noire) comparés avec les paramètres enregistrés par l'instrument ISL (Couleur rouge). Nous constatons que la machine ANN a une bonne mémoire pour la plupart des séries de temps, mais la machine commence à perdre la mémoire à la fin de chaque série. La machine peut être utilisée pour la prédiction des perturbations ionosphériques, qui ont une grande relation avec l'activité sismique ; la méthode de réseau de neurones artificiels joue un rôle important dans la prévention des risques sismiques. Nous proposons de tester d'autres modèles de réseaux neuronaux comme les réseaux à fonction de base radiale (RBF) pour choisir le meilleur réseau de neurones qui peut être utilisé pour la prédiction des données de l'instrument ISL su satellite DEMETER avec une longue mémoire.

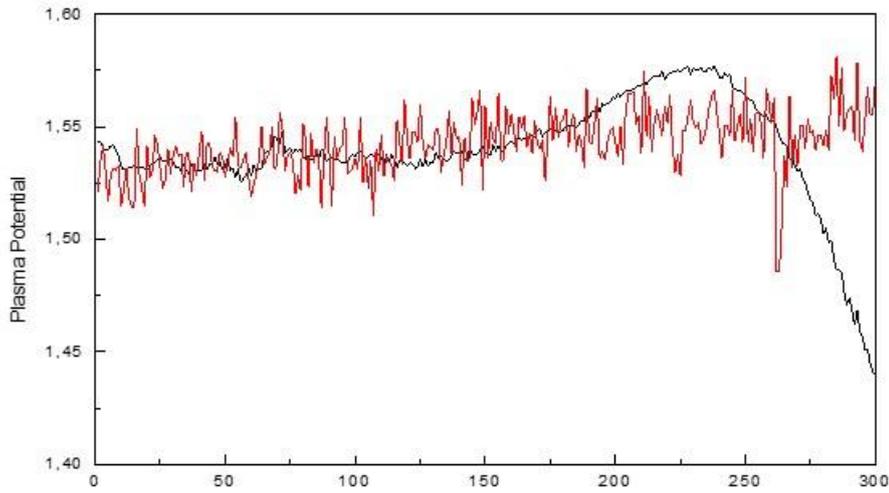
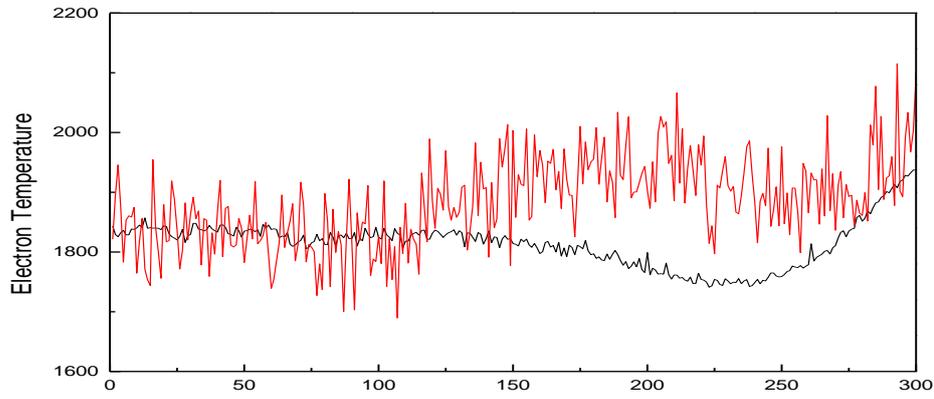
### **III.6) Analyse des données de l'instrument IAP**

Afin de vérifier la capacité des ANNs de prédire les paramètres de l'instrument IAP, une machine MLP à trois couches est implémentée ; la couche d'entrée est composée de huit neurones qui correspondent aux paramètres du plasma enregistré par l'instrument IAP, une couche cachée de sept neurones (obtenus après plusieurs essais) et une couche de sortie à huit neurones qui correspondent également aux paramètres du plasma IAP. Les données de l'orbite 27447-1 qui balaient la région de L'Aquila deux jours avant le choc principal de 06 Avril 2009 sont utilisées pour l'apprentissage de la machine neuronale. La première série temporelle de 151 échantillons est utilisée comme entrée de la machine (voir Fig.III.5). La deuxième série à 151 échantillons est utilisée comme sortie désirée (voir Fig.III.6). L'apprentissage de la machine MLP se fait en mode supervisé en utilisant l'algorithme de la retro-propagation du gradient stochastique et les poids de

connexion sont optimisés. Afin de vérifier la capacité de cette machine de prédire les futurs paramètres de l'instrument IAP, la deuxième série temporelle est utilisée comme entrée et une sortie est calculée en propageant l'entrée via cette machine en utilisant les poids de connexion, à ce stade, aucun apprentissage n'est nécessaire puisque les poids de connexion sont optimisés dans la première étape. Les résultats obtenus sont comparés avec les paramètres du plasma réels enregistrées (voir FIG.III.7), nous constatons que la machine MLP est en mesure de prédire un modèle acceptable de paramètres, mais à la fin de chaque série de temps le réseau neuronal commence à perdre la mémoire, par conséquent, le réseau MLP n'a pas une longue mémoire. Par conséquent, nous avons toujours besoin de mettre à jour les poids de connexion pour obtenir des résultats exacts. Nous suggérons l'application de l'ensemble du processus à des données d'autres orbites afin de généraliser son efficacité.

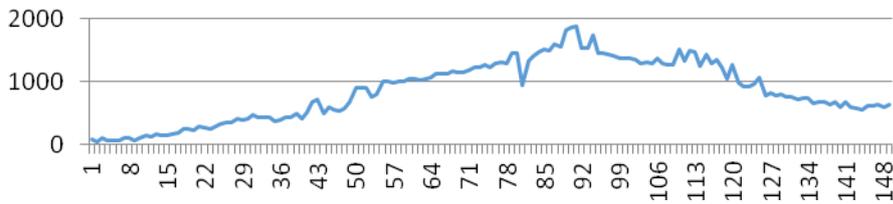


**Fig. III.4.** Paramètres du plasma ionosphérique prédits (couleur noire) par rapport aux paramètres enregistrés par satellite DEMETER (couleur rouge).

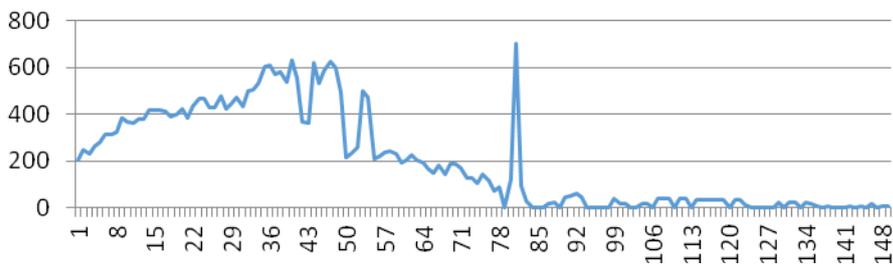


**Fig.III.4.** La suite

**NH Plus**



**NHe Plus**



**Fig. III.5** Premier groupe de 151 échantillons de l'instrument IAP paramètres utilisés pour l'apprentissage du réseau MLP.

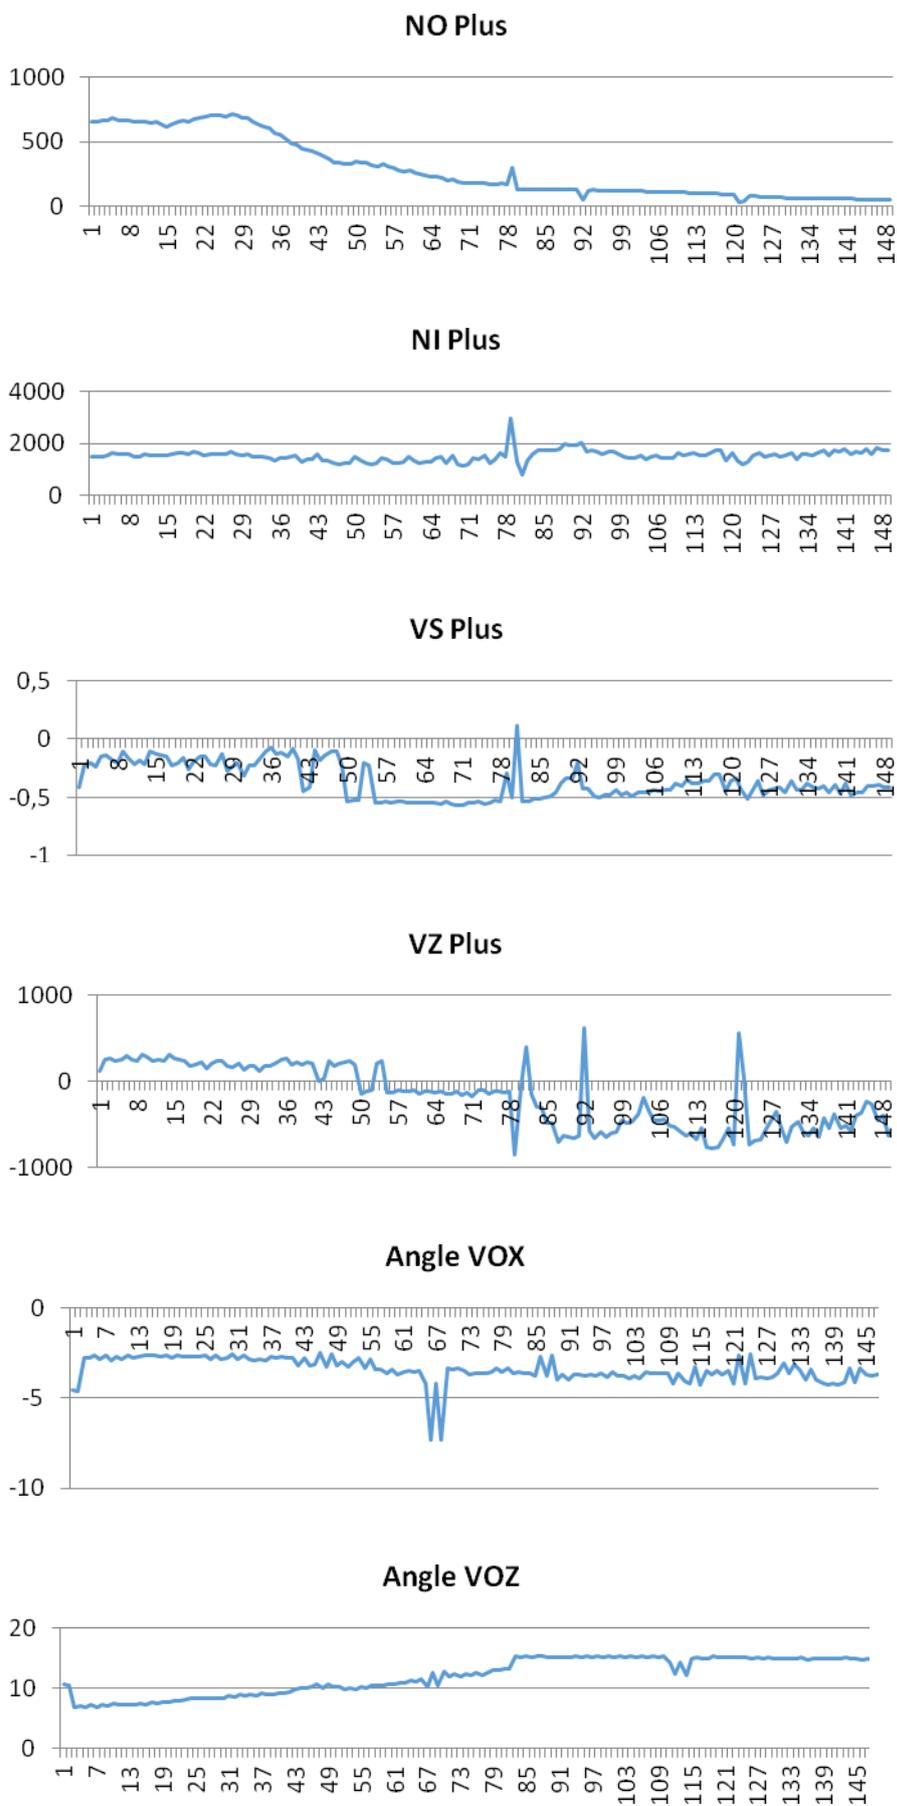
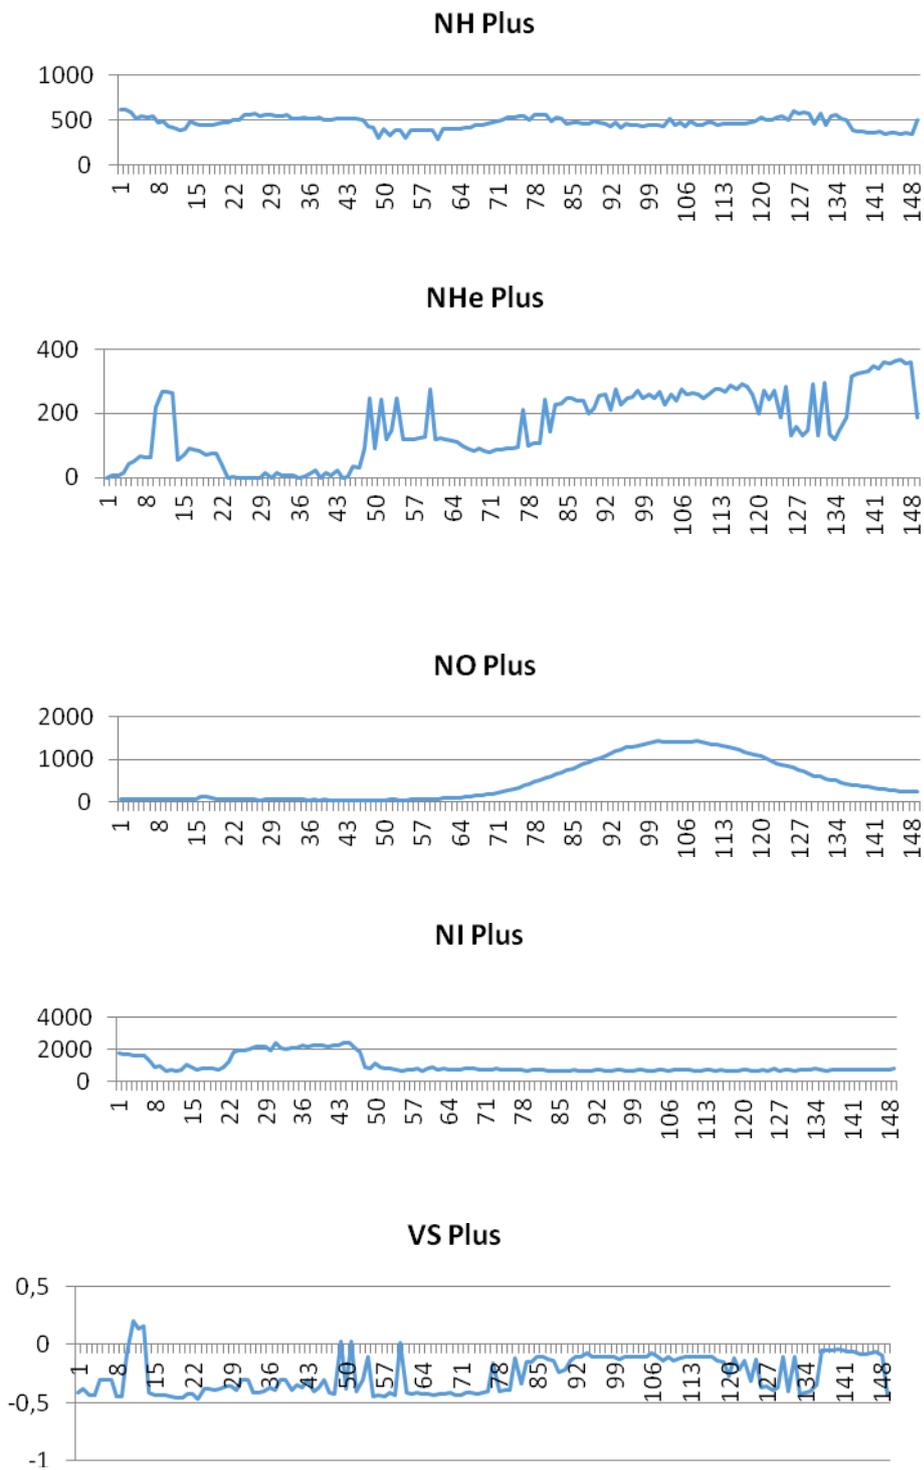
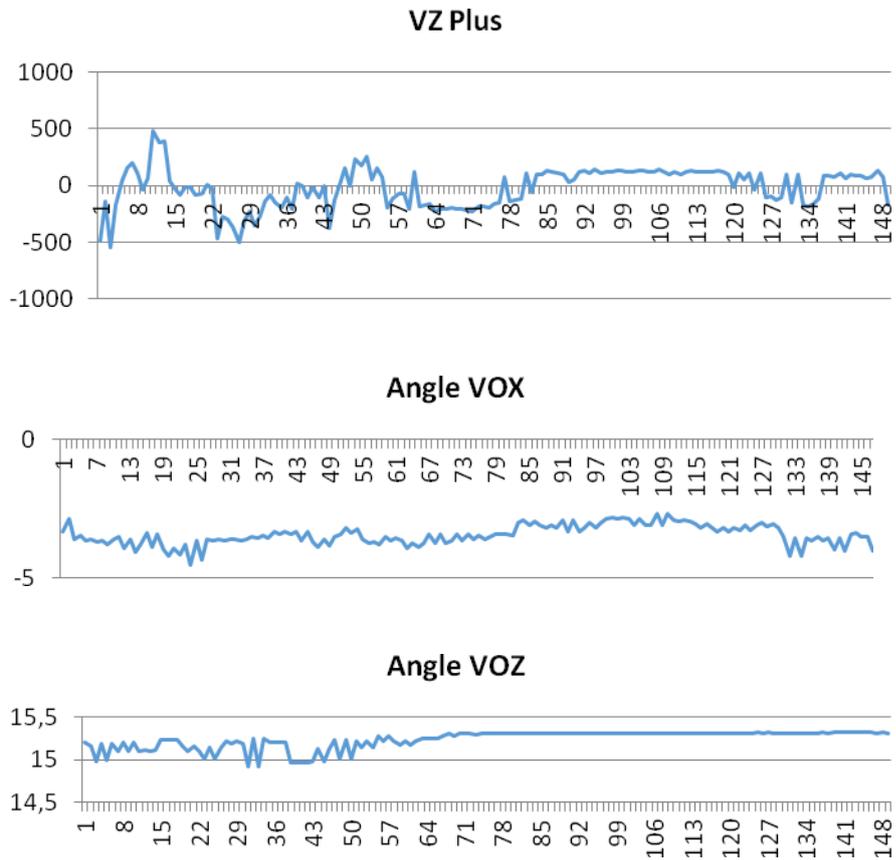


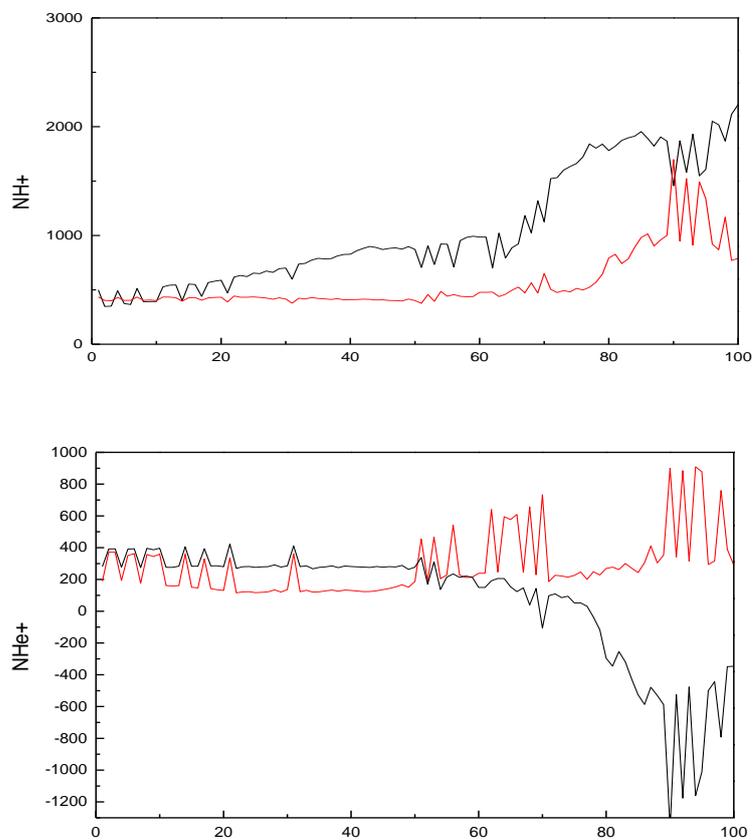
Fig. III.5 La suite



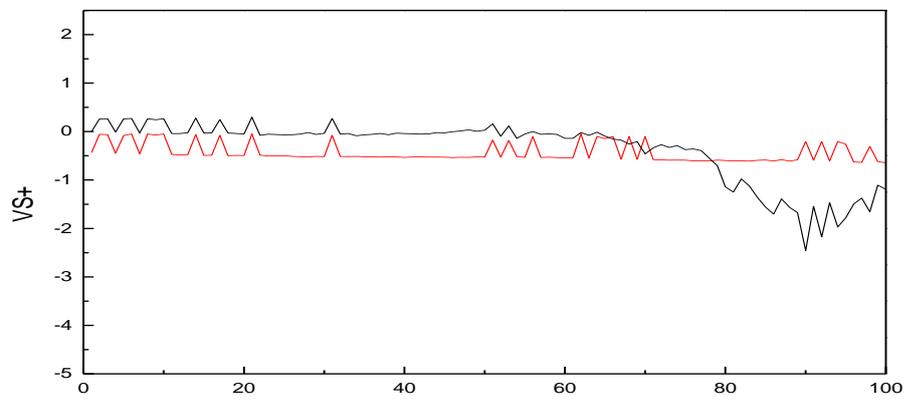
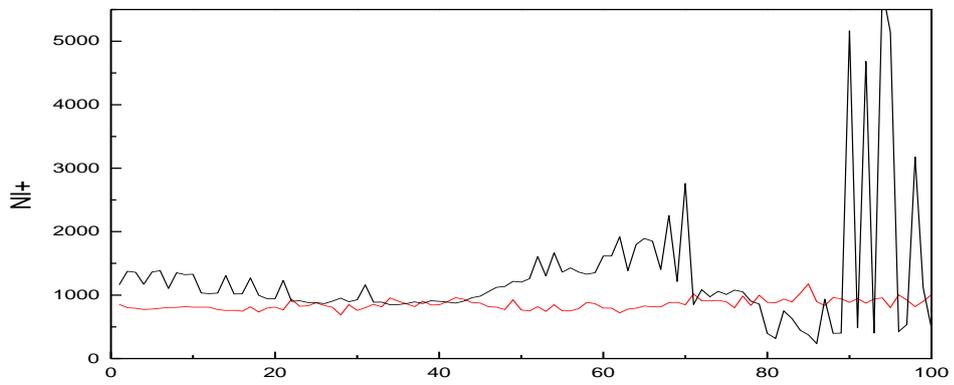
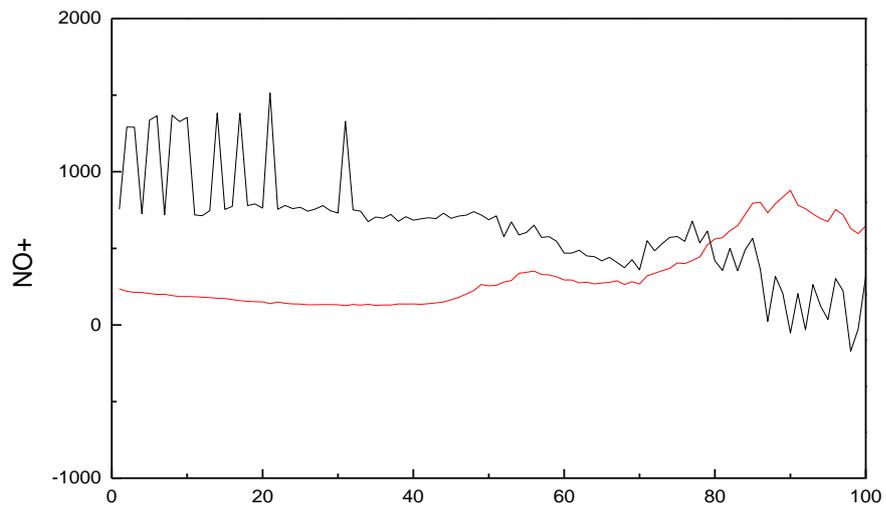
**Fig. III.6** Deuxième groupe de 151 échantillons de l'instrument IAP utilisés comme sortie désirée de la machine MALP pour apprentissage.



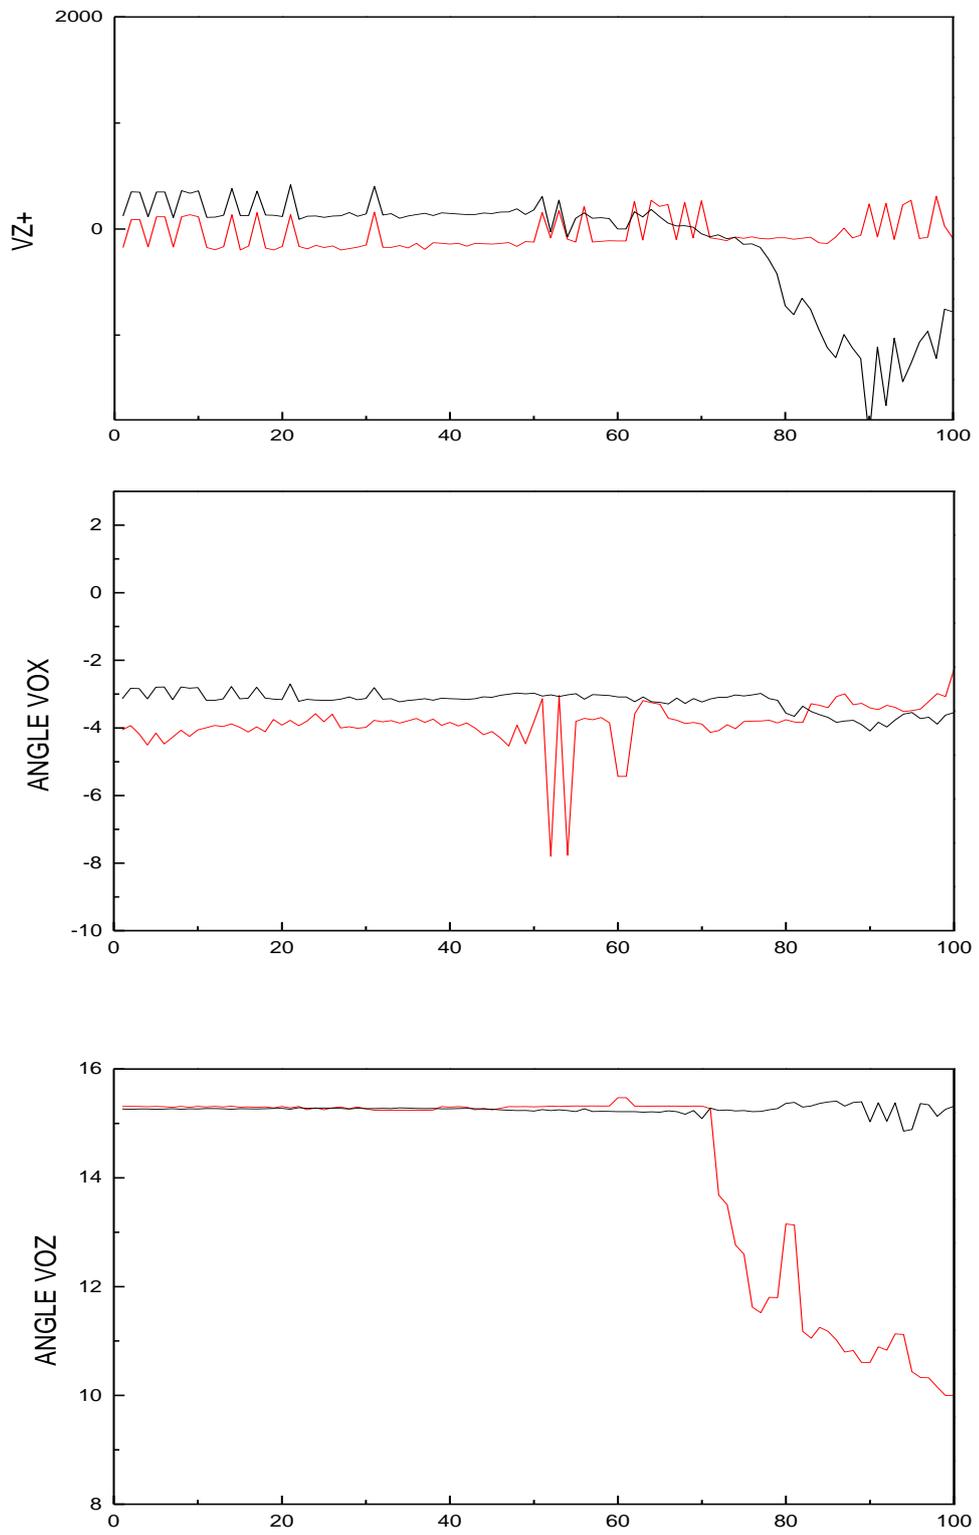
**Fig. III.6** La suite.



**Fig. III.7** Paramètres de l'instrument IAP du plasma ionosphérique prédits en utilisant la machine MLP implémentée



**Fig. III.7** La suite



**Fig. III.7** La suite

## **Prediction of Ionospheric Perturbations Using Artificial Neural Network. Application to ISL Instrument Data- DEMETER Mission**

Sid-Ali Ouadfeul, Victor Tourtchine, and Leila Aliouane

Ce travail a été publié dans Lecture notes in Computer Sciences (Springer), nous donnons ici le résumé en français, l'article complet se trouve en annexe 1.

### **Résumé :**

Dans cet article, une tentative de prédiction des paramètres ionosphériques enregistrés par l'instrument Langmuir (ISL) installé à bord du satellite DEMETER en utilisant les réseaux multicouches est implantée. La machine MLP proposée est composée de trois couches, une couche d'entrée à quatre neurones, une couche cachée à dix neurones et une couche de sortie ayant le même nombre d'unités telle que la couche d'entrée. Les paramètres prédits sont : La densité des électrons, la densité des ions, la température des électrons le potentiel du plasma. L'application aux données de l'orbite 27447-1 enregistrées deux jours avant le tremblement de terre de L'Aquila du 06 Avril 2009 montre clairement la puissance du réseau de neurones artificiels dans la prévision des perturbations ionosphériques et l'analyse du Plasma mais à très court terme.

**Mots-clés :** ISL, Demeter, MLP, Prédiction.

## **Ionospheric Data Analysis of Demeter Sattelite Using Neural Network: Application to IAP Instrument**

Sid-Ali Ouadfeul, Leila Aliouane and Victor Tourtchine

Ce travail a été publié dans Lecture note in Computer Sciences (Springer), nous donnons ici le résumé en français, l'article complet se trouve en annexe 2.

### **Résumé :**

Dans cet article, nous utilisons les réseaux de neurones artificiels de type Multilayer Perceptron (MLP) pour la prédiction des perturbations ionosphériques par analyse des données enregistrées par l'instrument analyseurs du plasma (IAP) installé à bord du satellite DEMETER Les données utilisées comme entrée de la machine MLP et comme sortie pour l'apprentissage sont : La densité de l'Hélium, des ions et des électrons ; la température des ions, la vitesse et direction des ions. La machine MLP est composée d'une couche d'entrée, une couche cachée et une couche de sortie. L'application aux données du satellite DEMETER de la demi l'orbite 27447-1 montre que la machine MLP est capable de prédire les paramètres du plasma ionosphérique mais très court terme.

**Mots-clés :** IAP, DEMETER, MLP, perturbations, prédiction.

**Chapitre IV :           Analyse Multi fractale  
par transformée en ondelettes continue des  
données du satellite DEMETER avant le  
séisme de L'Aquila de 2009**

### IV.1) Introduction

L'analyse fractale est devenue un outil très utile pour l'étude de la physique du plasma, Nurujjaman et al (2009) ont utilisé la transformée en ondelettes continue pour effectuer une analyse Multifractale des oscillations non-linéaires dans un plasma à décharge luminescente. Imamura et al (2010) ont publié un document sur l'analyse fractale des données de propagation de LF sous-ionosphérique et en considérant le couplage lithosphère-atmosphère-ionosphère ; les résultats obtenus montrent que la connexion de l'analyse fractale pour les données VLF / LF ionosphériques avec la sismicité se trouve être pas très prononcée.

L'étude des risques naturels en utilisant les données du microsatellite français DEMETER est devenue un sujet de recherche moderne (Parrot et al, 2006 ; Sarkar et al, 2007 ; Zhang et al, 2009 ; Akhoondzadeh et al, 2010), la plupart des articles publiés établissent les données enregistrées par la mission DEMETER avant les risques naturels. Sarkar et al (2010) ont analysé les anomalies ionosphériques associées au séisme en Haïti du 12 Janvier 2010 observée par le satellite DEMETER, les résultats obtenus montrent une augmentation significative de la densité et de la température des électrons près de l'épicentre. Une diminution de la température des électrons est observée quelques jours après le tremblement de terre. Une anomalie de variations de ces paramètres ionosphériques est observée à la fois dans le jour et la nuit avant le tremblement de terre. L'analyse statistique des données DEMETER montre que les données satellitaires peuvent jouer un rôle important pour l'étude des phénomènes précurseurs associée à des tremblements de terre.

De nombreux auteurs ont utilisé le modèle Mouvement brownien Fractionnaire (MBF) pour réaliser une analyse fractale des données satellitaires DEMETER (Zaourar et al, 2011, Zaourar et al, 2009), ils ont essayé de montrer le comportement mono-fractal de ces données avant les tremblements de terre. La Méthode des Maxima du Module de la transformée en Ondelettes (MMTO) est devenue un outil très utile en géophysique, Ouadfeul et Aliouane (2011, 2012) ont mis en place une technique de segmentation automatique du lithofaciès en utilisant la méthode MMTO, les résultats obtenus montrent la puissance de cette méthode pour la segmentation du lithofaciès.

Ouadfeul et al (2012) ont utilisé cette méthode pour la reconnaissance du faciès à partir des données sismiques synthétiques des données du forage Allemand Kontinentales Tiefbohrprogramm de Bundesrepublik Deutschland (KTB). Dans ce chapitre, la méthode MMTO est utilisée pour démontrer le comportement multifractal des données enregistrées par l'instrument Langmuir (ISL) du satellite DEMETER, enregistrées au cours du 04 Avril 2009, deux jours avant le tremblement de terre de L'Aquila.

## IV.2) Analyse MMTO

La méthode MMTO est appliquée aux données de l'instrument ISL du satellite DEMETER enregistrées au cours de la nuit du 04 d'Avril 2009, deux jours avant le tremblement de terre de L'Aquila, la figure IV.1 montre l'interférogramme du tremblement de terre qui révèle le déplacement de surface. Les données de l'instrument ISL enregistrées au cours du 04 Avril 2009, deux jours avant le tremblement de terre de L'Aquila sont analysées en utilisant la méthode des maxima du module de la transformée en ondelettes continue (MMTO), le code source de la méthode MMTO a été développé en langage C. Les données sont: Densité des électrons et des ions, la température des électrons et le potentiel du plasma. La figure IV.2 montre les graphes de ces données du plasma en fonction du temps. Les données des deux modes Burst et Survey sont fusionnées, le pas d'échantillonnage est de 1 seconde. Ces données DEMETER sont composées de 1837 échantillons, ce qui est suffisant pour appliquer la méthode MMTO, notons que la méthode MMTO nécessite au moins 128 échantillons (Biswas et al, 2012).

Le premier signal à analyser est la densité des électrons ; la figure IV.3 montre le module de sa transformée en ondelettes continue, l'ondelette d'analyse est celle de Morlet complexe (Grosman et Morlet, 1985). La deuxième étape consiste à calculer les maxima du module de la transformée en ondelettes continue, les chaînes de maxima sont appelés le squelette (voir Fig IV4). La fonction de partition est alors calculée et présentée en échelle logarithmique par rapport à l'échelle  $q$ ;  $q$  varie de -2 à +2 avec un pas de 0,125 (voir Fig. IV5). La courbe la plus basse de la courbe de la fonction de partition correspondent à  $q = -2$ , cependant la courbe la plus haute correspond à  $q = + 2$ . Le spectre des exposants est estimé pour chaque valeur de  $q$  en utilisant une régression linéaire du logarithme de la fonction de partition en fonction du logarithme de l'échelle  $a$ . La figure IV.6 représente le spectre des exposants  $\tau(q)$  par rapport à  $q$ ,  $q$  variant de -2 à +2, avec un pas de 0,125. Le spectre des singularités est estimé en utilisant les poids de Boltzmann à partir des coefficients de la transformée en ondelettes et la fonction de partition (Arneodo et Bacry, 1995), la figure IV.7 montre le spectre des singularités en fonction de l'exposant de Hölder ou l'exposant de singularité.

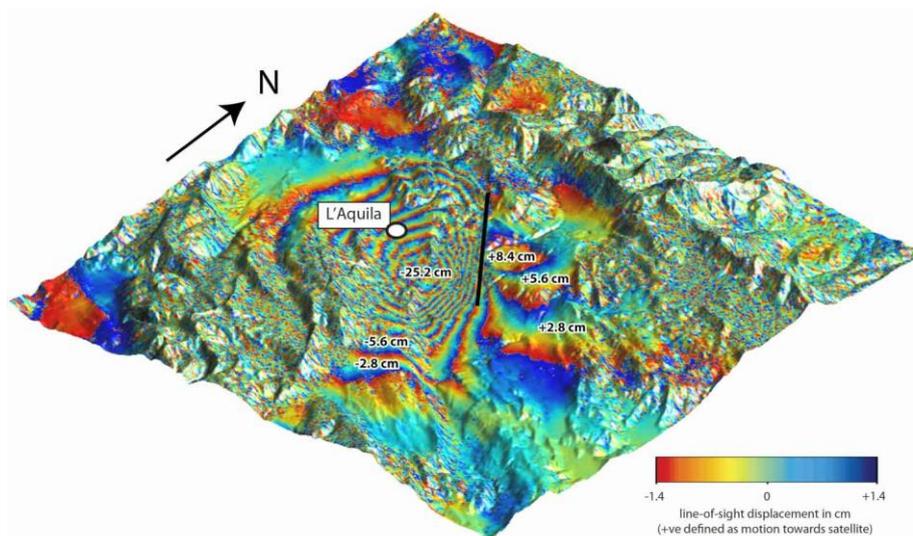


Fig.IV.1: Interférogramme du tremblement de terre de l'Aquila qui révèle le déplacement de surface.

### IV.3) Interprétation des résultats

Il est clair que le spectre des exposants de la densité des électrons n'a pas un comportement linéaire (Fig.IV.9), de plus dans le spectre des singularités de la densité des électrons on observe que l'exposant de Hölder locale varie de 0,2 à 0,8 tandis que le spectre  $D(h)$  varie de 0,1 à 0,9, les faibles exposants de Hölder sont plus dominants par rapport aux exposants élevés, ce qui prouve que le contenu en hautes fréquences est plus dominant dans le signal de densité des électrons, donc plus perturbée avant le choc principal du séisme de l'Aquila. Par conséquent, l'analyse des figures IV.6 et IV.7 montre le comportement multifractal du signal de densité des électrons avant le séisme de L'Aquila.

Les spectres des exposants et de singularité de la densité des ions (voir Figs IV.8 et IV.9) présentent les mêmes comportements comme ceux des spectres des exposants et des singularités de la densité des électrons, par conséquent, le signal de densité des ions a un comportement multifractal avant le tremblement de terre de L'Aquila. La figure IV.10 montre le spectre des exposants de la température des électrons en fonction du  $q$ , tandis que la figure IV.11 montre le spectre des singularités en fonction de l'exposant de singularité qui varie de 0,20 à 0,80. Par conséquent, le signal de la température des électrons dispose également d'un comportement multifractal, mais il est moins perturbé par rapport aux deux premiers signaux du plasma ionosphérique. Les figures IV.12 et IV.13 montrent que les spectres des exposants et des singularités du potentiel du plasma présentent les

mêmes formes, telles que la température d'électrons. Par conséquent que le potentiel du plasma a un comportement multifractal.

Pour vérifier le comportement de l'ionosphère dans les jours calmes, les données de l'instrument ISL enregistrées le 04 Juin 2009, deux mois après le choc principal du tremblement de terre de L'Aquila sont analysées par la méthode MMTO, la figure IV.14 représente la densité des électrons, la densité des ions, la température des électrons et le potentiel du plasma, respectivement. La figure IV.15a présente le spectre des exposants obtenus par analyse MMTO de la densité des électrons, tandis que la figure IV.15b représente le spectre des singularités. Dans ce cas, le spectre des exposants est une ligne droite d'équation  $\tau(q) = 1,16 * q-1$  et le spectre des singularités  $D(h)$  est nulle partout sauf au point  $h = 1,16$  où  $D(h) = 1$ , cela suffit pour dire que le signal de la densité des électrons a un comportement monofractal dans les jours calmes. Les spectres des exposants et des singularités de la densité des ions sont représentés sur les figures IV.16a et IV.16.b respectivement, le spectre des exposants a un comportement linéaire d'équation  $\tau(q) = 1,28*q-1$  et le spectre de singularités comporte une équation  $D(h) = 0$  si  $h \neq 1,28$  et  $D(h) = 1$  si  $h = 1,28$ . Par conséquent, le signal de la densité des ions a un comportement monofractal. L'analyse MMTO du signal du potentiel du plasma et la température des électrons sont présentés dans les figures IV.17a, IV.17b, IV.18a et IV.18b, les résultats obtenus montrent que ces deux signaux ionosphériques ont un comportement monofractal.

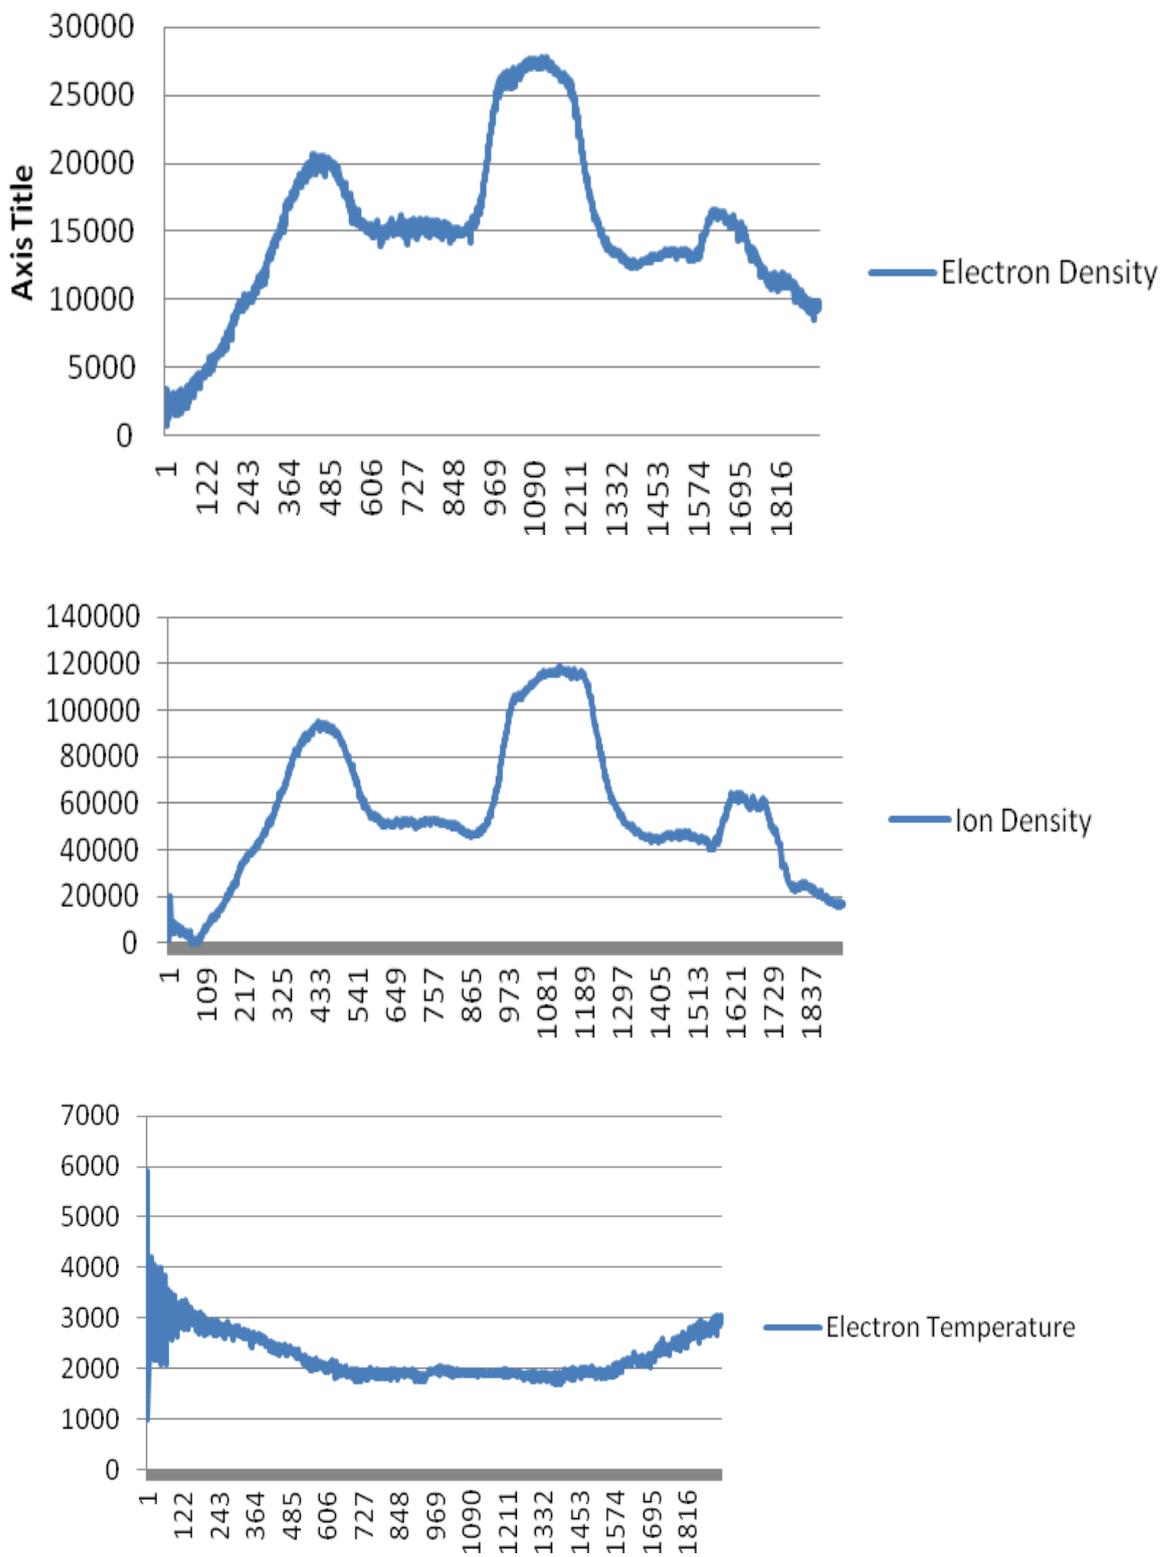


Fig.IV.2 Données de l'instrument ISL de la demi-orbite 27447-1 enregistrées le 04 Avril 2009 par rapport au temps.

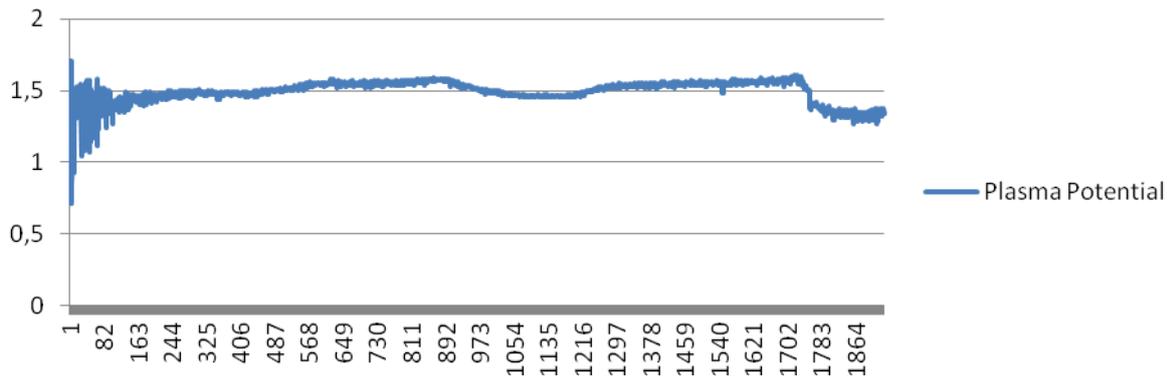


Fig. IV.2 Suite.

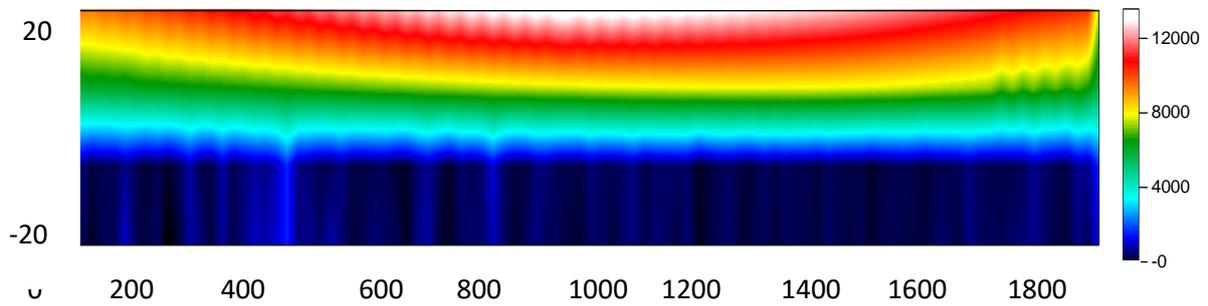


Fig.IV.3 Module de la transformée en ondelettes continue du signal de la densité des électrons présente dans le demi plan temps-log dilatation, l’ondelette analysante est la Morlet complexe.

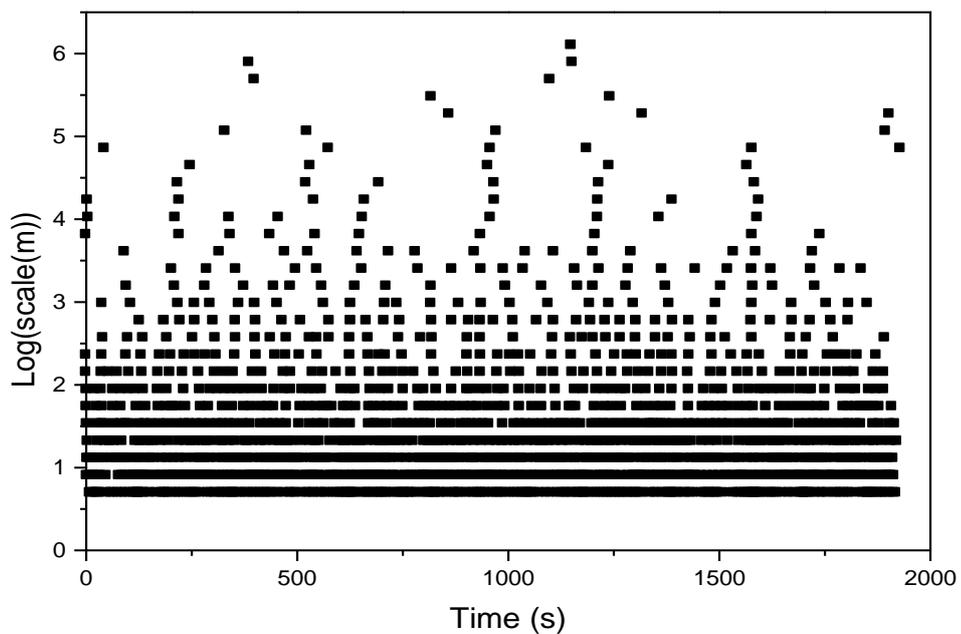


Fig.IV.4 Squelette de la transformée en ondelettes continue dans le demi plan temps- log dilatation.

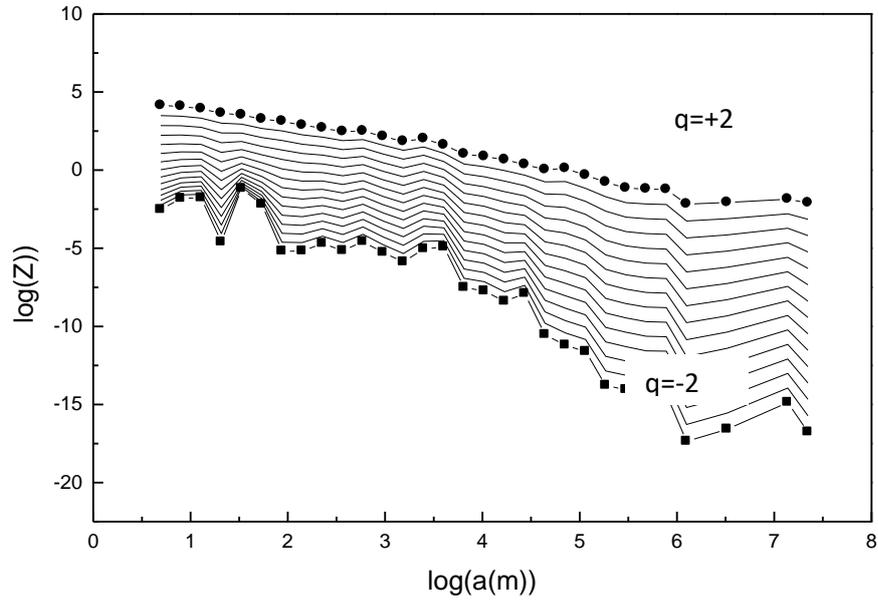


Fig.IV.5 Fonction de partition en fonction du logarithme de l'échelle pour chaque valeur de,  $q$  varie de -2 to +2 avec un pas de 0.125.

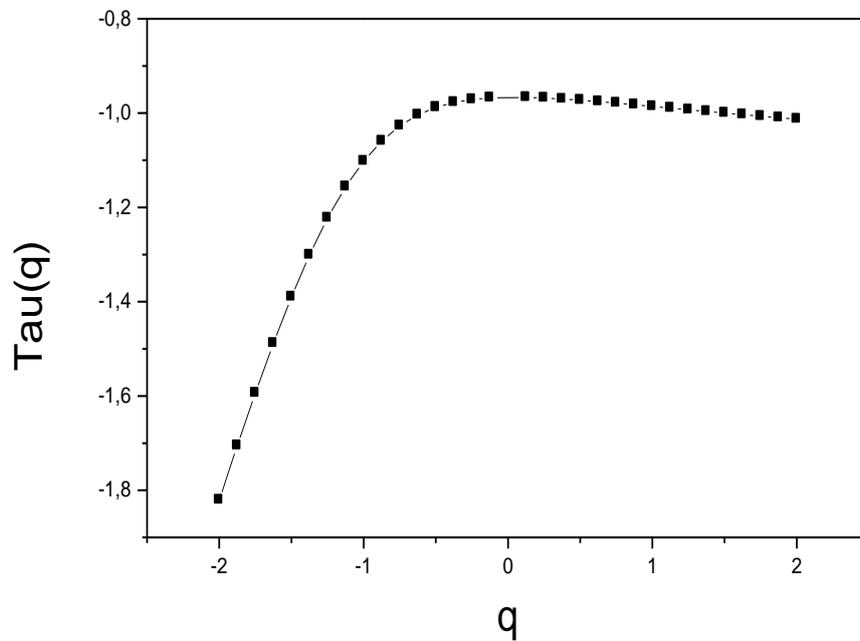


Fig.IV.6 Spectre des exposants en fonction  $q$  du signal de la densité des électrons.

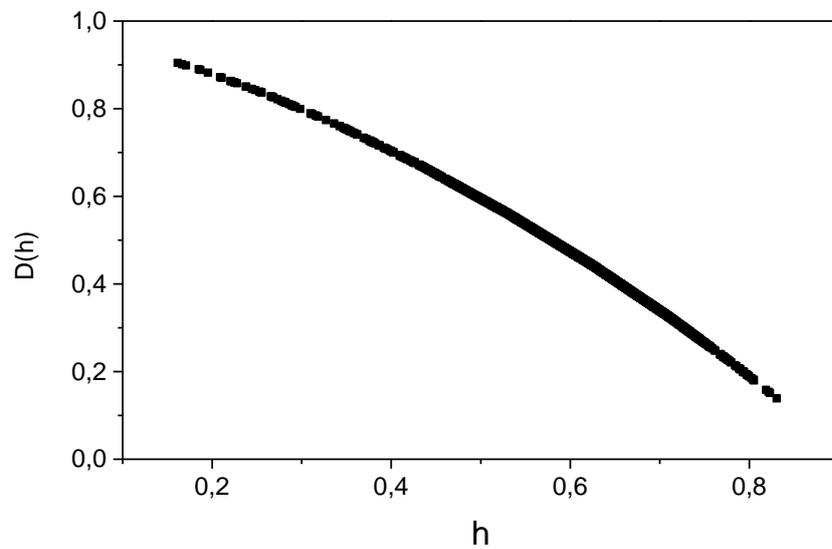


Fig.IV.7 Spectre des singularités de la densité des électrons indiquant le comportement multifractal de la physique du plasma.

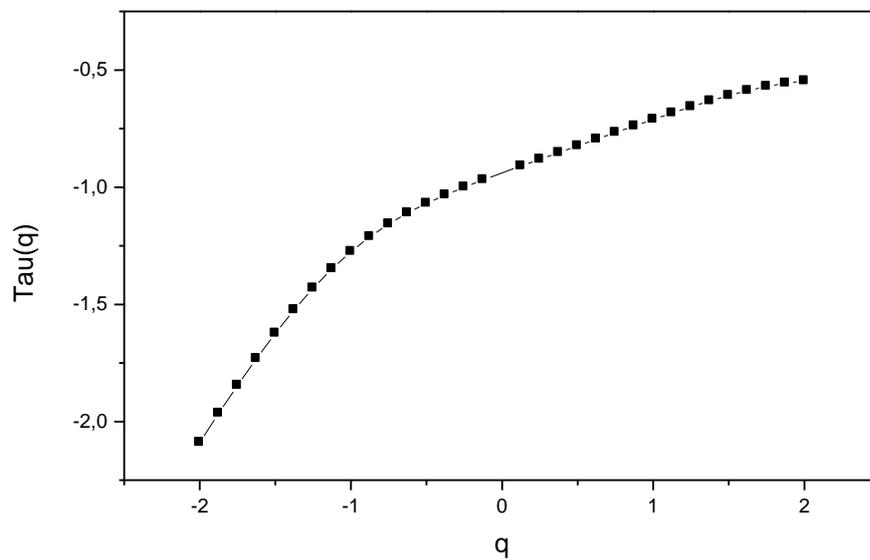


Fig.IV.8 Spectre des exposants obtenu par analyse MMTO de la densité des ions.

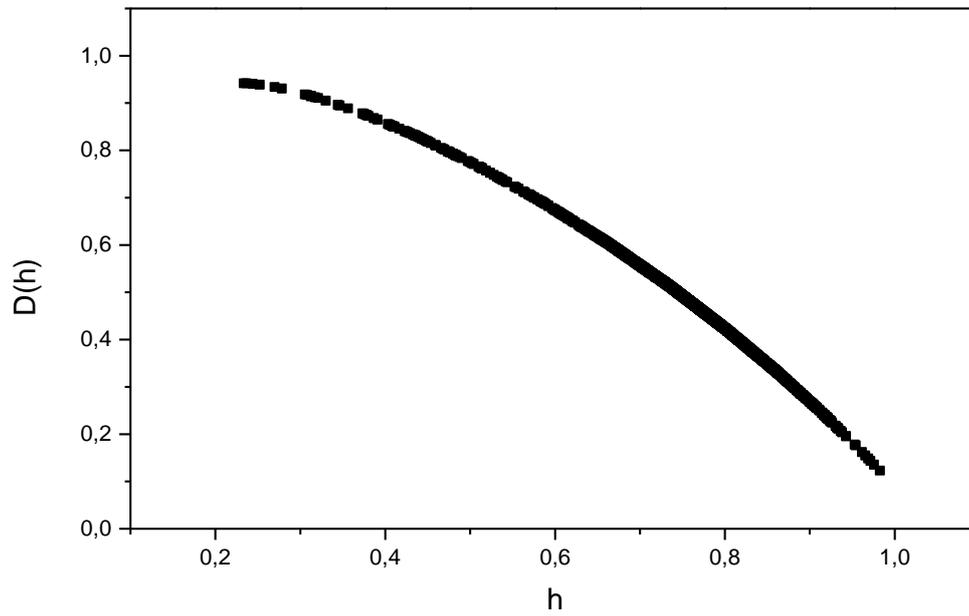


Fig.IV.9 Spectre des singularités du signal de la densité des ions.

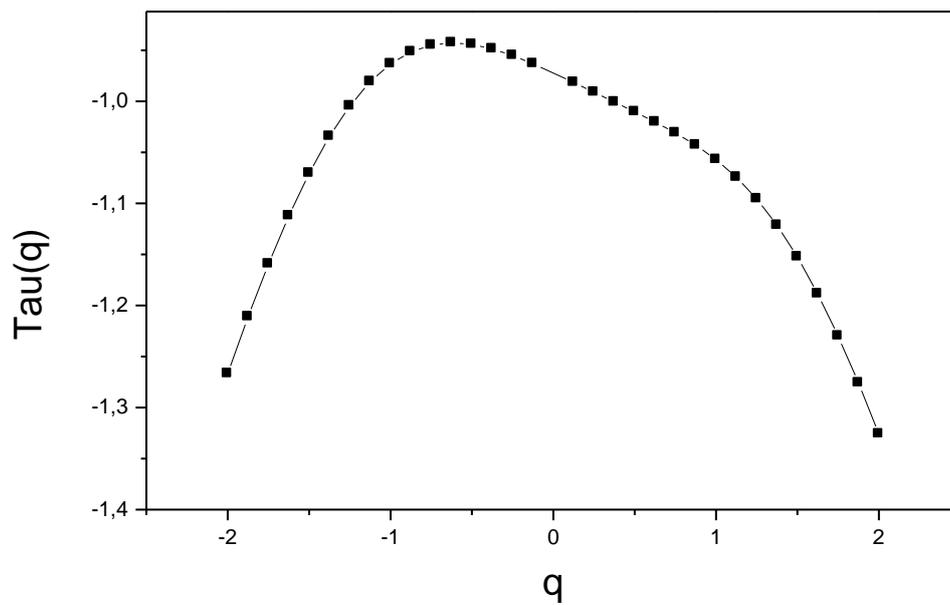


Fig.IV.10 Spectre des exposants de la densité des électrons.

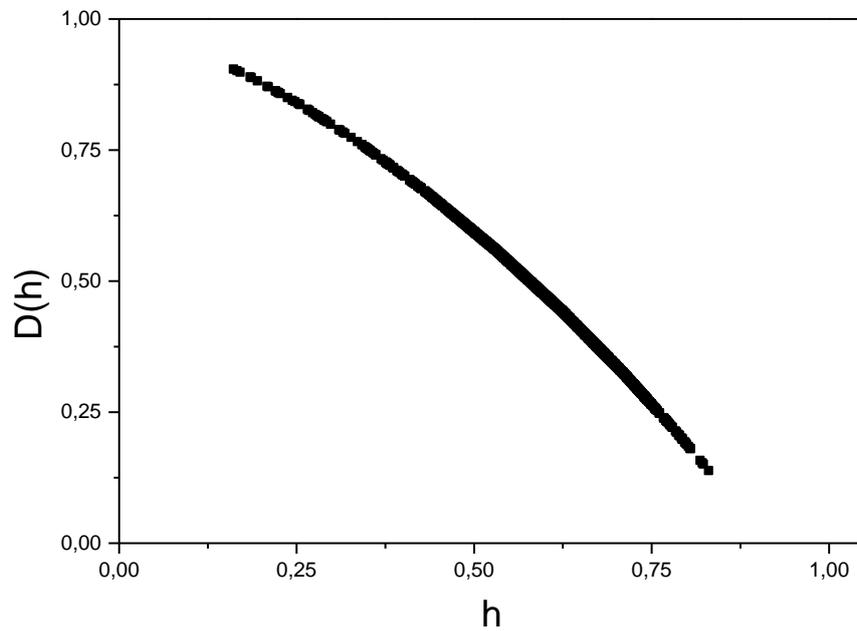


Fig.IV.11 Spectre des singularités du signal de la densité des électrons.

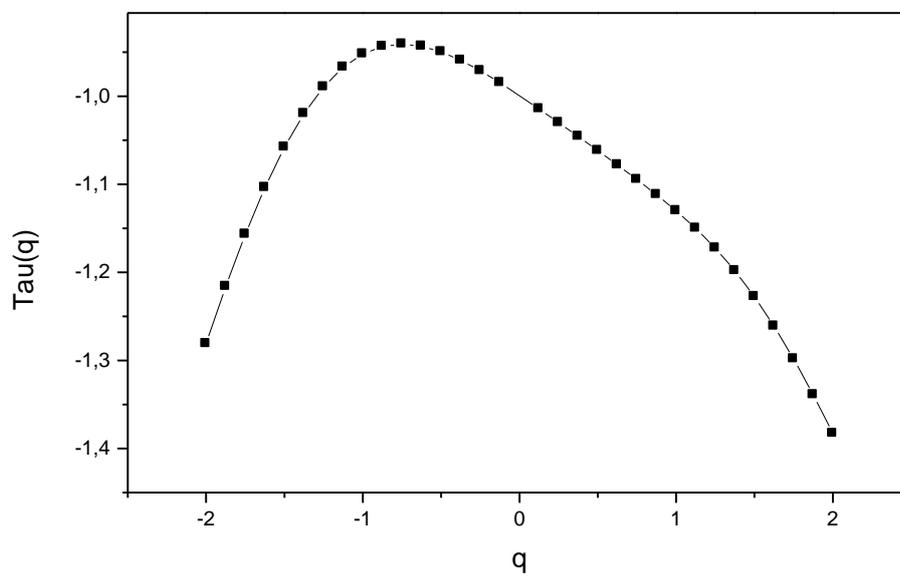


Fig.IV.12 Spectre des exposants du potentiel du plasma.

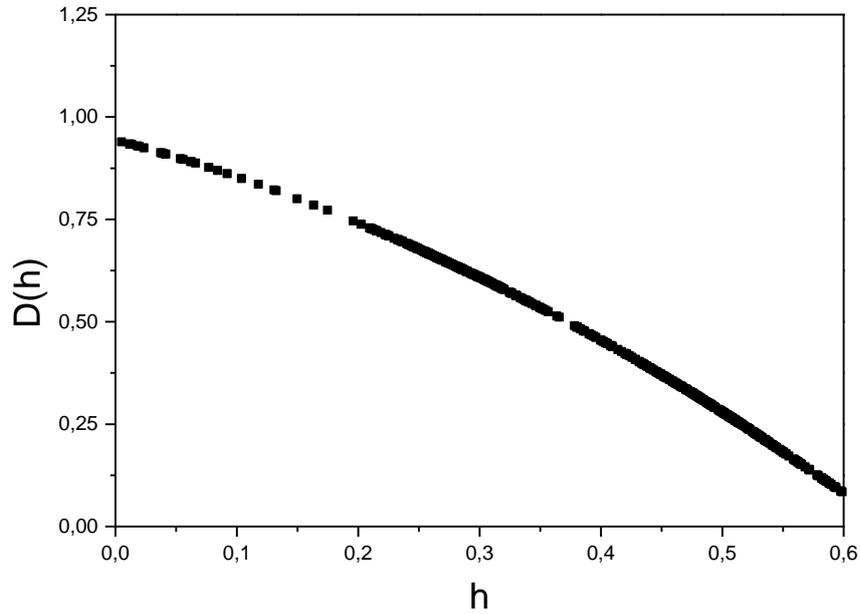


Fig.IV.13 Spectre des singularités du signal potentiel du plasma.

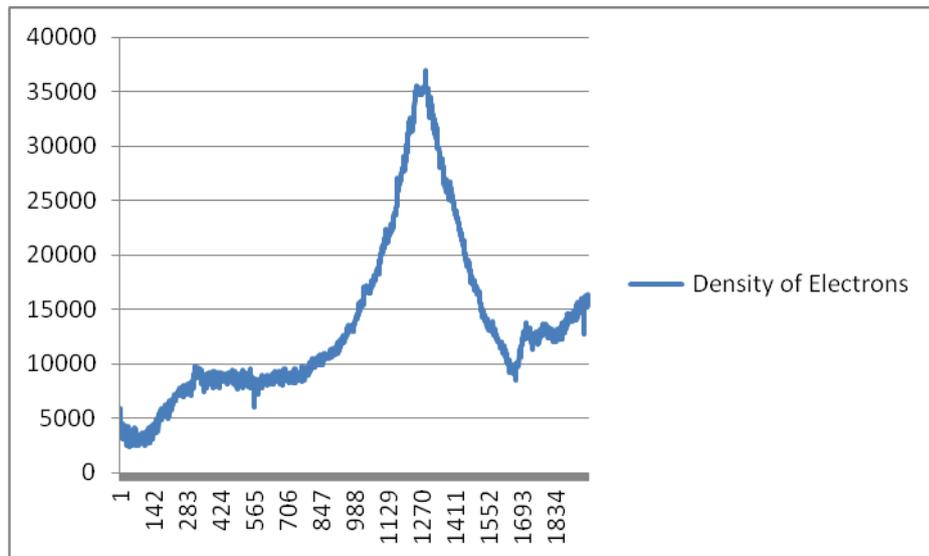


Fig.IV.14 Données de l'instrument ISL de la demi-orbite 27447-1 enregistrées au cours de 04 Juin 2009, deux mois après le choc principal de L'Aquila en fonction du temps.

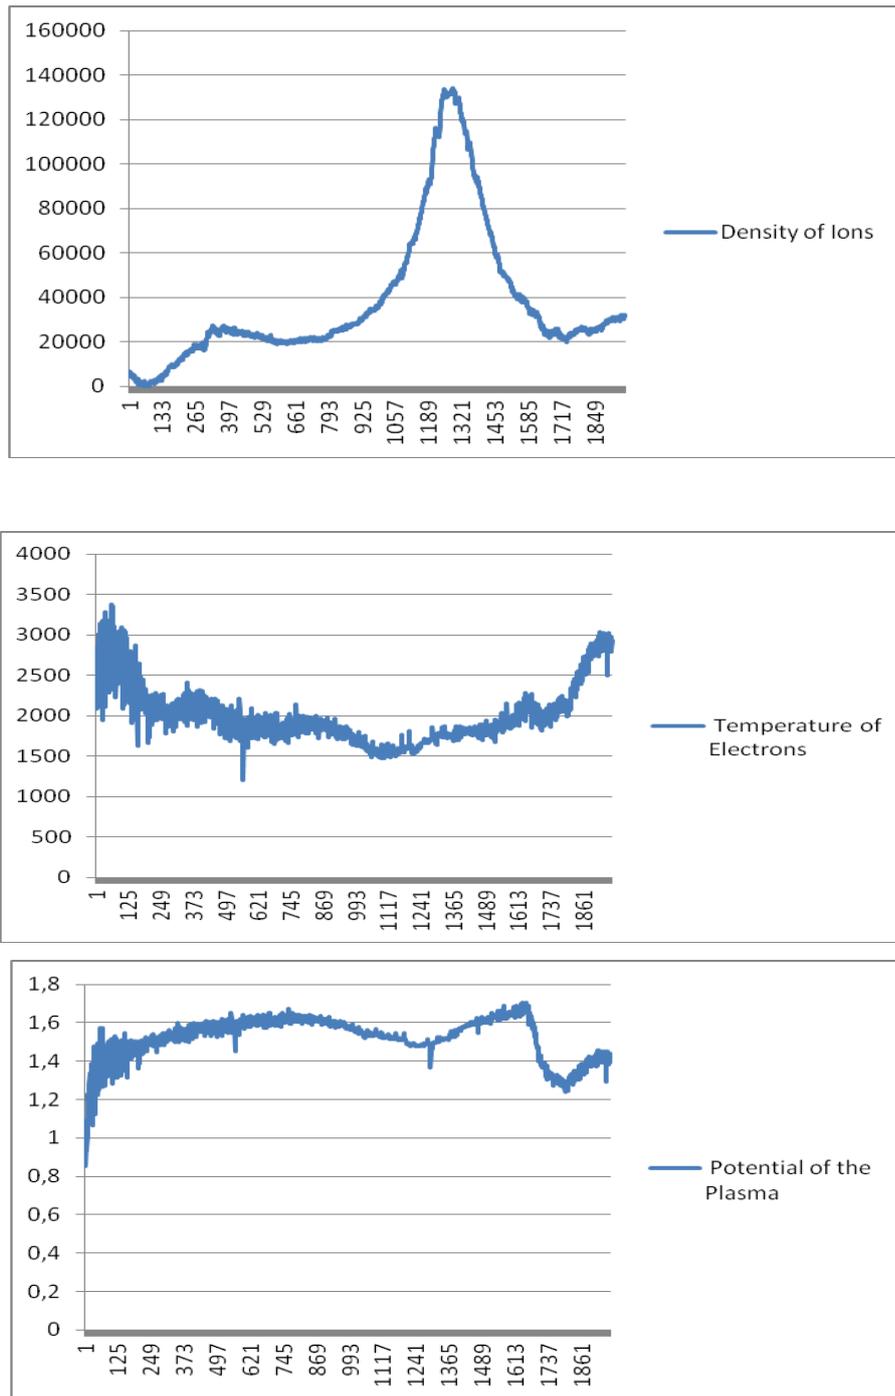


Fig.IV.14 La Suite

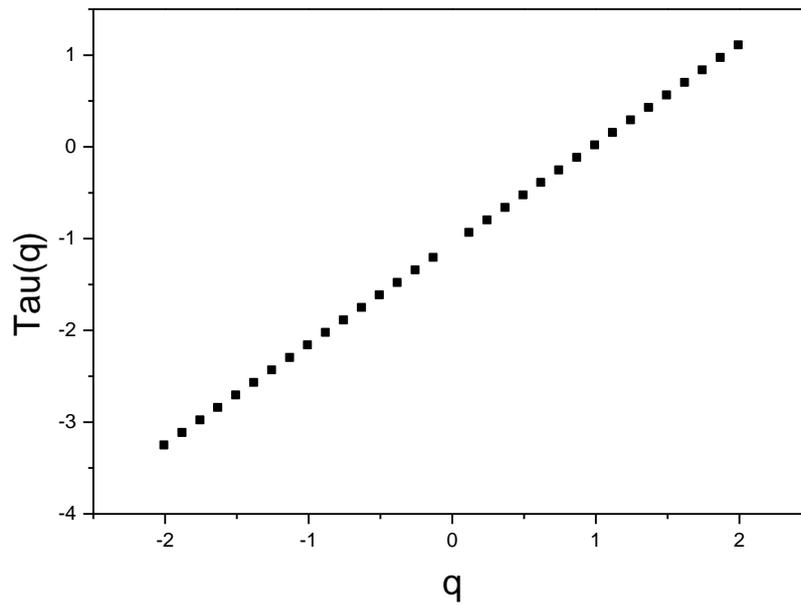


Fig. IV.15a Spectre des exposants du signal de la densité des électrons enregistrée le 04 Juin 2009.

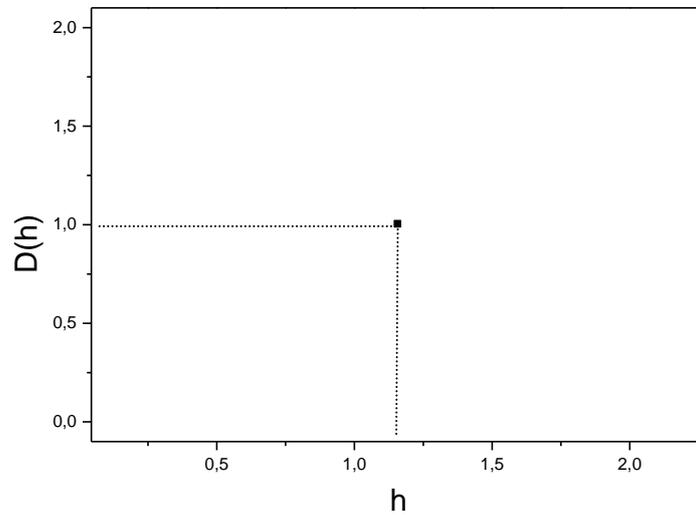


Fig.IV.15b Spectre des singularités de la densité d'électrons enregistré le 04 Juin 2009.

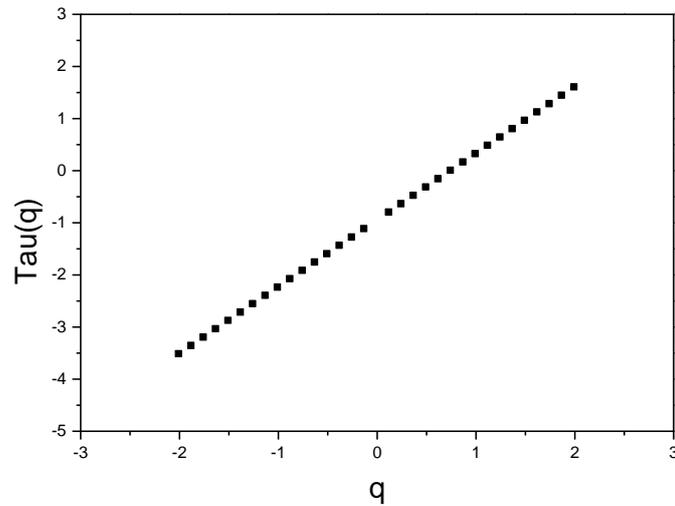


Fig.IV.16a Spectre des exposants de la densité des ions enregistrée deux mois après le choc principal du tremblement de terre de L'Aquila.

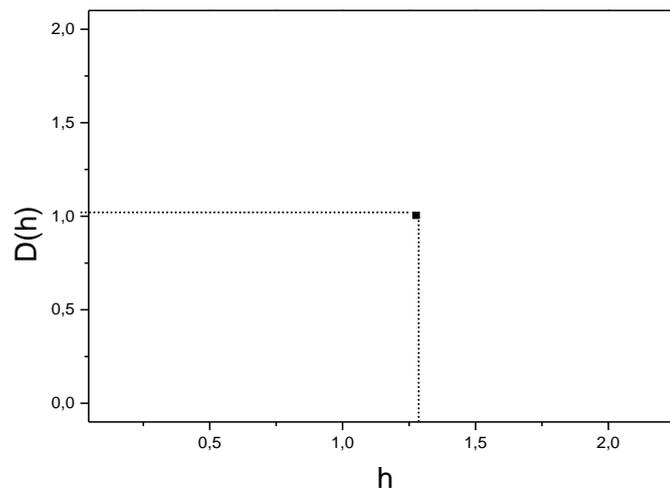


Fig.IV.16b Spectre des singularités de la densité des ions enregistrée deux mois après le tremblement de terre L'Aquila.

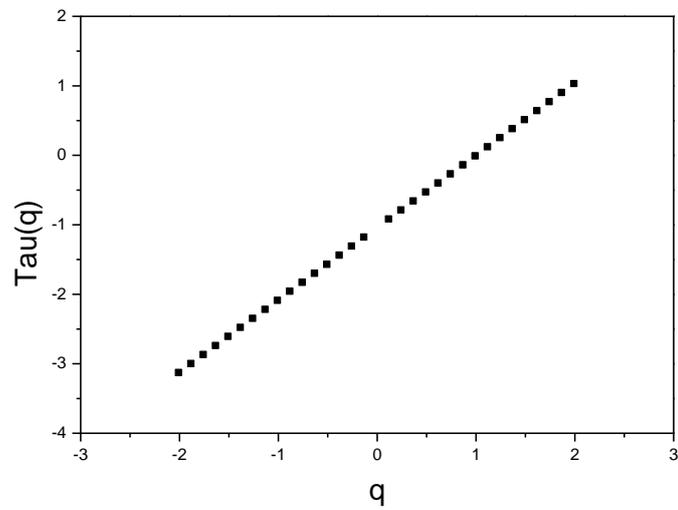


Fig.IV.17a Spectre des exposants du potentiel du plasma enregistré par DEMETER au cours du 04 Juin 2009

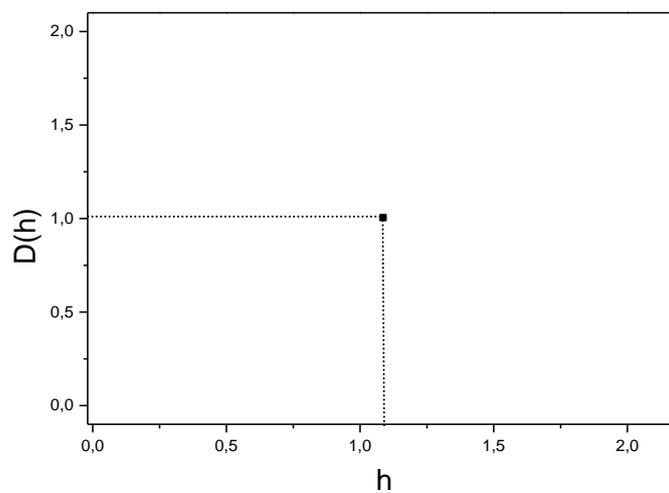


Fig.IV.17b Spectre des singularités du potentiel du plasma enregistré par DEMETER le 04 Juin 2009.

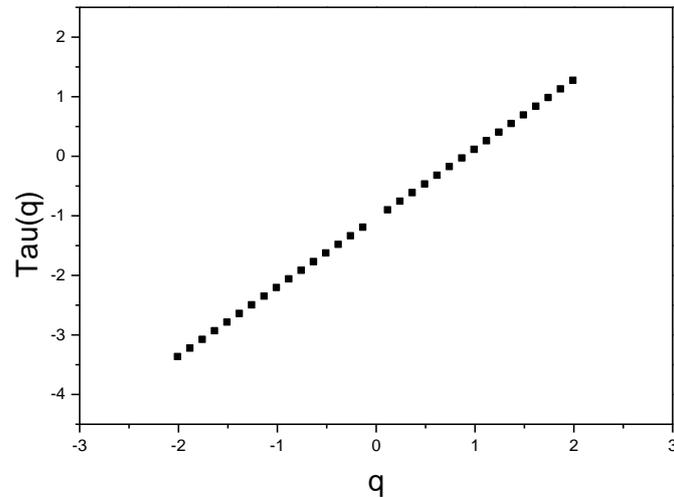


Fig.IV.18a Spectre des exposants de la température des électrons enregistrées le 04 juin 2009

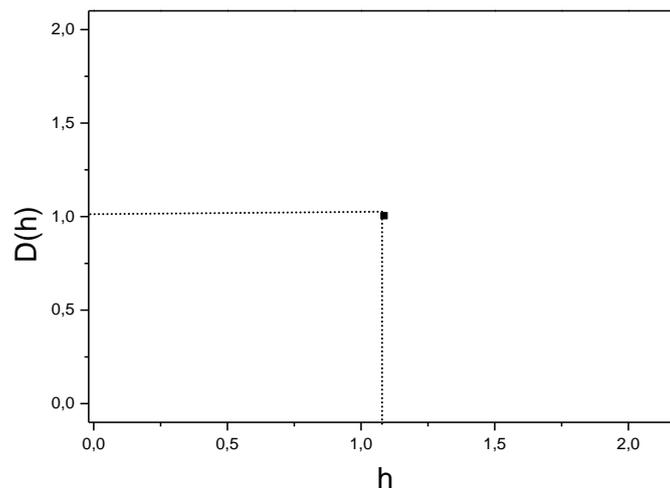


Fig.IV.18b Spectre des singularités de la température des électrons enregistré le 04 Juin 2009.

#### IV.4) Conclusion

L'analyse MMTO des données de l'instrument ISL installé à bord de la mission DEMETER enregistrés deux jours avant le tremblement de terre de L'Aquila de 2009 montre clairement le comportement multifractal de ces signaux du plasma ionosphérique. L'analyse des signaux enregistrés par le même instrument enregistrés le 04 Juin 2009, deux mois après le choc principal, montre que la réponse physique de l'ionosphère a un comportement monofractal. Ce qui n'est pas en accord avec de nombreuses recherches dans la littérature (Zaourar et al, 2009; Zaourar et al, 2011) qui utilisent le modèle du Mouvement brownien Fractionnaire (mbf) pour étudier le compor-

tement non-linéaire de l'ionosphère avant les tremblements de terre. Par conséquent, nous suggérons d'utiliser des outils d'analyse multifractale comme la méthode des maxima du module de la transformée en ondelettes, le mouvement brownien multi-fractionnaire (Ayache et Levy Vehel, 2000) et la méthode Multifractal Detrended Fluctuations Analysis (Eke et al, 2000) pour l'analyse multifractale des données du satellite DEMETER avant les tremblements de terre.

### **Wavelet-Based Multifractal Analysis of DEMETER Satellite Data Before the L'Aquila Earthquake of 2009**

Sid-Ali Ouadfeul, Victor Tourtchine, and Leila Aliouane

Ce travail a été publié dans la revue *Arabian Journal of Sciences and Engineering* (Springer), nous donnons ici le résumé en français, pour l'article complet voir l'annexe 3.

#### **Résumé**

L'objectif principal de cet article est de démontrer le comportement multifractal des signaux du plasma ionosphérique enregistrés par l'instrument ISL installé à bord du satellite DEMETER avant le tremblement de terre de L'Aquila de 2009. L'analyse multifractale est réalisée en utilisant la Méthode des Maxima du Module de la Transformée en Ondelettes (MMTO). Les signaux à analyser sont les suivants : Densité des électrons et des ions, température des électrons et le potentiel du plasma. L'analyse MMTO des données enregistrées pendant le 4 Avril 2009, qui reconnaît de nombreuses perturbations ionosphériques avant le choc principal du tremblement de terre de L'Aquila montre clairement le comportement multifractal de la réponse physique du plasma ionosphérique. L'analyse MMTO des données du plasma ionosphérique enregistrées par le satellite DEMETER deux mois après le choc principal du tremblement de terre de L'Aquila montre le comportement monofractal de la réponse du plasma.

Mots-clés : Multifractal , MMTO , ISL , DEMETER, tremblement de terre de L'Aquila.

## **Conclusion générale et Recommandations**

## **Conclusion générale et Recommandations :**

Nous avons analysé les données du plasma ionosphérique en utilisant deux outils à savoir les réseaux de neurones artificiels et l'analyse multifractale combinée avec la transformée en ondelettes continue. L'analyse par réseaux de neurones de type multilayer perceptron montre clairement que la machine MLP a une capacité de prédiction mais à très court terme. La machine neuronale proposée a une bonne mémoire pour la plupart des séries de temps à court terme, mais la machine commence à perdre de la mémoire à la fin de chaque série. Par conséquent, nous avons besoin toujours de mettre à jour les poids de connexion pour obtenir de meilleurs résultats. La machine peut être largement utilisée pour la prédiction des perturbations ionosphériques, ces derniers ont une grande relation avec l'activité sismique ; la méthode des réseaux de neurones artificiels joue un rôle important dans la prévention des risques sismiques. Nous proposons aussi de tester d'autres modèles de réseaux neuronaux comme les réseaux à fonction de base radiale (RBF) pour choisir le meilleur réseau de neurones qui peut être utilisé pour la prédiction des données des instrument IAP et ISL du satellite DEMETER. L'analyse des données du plasma ionosphérique par la méthode des maxima du module de la transformée en ondelettes continue des données de l'instrument ISL installé à bord de la mission DEMETER montre clairement le comportement multifractal de la réponse physique du plasma ionosphérique avant le choc principal du tremblement de terre de L'Aquila. L'analyse MMTO de ces paramètres deux mois après le choc principal montre que la réponse physique ionosphère a un comportement monofractal. Ceci n'est pas en accord avec de nombreuses recherches dans la littérature qui utilisent le modèle mouvement brownien fractionnaire (mBf) pour étudier le comportement non-linéaire de l'ionosphère avant les tremblements de terre. Par conséquent, nous suggérons d'utiliser des outils d'analyse multifractale tels la méthode des maxima du module de la transformée en ondelettes, le mouvement brownien multi-fractionnaire et la méthode Multifractal Detrended Fluctuations Analysis (MDFA) pour l'analyse fractale des données du satellite DEMETER avant les tremblements de terre. A travers ce travail de thèse, nous avons montré le caractère très complexe du plasma ionosphérique, qui est aussi très variable dans le temps, très difficile à prédire par la technique des réseaux de neurones. Le travail de cette thèse rentre dans le cadre de la prévention contre les risques naturels, nous suggérons d'appliquer d'autres outils de traitement du signal sur ces données pour comprendre mieux la physique très complexe du plasma ionosphérique tel que le deep learning et la logique floue.

# **Bibliographie**

**Bibliographie:**

1. **Arneodo, A., Bacry, E.,** 1995, Ondelettes ,multifractal et turbulence de l'ADN aux croissances cristallines, Diderot editeur arts et sciences ,Paris, 1995.
2. **Arneodo A, Grasseau G, Holschneider M,** 1988, Wavelet transform of multifractals. Phys Rev Lett 61:2281–2284
3. **Ayache, A., Levy Vehel, J.,** 2000, The Generalized Multifractal Brownian Motion, Statistical Inference for Stochastic Processes, Volume 3, Issue 1-2, pp 7-18.
4. **Akhoondzadeh, M., Parrot, M., and Saradjian, M. R.,** 2010, Electron and ion density variations before strong earthquakes ( $M > 6.0$ ) using DEMETER and GPS data, Nat. Hazards Earth Syst. Sci., 10, 7–18, doi:10.5194/nhess-10-7-2010, 2010.
5. **Abdallah, A. et Bouzzgarou, H.,** 2012, Application de l'imitation comme moyen de pilotage de robots mobiles, EnstaParitech.
6. **Bankov , L.G., Parrot , M., Heelis, R.A., Berthelier , .-J., Marinov , P.G., Vassileva , A.K.,** 2010, DEMETER and DMSP satellite observations of the disturbed  $H^+/O^+$  ratio caused by Earth's seismic activity in the Sumatra area during December 2004, ; Advances in Space Research 46, 4 (2010) 419-430.
7. **Biswas, A., Zeleke, T.B., Si, B.C.,** 2012, Multifractal detrended fluctuation analysis in examining scaling properties of the spatial patterns of soil water storage, , Nonlin. Processes Geophys., 19, 227-238, doi:10.5194/npg-19-227-2012.
8. **Banerjee, A., Bej, A., Chatterjee, T.N,** 2012, On the existence of a long range correlation in the Geomagnetic Disturbance storm time (Dst) index, Astrophysics and Space Science, Volume 337, Issue 1, pp 23-32 (2012).
9. **Benahmed, N.,** 2002, Optimisation de réseaux de neurones pour la reconnaissance de chiffres manuscrits isolés : sélection et pondération des primitives par algorithmes génétiques. Mémoire de maîtrise électronique, Montréal, École de technologie supérieure.
10. **Benameur, L.,** 2012, Contribution à l'optimisation complexe par des techniques de Swarm Intelligence, Thèse de Doctorat, Université Mohamed V Agdal Rabat Maroc.
11. **Brousseau, C.,** 2005, Caractérisation Large Bande de fréquence : Application Au Radar Et Au Sondage De Canal. Signal and Image processing, Travaux scientifiques, diplôme d'habilitation à diriger des recherches université rennes 1, 2005.
12. **Cicerone R. D., Ebel J. E., Britton J.,** 2009, A systematic compilation of earthquake precursors. Tectonophysics, Volume 476, Issues 3–4, 25 October 2009, Pages 371-396.
13. **CNRS & CNES,** 2004, DEMETER: à l'écoute des tremblements de terre, p. 1-28.

14. **Dabas R. S., Das R. M., Sharma K. et al.**, 2007, Ionospheric precursors observed over low latitudes during some of the recent major earthquakes. *Journal of Atmospheric and Solar-Terrestrial Physics*, 69, p. 1813-1824.
15. **Davies K. & Baker D. M.**, 1965, Ionospheric effects observed around the time of the Alaskan earthquake of March 28, 1964. *Journal of Geophysical Research*, 70, p. 2251- 2253.
16. **Djeddou, M.**, 2014, Prédiction du taux d'échec avec les réseaux neurones artificiels dans une station de traitement des eaux résiduaires, Thèse de Doctorat, Université de Biskara.
16. **Hebb, D.**, 1949, *The organization of behavior*. Wiley, New York.
17. **Hobara, Y., Parrot M.**, 2005, Ionospheric perturbations linked to a very powerful seismic event. *Journal of Atmospheric and Solar-Terrestrial Physics*, 67, p. 677-685.
18. **Hopfield, J.J.**, 1982, Neural networks and physical systems with emergent collective computational abilities, *PNAS April* 1, 1982 79 (8) 2554-2558; <https://doi.org/10.1073/pnas.79.8.2554>
19. **Rozhnoi A., Solovieva M., Molchanov O. et al.**, 2007, Observation evidences of atmospheric gravity waves induced by seismic activity from analysis of subionospheric LF signal Holub R. F., Brady B. T. (1981) - The effect of stress on radon emanation from rock. *Journal of Geophysical Research*, 86, p. 1776-1784.
20. **Horie T., Maekawa S., Yamauchi T. et al.**, 2007, A possible effect of ionospheric perturbations associated with the Sumatra earthquake, as revealed from subionospheric very-low-frequency (VLF) propagation (NWC-Japan). *International Journal of Remote Sensing*, 28, p. 3133-3139. *spectra. Natural Hazards and Earth System Sciences*, 7, p. 625-628.
21. **Chuo Y. J., Liu J. Y., Pulinets S. A. et al.**, 2002, The ionospheric perturbations prior to the Chi-Chi and Chia-Yi earthquakes. *Journal of Geodynamics*, 33, p. 509-517.
22. **Imamura, T., Ida, Y., Kasahara, Y., Nakamura, T., Hobara, Y., and Hayakawa, M.**, 2010, Fractal analysis of subionospheric LF propagation data and consideration of the lithosphere-atmosphere-ionosphere coupling, *Nat. Hazards Earth Syst. Sci.*, 10, 901-906, 2010.
23. **Larkina V., Migulin V., Molchanov O., Kharkov I., Inchin A. and Schvetcoca V.**, 1989, Some statistical results on very low frequency radiowave emissions in the upper ionosphere over earthquakes zones. *Phys. Earth Plan. Inter.*, 57, 100-109.
24. **Lebreton, J.-P.**, 2012, On the issue of surface contamination of a Langmuir Probe sensor: DEMETER ISL results, *Geophysical Research Abstracts*, vol. 14, EGU2012-13806.
25. **Liperovsky V. A., Pokhotelov O. A., Liperovskaya E. V. et al.**, 2000, Modification of sporadic E-layers caused by seismic activity. *Surveys in Geophysics*, 21, p. 449-486.

26. **Liu, T.**, 2013, Implémentation de méthodes d'intelligence artificielle pour le contrôle du procédé de projection thermique. Thèse de Doctorat, Université de Technologie de Belfort-Montbéliard, 2013.
27. **Lynch, M., Patel, H., Abrahamse, A., Rupa Rajendran, A., Medsker, L.**, 2001, Neural network applications in physics. In: Proceedings of the International Joint Conference on Neural Networks, IJCNN 2001, vol. 3, pp. 2054–2058 (2001), doi:10.1109/IJCNN.2001.938482
28. **Lebreton, J.-P.**, 2012, On the issue of surface contamination of a Langmuir Probe sensor: Demeter IS results, Geophysical Research Abstracts, vol. 14, EGU2012-13806.
29. **Lundstedt, H., Wintoft, P.**, 1994, Prediction of geomagnetic storms from solar wind data with the use of a neural network, Annales Geophysicae, Volume 12, Issue 1, pp 19-24 (1994).
30. **McCulloch, W. S., Pitts, W., A.**, 1943, Logical Calculus of the Ideas Immanent in Nervous Activity, Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133, 1943.
31. **Mallat, S.; Hwang, W.L.**, 1992, Singularity detection and processing with wavelets," in Information Theory, IEEE Transactions on, vol.38, no.2, pp.617-643, doi: 10.1109/18.119727.
32. **Mandelbrot, B.**, 1963, The variation of certain speculative prices. J.of Business 36, 394-419.
33. **Mandelbrot, B.**, 1967, How long is the coast of Britain? Statistical self-similarity and fractional dimension. Science 156, 636-638.
34. **Mandelbrot, B., Van Ness, J.**, 1968, Fractional brownian motion, fractional noises and applications. S.I.A.M Review 10, 422-437.
35. **Mandelbrot, B.**, 1974, The Fractal Geometry of Nature. W.H. Freeman ed.
36. **Mandelbrot, B.**, 1975, Les Objets fractals : forme, hasard et dimension, Flammarion ed, Paris.
37. **Mandelbrot, B.**, 1977, Fractals: Form, Chance and Dimension., Freeman ed.
38. **Mandelbrot, B.**, 1983, The Fractal Geometry of Nature. W.H. Freeman.
39. **Mallat, S., Hwang, M.L.**, 1992, Singularity detection and processing with wavelets, IEEE Transactions on Information Theory ( Volume: 38 , Issue: 2 , March 1992
40. **Muto, F., Yoshida, M., Horie, T., et al.**, 2008, Detection of ionospheric perturbations associated with Japanese earthquakes on the basis of reception of LF transmitter signals on the satellite DEMETER. Natural Hazards and Earth System Sciences, 8, p. 135-141.
41. **Mirikitani, D.T, Ouarbya, L.**, 2009, Modeling D st with Recurrent EM Neural Networks, 2009, Lecture Notes in Computer Science Volume 5768, 2009, pp 975-984 (2009).

42. **Molchanov, O.A., Hayakawa, M., Oudoh, T., et al**, 1998, Precursory effects in the subionospheric VLF signals for the Kobe earthquake. *Physics of the Earth and Planetary Interiors*, 105, p. 239-248.
43. **Morlet, J., Arens, G., Fourgeau, E and Giard, D.**, 1982, Wave propagation and sampling theory, *Geophysics*, 47(2), 203-236.
44. **Nurujjaman, Md., Narayanan, R., Sekar Iyengar, A.N.**, 2009, Continuous wavelet transform based time-scale and multi-fractal analysis of the nonlinear oscillations in a hollow cathode glow discharge plasma, *Phys. Plasmas* 16, 102307 (2009); <http://dx.doi.org/10.1063/1.3241694>.
45. **Ondoh, T.**, 1998, Ionospheric disturbances associated with great earthquake of Hokkaido southwest coast, Japan of July 12, 1993. *Physics of the Earth and Planetary Interiors*, 105.
46. **Rozhnoi, A., Solovieva M., Molchanov, O., et al.**, 2007, Observation evidences of atmospheric gravity waves induced by seismic activity from analysis of subionospheric LF signal spectra. *Natural Hazards and Earth System Sciences*, 7, p. 625-628.
47. **Rumelhart et al.**, 1962, Apprentissage par rétro-propagation pour les réseaux multi-couches. Learning representations by back-propagating errors, *Nature*, vol. 323 (1986).
48. **Sarkar, S., Gwal, A. K., Parrot, M.**, 2007, Ionospheric variations observed by the DEMETER satellite in the mid-latitude region during strong earthquakes. *Journal of Atmospheric and Solar-Terrestrial Physics*, 69, p. 1524-1540.
49. **Sgrigna, V., Buzzi, A., Conti, L., et al.**, 2007, Seismo-induced effects in the near-earth space: Combined ground and space investigations as a contribution to earthquake prediction. *Tectonophysics*, 431, p. 153-171.
50. **Tertois, S.**, 2003, Réduction des effets des non-linéarités dans une modulation multiporteuse a l'aide de réseaux de neurons, these de Doctorat, Université Rennes 1.
51. **Ondoh, T.**, 2003, Anomalous Sporadic-E layers observed before M1., Hyogo-Ken Nanbu earthquake; terrestrial gas emanation model. *Advances in Polar Upper Atmosphere Research*, 17, p. 96-108.
52. **Ondoh, T.**, 2004, Anomalous Sporadic-E ionization before a great earthquake. *Advances in Space Research*, 34, p. 1830-1835.
53. **Ouadfeul, S.-A. and Aliouane, L.**, 2013, Lithofacies prediction from well log data using a multilayer perceptron (MLP) and Kohonen's self-organizing map (SOM) – a case study from the Algerian Sahara, *Pattern Recogn. Phys.*, 1, 59-62, doi:10.5194/prp-1-59-2013.
54. **Ouadfeul, S., Aliouane, L.**, 2012, Lithofacies Classification Using the Multilayer Perceptron and the Self-organizing Neural Networks, 2009, *Neural Information Processing Lecture Notes in Computer Science Volume 7667*, 2012, pp 737-744.

55. **Ouadfeul, S.-A. and Aliouane, L.**, 2013, Lithofacies prediction from well log data using a multilayer perceptron (MLP) and Kohonen's self-organizing map (SOM) – a case study from the Algerian Sahara, *Pattern Recogn. Phys.*, 1, 59-62, doi:10.5194/prp-1-59-2013.
56. **Ouadfeul S, Aliouane L**, 2011, Multifractal analysis revisited by the continuous wavelet transform applied in lithofacies segmentation from well-logs data. *Int J Appl Phys Math* 1(1):10–18
57. **Ouadfeul, S-A, Aliouane, L.**, 2013a, Automatic lithofacies segmentation using the wavelet transform modulus maxima lines combined with the detrended fluctuations analysis. *Arab J Geosci* 6(3):625–634
58. **Ouadfeul, S-A, Aliouane, L.**, 2013b, Automatic lithofacies segmentation using the wavelet transform modulus maxima lines combined with the detrended fluctuations analysis. *Arab J Geosci* 6(3):625–634.
59. **Ouadfeul, S., Hamoudi, M.**, 2012, Fractal Analysis of InterMagnet Observatories Data, *Fractal Analysis and Chaos in Geosciences*, Sid-Ali Ouadfeul (Ed.), ISBN: 978-953-51-0729-3, InTech, DOI: 10.5772/51259.
60. **Ouadfeul, S., Hamoudi, M., Aliouane, L.**, 2012, A wavelet based multifractal analysis for facies recognition from seismic data. Application to the pilot KTB borehole. *Arab J Geosci* 6(7):2203–2209.
61. **Parrot, M., Berthelier, J. J., Lebreton, J. P., Sauvaud, J. A., Santolik, O., and Blecki, J.**, 2006, Examples of unusual ionospheric observations made by the DEMETER satellite over seismic regions, *Phys. Chem. Earth*, 31, 486–495..
62. **Parrot, M.**, 1994, Statistical study of ELF VLF emissions recorded by a low-altitude satellite during seismic events. *Journal of Geophysical Research*, 99, p. 23339-23347.
63. **Peterson, C.**, 1992, Neural Networks in High Energy Physics, 1991, Plenary talk presented at the "Computing in High Energy Physics", September 21 -25, 1991, Annecy, France (1992).
64. **Rozhansky, V., Molchanov, P., Veselova, I., Voskoboinikov, S., Kirk, A., Fishpool, G., Boerner, P., Reiter, D., and Coster, D.**, 2013, Modeling of the edge plasma of MAST Upgrade with a Super-X divertor including drifts and an edge transport barrier, *Plasma Phys. Control. Fusion*, doi:10.1088/0741-3335/55/3/035005.
65. **Serebryakova, O. N., Bilichenko, S. V., Chmyrev, V. M., et al**, 1992, Electromagnetic ELF radiation from earthquake regions as observed by low-altitude satellites. *Geophysical Research Letters*, 19, p. 91-94.
66. **Svensson, J., von Hellermann, M., and König, R.**, 1999, Analysis of JET charge exchange spectra using neural networks, *Plasma Phys. Control. Fusion* 41 315 doi:10.1088/0741-3335/41/2/016 (1999).

- 
67. **Sarkar, S., Gwal, A. K., and Parrot, M.,** 2007, Ionospheric variations observed by the DEMETER satellite in the mid-latitude region during strong earthquakes, *J. Atmos. Solar-Terr. Phys.*, 69, 1524–1540, 2007.
  68. **Sutcliffe, P.R,** 2000, The development of a regional geomagnetic daily variation model using neural networks, *Ann. Geophysicae* 18, 120-128 (2000).
  69. **Taylor, M., Diaz., A.I.,** 2007, On the deduction of galaxy abundances with evolutionary neural networks. *Publications of the Astronomical Society of the Pacific* (2007).
  70. **Thomson, A. W. P.,** 1993, Non-linear predictions of  $A_p$  by activity class and numerical value, *pure and applied geophysics*, Volume 146, Issue 1, pp 163-193 (1993).
  71. **Teng W., Xiang-Dong, G., Wei, L.,** 2010, Characterisation of the plasma density with two artificial neural network models, *Chinese Phys. B* 19 070505 doi:10.1088/1674-1056/19/7/070505 (2010).
  72. **Wei, L., Jun-Fang, C., and Teng, W.,** 2009, Prediction of the plasma distribution using an artificial neural network, *Chinese Phys. B* 18 2441 doi:10.1088/1674-1056/18/6/053 (2009).
  73. **Zaourar, N., Mebarki, R., Hamoudi, M., Parrot, M.,** 2011, La dynamique fractale des perturbations séismo-ionosphériques enregistrées par le micro-satellite DEMETER, *Revue Télédétection*, vol.10 n°2-3, 2011.
  74. **Zaourar, N., Mebarki, R., Hamoudi, M., Briquieu, L., Parrot, M ,** 2009, Analyse fractale des fluctuations seismo-ionosphériques, *Journées d'animation Scientifique (JAS09) de l'AUF*, Algiers, 2009.
  75. **Yu, C., and Manry, M. T.,** 2002, A modified hidden optimization algorithm for feedforward neural networks, *Signals, Systems and Computers, 2002, Conference Record of the Thirty-Sixth Asilomar Conference on*, v01.2, pp. 1034 - 1038.
  76. **Zhang, X., Qian, J., Ouyang, X., Shen, X., Cai, J., Zhao, S.,** 2009, Ionospheric electromagnetic perturbations observed on DEMETER satellite before Chile  $M7.9$  earthquake, *Earthquake Science*, Volume 22, Issue 3, pp 251-255 (2009).
  77. **Zhang, X. Shen, X. Liu, J. Ouyang, X. Qian, J. and Zhao, S.,** 2009, Analysis of ionospheric plasma perturbations before Wenchuan earthquake, *Nat. Hazards Earth Syst. Sci.*, 9, 1259–1266, 2009.

# **Annexe 1**

# Prediction of Ionospheric Perturbations Using Artificial Neural Network. Application to ISL Instrument Data- DEMETER Mission

Sid-Ali Ouadfeul, Victor Tourtchine, and Leila Aliouane

LIMOSE, Faculté des Sciences,  
Université M'hamad Bougara de Boumerdes,  
Avenue de l'indépendance, Boumerdes, Algeria  
LABOPHYT, Faculté des Hydrocarbures et de la Chimie,  
Université M'hamad Bougara de Boumerdes,  
Avenue de l'indépendance, Boumerdes, Algeria  
SOuadfeul@gmail.com

**Abstract.** In this paper, a tentative of prediction of Instrument Langmuir (ISL) installed in the DEMETER satellite is implanted. Prediction is based on the Multilayer Perceptron (MLP) neural network model. The MLP machine is composed of three layers, an input layer with four neurons, a hidden layer with ten neurons and an output layer with the same number of units like the input layer. Parameters to be predicted are electrons and ions density, electrons temperatures and plasma potential. Application to the data of orbit 27447-1 recorded two days before the Laquila earthquake of 06 April 2009 clearly shows the power of the artificial neural network in the prediction of ionospheric perturbations and Plasma analysis.

**Keywords:** ISL Demter, MLP, Prediction.

## 1 Introduction

The artificial neural networks (ANNs) have been widely used in physics (Peterson, 1992, Lynch et al, 2001, Ouadfeul and Aliouane, 2013). In plasma physics the ANNs are used by many authors to characterize it. Teng et al (2010) have used a multilayer perceptron algorithm and radial based function algorithm in order to predict the plasma density in a plasma system, the effectiveness of two artificial neural network models is demonstrated. Wei et al (2009) have established an artificial neural network (ANN) model using a back-propagation training algorithm in order to predict the plasma spatial distribution in an electron cyclotron resonance (ECR) — plasma-enhanced chemical vapor deposition (PECVD) plasma system. In this paper we test the efficiency of the Multilayer Perceptron (MLP) for prediction of ionosphere parameters recorded by DEMETER Satellite Langmuir instruments. We start by describing the instrument and the data, after that we describe the neural network MLP machine with detailing its training parameters, the technique is applied to real data

recorded two days before the main shock of L'Aquila earthquake. We finalize the paper by results interpretation and a conclusion.

## 2 Langmuir Instrument and DEMETER Satellite

DEMETER satellite is designed to study ionospheric disturbances related to earthquake, volcano and human activity, and to detect the electromagnetic environment in global scale (Lebreton , 2012). The satellite has quasisolar-synchronous circular orbit with declination  $98.23^\circ$ , weight 130 kg and height 710 km (which decreased to 660 km in the middle of December, 2005). Its life was supposed to be two years. However, it is still operating now. The Langmuir probe is in principle a simple and very versatile space plasma diagnostic instrument for in situ measurements. A classical Langmuir probe uses a single sensor, which may be of different geometry (cylindrical or spherical). The DEMETER Langmuir Probe (ISL: Instrument Sonde de Langmuir) comprises two Langmuir Probe sensors. It includes a classical cylindrical sensor (5 cm long, dia 6 mm) and a 4-cm diameter spherical Segmented Langmuir Probe (SLP) whose surface is divided in six 1-cm disk sections (Lebreton, 2012, Zhang et al, 2009). A set of instruments were deployed on the satellite, including ICE to detect electric field from DC to 3.5 MHz; IMSC to measure the magnetic field from a few Hz to 20 kHz; IAP to detect ion density and temperature and so on; ISL, Langmuir probe to measure the electron density and temperature. Two kinds of data with different operating modes are provided: survey mode with low sampling rate and burst mode with high sampling rate as the satellite flies over the seismic zones. The mission center of DEMETER provides the data that can be downloaded and Quicklook images (Zhang et al, 2009). Detailed data guide can be referred to the website of DEMETER, <http://demeter.cnrs-orleans.fr>.

The Langmuir probe is in principle a simple and very versatile space plasma diagnostic instrument for in situ measurements. A classical Langmuir probe uses a single sensor, which may be of different geometry (cylindrical or spherical). The DEMETER Langmuir Probe (ISL: Instrument Sonde de Langmuir) comprises two Langmuir Probe sensors. It includes a classical cylindrical sensor (5 cm long, dia 6 mm) and a 4-cm diameter spherical Segmented Langmuir Probe (SLP) whose surface is divided in six 1-cm disk sections (Lebreton , 2012).

## 3 The Multilayer Perceptron

Multilayer feed-forward networks form an important class of neural networks. Typically the network consists of a set of sensory units or input nodes, that constitute the input layer, one or more hidden layers of neurons or computation nodes, and an output layer. Multi-layer Perceptron (MLP) neural networks with sufficiently many non-linear units in a single hidden unit layer have been established as universal function approximators. The advantages of the MLP are: Hidden unit outputs (basis functions)

change adaptively during training, making it unnecessary for the user to choose them beforehand. The number of free parameters in the MLP can be unambiguously increased in small increments by simply increasing the number of hidden units.

The basic functions are bounded making overflow errors and round-off errors unlikely. The MLP is a feed-forward network consisting of units arranged in layers with only forward connections to units in subsequent layers. The connections have weights associated with them. Each signal traveling along a link is multiplied by its weight.

The input layer, being the first layer, has input units that distribute the inputs to units in subsequent layers. In the following (hidden) layer, each unit sums its inputs and adds a threshold to it and nonlinearly transforms the sum (called the net function) to produce the unit output (called the activation). The output layer units often have linear activations, so that output activations equal net function values.

The layers sandwiched between the input and the output layers are called hidden layers, and the units in the hidden layers are called hidden units (Ouadfeul and Aliouane, 2012, 2013).

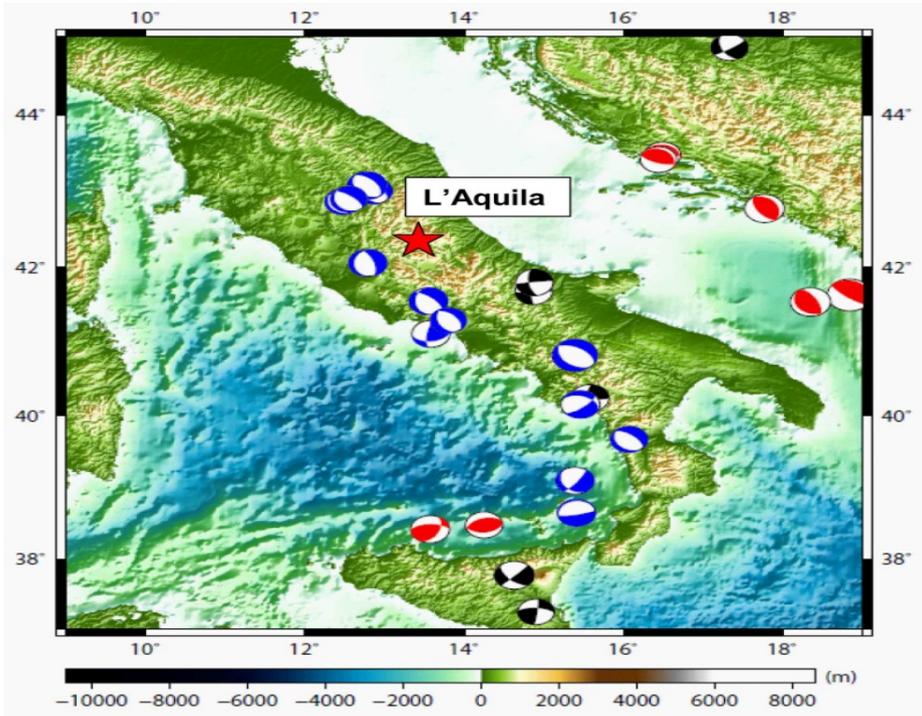
## 4 Application to Real Data

To check the efficiency of the Multilayer perceptron neural network model in the prediction of ionospheric perturbations, data of the 04 April 2009 recorded by the ISL instrument two days before of Italian earthquake of L'Aquila are analyzed. Let us start by giving more details about this huge seismic disaster.

### 4.1 L' Aquila Earthquake

The 2009 L'Aquila earthquake occurred in the region of Abruzzo, in central Italy (see Fig. 01). The main shock occurred at 03:32 CEST (01:32 UTC) on 6 April 2009, and was rated 5.8 or 5.9 on the Richter scale and 6.3 on the moment magnitude scale; its epicenter was near L'Aquila, the capital of Abruzzo, which together with surrounding villages suffered most damage. There have been several thousand foreshocks and aftershocks since December 2008, more than thirty of which had a Richter magnitude greater than 3.5.

The earthquake was felt throughout central Italy; 297 people are known to have died, making this the deadliest earthquake to hit Italy since the 1980 Irpinia earthquake. In a subsequent inquiry of the handling of the disaster, seven members of the Italian National Commission for the Forecast and Prevention of Major Risks were accused of giving "inexact, incomplete and contradictory" information about the danger of the tremors prior to the main quake. On 22 October 2012, six scientists and one ex-government official were convicted of multiple manslaughter for downplaying the likelihood of a major earthquake six days before it took place. They were each sentenced to six years' imprisonment.



**Fig. 1.** Map of Italy centered around the L'Aquila region

## 4.2 Data Analysis

Data of ISL Langmuir DEMETER satellite recorded two days before then main shock of L'Aquila earthquake are analyzed by the multilayer perceptron, the goal is check the efficiency of the MLP neural network to predict future time series. Parameters to be predicted are: Electron Density, Ion Density, Electron temperature and Plasma potential. A neural network machine of three layers is implanted, the input layer is constituted of four neurons, and the hidden layer is composed of 10 neurons and an output layer of four neurons. The first 640 samples recorded by the ISL instrument are used as input (see Fig. 2); the second 640 samples are used as a desired output of the MLP machine (see Fig. 3).

In the training stage weights of connection are optimized to minimize the root mean square error between the desired output and the calculated output by the MLP machine. To check the power of the MLP machine for prediction of these parameters, a generalization of this implanted machine is done. At this step the second 640 samples are now used as an input of the MLP machine, the goal is to predict a future time series of 300 samples.

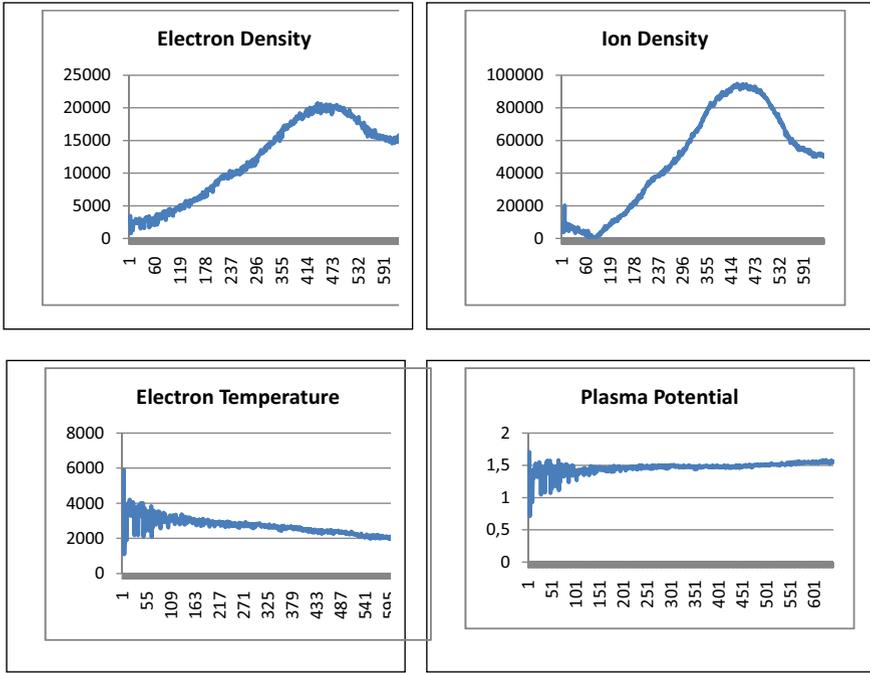


Fig. 2. Input of the Multilayer Perceptron neural network machine

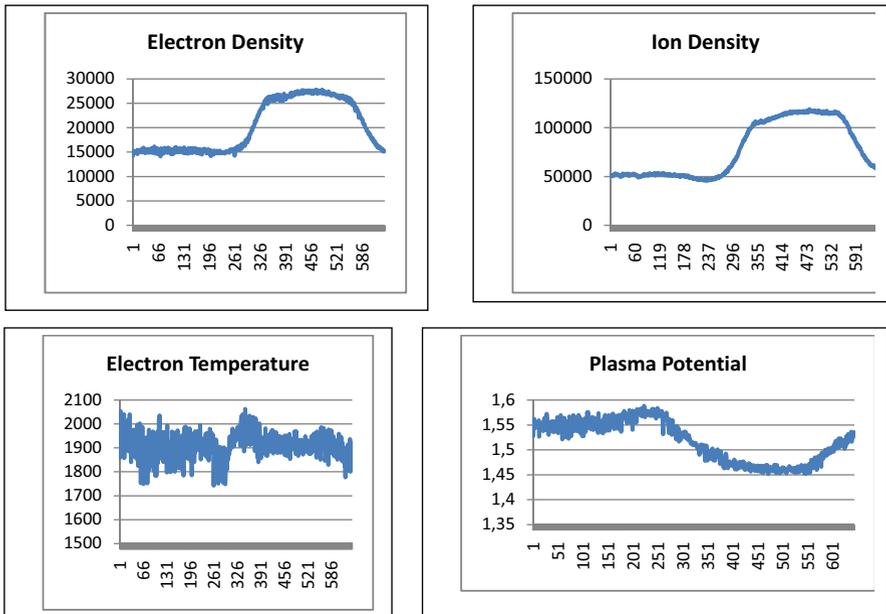
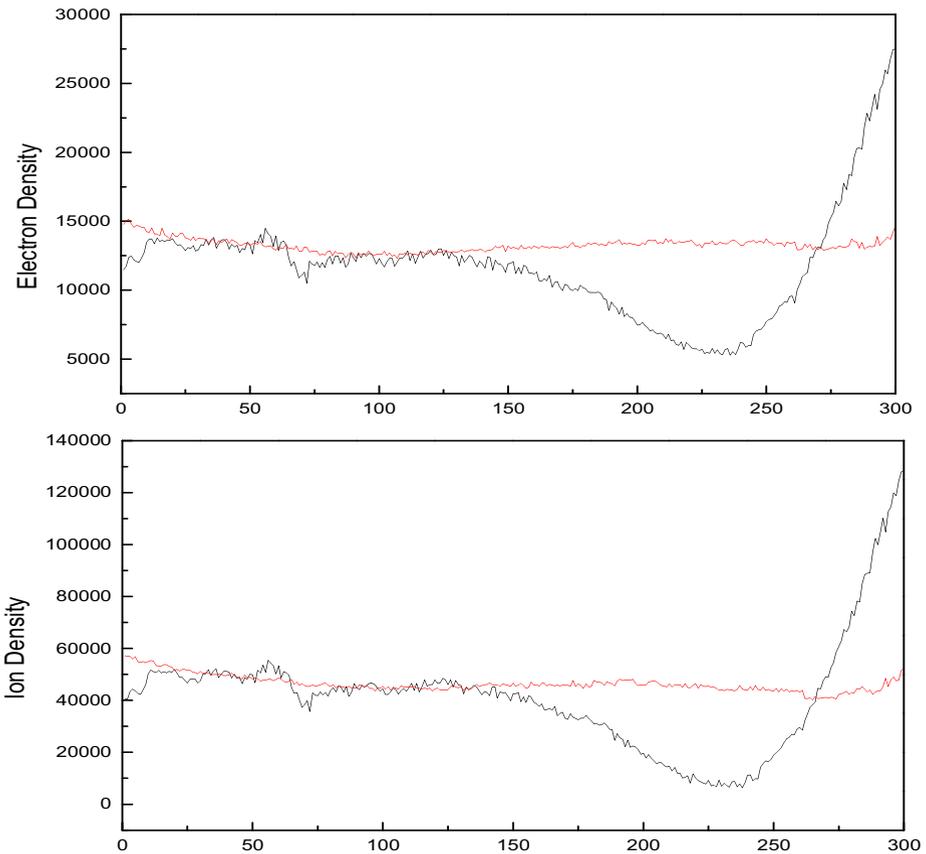


Fig.3. Desired output of the MLP machine

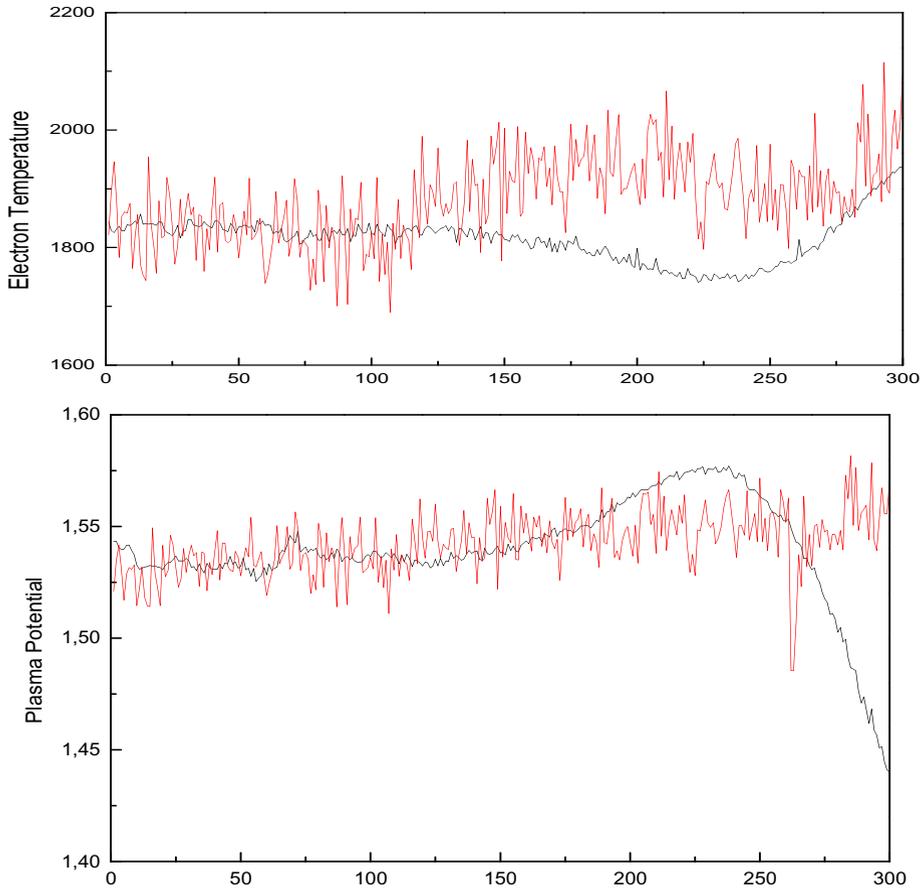
## 5 Results, Interpretation and Conclusion

Graphs of predicted plasma parameters are presented in black color in Fig. 4, Red graphs are the recorded parameters by the ISL Demeter satellite. Comparison between the two graphs clearly shows that the implanted neural network machine has the capacity and the memory to provide future ionosphere parameters. We can see that the ANN machine has a good memory for the most of each time series, however the machine start to lose slightly the memory at the end of each series.

The implanted machine can greatly be used for prediction of ionospheric perturbations, which have a big relation with seismic activity; the artificial neural network method plays an important role in the seismic hazard prevention. We suggest testing other neural network models like the Radial Basis Function (RBF) to decide about which kind of neural network can be used for prediction of ISL Langmuir satellite data.



**Fig. 4.** Predicted plasma ionospheric parameters (black color) compared to recorded parameters by DEMETER satellite (red color)



**Fig. 4.** (Continued.)

## References

1. Peterson, C.: Neural Networks in High Energy Physics. In: Plenary talk presented at the "Computing in High Energy Physics", Anney, France, September 21-25, 1991 (1992)
2. Lynch, M., Patel, H., Abrahamse, A., Rupa Rajendran, A., Medsker, L.: Neural network applications in physics. In: Proceedings of the International Joint Conference on Neural Networks, IJCNN 2001, vol. 3, pp. 2054–2058 (2001), doi:10.1109/IJCNN.2001.938482
3. Leberton, J.-P.: On the issue of surface contamination of a Langmuir Probe sensor: Demter IS results. Geophysical Research Abstracts 14, EGU2012-13806
4. Ouadfeul, S.-A., Aliouane, L.: Lithofacies prediction from well log data using a multilayer perceptron (MLP) and Kohonen's self-organizing map (SOM) – a case study from the Algerian Sahara. Pattern Recogn. Phys. 1, 59–62 (2013), doi:10.5194/prp-1-59-2013
5. Ouadfeul, S.-A., Aliouane, L.: Lithofacies Classification Using the Multilayer Perceptron and the Self-organizing Neural Networks. In: Huang, T., Zeng, Z., Li, C., Leung, C.S. (eds.) ICONIP 2012, Part V. LNCS, vol. 7667, pp. 737–744. Springer, Heidelberg (2012)

6. Teng, W., Xiang-Dong, G., Wei, L.: Characterisation of the plasma density with two artificial neural network models. *Chinese Phys. B* 19, 070505 (2010), doi:10.1088/1674-1056/19/7/070505
7. Wei, L., Jun-Fang, C., Teng, W.: Prediction of the plasma distribution using an artificial neural network. *Chinese Phys. B* 18 2441 (2009), doi:10.1088/1674-1056/18/6/053
8. Zhang, X., Qian, J., Ouyang, X., Shen, X., Cai, J., Zhao, S.: Ionospheric electromagnetic perturbations observed on DEMETER satellite before Chile M7.9 earthquake. *Earthquake Science* 22(3), 251–255 (2009)

## **Annexe 2**

# Ionospheric Data Analysis of Demeter Sattelite Using Neural Network: Application to IAP Instrument

Sid-Ali Ouadfeul, Leila Aliouane, and Victor Tourtchine

LIMOSE, Faculté des Sciences,  
Université M'hamad Bougara de Boumerdes,  
Avenue de l'indépendance, Boumerdes, Algeria  
LABOPHYT, Faculté des Hydrocarbures et de la Chimie,  
Université M'hamad Bougara de Boumerdes,  
Avenue de l'indépendance, Boumerdes, Algeria  
SOuadfeul@gmail.com

**Abstract.** In this paper, we use the artificial neural network for prediction of ionospheric perturbations by the analysis of the Instrument Plasma Analyzer (IAP) data using the Multilayer Perceptron (MLP) neural network. Data that are used as an input and output for the training of the MLP machine are: the Helium, Electron and Ions densities, Ions temperature, Ions speed and direction. The MLP machine is composed with an input layer, an output layer and a hidden layer. Application to the Demeter satellite data of orbit 27447-1 shows that the MLP neural network machine can give good results for plasma disturbances and can be used for prediction of seismo-ionospheric perturbations.

**Keywords:** IAP, Demeter, MLP, disturbances, prediction.

## 1 Introduction

The artificial intelligence has becoming a very useful tool in plasma physics (Rozhansky et al, 2013; Svensson et al, 1999). In earth plasma the artificial intelligence is used for analysis of data recorded by satellite missions (Taylor et al, 2007). French DEMETER (Detection of Electro-Magnetic Emissions Transmitted from Earthquake Regions) micro-satellite mission had been especially designed to provide global scale observations in the topside ionosphere over seismically active regions (Bankov et al, 2010). In this paper, we used the Multilayer perceptron neural network for prediction of ionosphere plasma parameters recorded by the Instrument Plasma Analyze (IAP) installed on board of DEMETR mission; the goal is to predict future plasma parameters which are: Number of Hydrogen particles in the plasma (NH+), number of Helium (NHe+) and Oxygen particles (NO+), ions temperature (NI+), ions speed (VS and VZ), angles of ions arrival (VOX and VOZ).

## 2 Instrument Plasma Analyzer (IAP)

The IAP (Instrument Analyseur de Plasma) experiment installed on consists of two analyzers: APR (Analyseur à Potentiel Retardateur, Retarding Potential Analyzer)

performs the energy analysis of ram direction ions and ADV (Analyseur pour Direction de Vitesse, Velocity Direction Analyzer) determines the average angles of arrival of the ions. APR measurements allow determining the density, temperature and bulk energy of the ionospheric ions. IAP has 2 Survey modes of operation a medium energy resolution mode for APR providing a complete set of plasma parameters every  $\sim 360$  ms and a high energy resolution mode with a lower temporal resolution providing a complete set of measurements every 720 ms. Density fluctuations from ADV measurements are available with a time resolution of 12.8 ms. There is also one Burst mode of operation featuring high energy and high temporal resolution with a complete set of plasma parameters every  $\sim 360$  ms. Density fluctuations are available with a time resolution of 6.4 ms. The objective of the IAP experiment is to characterize the state of the ionospheric plasma, in order to detect perturbations that may be associated with seismic activity and to provide the plasma parameters that are needed to analyze the data from the plasma wave instruments, ICE and IMSC. As a secondary objective, near real time ionospheric data can be provided for space weather purposes.

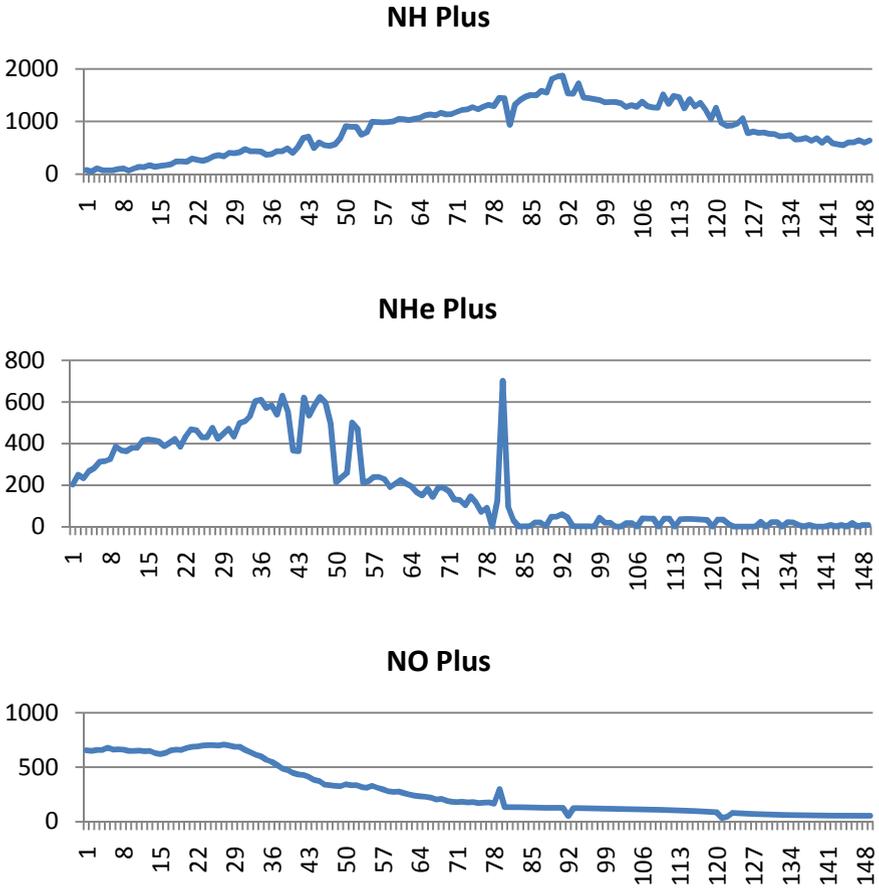
### **3 The Multilayer Perceptron Neural Network**

Multilayer feed-forward networks form an important class of neural networks. Typically the network consists of a set of sensory units or input nodes, that constitute the input layer, one or more hidden layers of neurons or computation nodes, and an output layer. Multi-layer Perceptron (MLP) neural networks with sufficiently many non-linear units in a single hidden unit layer have been established as universal function approximators. For more details about the MLP, we invite readers to the papers of Ouadfeul and Aliouane (2012, 2013).

### **4 Data Analysis, Results and Conclusion**

A multilayer neural network machine with three layers is implanted; the input layer is composed with eight neurons that correspond to the eight IAP plasma parameters, a hidden layer of seven neurons (obtained by test) and an output layer of eight neurons that correspond also to the IAP plasma parameters. Data of orbit 27447-1 that sweep L'Aquila area two days before the main chock of 09 April 2009 are used for the training of the neural network machine. The first time series of 151 (see Fig. 01) samples is used as an input, however the second 151 samples are used as an output (see Fig. 02). The implanted MLP machine is trained in a supervised learning and weights of connection are optimized. To check the efficiency of this neural machine the second time series is used as an input and an output is calculated by propagating the input via this machine, at this stage no training is needed since the weights of

connection are calculated in the first stage. Obtained results are compared with the actual recorded plasma parameters (see Fig. 3), one can observe that the MLP machine is able to provide an acceptable model of parameters, however at the end of each time series the artificial neural network machine start to lose the memory, by consequence the MLP neural network has not long term memory, so we need always to update the weights of connection to give exact results. We suggest application of the whole process to data of other orbit to generalize its efficiency and generalize a rule.



**Fig. 1.** First 151 samples of IAP instrument parameters of DEMETER satellite used for the MLP training

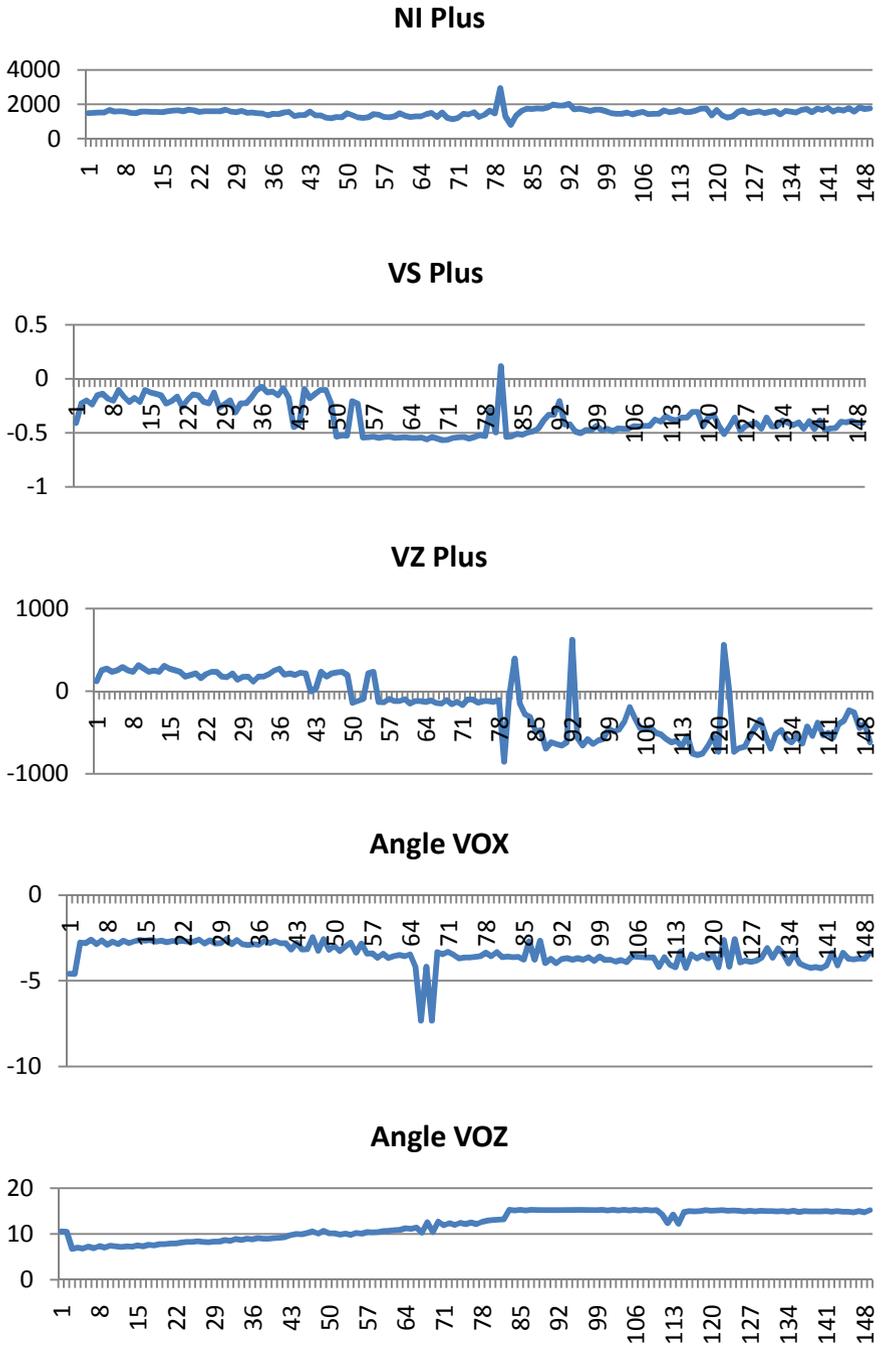
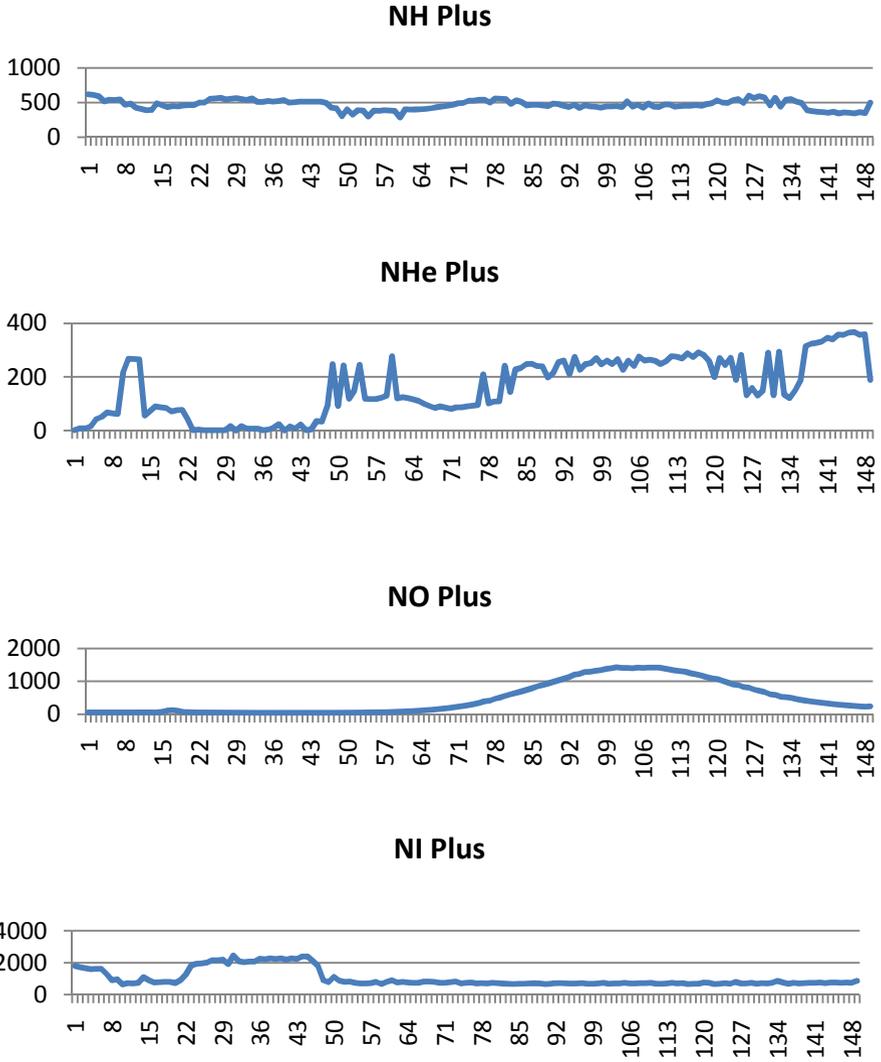


Fig. 1. (Continued.)



**Fig. 2.** Second 151 samples of IAP instrument used as an output for the MLP training

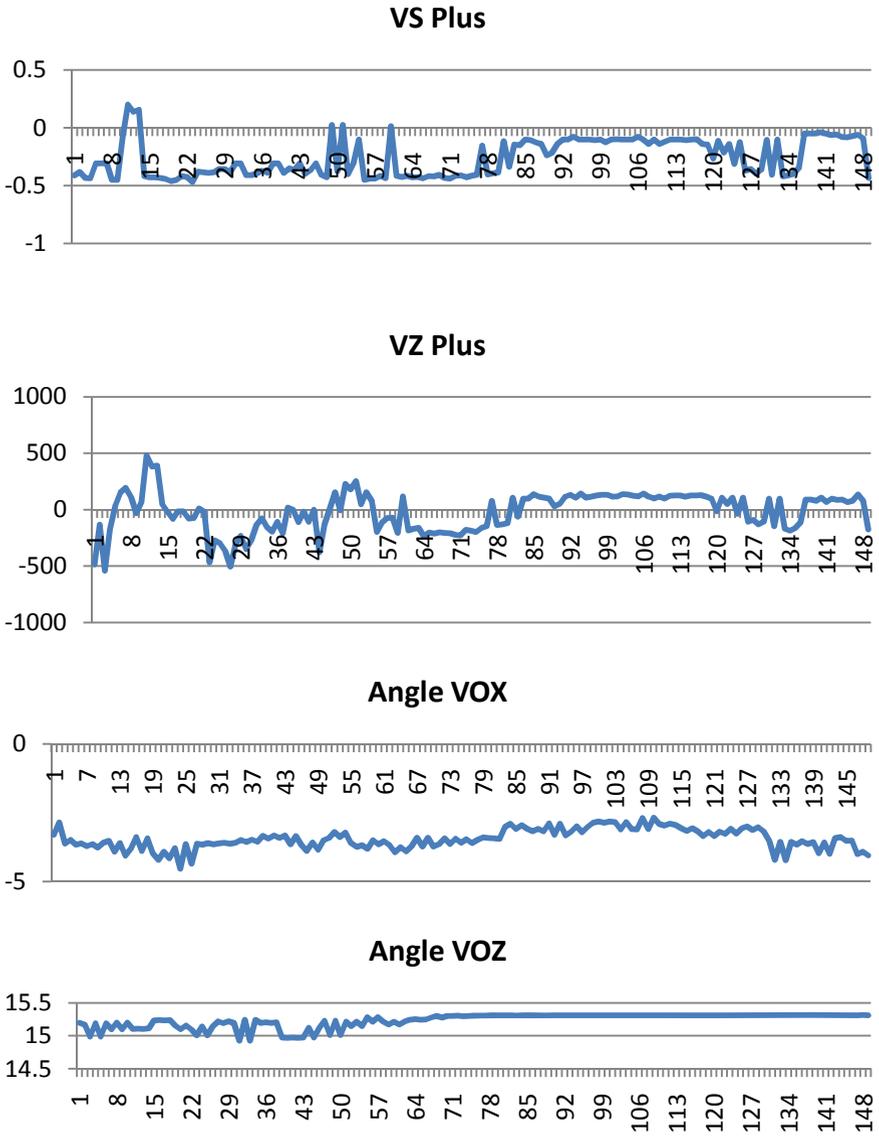
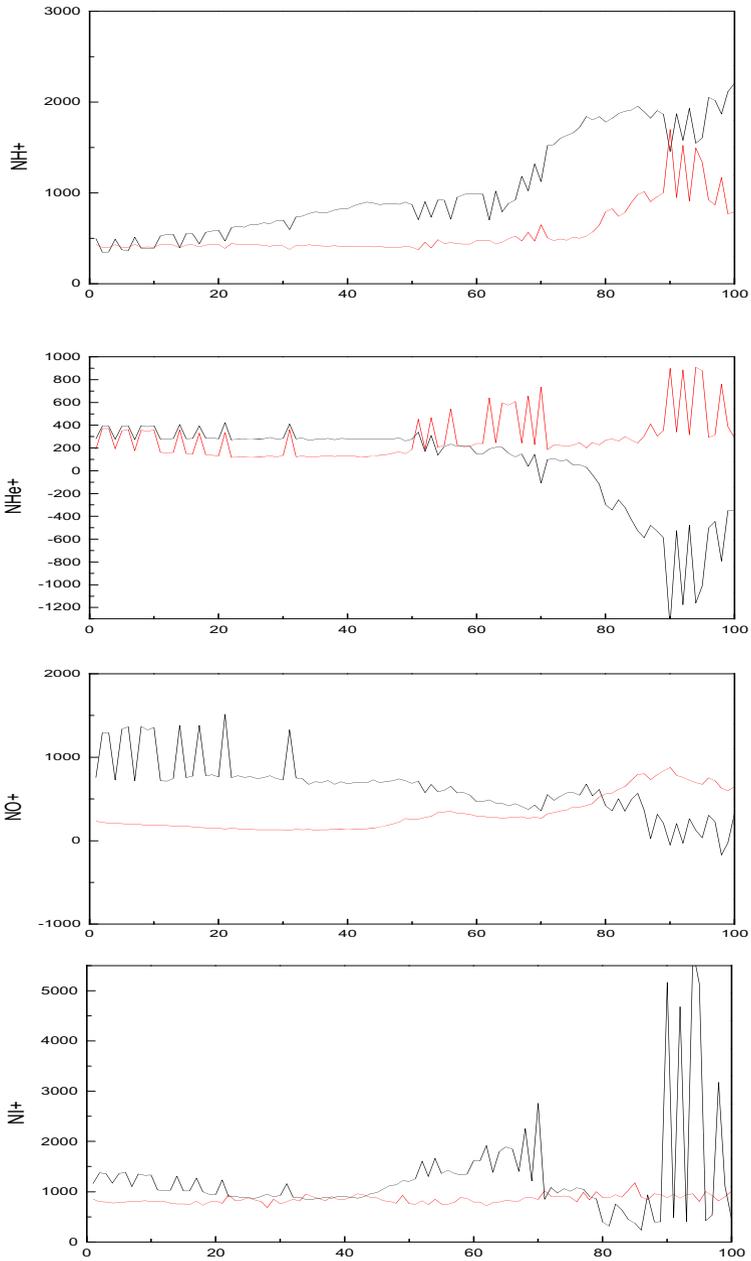
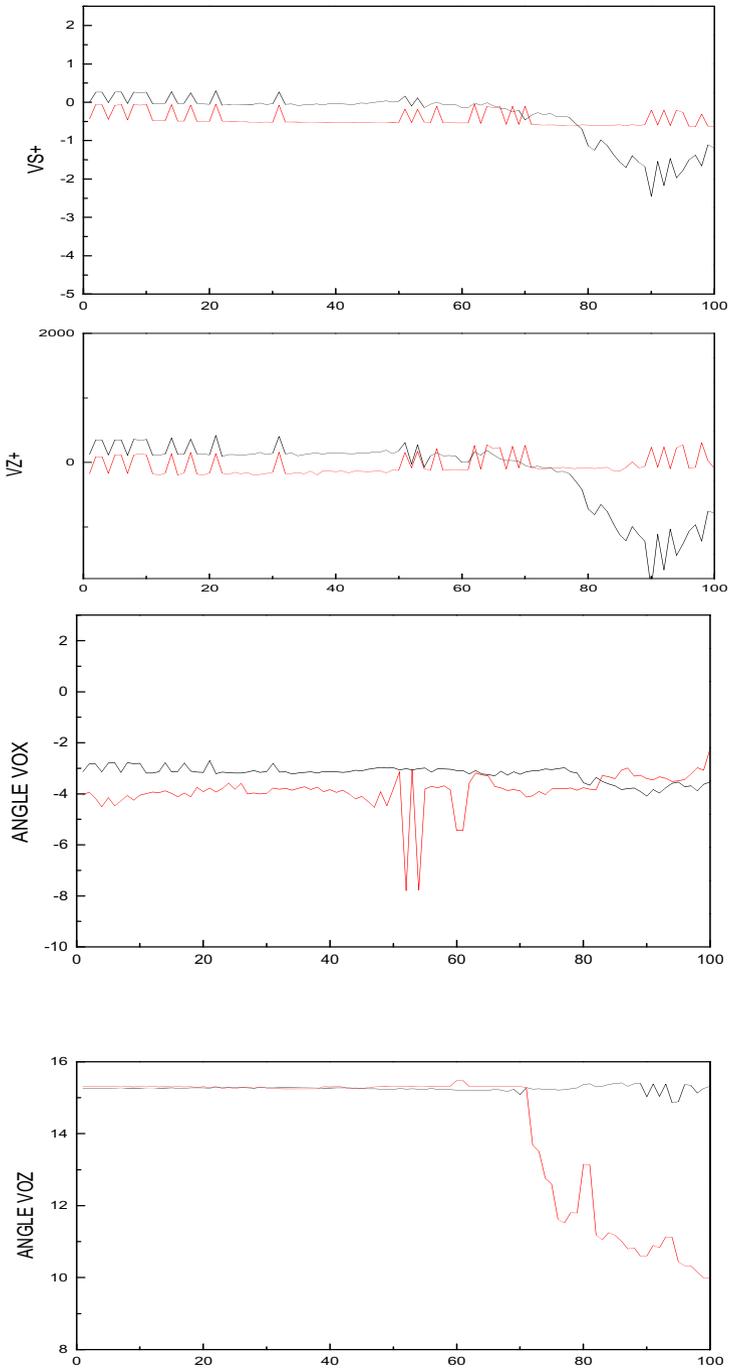


Fig. 2. (Continued.)



**Fig. 3.** Predicted IAP plasma parameters using the implanted MLP machine



**Fig.3. (Continued.)**

## References

1. Bankov, L.G., Parrot, M., Heelis, R.A., Berthelier, -J., Marinov, P.G., Vassileva, A.K.: DEMETER and DMSP satellite observations of the disturbed H<sup>+</sup>/O<sup>+</sup> ratio caused by Earth's seismic activity in the Sumatra area during December 2004. *Advances in Space Research* 46(4), 419–430 (2010)
2. Ouadfeul, S.-A., Aliouane, L.: Lithofacies prediction from well log data using a multi-layer perceptron (MLP) and Kohonen's self-organizing map (SOM) – a case study from the Algerian Sahara. *Pattern Recogn. Phys.* 1, 59–62 (2013), doi:10.5194/prp-1-59-2013
3. Ouadfeul, S.-A., Aliouane, L.: Lithofacies Classification Using the Multilayer Perceptron and the Self-organizing Neural Networks. In: Huang, T., Zeng, Z., Li, C., Leung, C.S. (eds.) *ICONIP 2012, Part V. LNCS*, vol. 7667, pp. 737–744. Springer, Heidelberg (2012)
4. Rozhansky, V., Molchanov, P., Veselova, I., Voskoboynikov, Kirk, A., Fishpool, G., Boerner, P., Reiter, D., Coster, D.: Modeling of the edge plasma of MAST Upgrade with a Super-X divertor including drifts and an edge transport barrier. *Plasma Phys. Control. Fusion* (2013), doi:10.1088/0741-3335/55/3/035005
5. Svensson, J., von Hellermann, M., König, R.: Analysis of JET charge exchange spectra using neural networks. *Plasma Phys. Control. Fusion* 41, 315 (1999), doi:10.1088/0741-3335/41/2/016
6. Taylor, M., Diaz, A.I.: On the deduction of galaxy abundances with evolutionary neural networks. *Publications of the Astronomical Society of the Pacific* (2007)

## **Annexe 3**

# *Wavelet-Based Multifractal Analysis of DEMETER Satellite Data Before the L'Aquila Earthquake of 2009*

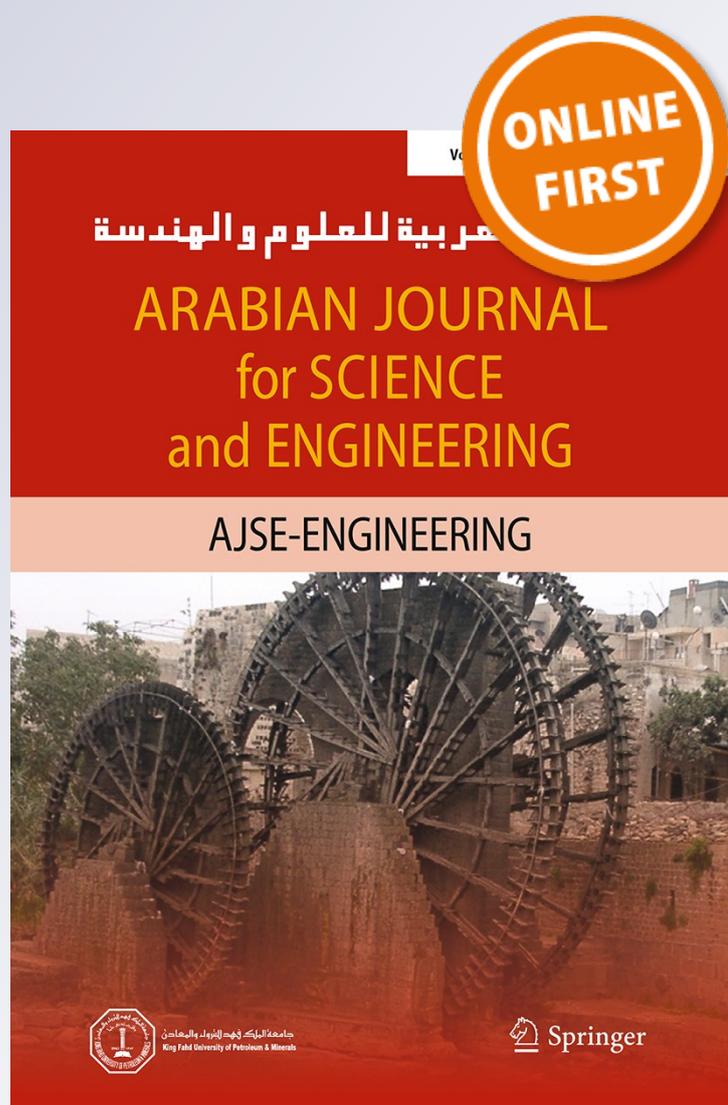
**Sid-Ali Ouadfeul, Victor Tourtchine &  
Leila Aliouane**

**Arabian Journal for Science and  
Engineering**

ISSN 1319-8025

Arab J Sci Eng

DOI 10.1007/s13369-015-1938-9



**Your article is protected by copyright and all rights are held exclusively by King Fahd University of Petroleum & Minerals. This e-offprint is for personal use only and shall not be self-archived in electronic repositories. If you wish to self-archive your article, please use the accepted manuscript version for posting on your own website. You may further deposit the accepted manuscript version in any repository, provided it is only made publicly available 12 months after official publication or later and provided acknowledgement is given to the original source of publication and a link is inserted to the published article on Springer's website. The link must be accompanied by the following text: "The final publication is available at [link.springer.com](http://link.springer.com)".**

# Wavelet-Based Multifractal Analysis of DEMETER Satellite Data Before the L'Aquila Earthquake of 2009

Sid-Ali Ouadfeul<sup>1</sup> · Victor Tourtchine<sup>1</sup> · Leila Aliouane<sup>2</sup>

Received: 21 April 2015 / Accepted: 19 October 2015  
© King Fahd University of Petroleum & Minerals 2015

**Abstract** The main goal of this paper is to demonstrate the multifractal behavior of the ionospheric plasma signals recorded by the ISL instrument installed onboard of the DEMETER satellite before the L'Aquila earthquake of 2009. Multifractal analysis is performed using the so-called the wavelet transform modulus maxima lines (WTMM) method. Signals to be analyzed are: density of electrons and ions, temperature of electrons, and the potential of the plasma. WTMM analysis of the data recorded during April 4, 2009 which recognizes many ionospheric disturbances before the L'Aquila earthquake clearly shows the multifractal behavior of the ionosphere plasma physical response. WTMM analysis of data recorded by the DEMETER satellite two months after the L'Aquila earthquake main shock shows the monofractal behavior of the plasma response.

**Keywords** Multifractal · WTMM · ISL · DEMETER · L'Aquila earthquake

## 1 Introduction

The fractal analysis has becoming a very useful tool for the study of the plasma physics; Nurujjaman et al. [1] have used a continuous wavelet transform-based timescale and multifractal analysis of the nonlinear oscillations in a hol-

low cathode glow discharge plasma. Imamura et al. [2] have published a paper on the fractal analysis of subionospheric LF propagation data and consideration of the lithosphere–atmosphere–ionosphere coupling; obtained results show that the connection of the fractal analysis for the subionospheric VLF/LF data with seismicity is found to be not very pronounced.

Natural hazards study using data of the French microsatellite DEMETER has becoming a hot topic of research [3–6], almost of the published papers establish data recorded by the DEMETER mission prior to natural hazards. Sarkar et al. [5] have analyzed the ionospheric anomalies associated with the Haiti earthquake of January 12, 2010 observed by DEMETER satellite, and obtained results show a significant enhancement of electron density and electron temperature near the epicenter. Decrease in electron temperature is observed few days after the earthquake. Anomalous plasma parameter variations are detected both in day and night times before the quake. Statistical processing of the DEMETER data demonstrates that satellite data can play an important role for the study of precursory phenomena associated with earthquakes.

Many authors have used the Brownian fractional motion (mBf) model to realize a fractal analysis of DEMETER satellite data [7, 8], and they have tried to show the fractal behavior of these data prior to earthquakes.

The wavelet transform modulus maxima lines (WTMM) have become a very useful tool in geophysics; Ouadfeul and Aliouane [9] have established a technique of automatic lithofacies segmentation using the WTMM method, and obtained results show the power of this method for lithofacies segmentation. Ouadfeul and Hamoudi [10] have used the WTMM method to demonstrate the multifractal behavior of geomagnetic field data recorded by the INTERMAGNET observatories.

✉ Sid-Ali Ouadfeul  
SOuadfeul@gmail.com

<sup>1</sup> LIMOSE, Département de Physique, Faculté des Sciences, Université M'Hamed Bougara de Boumerdès, Avenue de l'indépendance, 35000 Boumerdès, Algeria

<sup>2</sup> LABOPHYT, FHC, Université M'Hamed Bougara de Boumerdès, Avenue de l'indépendance, 35000 Boumerdès, Algeria

Quadfeul et al. [11] have used this technique for facies recognition from synthetic seismic data of the Kontinentales Tiefbohrprogramm de Bundesrepublik Deutschland (KTB) boreholes data.

In this paper, the wavelet transform modulus maxima lines (WTMM) is used to demonstrate the multifractal behavior of the DEMETER satellite data recorded by the Langmuir instrument (ISL).

We began the paper by describing the Local Hölder exponent and wavelet transform modulus maxima lines method, and then the whole method is applied to ISL DEMETER data recorded during April 4, 2009, two days before the L'Aquila earthquake. The paper is ended by results interpretation and conclusions.

### 2 Local Hölder Exponent

Let  $f : \omega \rightarrow R$  be a function, where  $\omega \in R$  an open set. One classically says that  $f \in C_l^h(\omega)$  where  $0 < h < 1$  if there exists a constant  $C$  such that, for all  $x, y$  in  $\omega$ :

$$|f(x) - f(y)| \leq C |x - y|^h$$

$h$  is called the Local Hölder exponent.

If  $m < h < m + 1$  ( $m \in N$ ), then  $f \in C_l^h(\omega)$  means that there exists a constant  $C$  such that, for all  $x, y$  in  $\omega$ ,

$$|\partial^m f(x) - \partial^n f(x)| \leq C |x - y|^{h-m}$$

The Hölder exponent can be understood as a global indicator of the local differentiability of a function  $s$ .

The scaling parameter (the so-called Hurst exponent) estimated when analyzing process by using Fourier's transform [9] is a global measure of self-affine process, while the singularity strength  $h$  can be considered as a local version (i.e., it describes 'local similarities') of the Hurst exponent. In the case of monofractal signals, which are characterized by the same singularity strength everywhere ( $h(z) = \text{constant}$ ), the Hurst exponent equals  $h$ . Depending on the value of  $h$ , the input signal could be long-range correlated ( $h > 0.5$ ), uncorrelated ( $h = 0.5$ ) or anticorrelated ( $h < 0.5$ ).

### 3 The Wavelet Transform Modulus Maxima Lines

The wavelet transform modulus maxima lines (WTMM) method is a multifractal analysis technique originally developed by Mallat and Hwang [12]. Bacry, Muzy, and Arneodo were early users of this methodology. It has subsequently been used in fields related to signal processing and used for image processing by Arneodo et al. [13]. The WTMM method is based on the modulus of the continuous wavelet transform (CWT), and it is composed of two main steps:

1. Calculation of the modulus of the CWT and calculation of its maxima.
2. Calculation of the function of partition, estimation of the spectrum of exponents, and estimation the spectrum of singularities.

Let us consider a signal  $S(z)$ , and its continuous wavelet transform with an analyzing wavelet  $\emptyset(z)$  is defined by [14]:

$$T_\emptyset(a, b) = \frac{1}{a} \int_{-\infty}^{+\infty} S(z) \emptyset^* \left( \frac{z-b}{a} \right) dz \tag{1}$$

$a$  is a scale parameter ( $a > 0$ ),  $b$  is a translation,  $\emptyset^*$  is the complex conjugate of  $\emptyset$

The analyzing wavelet must check the admissibility condition:

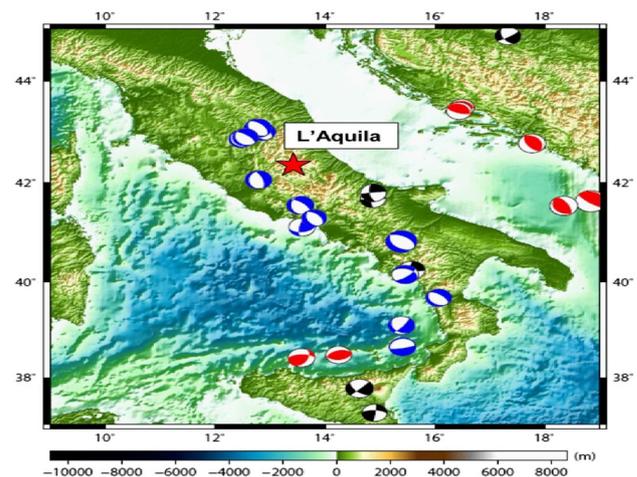
$$\int_{-\infty}^{+\infty} \emptyset(z) dz = 0 \tag{2}$$

The second stage consists to calculate the maxima of the modulus of the continuous wavelet transform; at this stage the first and the second derivatives of the modulus of the continuous wavelet transform are used.

We call  $(a, b_0)$  a maxima of the modulus of the CWT at the point  $b_0$ , if for all,  $b \rightarrow b_0$ ,  $|T_\emptyset(a, b_0)| > |T_\emptyset(a, b)|$ .

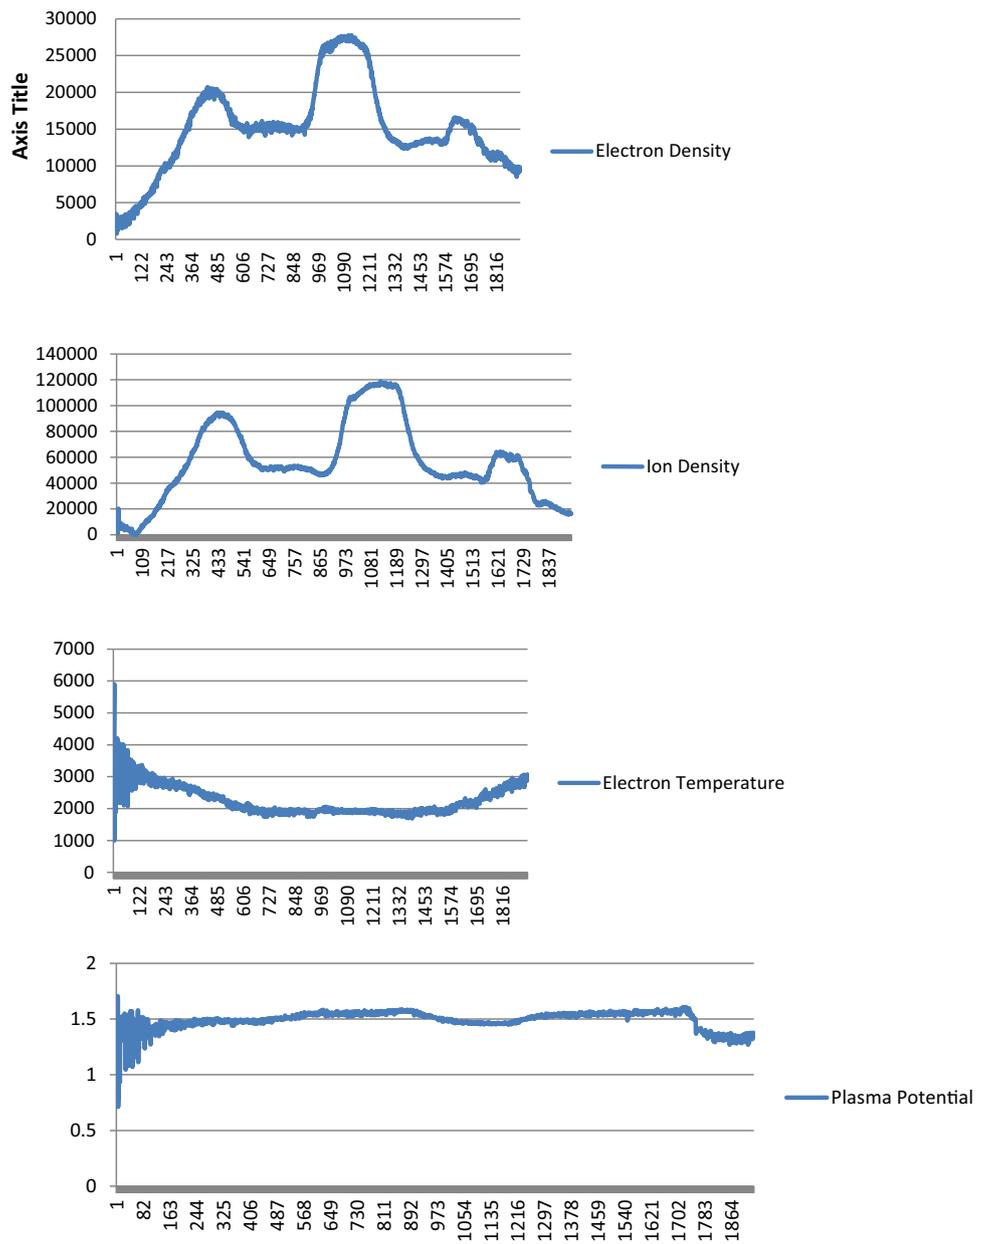
The function of partition  $Z(q, a)$  is a summation of the modulus of the CWT at the set of maxima  $L(b)$  with a  $q$  moment. The function of partition is given as [15]:

$$Z(q, a) = \sum_{L(b)} |T_\emptyset(a, b_i)|^q \tag{3}$$



**Fig. 1** Map of the Italy and the L'Aquila area with focal mechanism, three kinds of faults are observed: normal (blue), thrust (red) and strike-slip (black)

**Fig. 2** ISL instrument data of the half orbit 27447-1 recorded during April 4, 2009 versus the time



The spectrum of exponents is then derived from the function of partition, it is related to  $Z(q, a)$  by a power law for low scales:

$$Z(q, a) = a^{\tau(q)} \quad \text{if } a \rightarrow 0 \tag{4}$$

The spectrum of singularities is related to the spectrum of exponent by the Legendre's transform [15].

$$D(h) = \text{Min}(qh - \tau(q)) \tag{5}$$

where  $h$  is the Hölder exponent.

The spectrum of singularities measures the dominance of each singularity exponent, and exponents with high spectrum

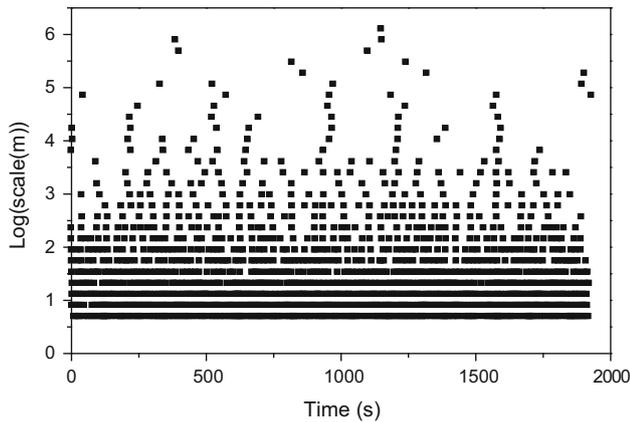
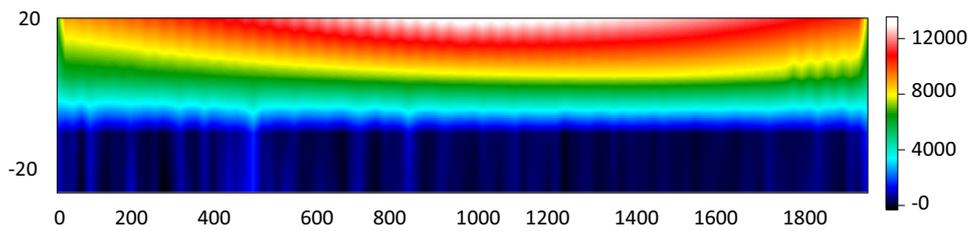
of singularities are more dominant in a given signal than other exponents [13,15].

Arneodo and Bacry [15] have shown the power of the WTMM method to distinguish between monofractal and multifractal behaviors of a given signal; in fact, if the spectrum of exponent is not a straight line and the spectrum of singularities is not localized in one point, the signal has a multifractal behavior.

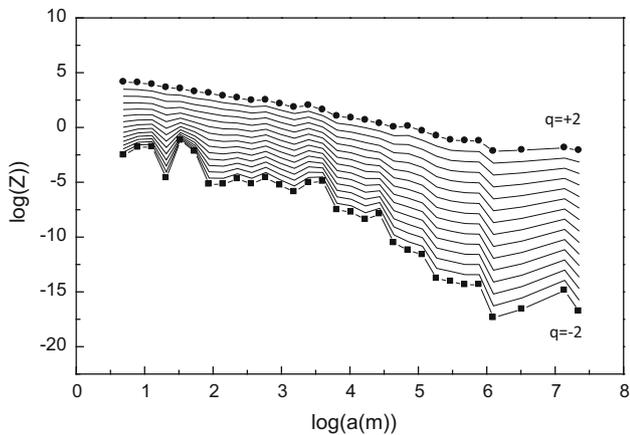
#### 4 Application to Real Data

The whole WTMM process will be applied to the ISL DEMETER instrument data recorded during the night April 4, 2009,

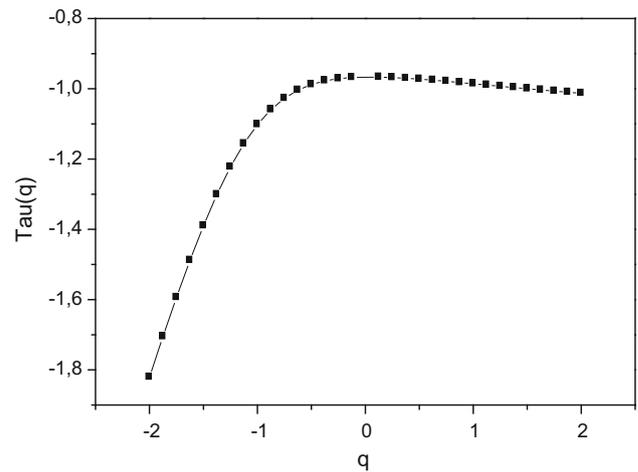
**Fig. 3** Modulus of the continuous wavelet transform of the electron density signal presented in the frame time-logarithm scale, and the analyzing wavelet is the Complex Morlet



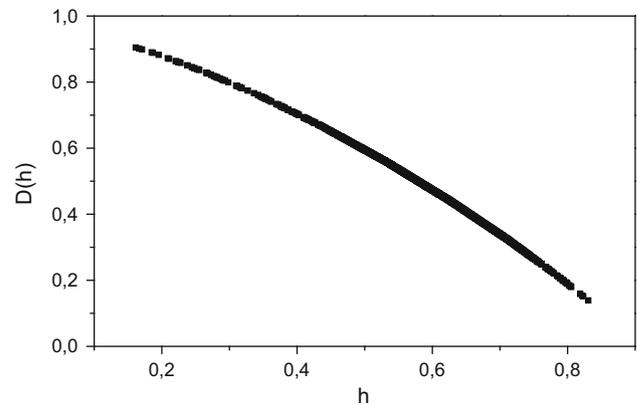
**Fig. 4** Skelton of the modulus of the continuous wavelet transform presented in the frame time-logarithm (scale)



**Fig. 5** The function of partition versus logarithm of scale for each value of  $q$ ,  $q$  varying from  $-2$  to  $+2$  with a step of  $0.125$



**Fig. 6** Spectrum of exponent versus  $q$  of the electron density signal



**Fig. 7** Singularities spectrum of the electron density signal indicating the multifractal behavior of the plasma physics

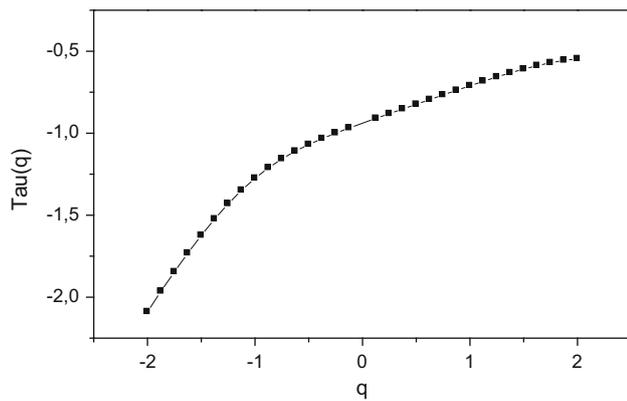
two days before the L'Aquila earthquake. The goal is to show that the physical response of the ionosphere plasma has a multifractal behavior before the L'Aquila earthquake. Many authors have observed a set of ionospheric perturbations few days before earthquakes [4,5]. Let us start by talking about the L'Aquila earthquake.

#### 4.1 L'Aquila Earthquake

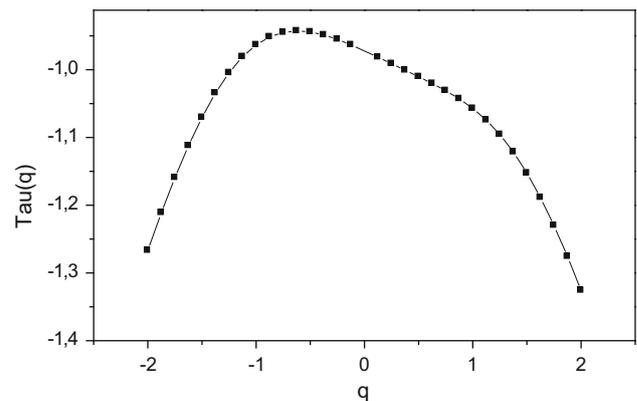
The 2009 L'Aquila earthquake occurred in the region of Abruzzo, in central Italy (see Fig. 1). The main shock

occurred at 03:32 CEST (01:32 UTC) on April 6, 2009, and was rated 5.8 or 5.9 on the Richter scale and 6.3 on the moment magnitude scale; its epicenter was near L'Aquila, the capital of Abruzzo, which together with surrounding villages suffered most damage. There have been several thousand foreshocks and aftershocks since December 2008, more than 30 of which had a Richter magnitude greater than 3.5.

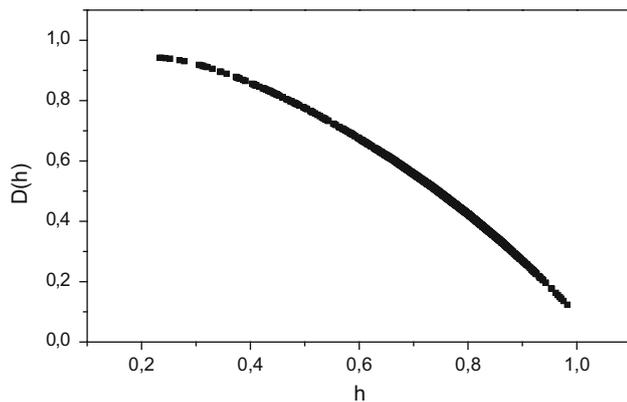
The earthquake was felt throughout central Italy; 297 people are known to have died, making this the deadliest earthquake to hit Italy since the 1980 Irpinia earthquake. In a subsequent inquiry of the handling of the disaster, seven



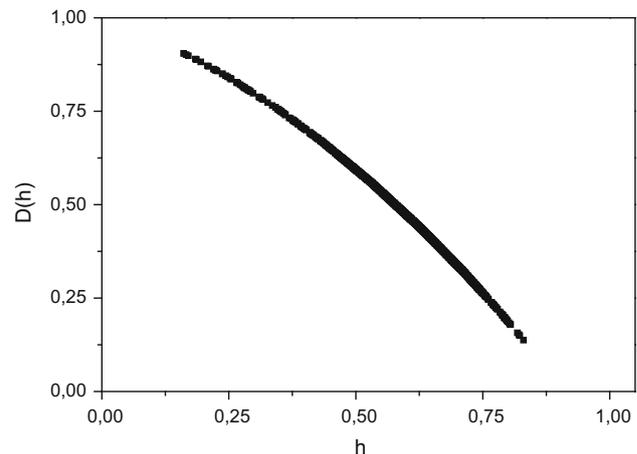
**Fig. 8** Spectrum of exponents obtained by the WTMM analysis of the ions density



**Fig. 10** Spectrum of exponents of electron temperature



**Fig. 9** Spectrum of singularities of the ion density signal



**Fig. 11** Spectrum of singularities of electron temperature

members of the Italian National Commission for the Forecast and Prevention of Major Risks were accused of giving “inexact, incomplete and contradictory” information about the danger of the tremors prior to the main quake.

#### 4.2 DEMETER Satellite

DEMETER satellite is designed to study ionospheric disturbances related to earthquake, volcano and human activity, and to detect the electromagnetic environment in global scale [16]. The satellite has quasi-solar-synchronous circular orbit with declination  $98.23^\circ$ , weight 130kg and height 710 km (which decreased to 660km in the middle of December, 2005). Its life was supposed to be 2 years. However, it is still operating now. The Langmuir probe is in principle a simple and very versatile space plasma diagnostic instrument for in situ measurements. A classical Langmuir probe uses a single sensor, which may be of different geometry (cylindrical or spherical). The DEMETER Langmuir Probe (ISL: Instrument Sonde de Langmuir) comprises two Langmuir probe sensors. It includes a classical cylindrical sensor (5 cm long, dia 6 mm) and a 4-cm diameter spherical segmented Lang-

muir probe (SLP) whose surface is divided in six 1-cm disk sections [6, 16]. A set of instruments were deployed on the satellite, including ICE to detect electric field from DC to 3.5 MHz; IMSC to measure the magnetic field from a few Hz to 20kHz; IAP to detect ion density and temperature and so on; ISL, Langmuir probe to measure the electron density and temperature. Two kinds of data with different operating modes are provided: survey mode with low sampling rate and burst mode with high sampling rate as the satellite flies over the seismic zones. The mission center of DEMETER provides the data that can be downloaded and quick look images [6]. Detailed data guide can be referred to the website of DEMETER, <http://DEMETER.cnrs-orleans.fr>.

The Langmuir probe is in principle a simple and very versatile space plasma diagnostic instrument for in situ measurements. A classical Langmuir probe uses a single sensor, which may be of different geometry (cylindrical or spherical). The DEMETER Langmuir probe (ISL: Instrument Sonde de Langmuir) comprises two Langmuir Probe sensors. It includes a classical cylindrical sensor (5 cm long, dia 6 mm)

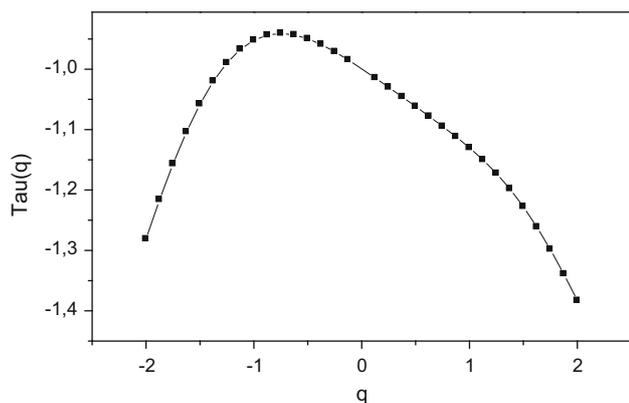


Fig. 12 Spectrum of exponents of the plasma potential

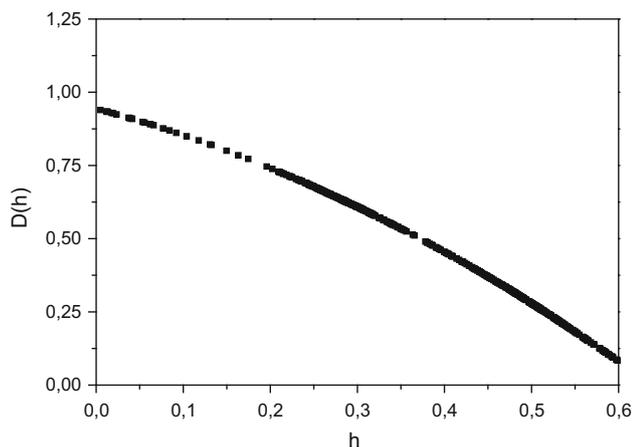


Fig. 13 Spectrum of singularities of the plasma potential signal

and a 4-cm diameter spherical Segmented Langmuir Probe (SLP) whose surface is divided in six 1-cm disk sections [16].

### 4.3 Data Analysis

Data of ISL instrument recorded during April 4, 2009, two days before the L'Aquila earthquake were analyzed using the wavelet transform modulus maxima lines (WTMM) method, and source code of the WTMM method are developed in C language. Data are: density of electrons and ions, temperature of electrons, and potential of the plasma. Figure 2 shows these plasma parameters versus the time, data of the two modes burst and survey are merged. The sampling interval for the two modes is 1 s, these DEMETER data are composed with 1837 sample which is enough to apply the WTMM method, in fact the WTMM method requires only at least 128 samples [17].

The first analyzed signal is the density of electron; Fig. 3 shows the modulus of its continuous wavelet transform. The analyzing wavelet is the Complex Morlet [14]. The second stage consists to calculate maxima of the modulus of the con-

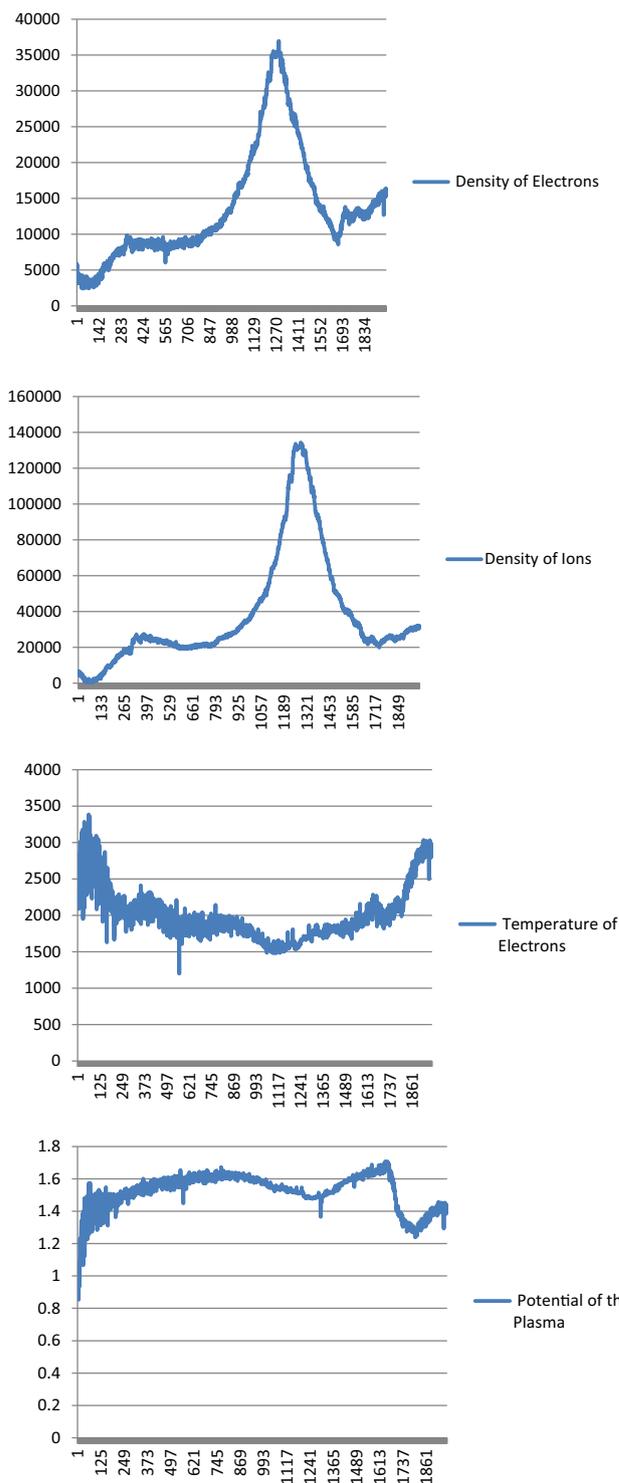
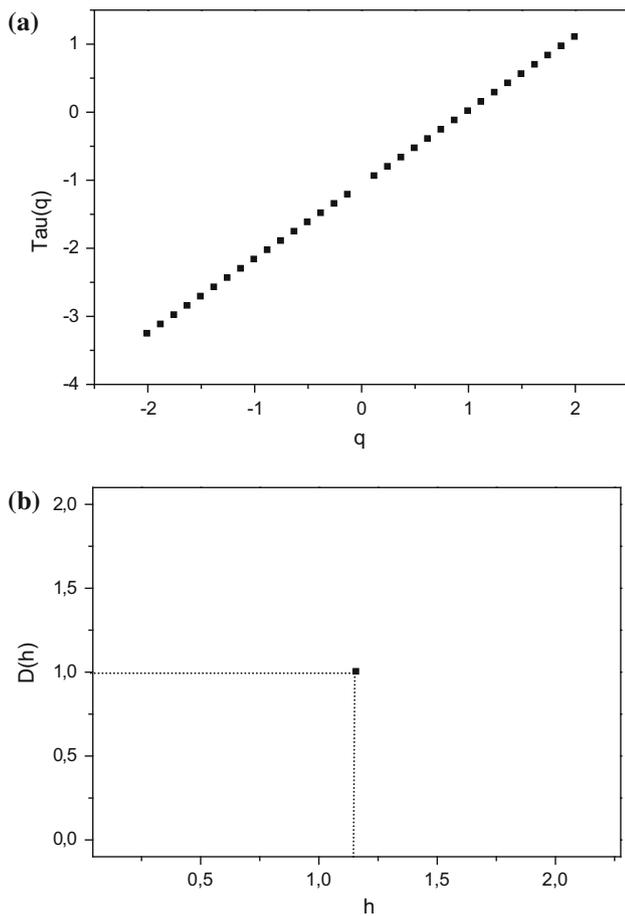


Fig. 14 ISL instrument data of the half orbit 27447-1 recorded during June 4, 2009 two months after the Main shock of L'Aquila versus the time

tinuous wavelet transform, and chains of maxima are called the skeleton (see Fig. 4). The function of partition is then calculated and presented in the log-log frame versus the scale;  $q$  is varying from  $-2$  to  $+2$  with a sampling inter-

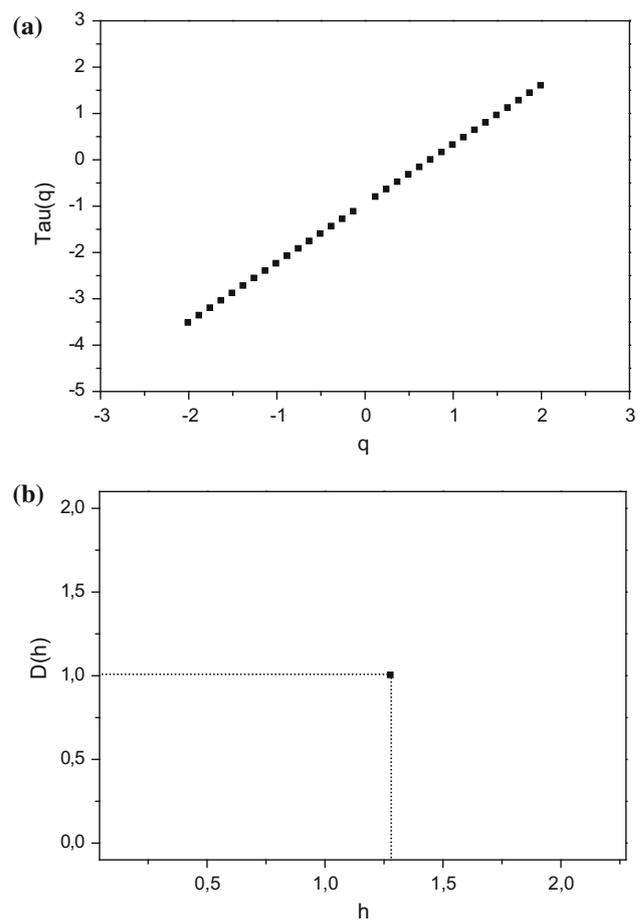


**Fig. 15** **a** Spectrum of exponents of the density of electrons recorded during June 4, 2009. **b** Spectrum of singularity of the density of electrons recorded during June 4, 2009

val of 0.125 (see Fig. 5). Low curve values of logarithm the function of partition are corresponding to  $q = -2$ ; however, the high curve values are corresponding to  $q = +2$ . The spectrum of exponents is estimated for each value of  $q$  using a linear regression of logarithm the function of partition versus logarithm the scale. Figure 6 shows the spectrum of exponents  $\tau(q)$  versus  $q$ ,  $q$  varying from  $-2$  to  $+2$  with a sampling interval of  $+0.125$ . The spectrum of singularities is estimated using the Boltzmann's weights from the wavelet transform coefficients and the function of partition [15], Fig. 7 shows the spectrum of singularities versus the so-called Hölder exponent or exponent of singularities.

### 5 Result Interpretation

Figure 6 shows the spectrum of exponent versus the moment order which is varying from  $-2$  to  $+2$ , and this spectrum has not a linear behavior which is the indicator of a multifractal behavior of the electron density signal. Figure 7 shows the

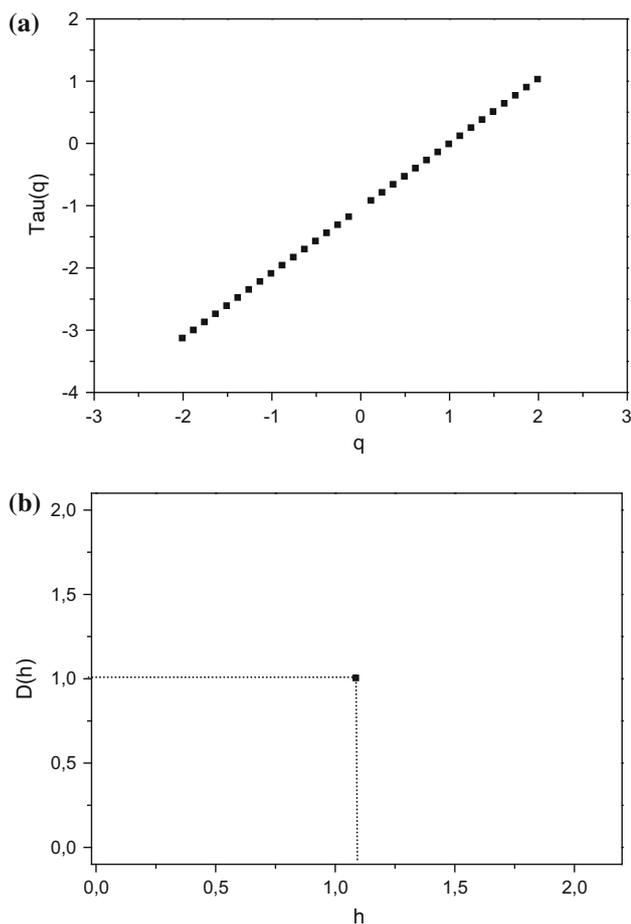


**Fig. 16** **a** Spectrum of exponents of the density of ions recorded two months after the L'Aquila earthquake main shock. **b** Spectrum of singularities of the density of ions recorded two months after the L'Aquila earthquake main shock

singularity spectrum of the electron density, the local Hölder exponent is varying from 0.2 to 0.8, while the spectrum  $D(h)$  is varying from 0.1 to 0.9, the low Hölder exponents are more dominant than the high exponents, which proves that the electron density signal has more high-frequency content, so more disturbed before the L'Aquila earthquake main shock.

Analysis of Figs. 6 and 7 demonstrates the multifractal behavior of the density of electron signal prior to the earthquake.

The spectra of exponent and singularity of the ion density (see Figs. 8, 9) exhibit the same behavior like spectrums of exponents and singularity of the electron density, and as a consequence, it has a multifractal behavior prior to the L'Aquila earthquake. Figure 10 shows the spectrum of exponents of the electron temperature versus the moment number ( $q$ ), while Fig. 11 shows the spectrum of singularities versus the Hölder exponent which is varying from 0.20 to 0.80. As a consequence, the electron temperature has also a multifractal behavior; however, it is less disturbed than the two first plasma parameters.



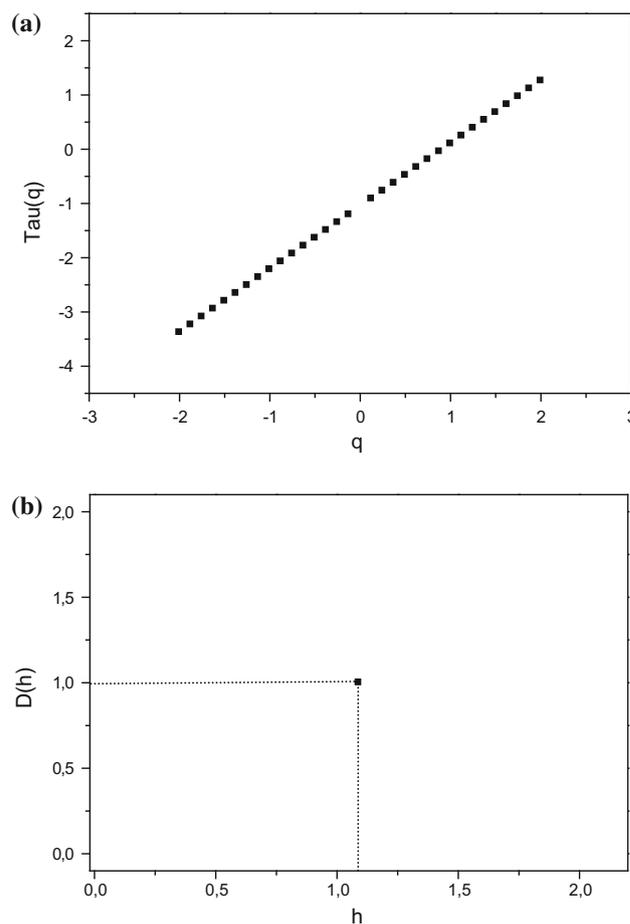
**Fig. 17** **a** Spectrum of exponents of the potential of the plasma recorded by DEMETER during June 4, 2009. **b** Spectrum of singularities of the potential of the plasma recorded by DEMETER during the fourth of June 2009

Figures 12 and 13 show that the spectra of exponents and singularities of the plasma potential exhibits the same forms such as the electron temperature, so the plasma potential has a multifractal behavior.

To check the behavior of the ionosphere in calm days, data of ISL instrument recorded two months after the L'Aquila earthquake main shock are analyzed by the WTMM method, Fig. 14 shows the electron density, the ion density, the electron temperature, and the plasma potential, respectively.

Figure 15a shows the spectrum of exponents obtained by the WTMM analysis of electron density, while Fig. 15b shows the spectrum of singularities.

In this case, the spectrum of exponents is a straight line of equation  $\tau(q) = 1.16 * q - 1$  and the spectrum of singularities  $D(h)$  is null for all the  $h$  axis only in one point  $h = 1.16$  where  $D(h) = 1$ , this is enough to say that the electron density has a monofractal behavior in calm days. Spectra of exponents and singularities of the ion density are shown in Fig. 16a, b, respectively, the spectrum of exponents has a



**Fig. 18** **a** Spectrum of exponents of the temperature of electrons recorded in June 4, 2009. **b** Spectrum of singularities of the temperature of electrons recorded in the June 4, 2009

linear behavior with equation  $\tau(q) = 1.28q - 1$  and the spectrum of singularities has an equation  $D(h) = 0$  if  $h$  is different to 1.28 and  $D(h) = 1$  if  $h = 1.28$ . As a consequence, the ion density has a monofractal behavior. WTMM analyses of the electron temperature and plasma potential are shown in Figs. 17a, b, and 18a, b, obtained results show that these two ionospheric parameters have a monofractal behavior.

## 6 Conclusion

The wavelet transform modulus maxima lines analysis of the ISL instrument data installed onboard of the DEMETER mission clearly shows the multifractal behavior of ionosphere physical response prior to L'Aquila earthquake main shock, and the WTMM analysis of these parameters 2 months after the main shock shows that the ionosphere physical response has a monofractal behavior.

This is not agree with many researches in the literature [7,8] that used the so-called fractional Brownian

motion (mBf) model to study the nonlinear behavior of the ionosphere prior to the earthquakes. As a consequence, we suggest using multifractal analysis tools such the wavelet transform modulus maxima lines, the multifractional Brownian motion [18], and the multifractal detrended fluctuations analysis [19] for the fractal analysis of DEMETER satellite data prior to earthquakes. The fractional Brownian motion supposes the uniqueness of the exponent of singularities during a given time interval which is not appropriate for the study of the ionospheric data prior to natural hazards such as earthquakes.

## References

1. Nurujjaman, Md.; Narayanan, R.; Sekar Iyengar, A.N.: Continuous wavelet transform based time-scale and multi-fractal analysis of the nonlinear oscillations in a hollow cathode glow discharge plasma. *Phys. Plasmas* **16**, 102307 (2009). doi:[10.1063/1.3241694](https://doi.org/10.1063/1.3241694)
2. Imamura, T.; Ida, Y.; Kasahara, Y.; Nakamura, T.; Hobara, Y.; Hayakawa, M.: Fractal analysis of subionospheric LF propagation data and consideration of the lithosphere–atmosphere–ionosphere coupling. *Nat. Hazards Earth Syst. Sci.* **10**, 901–906 (2010)
3. Akhoondzadeh, M.; Parrot, M.; Saradjian, M.R.: Electron and ion density variations before strong earthquakes ( $M > 6.0$ ) using DEMETER and GPS data. *Nat. Hazards Earth Syst. Sci.* **10**, 7–18 (2010). doi:[10.5194/nhess-10-7-2010](https://doi.org/10.5194/nhess-10-7-2010)
4. Parrot, M.; Berthelier, J.J.; Lebreton, J.P.; Sauvaud, J.A.; Santolik, O.; Blecki, J.: Examples of unusual ionospheric observations made by the DEMETER satellite over seismic regions. *Phys. Chem. Earth* **31**, 486–495 (2006)
5. Sarkar, S.; Gwal, A.K.; Parrot, M.: Ionospheric variations observed by the DEMETER satellite in the mid-latitude region during strong earthquakes. *J. Atmos. Solar-Terr. Phys.* **69**, 1524–1540 (2007)
6. Zhang, X.; Shen, X.; Liu, J.; Ouyang, X.; Qian, J.; Zhao, S.: Analysis of ionospheric plasma perturbations before Wenchuan earthquake. *Nat. Hazards Earth Syst. Sci.* **9**, 1259–1266 (2009)
7. Zaourar, N.; Mebarki, R.; Hamoudi, M.; Parrot, M.: La dynamique fractale des perturbations séismo-ionosphériques enregistrées par le micro-satellite DEMETER. *Rev. Télédelec.* **10**(2–3), 77–90 (2011)
8. Zaourar, N.; Mebarki, R.; Hamoudi, M.; Briquieu, L.; Parrot, M.: Analyse fractale des fluctuations séismo-ionosphériques. Troisièmes Journées d'Animation scientifique du Réseau de Télédetection de l'AUF, JAS'09, USTHB, Algiers, 8–11 November 2009
9. Ouadfeul, S.; Aliouane, L.: Multifractal analysis revisited by the continuous wavelet transform applied in lithofacies segmentation from well-logs data. *Int. J. Appl. Phys. Math.* **1**(1), 10–18 (2011)
10. Ouadfeul, S.; Hamoudi, M.: Fractal Analysis of InterMagnet Observatories Data, Fractal Analysis and Chaos in Geosciences, Dr. Sid-Ali Ouadfeul (ed.) InTech (2012), ISBN:978-953-51-0729-3. doi:[10.5772/51259](https://doi.org/10.5772/51259)
11. Ouadfeul, S.; Hamoudi, M.; Aliouane, L.: A wavelet based multifractal analysis for facies recognition from seismic data. Application to the pilot KTB borehole. *Arab. J. Geosci.* **6**(7), 2203–2209 (2012)
12. Mallat, S.; Hwang, W.L.: Singularity detection and processing with wavelets. *IEEE Trans. Inf. Theory* **38**(2), 617–643 (1992). doi:[10.1109/18.119727](https://doi.org/10.1109/18.119727)
13. Arneodo, A.; Grasseau, G.; Holschneider, M.: Wavelet transform of multifractals. *Phys. Rev. Lett.* **61**, 2281–2284 (1988)
14. Grossman, A.; Morlet, J.-F.: Decomposition of functions into wavelets of constant shape, and related transforms. In: Streit, L. *Mathematics and Physics, Lectures on Recent Results*, World Scientific, Singapore (1985)
15. Arneodo, A.; Bacry, E.: Ondelettes, multifractal et turbulence de l'ADN aux croissances cristallines. Diderot Editeur arts et Sciences, Paris (1995)
16. Lebreton, J.-P.: On the issue of surface contamination of a Langmuir Probe sensor: DEMETER ISL results. In: *Geophysical Research Abstracts*, vol. 14, EGU2012-13806 (2012)
17. Biswas, A.; Zeleke, T.B.; Si, B.C.: Multifractal detrended fluctuation analysis in examining scaling properties of the spatial patterns of soil water storage. *Nonlinear Process. Geophys.* **19**, 227–238 (2012). doi:[10.5194/npg-19-227-2012](https://doi.org/10.5194/npg-19-227-2012)
18. Ayache, A.; Vehele, J.L.: The generalized multifractional brownian motion. *Stat. Inference Stoch. Process.* **3**(1–2), 7–18 (2000)
19. Eke, A.; Herman, P.; Bassingthwaighite, J.B.; Raymond, G.M.; Percival, D.B.; Cannon, M.; Balla, I.; Ikényi, C.: Physiological time series: distinguish fractal noises from motions. *Eur. J. Physiol.* **439**, 403–414 (2000)

