

Réseaux de Neurones Récurrents Appliqués à l'Automatisation du Marché à Terme : cas Producteur-Consommateur

Salima KENDI*, Fodil LAIB**, and Mohammed Said RADJEF***

Laboratoire de Modélisation et d'Optimisation des Systèmes (LAMOS), Université de Béjaia, Algérie.

salima_kendi@yahoo.fr, fodil.laib@cevital.com, radjefms@yahoo.fr

Résumé Dans ce travail, nous proposons une approche d'automatisation du processus de négociation du prix sur un marché à terme simplifié, en occurrence le marché producteur-consommateur. Cette approche consiste à représenter le système par un réseau de neurones récurrent capable de réagir au flux de prévisions de l'offre et de la demande dans l'émission des ordres d'achat et de vente, l'interaction de ces ordres aboutira à la génération d'une courbe de Prix du Marché (PM). Pour mesurer la performance de notre système de négociation automatique, nous avons d'abord émis des hypothèses sur les propriétés d'une courbe de Prix de Référence (PR), puis nous proposons des mesures analytiques permettant de calculer la distance entre les deux courbes (PM) et (PR). L'objectif du réseau de neurones est d'apprendre à générer une courbe (PM) qui soit la plus proche possible de la courbe (PR).

Mots clés : Négociation automatique, Marchés à terme, Réseaux de Neurones Récurrents, Apprentissage, Stratégies de négociation.

Introduction

La majorité des crashes financiers et des bulles spéculatives est due au comportement irrationnel de l'homme (comportement moutonnier, la panique, le désir du gain et la peur de perdre). Il est probable qu'en remplaçant l'homme par un automate dans la fixation des prix, il y'aurait moins de crashes financiers car les automates poursuivent des stratégies rationnelles tenant compte de la situation réelle du marché. Cette rationalité peut être un facteur de stabilité économique si ces automates sont capables de générer un prix accomplissant son rôle de régulateur de l'offre et de la demande.

Avant l'âge des ordinateurs, les négociants échangeaient des actions et des matières premières en s'appuyant sur l'intuition pour la fixation du prix. Avec l'augmentation du niveau de l'investissement et du commerce, les négociants recherchaient des outils augmentant leurs gains et minimisant leurs risques. L'analyse technique et fondamentale, les statistiques et la régression linéaire sont autant d'outils employés pour prévoir la direction du marché. Aucune de ces techniques ne s'est avérée être l'outil uniformément correct de prévision ; beaucoup d'analystes argumentent sur l'utilité de beaucoup d'approches [1].

L'analyse technique repose sur l'hypothèse que l'histoire se répète et que la direction du prix peut être déterminée en examinant les prix passés. Cette technique est employée par la majorité des opérateurs en bourse [2].

L'analyse fondamentale nécessite une description des facteurs explicatifs de l'offre et de la

* Département de recherche Opérationnelle, Université de Béjaia, Algérie (corresponding author).

** Groupe CEVITAL, Garidi II, Kouba, Alger, Algérie.

*** Laboratoire de Modélisation et d'Optimisation des Systèmes (LAMOS), Université de Béjaia, Algérie.

demande d'un produit sur une période donnée. L'ensemble des relations de causalité entre les variables constitue un modèle économique qui est formalisé en un modèle économétrique [3].

Dans la grande variété des techniques de modélisation des marchés, chaque approche a son propre ensemble de défenseurs et de détracteurs. Le but commun de toutes ces méthodes est de prévoir les mouvements de prix à partir de l'information passée. Ces méthodes fonctionnent mieux lorsqu'elles sont utilisées simultanément. L'avantage principal d'employer un réseau de neurones demeure dans le fait qu'il permet d'apprendre à employer efficacement ces méthodes en association.

Différentes études empiriques ont testé l'efficacité des marchés à terme en montrant que les prix à terme sont des prévisions non biaisées des prix au comptant. Les premières ont été réalisées en 1974 sur les marchés à terme de bétail sur pied et par Bigman, Goldfarb et Schechtman (1983) [4] sur les marchés à terme de grains à Chicago. Les deux études concluent à l'inefficacité des marchés à terme.

La capacité des réseaux de neurones de traiter avec l'incertain et de découvrir des rapports non-linéaires dans des données d'entrée les rend plus aptes à modéliser les systèmes dynamiques non-linéaires tels que le marché boursier [1]. Selon Wong, Bodnovich et Selvi [5], les domaines d'application les plus fréquents des réseaux de neurones durant les dix dernières années sont les opérations de production (53,5%) et les finances (25,4%).

Il y a une littérature étendue sur les applications financières des réseaux de neurones (Trippi et Turban, 1993 [6]; Refenes, 1994 [7]; Odom et Sharda (1990) [8]; Coleman, Graettinger et Lawrence (1991) [9]; Salchenkerger, Cinar et Lash (1992) [10]; Tam et Kiang (1992) [11]; Wilson et Sharda (1994) [12]; Weigend, Rumelhart et Hubermann (1991) [13]; ...).

1 Définition du contrat à terme

Un contrat à terme est une promesse de vente d'un produit à une date ultérieure et pour un prix immédiatement fixé. Sur un marché de contrats à terme, l'opérateur achète ou vend des contrats sans nécessairement posséder la marchandise servant de support aux contrats. Un opérateur peut s'engager en mars à livrer pour le mois de septembre une marchandise qu'il ne possède pas. De la même manière, l'opérateur s'engageant à acheter sans être assuré que son co-contractant possède les produits physiques ou sans avoir lui même la volonté d'en prendre réellement livraison. Le marché à terme est donc avant tout un *marché financier* [14].

2 Formulation mathématique du mécanisme du marché à terme

Soit $\mathcal{N} = \{1, \dots, n\}$ un ensemble de traders dans un marché à terme. Ces derniers estiment les niveaux de l'offre et de la demande à travers les informations provenant de différentes sources. Les traders envoient leurs ordres \mathbf{u}_i , $i \in \mathcal{N}$, sur la plate-forme du marché comme montré sur la figure 1. Les ordres de ventes sont mis dans la liste des ordres de vente, en occurrence LSO¹, et ceux d'achat dans la liste des ordres d'achat, LBO². Le meilleur ordre de vente (celui ayant le prix le plus bas) est toujours à la tête de LSO et le meilleur ordre d'achat (celui ayant le prix le plus haut) est toujours à la tête de LBO. Une session de contrats à terme se déroule dans un intervalle de temps $[0, T]$ réparti en un ensemble de périodes $\mathbb{T} = \{t_0, \dots, t_m\}$, tels que

$$t_0 = 0, t_m = T, t_j = t_{j-1} + h, j = 1, \dots, m,$$

où h est le pas de la discrétisation : $h = \frac{T}{m}$ [15].

¹ List of Selling Orders.

² List of Buying Orders.

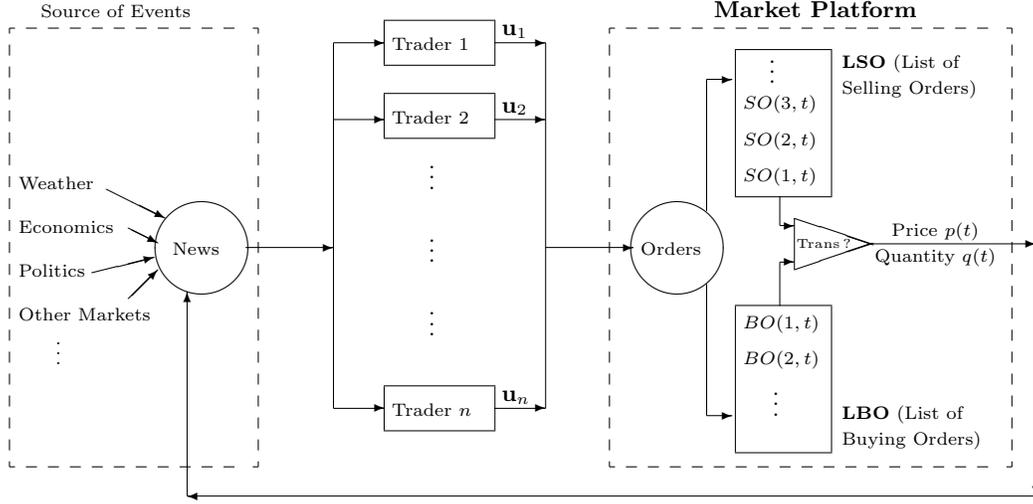


Fig. 1. Traders envoyant leurs ordres vers la plate-forme du marché

3 Définitions et hypothèses relatives à la courbe du prix

Il est généralement admis que la balance de l’offre et de la demande est le conducteur principal du prix. Afin de pouvoir évaluer la performance d’une stratégie de négociation, nous présentons ci-dessous quelques hypothèses sur les propriétés que devrait avoir une courbe de prix idéal.

Definition 1. (Prix nominal). Pour produire une unité d’un produit donné C , nous avons besoin d’utiliser c_k unités du composant C_k coûtant $p_k(t_{j-1})$ à l’instant t_{j-1} , avec $k = 1, \dots, K$ et $j = 1, \dots, m$. Ainsi, en incluant un ratio de marge bénéficiaire r , le prix nominal du produit C à l’instant t_j est

$$p^*(t_j) = (1 + r) \sum_{k=1}^K c_k p_k(t_{j-1}).$$

Hypothese 1. ($S\&D^3$ détermine la tendance du prix actuel). La courbe du prix doit inversement suivre la courbe de la balance ($S\&D$) de l’offre S et de la demande D . Si ($S\&D$) décline alors le prix doit augmenter et vice-versa.

Hypothese 2. (Le prix conduit le prochain mouvement de $S\&D$). Une augmentation significative du prix encourage l’investissement, ce qui provoquera une augmentation du niveau de l’offre, au même temps la consommation sera réduite. La réciproque est vraie.

Hypothese 3. (Le prix nominal détermine le niveau actuel du prix). Dans le cas d’un surplus, le prix de marché devrait baisser au-dessous du prix nominal dans le but de décourager la production et encourager la consommation. Inversement, dans le cas d’un déficit, le prix de marché devrait être au-dessus du prix nominal dans le but d’encourager la production et décourager la consommation. Si à n’importe quel instant t_j , le niveau de l’offre est égal au niveau de la demande, alors le prix du marché $p(t_j)$, à l’instant t_j devrait être égal au prix nominal, $p^*(t_j)$.

³ $S\&D$: abréviation de Supply and Demand (offre et demande).

Hypothese 4. (La volatilité de S&D transférée au prix). La volatilité de S&D devrait induire une volatilité équivalente sur la courbe du prix. Explicitement, dans tout sous-ensemble de temps $\{t_k, \dots, t_{k+h}\} \subset \{t_1, \dots, t_m\}$, la relation suivante est satisfaite :

$$\sigma_{S\&D}(t_k, t_{k+h}) \simeq \sigma_p(t_k, t_{k+h}),$$

où $\sigma_{S\&D}(t_k, t_{k+h})$ et $\sigma_p(t_k, t_{k+h})$ sont les écart-types de S&D et du prix respectivement sur la période (t_k, t_{k+h}) , avec $h \in \mathbb{N}$, $t_1 \leq t_k < t_{k+h} \leq t_m$.

Hypothese 5. Une bonne courbe de prix est celle où les transactions prennent lieu dans la majorité des périodes, c'est-à-dire la quantité transactionnelle $q(t_j)$ devrait être positive la plupart du temps, $j = 1, \dots, m$.

Hypothese 6. (Volumes homogènes). La volatilité des quantités transactionnelle $q(t_j)$ devrait être maintenue au minimum dans tout sous-ensemble de temps $\{t_k, \dots, t_{k+h}\} \subset \{t_1, \dots, t_m\}$,

$$\sigma_q(t_k, t_{k+h}) \simeq 0,$$

où $\sigma_q(t_k, t_{k+h})$ est l'écart-type de la variable q sur la période (t_k, t_{k+h}) , avec $h \in \mathbb{N}$, $t_1 \leq t_k < t_{k+h} \leq t_m$.

3.1 Critères de performance économique

Pour mesurer l'efficacité du réseau de neurones (RPQ) suivant les hypothèses 1-6 respectivement, les critères suivants sont utilisés :

$$z_1(\gamma, \mathbf{S}, \mathbf{D}) = \frac{1}{m} \sum_{j=1}^m \mathbf{1}_{[\text{sign}(G(t_j) - G(t_{j-1})) = -\text{sign}(p(t_j) - p(t_{j-1}))]}, \quad (1)$$

$$z_2(\gamma, \mathbf{S}, \mathbf{D}) = \frac{1}{m-1} \sum_{j=1}^{m-1} \mathbf{1}_{[\text{signe}(G(t_{j+1}) - G(t_j)) = \text{signe}(p(t_j) - p(t_{j-1}))]}, \quad (2)$$

$$z_3(\gamma, \mathbf{S}, \mathbf{D}) = \frac{1}{m} \sum_{j=1}^m \mathbf{1}_{[\text{sign}(G(t_j)) = -\text{sign}(p(t_j) - p^*(t_{j-1}))]}, \quad (3)$$

$$z_4(\gamma, \mathbf{S}, \mathbf{D}) = \frac{1}{m-h} \sum_{k=1}^{m-h} \mathbf{1}_{[|\sigma_G(t_k, t_{k+h}) - \sigma_p(t_k, t_{k+h})| \leq \epsilon]}, \quad (4)$$

$$z_5(\gamma, \mathbf{S}, \mathbf{D}) = \frac{1}{m} \sum_{j=1}^m \mathbf{1}_{[q(t_j) > 0]}, \quad (5)$$

$$z_6(\gamma, \mathbf{S}, \mathbf{D}) = \frac{1}{m-h} \sum_{k=1}^{m-h} \mathbf{1}_{[\sigma_p(t_k, t_{k+h}) \leq \epsilon]}, \quad (6)$$

où $G(t_j) = S(t_j) - D(t_j)$ représente la différence entre l'offre $S(t_j)$ et la demande $D(t_j)$, $\mathbf{1}_{[C]}$ est la fonction conditionnelle définie par $\mathbf{1}_{[C]} = 1$ si la condition C est vérifiée, sinon $\mathbf{1}_{[C]} = 0$, $0 < \epsilon \ll 1$ et z_i est un ratio prenant ses valeurs dans $[0, 1]$ et mesurant l'efficacité du réseau de neurones proposé selon l'hypothèse i ($i = 1, \dots, 6$).

La performance moyenne est

$$\bar{z}(\gamma, \mathbf{S}, \mathbf{D}) = \sum_{k=1}^6 w_k z_k, \quad (7)$$

où w_1, \dots, w_6 sont les poids associés aux critères ci-dessus, avec $0 \leq w_k \leq 1$, $k = 1, \dots, 6$ et $\sum_{k=1}^6 w_k = 1$.

4 Réseaux de neurones

De façon générale, on situe le début des réseaux de neurones artificiels à 1943 avec les travaux de McCulloch et Pitts [16]. Aujourd'hui, on retrouve les réseaux de neurones solidement implantés dans diverses industries.

Le modèle mathématique d'un neurone artificiel est essentiellement composé d'un intégrateur effectuant la somme pondérée de ses R entrées. Le résultat n de cette somme est ensuite transformé par une fonction de transfert f qui produit la sortie a du neurone. Les R entrées du neurone correspondent au vecteur $p = [p_1 \ p_2 \ \dots \ p_R]^T$, alors que $w = [w_{1,1} \ w_{1,2} \ \dots \ w_{1,R}]^T$ représente le vecteur des poids ou "poids synaptiques". La sortie n de l'intégrateur est donnée par l'équation suivante :

$$n = \sum_{j=1}^R w_{1,j} p_j - b, \quad (8)$$

b est appelé "biais" ou "seuil d'activation" du neurone. Le résultat n s'appelle "niveau d'activation" du neurone.

L'intérêt des neurones réside dans les propriétés qui résultent de leur association en réseaux. Un réseau de neurones est un ensemble de neurones interconnectés suivant une topologie de connexion. Il existe deux types de réseaux de neurones : les réseaux *statiques* (ou non bouclés) et les réseaux *dynamiques* (récurrents ou bouclés). Le graphe de ces derniers contient au moins un cycle, d'où le terme bouclage.

5 La configuration du marché producteur-consommateur

Le marché producteur-consommateur est un marché à terme avec seulement un producteur et un consommateur. Un automate vendeur est désigné à vendre la production du producteur et un automate acheteur est désigné à couvrir les besoins du consommateur.

La décision du vendeur automatisé dans la période t_j possède la forme suivante :

$$\mathbf{u}_1(t_j) = (u_{11}(t_j), u_{12}(t_j), u_{13}(t_j)), \quad (9)$$

L'ordre de l'acheteur automatisé a la forme suivante :

$$\mathbf{u}_2(t_j) = (u_{21}(t_j), u_{22}(t_j), u_{23}(t_j)), \quad (10)$$

où

- $u_{11}(t_j)$ et $u_{21}(t_j)$: le prix de vente et le prix d'achat respectivement.
- $u_{12}(t_j)$ et $u_{22}(t_j)$: la quantité offerte et la quantité demandée respectivement.
- $(u_{13}(t_j) \in [-1, +1])$ et $(u_{23}(t_j) \in [-1, +1])$: les facteurs d'ajustement de l'offre et de la demande respectivement (on note par $S_a(t_j)$ et $D_a(t_j)$ l'offre ajustée et la demande ajustée respectivement).

Une transaction aura lieu si les deux conditions suivantes sont vérifiées en même temps :

- i) $u_{12}(t_j) \neq 0$ et $u_{22}(t_j) \neq 0$,
- ii) $u_{21}(t_j) \geq u_{11}(t_j)$.

Dans ce cas, le prix transactionnel sera :

$$p(t_j) = \frac{u_{11}(t_j) + u_{21}(t_j)}{2}, \quad (11)$$

et la quantité transactionnelle sera :

$$q(t_j) = \min\{|u_{12}(t_j)|, u_{22}(t_j)\}. \quad (12)$$

En cas de non satisfaction des conditions, aucune transaction n'aura lieu à la période t_j et on pose conventionnellement :

$$p(t_j) = p(t_{j-1}) \text{ et } q(t_j) = 0. \quad (13)$$

6 Modélisation du marché à terme Producteur-Consommateur par les réseaux de neurones

Notre ultime objectif est de concevoir des automates capables de négocier les prix sur les marchés à terme, remplaçant ainsi les traders humains dans cette mission fastidieuse. Dans cette section, nous supposons que les deux automates, acheteur et vendeur, utilisent les mêmes paramètres dans leur formulation :

- du prix-désiré (u_{11} et u_{12} respectivement) à chaque instant t_j , c-à-d $u_{11}(t_j) = u_{12}(t_j)$, et d'après la relation (11), nous aurons $p(t_j) = u_{11}(t_j) = u_{21}(t_j)$;
- de la quantité désirée (u_{12} et u_{22} respectivement) à chaque instant t_j , c-à-d $u_{12}(t_j) = u_{22}(t_j)$, et d'après la relation (12), nous aurons $q(t_j) = |u_{12}(t_j)| = u_{22}(t_j)$.

Nous proposons une approche de modélisation du processus de négociation automatisée des prix et des quantités ⁴ pour un marché à terme de type producteur-consommateur. Cette approche consiste à représenter le système par un réseau de neurones récurrent capable de réagir aux variations de l'offre et de la demande dans la fixation des prix et des quantités à terme.

L'architecture du réseau proposé est fixée par tâtonnements, elle reste une parmi une infinité d'architectures qui peuvent être proposées pour le même réseau ; le but est d'approcher au mieux le comportement du système réel.

6.1 Présentation du réseau générateur des prix et des quantités à terme

Nous avons construit un réseau de neurones récurrent (RPQ) avec le toolbox "Neural Network" de MATLAB. Le réseau est constitué de neuf sous-réseaux MLP (SR(1)-SR(9)) dont chacun est composé de deux couches. Les premières couches de chacun des sous-réseaux possèdent trente neurones chacune et des fonctions d'activation tangente sigmoïde (tansig), sauf celle du premier sous-réseau qui possède une fonction d'activation radiale ou RBF (Radial Basis Function). Les secondes couches de chacun des sous réseaux possèdent un neurone chacune et des fonctions d'activation linéaires.

Les entrées externes du réseau sont : le prix nominal à l'instant t_{j-1} : $p^*(t_{j-1})$, l'offre à l'instant t_j : $S(t_j)$, la demande à l'instant t_j : $D(t_j)$.

Le réseau retourne deux sorties qui sont : le prix transactionnel à l'instant t_j : $p(t_j)$ et la quantité transactionnelle à l'instant t_j : $q(t_j)$.

où : $y_1(t_j)$ est le nombre de contrats que le producteur a vendu depuis l'instant t_1 jusqu'à t_j . $y_2(t_j)$ est le nombre de contrats que le consommateur a acheté depuis l'instant t_1 jusqu'à t_j .

Le réseau générateur des prix et des quantités à terme est représenté sur la figure 2.

⁴ On note par quantité le nombre de contrats échangés lors d'une transaction donnée.

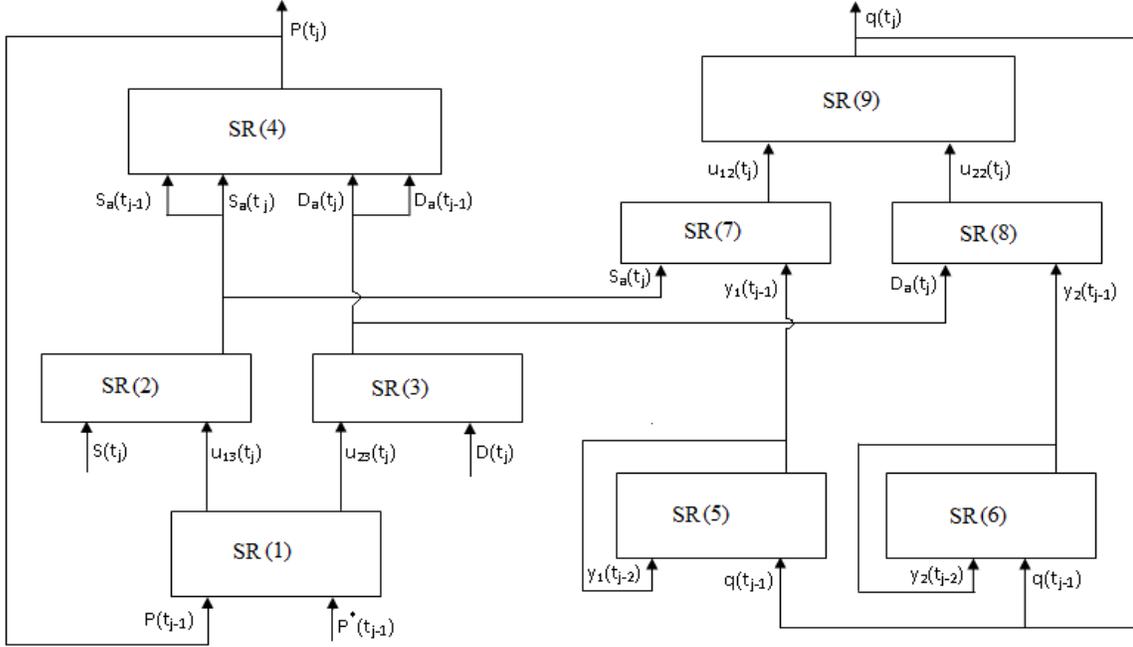


Fig. 2. Modèle de réseau de neurones générant les prix et les quantités à terme

7 Génération des données de l'apprentissage

7.1 Génération des entrées

Dans les marchés à terme, l'offre et la demande sont estimées par des personnes renvoyant leurs prévisions à chaque période. Ces estimations ne seront connues qu'une fois réalisées. Ces prévisions sont donc des variables aléatoires.

En pratique, une étude statistique est nécessaire pour détecter le type de loi à assigner au phénomène aléatoire de l'offre et de la demande et les valeurs de ses paramètres. Dans notre travail, nous utilisons un échantillon des prévisions de l'offre : $S(t_0), \dots, S(t_m)$ et un échantillon des prévisions de la demande : $D(t_0), \dots, D(t_m)$ comme des données d'apprentissage. En raison de la non connaissance des lois exactes qui régissent l'offre et la demande dans les marchés à terme, nous avons été amenés à supposer que ces dernières suivent, par exemple, une lois normale.

Nous supposons que : le nombre de périodes $m = 100$, l'offre suit une loi normale de moyenne $\mu_S = 5000$ et d'écart type $\sigma_S = 0.5$ et la demande suit la même loi de moyenne $\mu_D = 5000$ et d'écart type $\sigma_D = 0.3$. L'évolution des prévisions de l'offre et de la demande durant les m périodes est représentée sur la figure 3.

7.2 Génération des sorties désirées

Dans notre travail, nous avons d'abord cherché des prix et des quantités de transactions (en fonction de l'offre, de la demande et du prix nominal) maximisant la performance moyenne \bar{z} . Puis, nous les avons utilisés comme des sorties désirées pour le réseau de neurones proposé. Pour maximiser \bar{z} , nous avons opté pour les algorithmes génétiques en utilisant le toolbox "Genetic Algorithm and Direct Search" de MATLAB. Les paramètres utilisés dans l'algorithme génétique sont ceux qui existent par défaut : la taille de la population a été fixée à 100 ; la probabilité de croisement est de 0.8 ; le nombre de générations ~~est~~ à 100 ; le type de codage utilisé est le binaire.

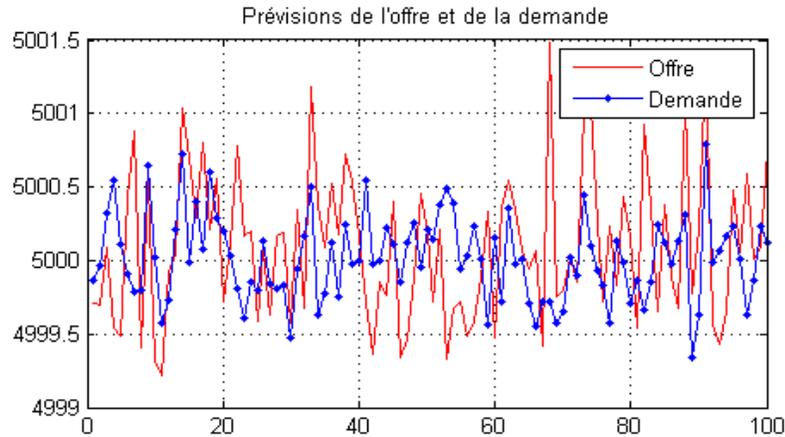


Fig. 3. Prévisions de l'offre et de la demande

8 Phase d'apprentissage

Les entrées sont injectées au réseau séquentiellement dans le temps (chaque séquence représente une période de transaction dans le marché à terme). L'algorithme d'apprentissage utilisé est le "TRAINS" (*Sequential order incremental training w/learning functions*). Nous avons défini cet algorithme en mettant : `net.adaptFcn='trains'`.

Le critère d'erreur utilisé est l'erreur quadratique moyenne : "MSE" (*Mean Squared Error performance function*). Cette fonction est définie dans le toolbox par la commande : `net.performFcn='mse'`. Le taux d'apprentissage choisi est celui par défaut : 0.1.

Les poids associés au réseau ont été initialisés par l'algorithme de Nguyen-Widrow (dans le toolbox, l'initialisation d'une couche i donnée suivant cet algorithme se fait par la commande : `net.layersi.initFcn='initnw'`). La courbe des prix générés par le réseau (accompagnée de la courbe des écarts entre les prévisions de l'offre et celles de la demande) est représentée sur la figure 4.

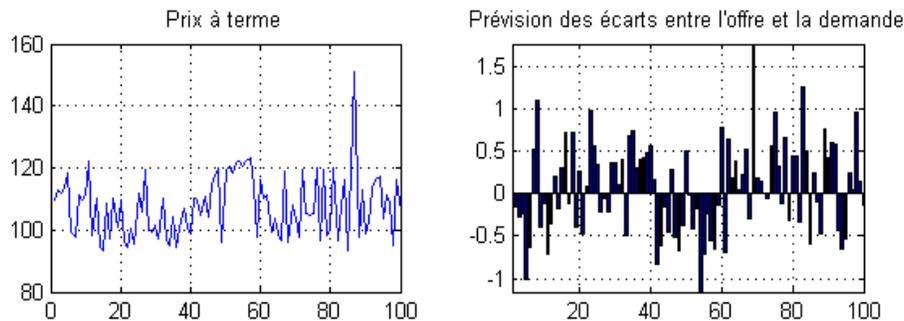


Fig. 4. Prix à terme générés par le réseau de neurones

Nous constatons bien que les variations des prix sont inversement proportionnelles aux variations des écarts entre les prévisions de l'offre et celles de la demande.

La courbe des quantités transactionnelles générées par le réseau est représentée sur la figures 5.

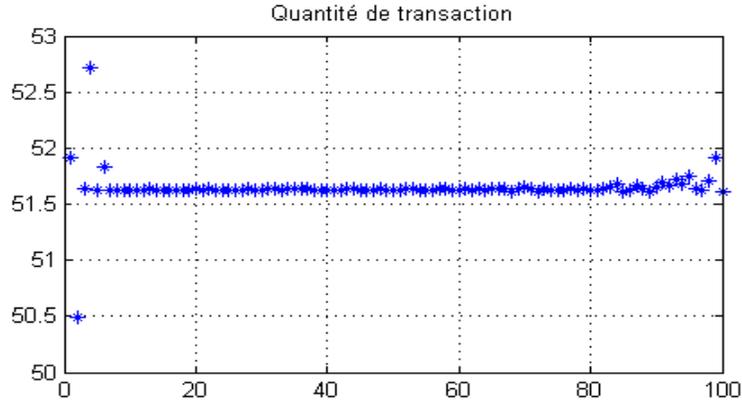


Fig. 5. Quantités de transactions générées par le réseau de neurones

9 Comparaison des sorties prix du réseau aux sorties désirées d'apprentissage

À la fin de l'apprentissage, nous avons obtenu le graphe de la figure 6.

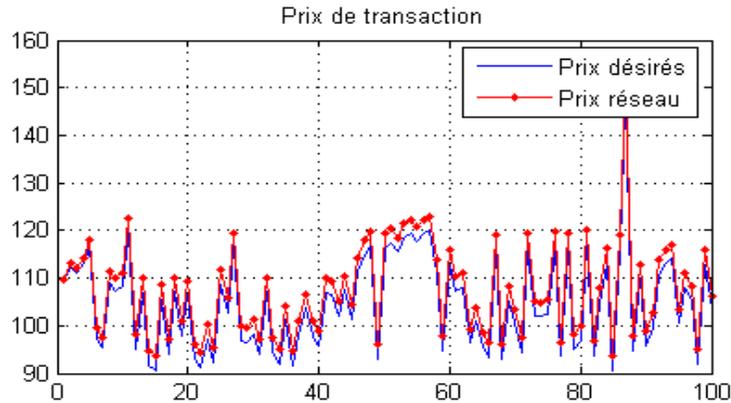


Fig. 6. Sorties du réseau prix et sorties désirées

Nous constatons que les deux courbes se rapprochent, l'erreur quadratique moyenne est égale à 0.0348.

10 Etude de performances

Soient les notations suivantes :

- Z_g : performances des résultats obtenus à travers les algorithmes génétiques en maximisant la moyenne \bar{z} des critères de performances suggérés dans les formules (1)-(6).
- Z_{rg} : performances des résultats obtenus par les réseaux de neurones dont les sorties désirées sont celles obtenues à travers les algorithmes génétiques en maximisant la moyenne \bar{z} .

Un tableau comparatif sur les performances des résultats obtenus par les sorties du réseau proposé et les sorties désirées est représenté sur la table 1.

	z_1	z_2	z_3	z_4	z_5	z_6	\bar{z}
Z_g	0.9495	0.7245	1.0000	0	1.0101	1.0000	0.7807
Z_{rg}	0.9495	0.7245	0.8889	0	1.0101	1.0000	0.7622
Z_g	0.9192	0.7449	1.0000	0	1.0101	0.9888	0.7772
Z_{rg}	0.9192	0.7449	0.9394	0	1.0101	0.9888	0.7671
Z_g	0.8788	0.7449	1.0000	0	1.0101	1.0000	0.7723
Z_{rg}	0.8788	0.7449	1.0000	0	1.0101	1.0000	0.7723
Z_g	0.9394	0.7551	1.0000	0	1.0101	1.0000	0.7841
Z_{rg}	0.9394	0.7551	0.9596	0	1.0101	1.0000	0.7774
Z_g	0.8889	0.7959	1.0000	0	1.0101	1.0000	0.7825
Z_{rg}	0.8889	0.7959	0.9091	0	1.0101	1.0000	0.7673
Z_g	0.8889	0.7755	1.0000	0	1.0101	1.0000	0.7791
Z_{rg}	0.8889	0.7755	0.9596	0	1.0101	1.0000	0.7723
Z_g	0.9192	0.7857	1.0000	0	1.0101	1.0000	0.7858
Z_{rg}	0.9192	0.7857	0.8485	0	1.0101	1.0000	0.7606
Z_g	0.9091	0.7653	1.0000	0	1.0101	1.0000	0.7807
Z_{rg}	0.9091	0.7653	0.9394	0	1.0101	1.0000	0.7706
Z_g	0.9091	0.7653	1.0000	0	1.0101	1.0000	0.7807
Z_{rg}	0.9091	0.7653	0.9394	0	1.0101	1.0000	0.7706
Z_g	0.9192	0.7857	1.0000	0	1.0101	1.0000	0.7858
Z_{rg}	0.9192	0.7857	0.8485	0	1.0101	1.0000	0.7606
Z_g	0.9091	0.7653	1.0000	0	1.0101	1.0000	0.7807
Z_{rg}	0.9091	0.7653	0.9394	0	1.0101	1.0000	0.7706

Tab. 1. Performances obtenues par les sorties du réseau proposé et les sorties désirées

11 Analyse des résultats du tableau

Nous remarquons que les performances les plus élevées sont obtenues directement à travers les algorithmes génétiques en maximisant la moyenne \bar{z} . Mais ce qui nous intéresse est un modèle fixe capable d'apprendre le mécanisme du marché à terme, c'est-à-dire : le modèle d'un réseau de neurones. Nous constatons que les performances des résultats du réseau de neurones sont légèrement plus basses que les précédentes ; cela s'explique car l'apprentissage peut être bon mais pas parfait.

12 Test et généralisation

À la fin de la phase d'apprentissage, nous avons testé si le réseau (pour la courbe des prix, par exemple) peut se généraliser à des données n'appartenant pas à l'ensemble d'apprentissage. Nous avons généré un échantillon de taille 20 (de même loi de probabilité que l'ensemble d'apprentissage). Les résultats sont représentés sur la figure 7.

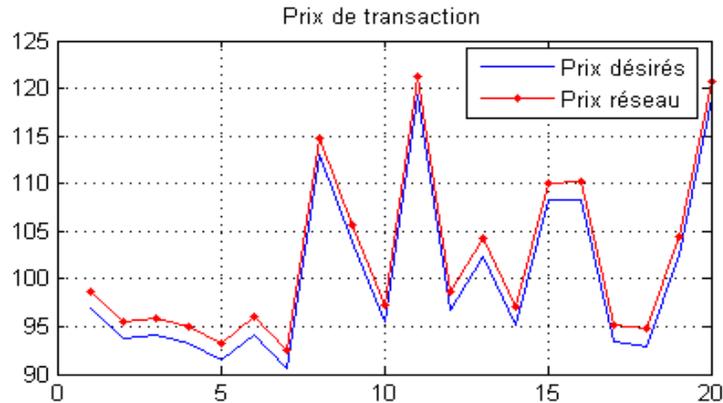


Fig. 7. Sorties prix du réseau et sorties désirées

L'erreur quadratique obtenue est égale à 0.4, nous remarquons que les résultats ne se rapprochent pas très bien des résultats attendus, donc nous concluons que le réseau ne possède pas une très bonne capacité de généralisation à d'autres données (de même loi).

Nous avons obtenu des résultats similaires pour la courbe des quantités transactionnelles.

13 Application d'autres algorithmes pour l'apprentissage

Nous avons utilisé d'autres algorithmes pour effectuer la phase d'apprentissage. Les résultats obtenus ne sont pas satisfaisants.

À titre d'exemple, après application de l'algorithme de rétro-propagation du gradient, la figure 8 montre le grand écart entre la courbe des prix à terme générés par le réseau et la courbe des prix désirés.

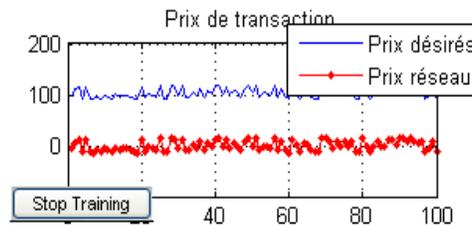


Fig. 8. Sorties du réseau prix et sorties désirées

Nous déduisons que l'algorithme séquentiel : "Sequential order incremental training" est le plus approprié pour l'apprentissage de notre réseau de neurones. Cela est dû à l'aspect séquentiel des données (dynamisme du système du marché à terme).

Conclusion

Après avoir réalisé notre étude et analysé les résultats, nous en tirons certaines conclusions :
 – le mécanisme de la plate-forme du marché à terme peut être modélisé par les réseaux de neurones, ce qui donne la possibilité d'avoir un modèle capable d'apprendre son comportement (détermination des prix et des quantités transactionnelles) ;

- le choix du modèle de réseaux de neurones influe considérablement sur les performances du modèle et, par conséquent, sur les performances des résultats ;
- la méthode que nous avons adoptée en maximisant d’abord les critères de performances suggérés en utilisant les algorithmes génétiques a donné de bons résultats pour les modèles de réseaux de neurones.

Références

1. R. Lawrence. Using neural networks to forecast stock market prices. Department of Computer Science, University of Manitoba, December 12 1997.
2. R J. Van Eyden. The Application of Neural Networks in the Forecasting of Share Prices. Finance and Technology Publishing, 1996.
3. J. Cordier. Les marchés à terme. Paris, 1984.
4. D. Bigman, D. Goldfarb and E. Schechtman, Futures markets efficiency and the time content of the information sets, *Journal of Futures Markets*, (1983), pp. 321–334.
5. B. K. Wong, T. A. Bonovich and Y. Selvi, Neural network applications in business : A review and analysis of the literature, *Decision Support Systems*, 19 (1997), pp. 301–320.
6. R. Trippi and E. Turban. Neural Networks in Finance and Investment : Using Artificial Intelligence to Improve Real-world Performance. Chicago : Probus, 1993.
7. A. N. Refenes. Neural Networks in the Capital Markets. Chicester : Wiley, 1995.
8. M. D. Odom and R. Sharda, A neural network model for bankruptcy prediction, In : *Proceedings of the IEEE International Joint Conference on Neural Networks*. San Diego, CA, 2 (1990), p. 163–168.
9. K. G. Coleman, T. J. Graettinger and W. F. Lawrence, Neural networks for bankruptcy prediction : The power to solve financial problems, *AI Review*, (1991), p. 48–50.
10. L. M. Salchenkerger, E. M. Cinar and N. A. Lash, Neural networks : A new tool for predicting thrift failures, *Decision Science*, 23(4) (1992), p. 899–916.
11. K. Y. Tam and M. Y. Kiang, Managerial applications of neural networks : The case of bank failure predictions, *Management Science*, 38(7) (1992), p. 926–947.
12. R. Wilson and R. Sharda, Bankruptcy prediction using neural networks, *Decision Support Systems*, 11 (1994), p. 545–557.
13. A. S. Weigend, D. E. Rumelhart and B. A. Huberman, Generalization by weight-elimination with application to forecasting, *Advances in Neural Information Processing Systems*, 3 (1991), p. 875–882.
14. Y. Simon and D. Lautier. *Marchés dérivés de matières premières et gestion du risque de prix*. ECONOMICA. Paris, 2^e édition, 2001.
15. M.S. Radjef and F. Laib. On the Mechanism of the Futures Market : a Formulation and Some Analytical Properties. Communication presented at the 13th International Symposium on Dynamic Games and Applications, Wroclaw (Poland), 30th June-3rd July, 2008
16. W. S. McCulloch and W. Pitts, A logical calculus of the ideas immanent in nervous activity, *Bull. Math. Biophysics*, (1943), pp. 5 :115–133.