

Réflexions autour de la Modélisation des dynamiques économiques par agents intelligents : analyse, exemples et potentialités

Kurosh Madani,

Laboratoire Images, Signaux et Systèmes Intelligents (LISSI),
Université Paris-Est Créteil (UPEC)

Olivier Meier

LIPHA Paris-Est – Université Paris Est (UPEC)

Introduction

L'analyse et la compréhension des mécanismes économiques et sociétaux représentent un défi majeur pour les sociétés modernes. Ces mécanismes sont complexes, impliquant des interactions dynamiques entre divers agents économiques et sociaux. Traditionnellement, la modélisation de ces mécanismes reposait sur des approches analytiques ou paramétriques, mais celles-ci ont montré leurs limites face à la multitude de paramètres hétérogènes qu'elles doivent prendre en compte. De plus, la nature des données économiques et sociales est souvent qualitative et quantitative, rendant difficile une analyse précise et compréhensible.

Dans ce contexte, l'émergence de l'intelligence artificielle (IA) et plus particulièrement de l'intelligence artificielle bio-inspirée a ouvert de nouvelles perspectives. Au cours de la dernière décennie, ces technologies ont démontré leur capacité à modéliser des phénomènes complexes et à offrir des solutions alternatives aux problèmes de prévision et d'analyse, en particulier dans les domaines du traitement des données et de la modélisation des dynamiques économiques et sociales.

L'objectif de cet article est de présenter le développement, l'évaluation et l'application d'approches issues de l'IA bio-inspirée et de modèles basés sur des agents artificiels intelligents (AAI) pour analyser les mécanismes économiques et sociétaux. Il s'agit de montrer comment les concepts issus de l'IA bio-inspirée, et notamment ceux du « soft computing », peuvent s'articuler dans la modélisation des mécanismes économiques et sociétaux améliorant l'analyse, et le cas échéant, la compréhension et de ces mécanismes complexes.

La première section de l'article est dédiée aux principes fondateurs et à l'architecture générale d'un AAI. Il révèle les préceptes afférant à la modélisation, basés sur des agents et décrit comment l'IA bio-inspirée peut s'emboîter dans l'architecture d'un AAI. Finalement, en

détaillant les principes de fonctionnement de deux concepts issus de l'IA bio-inspirée, à savoir les systèmes d'inférence flous et les réseaux de neurones artificiels, la section 1 donne, à travers de deux exemples détaillés de leur application, la clé de leur exploitation pour la modélisation des mécanismes économiques et sociétaux.

La seconde section du présent article

1. Intelligence artificielle et modélisation basée sur AAI des mécanismes économiques et sociétaux

La modélisation des mécanismes économiques et sociétaux a traditionnellement reposé sur des approches analytiques, souvent fondées sur des systèmes d'équations linéaires et des hypothèses d'équilibre général. Ces méthodes, bien qu'efficaces pour analyser des environnements stables et bien structurés, s'avèrent limitées face à la complexité inhérente des systèmes économiques contemporains. Les interactions entre les acteurs économiques sont souvent dynamiques, non linéaires et imprévisibles (Tsfatsion & Judd, 2006). C'est dans ce contexte que l'intelligence artificielle (IA) offre un large éventail de nouveaux outils pour la modélisation de ces systèmes (Miller & Page, 2007). Parmi ces outils, les modèles basés sur des agents (MBA) sont particulièrement prometteurs, car ils permettent de modéliser des systèmes en tenant compte de l'hétérogénéité des acteurs et de leurs interactions dans des environnements dynamiques et incertains (Axelrod, 1997). Ainsi, ils offrent de nouvelles perspectives très prometteuses pour ce qui relève d'outils d'aide à la décision sous contraintes et dans les environnements complexes ((Chohra & Madani, 2018), (Chohra et Al., 2018)).

Contrairement aux modèles mathématiques classiques, qui partent de l'hypothèse que les agents économiques sont homogènes et parfaitement rationnels, les MBA incorporant des AAI permettent d'intégrer des comportements hétérogènes, irrationnels et partiellement (imparfaitement) informés (LeBaron, 2006). Cela les rend particulièrement adaptés à l'étude de systèmes complexes, tels que les marchés financiers, les réseaux de transport, ou les systèmes politiques, où l'interaction entre les agents conduit à des dynamiques émergentes et non-stationnaires. Ces modèles permettent également de mieux incorporer les effets non linéaires et les rétroactions, deux caractéristiques souvent observées dans les systèmes économiques et sociétaux, offrant ainsi un potentiel attrayant pour la prédiction et l'interprétation des répercussions de tels mécanismes sur les systèmes économiques et sociétaux.

Les MBA sont basés sur des entités appelées agents, qui peuvent représenter (modéliser) des entités fonctionnelles régissant le comportement d'acteurs économiques (des individus, des entreprises, des institutions ou même des gouvernements), interagissant dans un environnement donné. Ces agents sont dotés d'une autonomie (partielle ou totale) d'actions sur l'environnement dans lequel ils évoluent et avec lequel ils interagissent, prennent des décisions basées sur des règles comportementales, et leurs interactions locales conduisent à des dynamiques globales complexes. Ces dynamiques peuvent être difficiles à anticiper à l'aide de méthodes analytiques traditionnelles.

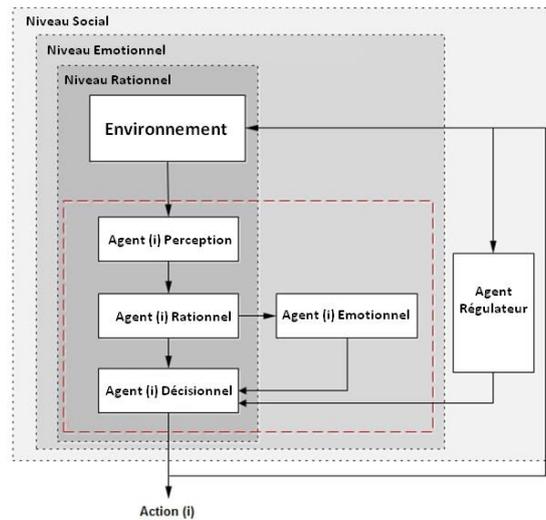


Figure.1 : Architecture globale de MBA multi-niveau comprenant trois niveaux d'interactions avec l'environnement : niveau rationnel, niveau émotionnel et niveau social.

La Figure.1 illustre l'architecture globale multi-niveau de MBA comprenant trois niveaux d'interactions avec l'environnement : niveau rationnel, niveau émotionnel et niveau social (Abdallah, 2023). Il est pertinent de noter que les agents artificiels constituant cette architecture peuvent à leur tour inclure des mécanismes algorithmiques et/ou computationnels issus des approches de l'intelligence artificielle (apprentissage-machine, soft-computing, etc.).

Exemple Potentiel d'Application à la modélisation des marchés financiers

L'un des champs d'application les plus emblématiques des MBA est la modélisation des marchés financiers. Dans ces marchés, les interactions entre les agents (investisseurs, courtiers, régulateurs, etc.) déterminent l'évolution des prix des actifs. Ces interactions sont souvent marquées par des informations imparfaites et asymétriques, ce qui rend les comportements des agents incertains et non linéaires.

Un modèle basé sur des agents peut simuler les décisions d'investissement des agents en fonction de l'information disponible, de leur aversion au risque, ou encore de leur horizon d'investissement. Les agents peuvent ajuster leurs portefeuilles d'actifs en fonction de l'évolution des prix, des nouvelles régulations ou des événements économiques imprévus. Par exemple, les MBA peuvent modéliser l'effet des annonces de politiques monétaires sur les marchés boursiers et observer les comportements collectifs, tels que les ventes de panique ou les achats en masse, qui peuvent provoquer des bulles spéculatives ou des crises financières. L'un des avantages majeurs des MBA dans ce contexte est leur capacité à reproduire des dynamiques émergentes imprévisibles, telles que les crises financières ou les bulles spéculatives. Ces phénomènes résultent souvent de comportements collectifs imprévisibles, où la décision d'un agent est influencée par les comportements de ses pairs (effet de mimétisme). Contrairement aux modèles traditionnels d'équilibre général, qui supposent que les agents réagissent de manière rationnelle aux variations de prix, les MBA permettent de capturer l'irrationalité et la volatilité des marchés financiers, offrant ainsi des perspectives nouvelles pour la régulation des marchés et la gestion des crises financières.

Potentiel d'Applications supplémentaires à la dynamique des prix et régulation des marchés

Les MBA peuvent également être utilisés pour analyser les effets des régulations sur les marchés financiers. Par exemple, les régulateurs peuvent être modélisés comme des agents ayant pour objectif de stabiliser les marchés en imposant des limites de fluctuation des prix ou en augmentant les exigences de fonds propres des institutions financières. Ces modèles permettent de tester différentes configurations de régulation et de prédire leurs effets sur la volatilité des prix et sur la stabilité du système financier global.

1.1 Les agents artificiels intelligents

Outre que percevoir son environnement, de traiter des informations et d'agir de manière à atteindre certains objectifs, un agent artificiel intelligent (AAI) est une entité autonome capable d'exploiter des techniques computationnelles et algorithmiques issues de l'intelligence artificielle et d'apprentissage-machine (machine-learnig). Ces agents peuvent représenter des entités économiques réelles telles que des entreprises, des consommateurs, ou des régulateurs approchant la réalité de leurs comportements complexes. Ainsi, chaque agent peut être doté de capacités computationnelles (calculatoire) et/ou de capacités cognitives qui lui permettent de prendre des décisions stratégiques en fonction des connaissances acquises par apprentissage artificiel ou extraites des informations disponibles et de ses objectifs. Dans le cadre de la modélisation économique, cette approche offre une représentation plus réaliste des comportements économiques, car elle tient compte de la rationalité limitée des agents, c'est-à-dire leur incapacité à traiter toutes les informations disponibles ou à prendre des décisions parfaitement optimisées.

Les AAI permettent également d'introduire des comportements hétérogènes. Par exemple, dans un marché, tous les agents ne réagissent pas de la même manière aux variations de prix en fonction des connaissances dont ils disposent ou en fonction de leur tempérament. Certains peuvent adopter des comportements plus agressifs, tandis que d'autres peuvent être plus conservateurs. De plus, les agents peuvent apprendre et ajuster leurs comportements en fonction de leur expérience ou de l'évolution de l'environnement économique. Cela permet de reproduire des phénomènes émergents observés dans la réalité, tels que l'adaptation progressive des stratégies d'investissement dans des conditions d'incertitude.

La Figure.2 illustre l'exemple d'architecture d'agent artificiel intelligent (AAI) multi-niveau à base d'intelligence artificielle bio-inspirée avec une capacité d'adaptation d'actions neuro-floue, une technique issue de la combinaison de deux modèles de soft-computing : un réseau de neurones artificiel (RNA) et un système d'inférence floue (à base de la logique floue). L'adaptation (la correction) de l'action d'un tel AAI s'effectue par le système d'inférence floue l'apport correctif nécessaire à la correction de l'action de celui-ci envers l'environnement. Le RNA est chargé d'estimer (corriger) les paramètres, notamment la distribution des fonctions d'appartenance de l'inférence floue à partir de l'apprentissage artificiel d'évolution de ces paramètres en fonction de l'évolution de l'environnement ou à partir des connaissances (représentées par une base d'apprentissage) sur l'évolution de ces paramètres.

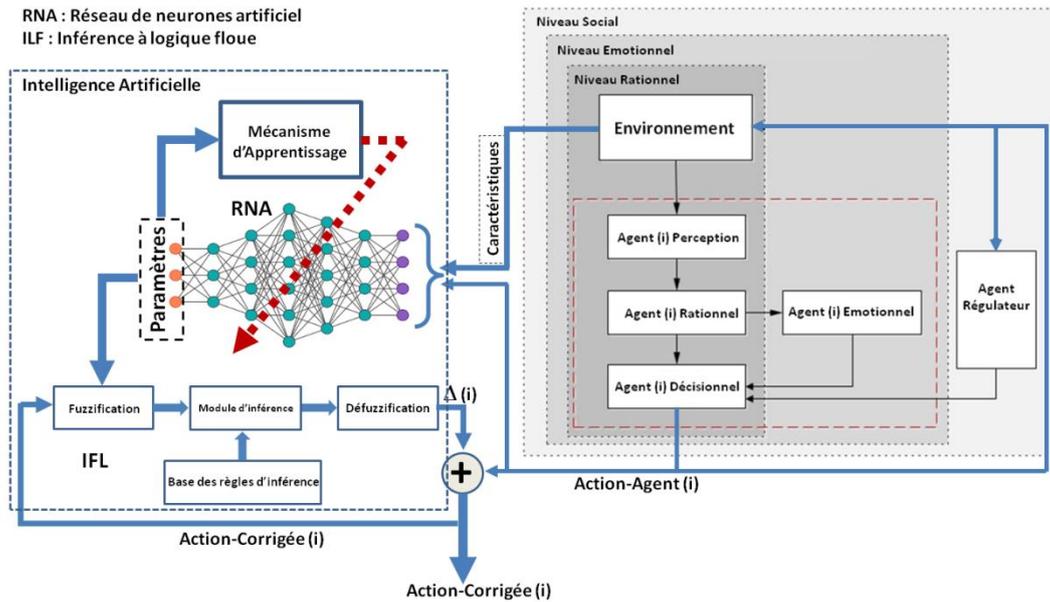


Figure.2 : Exemple d'architecture d'agent artificiel intelligent (AAI) multi-niveau à base d'intelligence artificielle bio-inspirée avec une capacité d'adaptation d'actions neuro-floue.

Comme on le constate dans l'exemple d'architecture d'AAI illustré par la Figure.2, la composante cognitive de l'AAI repose sur les concepts et techniques issus de l'intelligence artificielle bio-inspirée, dont le fonctionnement s'appuie sur des mécanismes observés dans le monde naturel. Il nous semblerait donc pertinent de dédier la section suivante à l'introduction du concept de l'IA bio-inspirée et des principaux modèles issus de ce concept.

1.2 Modèles bio-inspirés et soft computing

L'intelligence artificielle bio-inspirée s'appuie sur des mécanismes observés dans le monde naturel, tels que le fonctionnement des réseaux neuronaux dans le cerveau, les comportements collectifs des colonies d'insectes, ou encore les processus d'évolution biologique. Ces concepts ont été adaptés aux systèmes artificiels pour offrir des solutions innovantes à des problèmes complexes, notamment en matière de modélisation des systèmes économiques et sociétaux. L'IA bio-inspirée se distingue par sa capacité à gérer des situations d'incertitude, de non-linéarité et d'imprécision, des caractéristiques omniprésentes dans les systèmes économiques.

Parmi les modèles les plus prometteurs de l'IA bio-inspirée, et de ce fait les plus exploités, est la classe d'approches issues de soft-computing, également appelé « calcul tolérant ». Cette classe de méthode regroupe plusieurs concepts d'IA, telles que les systèmes flous (fuzzy logic), les algorithmes évolutionnaires et les réseaux neuronaux artificiels. Ces concepts et les techniques issues de ces derniers permettent de gérer des informations incertaines, imprécises ou incomplètes, de mettre en œuvre (modéliser) l'évolution des dynamiques collectives complexes et d'imiter le fonctionnement des systèmes complexes par apprentissage à partir d'exemples représentatifs du fonctionnement de ces derniers. Ainsi, contrairement aux approches traditionnelles du hard-computing, qui exigent des solutions précises et

déterministes, le soft-computing offre des solutions approximatives mais suffisamment robustes pour résoudre des problèmes complexes dans des environnements incertains.

1.2.1 Logique floue et système d'inférence floue

Introduite par Lotfi Zadeh en 1965 (Zadeh, 1965), la logique floue (fuzzy logic) a été conçue pour quantifier des grandeurs qualitatives comme par exemple « petit », « moyen », « grand », « un peu plus » ou « un peu moins », etc.. Elle repose sur la théorie des sous-ensembles flous, ou parties floues (Kaufmann, 1977), modélisant la représentation humaine des grandeurs, améliorant ainsi les performances des systèmes de décision qui impliquent des paramètres ou des grandeurs qualitatives. La théorie des sous-ensembles flous est appliquée à de nombreux domaines, notamment pour modéliser l'incertitude et l'imprécision ou pour représenter des informations précises sous forme lexicale.

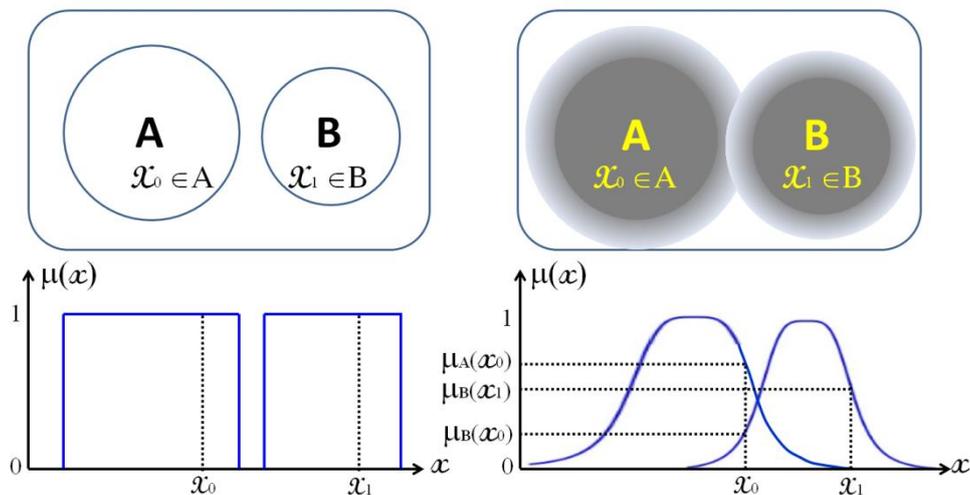


Figure.3 : Différence entre la notion d'appartenance dans la logique Booléenne et la logique floue.

Contrairement à la logique conventionnelle (logique Booléenne) où la valeur d'une variable « appartient » ou « n'appartient pas » à un ensemble (ou intervalle) A, la logique floue admet une appartenance modulée, exprimée comme un « degré d'appartenance ». Ainsi, dans la formulation floue, la valeur x d'une variable x appartient à l'ensemble A avec un degré d'appartenance $\mu(x) \in [0, 1]$. $\mu(\cdot)$ représente la « fonction d'appartenance » quantifiant l'évolution de ce degré d'appartenance. La Figure.3 illustre cette différence de point de vue sur l'appartenance entre la logique Booléenne et la logique floue.

Comme le montre la Figure.3, dans la logique Booléenne, quand $x = x_0$ la variable $x \in A$ et quand $x = x_1$ la variable $x \in B$. Dans la logique floue, quand $x = x_0$ la variable $x \in A$ avec un degré d'appartenance $\mu(x_0) = \mu_A(x_0)$ mais en même temps la variable $x \in B$ avec un degré d'appartenance $\mu(x_0) = \mu_B(x_0)$. De même, pour $x = x_1$, la variable la $x \in B$ avec un degré d'appartenance $\mu(x_1) = \mu_B(x_1)$ et $x \in A$ avec un degré d'appartenance $\mu(x_1) = \mu_A(x_1) = 0$. De ce fait, la valeur de la variable x dans la logique floue dépendra d'une part, à son degré d'appartenance aux ensembles des valeurs que peut prendre x et d'autre part, à l'évolution (allure) des fonctions d'appartenances qui régissent les règles lexiques décrivant ces appartenances. C'est dans ce cadre que le rôle du système d'inférence floue (appelé aussi le

moteur d'inférence) consiste à déterminer (décider) la valeur estimée de la variable x . La Figure.4 illustre le concept d'inférence floue.

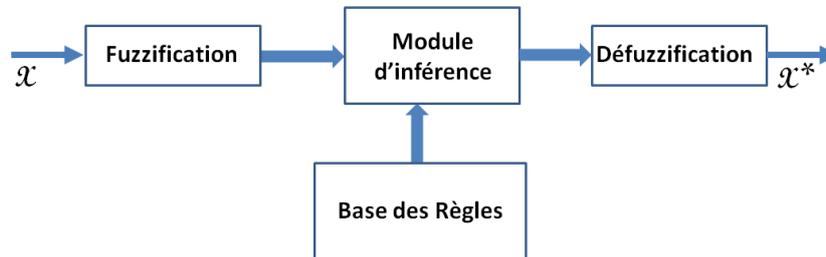


Figure.4 : Le concept d'inférence floue.

Comme on peut le constater dans la Figure.4, le système d'inférence floue comprend quatre modules : Fuzzification, Module d'inférence, Défuzzification et la Base des règles. La fuzzification consiste à déterminer les degrés d'appartenance de la variable aux ensembles flous des valeurs possibles (définies) pour cette variable. Le rôle du module d'inférence consiste à déterminer, à partir des degrés d'appartenance (issus de la fuzzification) et des règles lexiques (disponibles dans la base des règles), le mode calculatoire d'interpolation de la valeur quantitative de la variable x calculée à partir des degrés d'appartenances et la l'interprétation quantitative des règles obtenue à partir de la transformation par les opérations de la logique floue des règles : en d'autres termes, génération d'une nouvelle fonction d'appartenance régissant la valeur interpolée (estimée) x^* de la variable x . Finalement, la défuzzification consiste à déterminer (décider sur) la valeur de x^* et par conséquent, la décision qui en découle. Plusieurs modes calculatoires peuvent être exploités pour x^* . Parmi les plus utilisés on peut citer celle décrite par l'équation (1), où \bar{x} représente la moyenne de x , $\mu_i(\cdot)$ est la $i^{\text{ème}}$ ensemble flou (intervalle des valeurs possible) et K représente le nombre total des ensembles flous.

$$x^* = \frac{\int \bar{x} \sum_{i=1}^K \mu_i(x) dx}{\int \sum_{i=1}^K \mu_i(x) dx} \quad (1)$$

Exemple d'application didactique : Aide à la décision d'investissement sur les marchés financiers

Considérons l'application du concept de la logique floue et d'inférence floue dans le cadre d'investissement sur les marchés financiers. En effet, une telle inférence peut constituer un outil d'aide à la décision. Supposons les règles lexiques suivantes (constituant la Base des règles) dans le contexte de l'évolution de prix de produits financiers (actions, obligations, etc.) :

- I- **Si** l'évolution du prix de l'action A est inférieure à 5,00 € **Alors** conservation des actions A détenues et l'achat d'autres d'actions A (investissement).
- II- **Si** l'évolution du prix de l'action A est entre 8,50 € et 13,00 € **Alors** conservation des actions A détenues (ni vente ni d'achat d'actions supplémentaires).
- III- **Si** l'évolution du prix de l'action A est supérieure à 18,00 € **Alors** procéder à la vente des actions A détenues.

La question à trancher (décision à prendre) : *Quelle posture adopter si le prix d'action A a évolué de 7,50 € ?*

Compte tenu des règles ci-dessus, la formulation (définition) de l'espace des valeurs de la variable x , en l'occurrence « 'évolution du prix de l'action A », peut être effectuée en utilisant

la fonction d'appartenance « trapézoïde » (par exemple) sous la forme illustrée par la Figure.5. La valeur $x_0 = 7,50$.

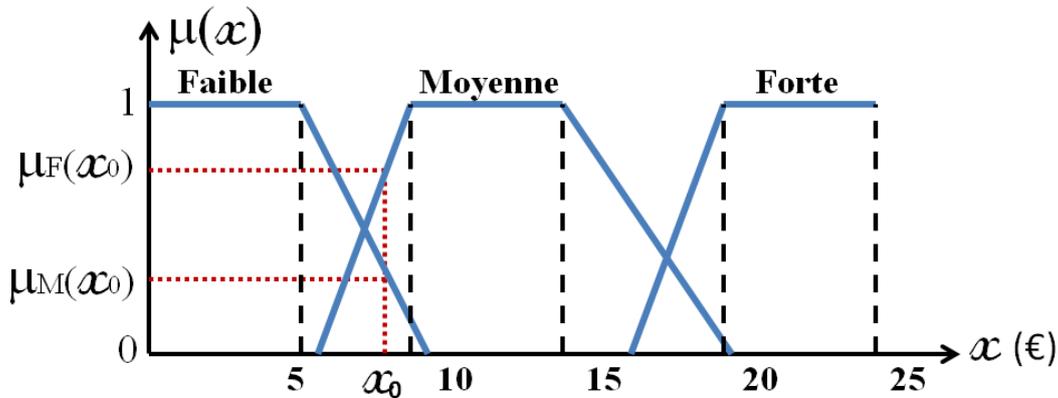


Figure.5 : Les fonctions d'appartenance issues des règles lexiques.

Référant à la Figure.5 et à la valeur de $x = 7,50$, la Fuzzification conduit aux degrés d'appartenances suivantes : $\mu_F(x_0 = 7,50) = 25\%$ et $\mu_M(x_0 = 7,50) = 75\%$. On remarque par ailleurs que $\mu_{Fo}(x_0 = 7,50) = 0\%$.

Opération d'inférence : $x^* = \frac{\int \bar{x} \sum_{i=1}^K \mu_i(x) dx}{\int \sum_{i=1}^K \mu_i(x) dx}$ où $i \in \{\text{Faible}, \text{Moyenne}, \text{Forte}\}$ (et donc $K=3$, ce qui signifie qu'il y a trois ensembles flous détenant les valeurs possibles de de la variable x). Conformément à la Figure.5, pour $i = 1$ (l'intervalle des valeurs « Faibles ») $\bar{x} = 4,5$ (soit, $\frac{9+0}{2}$), pour $i = 2$ (l'intervalle des valeurs « Moyennes ») $\bar{x} = 12,5$ (soit, $\frac{19+6}{2}$) et pour $i = 3$ (l'intervalle des valeurs « Fortes ») $\bar{x} = 20$ (soit, $\frac{25+15}{2}$). Cependant, il est pertinent de noter que $\mu_3(7,50) = \mu_{Fo}(7,50) = 0\%$ et de ce fait, $\bar{x} \mu_{Fo}(7,50) = 0$.

Par exemple, en utilisant la règle $Max(\mu_i(x))$ où $i \in \{\text{Faible}, \text{Moyenne}, \text{Forte}\}$, on obtient la mesure approximative de la variable x conformément à la Figure.6 illustrant la fonction d'appartenance régissant la valeur interpolée (estimée) x^* de la variable x .

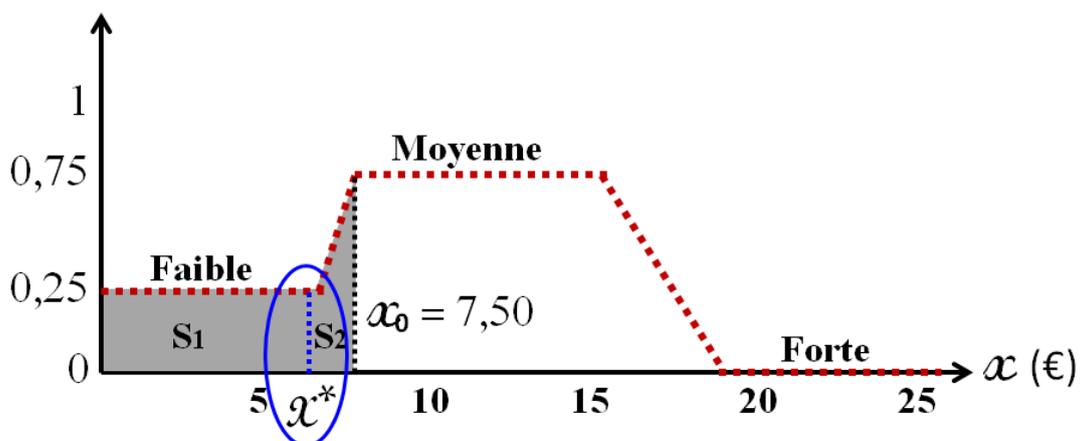


Figure.6 : La fonction d'appartenance régissant la valeur interpolée (estimée) x^* de la variable x et la valeur estimée x^* obtenue par la défuzzification.

La Défuzzification à partir du résultat illustré par la Figure.6 conduisant à la valeur estimée x^* :

$$x^* = \frac{\bar{x} S_1 + \bar{x} S_2 + [0]}{S_1 + S_2 + [0]}$$

$$x^* = \frac{[4,5 \times 0,25 \times 6,5] + [12,5 \times 0,75 \times 0,5 \times (7,5 - 6)] + [0]}{[0,25 \times 6,5] + [1,5 \times 0,5 \times (0,25 + 0,75)] + [0]}$$

$$x^* = \frac{[7,31] + [7,03] + [0]}{[1,62] + [0,75] + [0]} = 6,05$$

ce qui conduit à $x^* \cong 6$ €. Compte tenu de la valeur de x^* , l'évolution estimée du prix d'action A correspond à l'intervalle de « Faibles évolutions » et de ce fait, la décision adéquate consiste à : *conservation des actions A déjà détenues et l'achat d'autres d'actions A (investissement)*.

Autres exemples du potentiel d'application : gestion des risques en entreprise

Dans le domaine de la gestion des risques, l'IA bio-inspirée et le soft computing peuvent être utilisés pour modéliser des situations où l'information est partielle ou incertaine (Zadeh, 1994). Par exemple, un système flou (fuzzy system) peut être utilisé pour évaluer le risque de défaillance financière d'une entreprise en intégrant des critères qualitatifs aux indices quantitatifs caractérisant cette catégorie de défaillances. Les systèmes flous permettent de modéliser des situations où les critères d'évaluation sont imprécis, comme la perception de la solvabilité par les analystes financiers ou l'appréciation lexicale de l'éventualité d'un retournement de marché.

1.2.2 Réseaux de neurones artificiels

Inspirés du paradigme biologique du fonctionnement du cerveau, le réseau de neurones artificiels (RNA) est la métaphore biologique des concepts issues de la cybernétique et biocybernétique. Introduit par Warren McCulloch et Walter Pitts en 1943 (McCulloch & Pitts Kouvelis, 1943), le concept du neurone formel puis celui du « Perceptron » (Rosenblatt, 1958) ont constitué les fondements des RNA. Cependant, le développement réel du concept et l'engouement grandissant pour ces approches datent des années 80 par l'introduction du « Perceptron Multi-couches » (Rumelhart & Mc Clelland, 1986) et des « Réseaux Neuronaux » (Hopfield, 1982).

Perceptron Multi-couches (Multi-Layer Perceptron – MLP) est une structure constituée d'unités calculatoires (neurones artificiels) organisées en réseaux de couches (Figure.7-b). La première couche, appelée la « couche d'entrée », reçoit des paramètres (informations) d'entrée du réseau. La dernière couche, appelée la « couche de sortie », délivre la réponse (informations) du réseau neuronal (à l'entrée reçue) obtenue par la transformation successive de l'entrée par des couches intermédiaires, appelée les « couches cachées » du réseau. Ainsi, chaque couche cachée transforme, par des neurones la constituant, l'information reçue de la couche précédente et transmet l'information transformée à la couche suivante (jusqu'à la couche de sortie du réseau). La transformation au niveau de chaque neurone s'effectue sur la base d'agrégation des réponses pondérées des neurones de la couche précédente (appelée le calcul du « Potentiel Synaptique ») et la transformation par une opération (en principe non linéaire) par une fonction appelée la « fonction d'activation » du neurone (Figure.7-a).

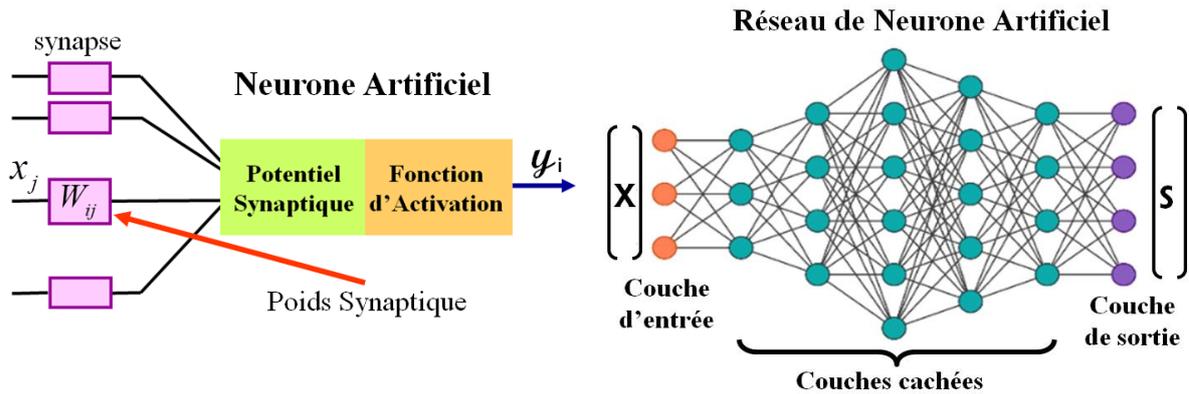


Figure.7 : Neurone formel (a) et réseau de neurones artificiels (b).

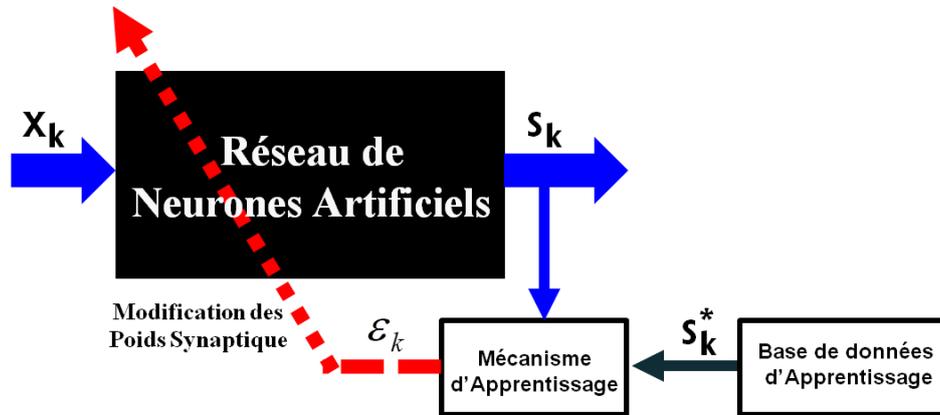


Figure.8 : Réseau de neurones artificiels en mode d'apprentissage. X_k représente le $k^{\text{ème}}$ exemple puisé dans la base d'apprentissage (vecteur d'entrée du réseau), S_k représente la réponse du réseau à X_k constituant ainsi le vecteur de sortie du réseau, S_k^* représente la réponse correcte (désirée) du réseau à X_k et à ϵ_k représente l'erreur de sortie du réseau pour le $k^{\text{ème}}$ exemple puisé dans la base d'apprentissage.

Comme nous l'avons mentionné précédemment, chaque neurone formel effectue la mise à jour de son état (désigné par y_i dans la Figure.7-a) sur la base d'agrégation des réponses (états) pondérées, par les poids synaptiques $W_{i,j}$, des neurones de la couche précédente (Potentiel Synaptique V_i) et la mise à jour en fonction de ce Potentiel Synaptique de son état par sa fonction d'activation $F(V_i)$. Les équations (2) et (3) détaillent cette mise à jour.

$$V_i = \sum_{j=1}^N W_{i,j} x_j \quad (2)$$

$$y_i = F(V_i) \quad (3)$$

Nombreuses fonctions d'activations ont été proposées dans la littérature scientifique. L'une des plus exploitée est la fonction « sigmoïde » explicitée par l'équation (4) où le paramètre T (un réel positif) représente un levier du contrôle de l'allure de la fonction. En effet, pour $T = 0$, $e^{\frac{-x}{T}} = 0$ et de ce fait $F(x, 0)$ avoisine la valeur 1. Pour $T \gg 1$ (c'est-à-dire quand T est grand), $e^{\frac{-x}{T}} = e^0 = 1$ et de ce fait $F(x, T \gg 1) = \frac{1}{2} = 0,5$. La Figure.9 illustre l'effet du paramètre de contrôle T sur l'allure de la fonction d'activation sigmoïdale.

$$F(x, T) = \frac{1}{1 + e^{-\frac{x}{T}}} \quad (4)$$

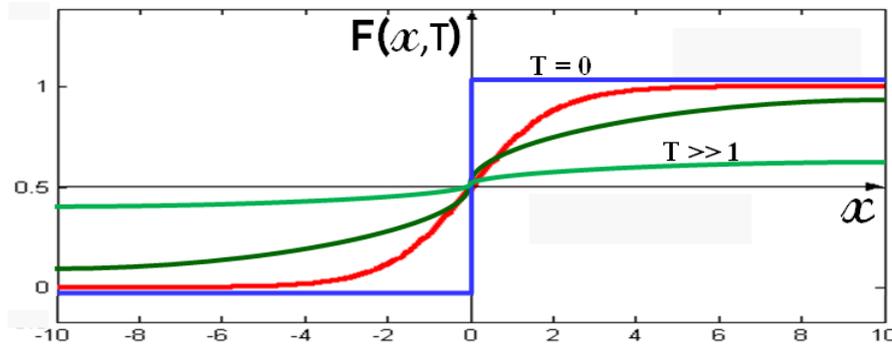


Figure.9 : Effet du paramètre de contrôle T sur l'allure de la fonction d'activation sigmoïdale.

La notion d'apprentissage puise son fonctionnement dans l'idée que la modification des poids synaptiques ($W_{i,j}$) modifie la réponse S du réseau neuronal à l'entrée (X) de celui-ci. Ainsi, la modification des poids synaptiques en fonction des erreurs successives de la réponse du réseau aux entrées issues d'une base d'apprentissage (contenant des exemples d'entrées avec la réponse désirable à celles-ci) va diminuer l'erreur du réseau et de ce fait, ajuster le comportement du réseau neuronal de sorte à répondre correctement aux entrées reçues par ce dernier. Le mécanisme d'apprentissage est chargé de la modification des poids synaptiques ($W_{i,j}$). L'équation (5) formalise le fonctionnement d'un tel processus d'apprentissage supervisé, où $G(X_k, \varepsilon_k)$ représente la règle d'apprentissage, ΔW_k^L représente la modification des poids synaptiques de la $L^{\text{ème}}$ couche du réseau neuronal pour le $k^{\text{ème}}$ exemple puisé dans la base d'apprentissage, $W_k^L = [W_{i,j}^L]$ est la matrices des poids synaptiques de la $L^{\text{ème}}$ couche du réseau neuronal, $\varepsilon_k = \|S_k - S_k^*\|$ représente l'erreur de la réponse du réseau pour le $k^{\text{ème}}$ exemple puisé dans la base d'apprentissage et S_k^* est la réponse correcte (désirée) attendue du réseau pour le $k^{\text{ème}}$ exemple puisé dans la base d'apprentissage.

$$\Delta W_k^L = G(X_k, \varepsilon_k) \quad (5)$$

L'apprentissage artificiel peut donc être interprété comme la construction progressive, durant le mode d'apprentissage, de la solution (approchée par le comportement adéquat du réseau neuronal) à partir des exemples représentatifs de celle-ci contenus dans la base d'apprentissage. De ce fait, la représentativité et la suffisance du nombre des exemples de la base d'apprentissage demeurent capital pour le fonctionnement des réseaux de neurones artificiels et d'une façon plus générale, pour toute approche d'IA basée sur l'apprentissage artificiel (Machine-Learning).

Exemple d'application : Modélisation de l'évolution des marchés financiers

L'un des champs d'application les plus emblématiques des RNA dans le domaine d'économie est la modélisation de l'évolution des marchés financiers de la prédiction du comportement de ces derniers : par exemple la prédiction du prix d'actions à partir de la dynamique des transactions. En effet, suivi de la dynamique des transactions et l'évolution de la valeur des actions peuvent constituer les données pour une base d'apprentissage pour la prédiction du prix des actions convoitées. La base d'apprentissage ainsi constituée va être représentative du

comportement (en l'occurrence financier) de l'action concernée en fonction de deux paramètres « X » et « Y » : X étant par exemple le « prix » de l'action et Y le « nombre de transactions par unité de temps » (par exemple par minute). La Figure.10 donne l'exemple de l'illustration graphique d'une telle base de données (d'apprentissage).

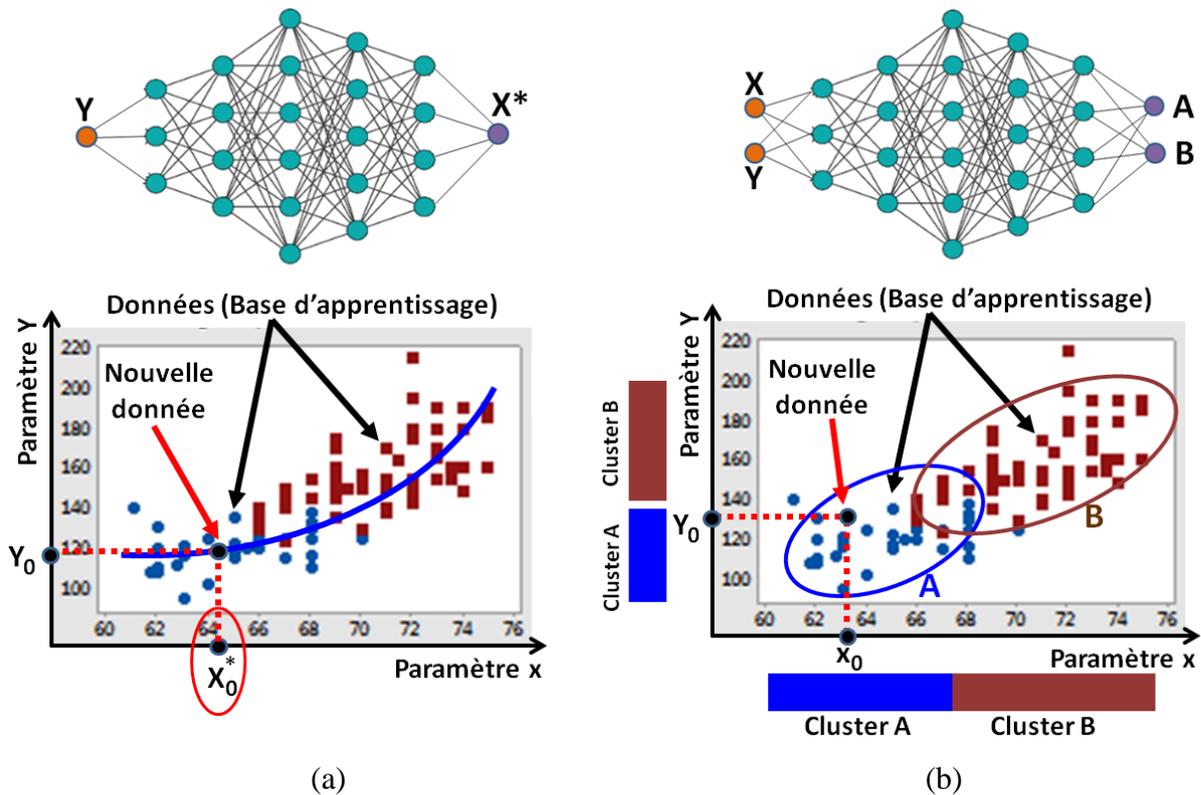


Figure.10 : Prédiction de prix d'action (Paramètre X) à partir de la dynamique des transactions (Paramètre Y) : $X^* = f^{-1}(Y) + \varepsilon$ (a) et Classificateur de comportement du marché à partir du prix d'action et de la dynamique des transactions (b).

Dans la partie (a) de la Figure.10, l'objectif de l'apprentissage est de régler les poids synaptiques de sorte à optimiser la régression statistique de la distribution des données de la base d'apprentissage. En d'autres termes, identifier le comportement $Y^* = f(X) + \varepsilon$ où Y^* est la valeur estimée (prédite) du paramètre Y avec ε avoisinant 0 (c'est-à-dire $\varepsilon \ll 1$). Cette même régression peut également être exploitée pour la prédiction du paramètre X à partir du paramètre Y : $X^* = f^{-1}(Y) + \varepsilon$. Ainsi, à partir d'un volume de transactions Y_0 (nouvelle donnée, non contenue dans la base d'apprentissage) le prédicteur neuronal estimera le prix que vaudra l'action (X_0^*).

Exemple d'application : Modélisation du comportement des marchés financiers

La même base d'apprentissage, issue du suivi de la dynamique des transactions et l'évolution de la valeur des actions, peut être exploitée pour l'apprentissage d'un RNA configuré en « classificateur ». L'architecture du classificateur neuronal est illustré dans la partie (b) de la Figure.10. Cette fois, l'objectif de l'apprentissage est de régler les poids synaptiques de sorte à partitionner l'espace des paramètres en zones de données homogènes : identifier des « clusters » homogènes des données dans l'espace des paramètres. Ainsi, en fonction des propriétés des

données de chaque cluster on peut identifier le comportement que représente chaque partition de données ainsi classifiée.

Par exemple, pour la distribution des données de la Figure.10, on peut identifier deux groupes (clusters) de comportements. En effet, le cluster « A » correspondant à une variation plus faible du prix d'action est caractérisé par une dynamique de 120 transactions par minute alors que le cluster « B » représente un accroissement plus significatif du prix d'action conjugué aux volumes importants des transactions. De ce fait, vraisemblablement le cluster A identifie une activité (une dynamique) usuel de l'action alors que le cluster B correspondrait à une activité anormale et de ce fait, spéculatif sur l'action concernée. Ainsi, par exemple pour la valeur X_0 de cette action avec une dynamique Y_0 des transactions (nouvelles données, non contenues dans la base d'apprentissage) le classificateur neuronal identifiera un comportement ordinaire (continu et non spéculatif) du marché de cette action.

Potentiel d'applications supplémentaires : Prédiction des crises économiques

Le soft computing est également particulièrement adapté à la prédiction des crises économiques. En intégrant des données qualitatives, telles que la confiance des consommateurs ou les perceptions des acteurs économiques, les systèmes flous peuvent être utilisés pour modéliser les indicateurs quantitatifs des signaux qualitatifs faibles annonciateurs de crises. Par exemple, la dégradation progressive de certains indicateurs flous, tels que la confiance des investisseurs ou la liquidité des marchés, peut indiquer une crise imminente. Ainsi, l'apprentissage des dynamiques de ces indicateurs flous par un RNA en configuration de classificateur peut identifier un comportement propice à l'émergence d'une situation de crise. Cette approche permet d'anticiper les crises économiques bien avant qu'elles ne deviennent visibles à travers les indicateurs économiques traditionnels.

Dans ce même registre, les algorithmes évolutionnaires, une autre famille d'outils issus de soft-computing inspirés des processus de sélection naturelle, peuvent également être appliqués pour optimiser les stratégies de gestion des risques (Michalewicz, 1992). Par exemple, une entreprise cherchant à minimiser son exposition à un certain type de risque (comme la volatilité des prix des matières premières) peut utiliser des algorithmes évolutionnaires pour identifier la meilleure combinaison de couvertures financières. Ces algorithmes permettent d'explorer un vaste espace de solutions potentielles et d'identifier la stratégie optimale en fonction des objectifs spécifiques de l'entreprise.

L'intelligence artificielle, en particulier dans ses dimensions bio-inspirées et basées sur des agents, offre des perspectives nouvelles et prometteuses pour la modélisation des mécanismes économiques et sociétaux. Les MBA permettent de capturer les interactions dynamiques et les comportements hétérogènes des agents économiques, tandis que les approches de soft computing permettent de gérer des informations incertaines et imprécises, caractéristiques des systèmes économiques contemporains. L'intégration de ces outils dans les analyses économiques ouvre la voie à une meilleure compréhension des dynamiques complexes qui sous-tendent les crises financières, les comportements des marchés et les décisions stratégiques des entreprises.

2. Applications pratiques des agents intelligents dans la gestion et l'économie

L'application des modèles basés sur des agents (MBA) dans la gestion et l'économie a permis de transformer la manière dont les organisations et les gouvernements prennent des décisions stratégiques. Ces outils basés sur l'intelligence artificielle permettent d'analyser et de simuler des systèmes complexes en tenant compte des interactions entre les agents, qui peuvent être des individus, des entreprises, ou des institutions publiques. Les MBA offrent une modélisation réaliste des processus économiques et organisationnels en intégrant des comportements hétérogènes, des dynamiques non linéaires, et des environnements incertains. Leur flexibilité permet d'aborder des problèmes dans divers domaines tels que la logistique, la gestion des ressources humaines, ou encore la mise en œuvre de politiques publiques.

Les applications des MBA sont vastes et variées, couvrant des domaines tels que la simulation et l'optimisation des chaînes d'approvisionnement, la gestion des ressources humaines, et l'analyse des politiques publiques. Ces modèles ont prouvé leur efficacité pour prévoir des dynamiques complexes et tester l'impact de différents scénarios dans des environnements incertains.

2.1 Simulation et optimisation des chaînes d'approvisionnement

La gestion des chaînes d'approvisionnement est un domaine où les agents intelligents ont montré une grande efficacité (Kouvelis et al., 2006). Les chaînes d'approvisionnement sont des systèmes complexes impliquant de multiples acteurs (fournisseurs, distributeurs, clients) interagissant dans un environnement dynamique et incertain. Les décisions prises au sein de ces chaînes doivent souvent être ajustées en temps réel en fonction de nombreux facteurs, tels que la fluctuation de la demande, la disponibilité des stocks, ou encore les variations des délais de livraison. Ces chaînes sont également sujettes à des perturbations imprévisibles, telles que des crises sanitaires, des catastrophes naturelles, ou des changements brusques dans les régulations commerciales.

Les MBA sont particulièrement adaptés à ce contexte, car ils permettent de modéliser chaque acteur de la chaîne comme un agent autonome capable de prendre des décisions en fonction des informations disponibles et de ses objectifs propres. Un fournisseur, par exemple, peut ajuster sa production en fonction des commandes reçues et des capacités de stockage, tandis qu'un distributeur peut décider de modifier ses stratégies d'approvisionnement en fonction de la demande locale et des prévisions de pénurie. Ces agents interagissent entre eux, et leurs décisions cumulées influencent l'ensemble de la chaîne d'approvisionnement.

Exemple d'application : Gestion et optimisation de flux dans la chaîne d'approvisionnement dans le contexte d'environnements perturbés

Les approches basées sur des agents, et d'une façon plus générale celle issues du concept des « systèmes multi-agents », peuvent simuler des scénarios impliquant des dynamiques complexes issues des agissements (stratégies) individuels et collectifs qui caractérisent les entités (agents) constituant de l'écosystème régie par celles-ci. , Par exemple, lors d'une perturbation majeure (sociétale, mondiale, etc.), impactant l'ensemble de l'écosystème logistique, de nombreuses entreprises sont contraintes d'ajuster rapidement leur stratégie d'acheminement (distribution) pour préserver la chaîne d'approvisionnement et faire face à des augmentations (variations) extrêmes de la demande. Un MBA permet de tester différents

scénarios en incorporant des stratégies individuelles, collectives coopératives ou concurrentes dans les comportements des agents subissant ces perturbations, et d'identifier les points critiques (qui nécessitent des ajustements) ou une stratégie globale fluidifiant le flux de distribution (ou d'approvisionnement).

Considérons donc l'exemple pratique suivant scénarisant une augmentation substantielle de la demande induisant une perturbation majeure des flux de distribution (par exemple logistique) du au contexte réaliste de constance des capacités des canaux de distributions. En effet, il n'est pas réaliste d'envisager une augmentation de la capacité des routes ou de construire des nouvelles routes. Il est pertinent de noter qu'une façon originale (et élégante) d'aborder le problème posé de considérer ce dernier sous l'angle d'un paradigme d'évacuation : en l'occurrence l'évacuation sous contrainte d'agents d'acheminement (dans le cas présent des unités de transports d'une entreprise de logistique) impactée par l'augmentation substantielle de la demande. Dans ce contexte et pour rendre plus pratique l'exemple considéré, supposons que l'espace de distribution (territoire, région, etc.) est représenté par un espace bidimensionnel d'une certaine surface comprenant deux accès d'une capacité donnée (capacité maximale d'évacuation) représentant le flux maximum de marchandises pouvant être acheminées par celles-ci. Alors, on peut formuler le problème en termes « d'évacuation » d'agents (unités de transports) par les accès disponibles (les deux portes) dans l'espace (territoire) considéré.

Nous proposons de tester l'efficacité d'une stratégie individuelle rationnelle d'acheminement que nous appellerons « Comportement-Rationnelle » (CR) versus une stratégie collective coopérative d'acheminement que nous appellerons « Comportement-Coopératif » (CC) où le comportement rationnel est complète par une coopération locale des agents transporteurs (Abdallah et Al, 2021). La Figure.11 illustre la formulation (sous l'angle du paradigme d'évacuation) du problème considéré. Comme le montre cette figure, un agent i est localisé par ses coordonnées x_i et y_i données par la géo localisation du véhicule (transporteur). L'agent dispose donc de sa position et des distances qui le séparent de chacun des deux accès A et B calculé à partir de sa position et positions des accès A et B dans le territoire couvert par le transporteur. L'équation (6) donne les distances séparant du transporteur (agent i) de chacun des deux accès A et B où x_A et y_A représentent les coordonnées de l'accès A comme x_B et y_B qui représentent les coordonnées de l'accès B.

$$\begin{cases} d_i(A) = \sqrt{(x_i - x_A)^2 - (y_i - y_A)^2} \\ d_i(B) = \sqrt{(x_i - x_B)^2 - (y_i - y_B)^2} \end{cases} \quad (6)$$

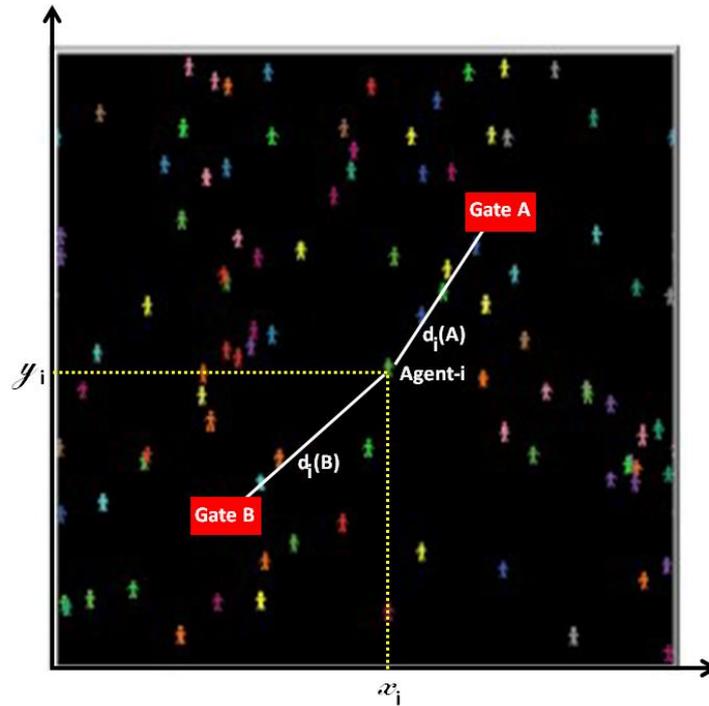


Figure.11 : Formulation, sous l’angle du paradigme d’évacuation, du problème de la régulation du flux d’approvisionnement.

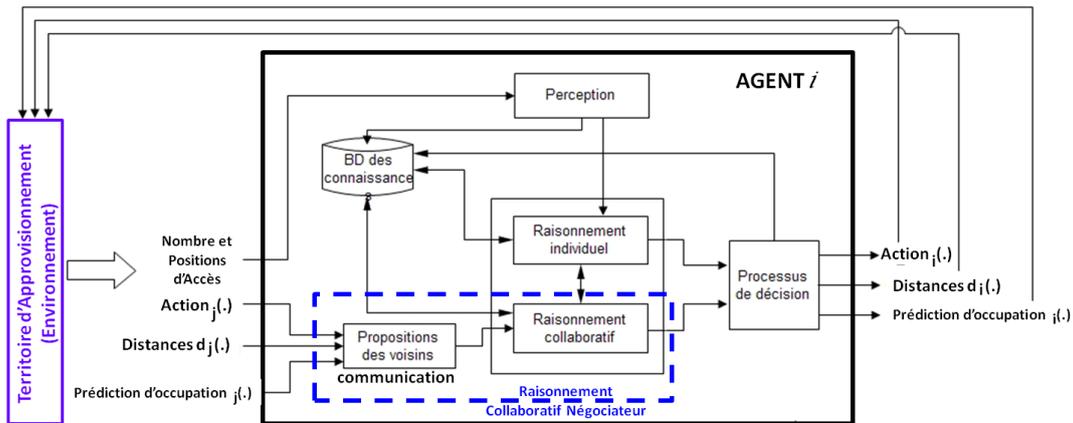


Figure.12 : Architecture d’un agent constituant le système multi-agent conçu pour la simulation de la régulation du flux d’approvisionnement ((Abdallah et Al, 2021), (Abdallah et Al, 2023)).

Ainsi, le problème considéré de la régulation du flux d’approvisionnement est formulé sous l’angle d’un paradigme d’évacuation comme suite : les accès (A et B dans l’exemple considéré) représentent des points (destinations) à approvisionner localisés dans le territoire d’approvisionnement desservi par les transporteurs (agents). On peut noter qu’en introduisant des accès supplémentaires et en variant leurs capacités individuelles d’évacuation, on augmente les destinations d’approvisionnement et la demande (le volume) d’approvisionnement. Le nombre d’agents présents dans l’environnement représente la demande totale (territoriale) car il est proportionnel au volume des marchandises transportées (volume de la demande territoriale). Chaque agent décide de l’orientation à donner à son déplacement avec l’objectif de se rapprocher de l’un des accès d’évacuation. Le nombre d’agents évacués représentera

l'efficacité de la stratégie de la régulation du flux d'approvisionnement. La Figure 12 illustre l'architecture d'un agent pouvant adopter deux comportements : « Comportement-Rationnelle » (CR) basé sur un raisonnement rationnel de diminution de sa distance à l'un des accès d'évacuations disponibles ou « Comportement-Coopératif » (CC) où le comportement rationnel est compléte par une aptitude de coopération locale de l'agent avec son voisinage (constitué de plus proches agents) et une capacité de négociation (avec les agents voisins) en acceptant l'orientation (l'action) proposée par un agent de son voisinage ou en formulant une contre-proposition. Il s'agit effectivement d'une dynamique de négociation entre l'agent et son voisinage (Abdallah, 2023). Par ailleurs, on note que l'agent peut percevoir des informations de l'environnement (en l'occurrence le nombre et la position des accès d'évacuations), peut communiquer avec l'environnement (en l'occurrence avec les autres agents) et agir en vers cet environnement par la modification de sa position dans cet environnement. L'agent peut également évaluer sa distance par rapport à chacun des acces disponibles ainsi qu'occupation de chaque accès à partir des communications reçues des autres agents (notamment, leurs localisations).

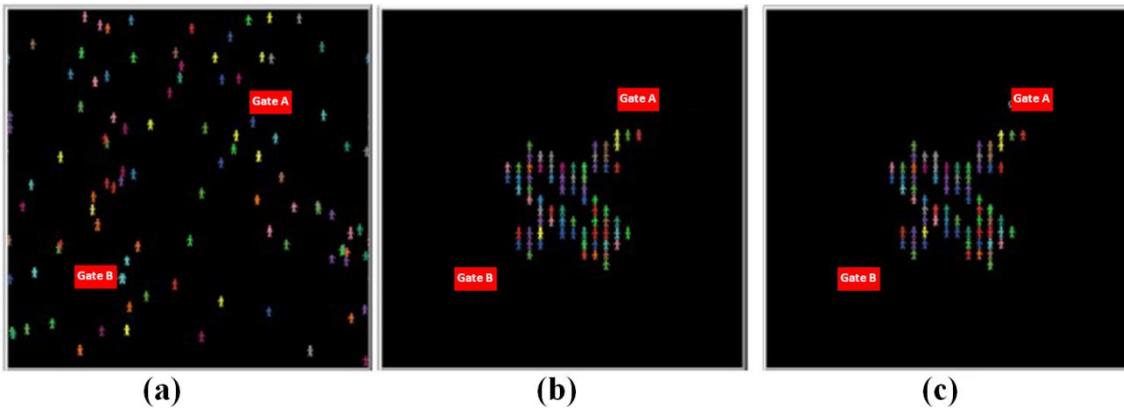


Figure.13 : Résultats de simulation pour 100 agents ou les agents agissent conformément à la stratégie CR ((Abdallah et Al, 2021), (Abdallah, 2023)).

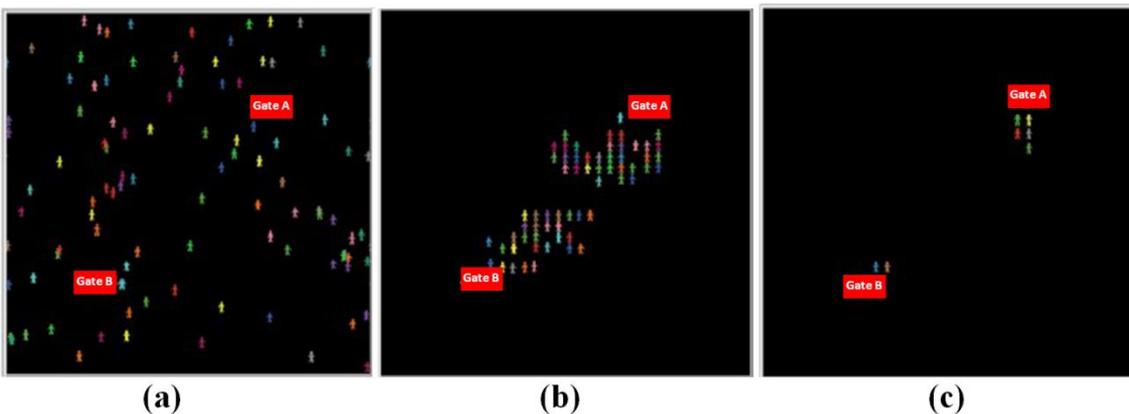


Figure.14 : Résultats de simulation pour 100 agents ou les agents agissent conformément à la stratégie CC ((Abdallah et Al, 2021), (Abdallah, 2023)).

Nous allons donc comparer, à travers de la simulation d'évacuation, le nombre d'agents évacués pour une stratégie CR (chaque agent ne raisonnant que rationnellement avec l'objectif de minimiser sa distance par rapport à l'un des accès disponibles) avec une stratégie CC (chaque agent coopère avec ses voisins en négociant l'action qu'il doit adopter). La Figure.13 illustre

les résultats de simulation pour 100 agents ou les agents agissent conformément à la stratégie CR. Les images (a), (b) et (c) montrent la distribution (localisation) et le nombre d'agents présents (non évacués) au début, à un instant intermédiaire (du processus d'évacuation) et vers la fin du processus (d'évacuation), respectivement. La Figure.14 illustre les résultats de simulation pour ces mêmes agents adoptant la stratégie CC et partant de la même posture initiale. Comme pour la Figure.13, les images (a), (b) et (c) de la présente figure relatent les résultats pour les mêmes instants (étapes) du processus (d'évacuation). Finalement la Figure.15 illustre l'évolution quantitative du nombre d'agents présents en fonction du temps (unité arbitraire).

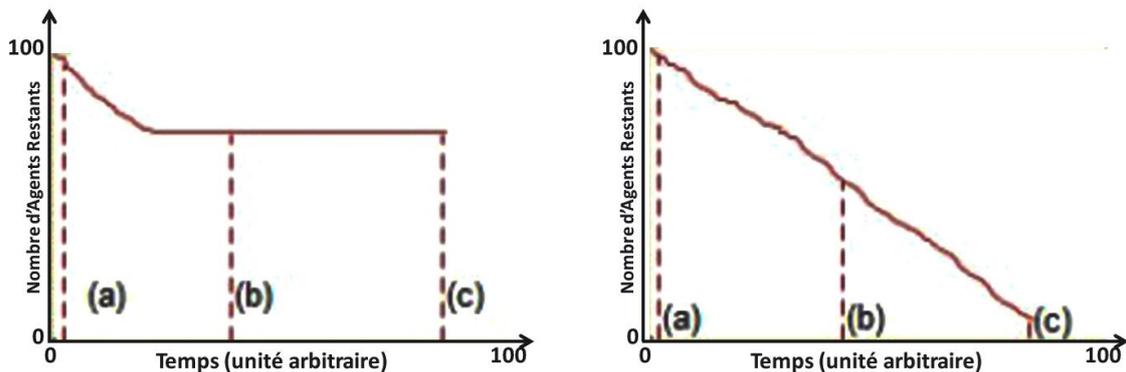


Figure.15 : évolution quantitative du nombre d'agents présents en fonction du temps (unité arbitraire) pour la stratégie CR (diagramme de gauche) et pour la stratégie CC (diagramme de droite). ((Abdallah et Al, 2021), (Abdallah, 2023))

	Stratégie CR			Stratégie CC		
	100	150	200	100	150	200
Nombre d'agents au début de la simulation	100	150	200	100	150	200
Nombre d'agents évacués à l'étape « c »	27	41	45	93	120	169
Nombre d'agents bloqués (à T=100)	73	109	155	0	0	0
Durée de la simulation (T)	100			100		

Comme on peut le constater (Figure.13), même opérant rationnellement en adoptant la stratégie CR, les conditions (les capacités d'évacuations des accès disponibles, la distribution spatiale des agents, etc.) complexes de l'environnement conduisent à une saturation du flux d'évacuation. En effet, bien que distribués plus proche des accès, les agents restants (non évacués) représentent une distribution spatiale monolithique (unique) préservant la complexité pour une évacuation fluide. Contrairement dans la Figure. 14 (stratégie CC), le flux d'évacuation n'est pas saturé et la distribution spatiale, aussi bien à l'étape (b) qu'à l'étape (c) du processus d'évacuation, n'est pas monolithique et le nombre d'agents restants (non évacués) décroît constamment. Le Tableau 1 donne des résultats de simulation pour différentes configurations initiales (au départ de la simulation) : 100, 150 et 200 agents. On peut constater que dans tous les cas de figures, le flux d'évacuation résultant de l'adoption de la stratégie CC celui qui aboutit à l'évacuation de tous les agents signifiant dans la formulation du problème posé que l'approvisionnement a été efficacement effectué : la totalité des marchandises ont été livrées (acheminées) à des destinations A et B du territoire.

Potentiel d'application à la gestion des perturbations dans la chaîne d'approvisionnement

Un MBA peut simuler des scénarios de crise, tels qu'une perturbation due à une pandémie mondiale ou à une pénurie soudaine de matières premières. Par exemple, lors de la pandémie de COVID-19, de nombreuses entreprises ont dû ajuster rapidement leur chaîne d'approvisionnement pour faire face à des interruptions de production, à des variations extrêmes de la demande, et à des restrictions de transport. Un MBA permet de tester différents scénarios en simulant comment chaque agent réagirait à ces perturbations, et en identifiant les points critiques de la chaîne qui nécessitent des ajustements.

En simulant ces interactions et en observant l'effet global sur la chaîne d'approvisionnement, les décideurs peuvent identifier les goulots d'étranglement potentiels et ajuster leurs politiques en conséquence (Farmer & Foley, 2009). Par exemple, une entreprise peut décider d'augmenter les stocks de sécurité, de diversifier ses fournisseurs, ou d'investir dans des technologies de production plus flexibles en fonction des résultats de la simulation. D'un autre côté, un MBA peut simuler la dynamique de propagation de la pandémie en tenant compte des comportements individuels ou collectifs concernant la réceptivité ou diligence à la vaccination permettant de tester différents scénarios de rupture d'activités économiques et l'impact d'infection des salariés sur ces activités ((Abdallah et Al, 2022), (Abdallah, 2023)).

Potentiel d'application à l'optimisation des chaînes d'approvisionnement sous contraintes environnementales

Les MBA peuvent également être utilisés pour optimiser les chaînes d'approvisionnement en tenant compte des contraintes environnementales. Par exemple, un agent représentant une entreprise peut être programmé pour minimiser son empreinte carbone en choisissant des options de transport plus écologiques, même si cela implique des coûts plus élevés. En simulant ces choix à travers toute la chaîne d'approvisionnement, les MBA permettent de trouver un équilibre entre la rentabilité économique et les objectifs environnementaux. Cela est particulièrement pertinent dans un contexte où les entreprises cherchent à améliorer leur durabilité tout en restant compétitives.

2.2 Gestion des ressources humaines et analyse organisationnelle

La gestion des ressources humaines (GRH) est un autre domaine où les agents intelligents peuvent apporter une contribution significative. Les organisations sont des systèmes complexes où les interactions entre les employés, les managers et les dirigeants influencent la performance globale. Dans ce contexte, les MBA permettent de modéliser les dynamiques organisationnelles en tenant compte des comportements individuels et des interactions sociales.

Les MBA peuvent simuler l'impact de certaines décisions managériales, telles que l'introduction de nouvelles politiques de rémunération ou la restructuration d'équipes. Ces modèles permettent de tester divers scénarios en observant comment chaque agent réagit à ces changements et comment cela affecte les dynamiques globales de l'organisation.

Potentiel d'application à la simulation des effets des politiques de rémunération

Supposons qu'une entreprise décide de mettre en place une nouvelle politique de rémunération basée sur la performance individuelle. Un MBA peut modéliser cette décision en représentant

chaque employé comme un agent ayant ses propres motivations, son niveau d'engagement, et son niveau de satisfaction. Certains employés peuvent être incités à augmenter leur productivité, tandis que d'autres peuvent être démotivés si les objectifs de performance ne correspondent pas à leurs attentes.

En simulant ces interactions, le modèle peut révéler des effets inattendus, tels que la fragmentation des équipes ou l'augmentation des tensions entre collègues. Les résultats de la simulation peuvent aider les décideurs à ajuster la politique avant son implémentation à grande échelle, en s'assurant que les effets positifs, comme l'augmentation de la productivité, sont maximisés, tandis que les effets négatifs, tels que la démotivation ou le stress, sont minimisés.

Potentiel d'application à l'analyse des réseaux informels de communication

Les MBA peuvent également être utilisés pour analyser les réseaux informels de communication au sein d'une organisation. Ces réseaux, qui ne sont pas toujours visibles dans les organigrammes officiels, jouent souvent un rôle crucial dans la circulation de l'information et la prise de décision. En modélisant les employés comme des agents interconnectés, un MBA peut identifier les individus clés dans ces réseaux, ceux qui agissent comme des relais d'information ou des sources de blocage. Cela permet aux gestionnaires d'améliorer la communication interne, de réduire les goulets d'étranglement, et d'accroître l'efficacité organisationnelle.

2.3 Analyse des politiques publiques et sociétales

Les modèles basés sur des agents trouvent également des applications précieuses dans l'analyse des politiques publiques. Les gouvernements et les institutions publiques doivent souvent prendre des décisions qui affectent des millions de citoyens et qui ont des répercussions sociétales importantes. Les MBA permettent de simuler l'impact de ces politiques en modélisant chaque citoyen comme un agent intelligent ayant ses propres comportements, opinions, et réactions aux décisions politiques.

Cette approche est particulièrement utile dans les situations où les effets des politiques publiques sont difficiles à prévoir, comme lors de la mise en œuvre de réformes de grande envergure ou de campagnes de santé publique. Les simulations permettent de tester l'efficacité de différentes stratégies avant leur déploiement à grande échelle.

Potentiel d'application à la simulation des politiques de vaccination

L'une des applications les plus significatives des MBA dans ce domaine a été la modélisation des campagnes de vaccination, en particulier lors de la pandémie de COVID-19. Les gouvernements ont dû faire face à des défis majeurs pour organiser et déployer des campagnes de vaccination efficaces, tout en tenant compte des comportements hétérogènes des citoyens, tels que la réticence à se faire vacciner ou l'adhésion aux mesures sanitaires.

En modélisant chaque citoyen comme un agent ayant ses propres opinions et comportements face à la vaccination, un MBA peut simuler l'impact de différentes stratégies de communication et de distribution. Par exemple, le modèle peut tester l'efficacité d'une campagne de vaccination ciblée, où les vaccins sont distribués en priorité aux groupes à risque, par rapport à une campagne plus large visant l'ensemble de la population. Ces simulations permettent aux décideurs de comprendre les dynamiques sociales autour de la vaccination et d'ajuster leurs stratégies pour maximiser le taux de vaccination et réduire la propagation du virus.

Potentiel d'application à la modélisation des politiques environnementales

Les MBA peuvent également être utilisés pour analyser l'impact des politiques environnementales, telles que la mise en place de taxes carbone ou de subventions pour les énergies renouvelables. Chaque citoyen ou entreprise peut être modélisé comme un agent ayant des priorités différentes, telles que la réduction des coûts ou la maximisation des profits, et des niveaux d'engagement variables en matière de durabilité environnementale. Ces simulations permettent d'anticiper l'impact des politiques publiques sur les comportements individuels et collectifs, et d'ajuster les politiques en conséquence pour atteindre les objectifs environnementaux sans provoquer de perturbations économiques majeures.

Les modèles basés sur des agents offrent un cadre puissant pour la simulation et l'analyse des systèmes économiques et organisationnels complexes. Dans des domaines aussi variés que la gestion des chaînes d'approvisionnement, la gestion des ressources humaines ou l'analyse des politiques publiques, les MBA permettent de tester des scénarios réalistes et d'anticiper les effets de décisions stratégiques dans des environnements dynamiques et incertains. Ces modèles contribuent ainsi à une meilleure prise de décision en offrant aux organisations et aux gouvernements des outils flexibles et adaptables pour simuler et optimiser leurs processus, tout en prenant en compte les interactions complexes entre les agents.

3. Vers une meilleure compréhension des mécanismes économiques et sociétaux

L'une des caractéristiques majeures des systèmes économiques et sociétaux est leur grande complexité. Cette complexité découle de l'interaction de multiples facteurs, souvent interdépendants et dynamiques, tels que les comportements individuels, les politiques publiques, les conditions de marché et les normes sociales. Les modèles basés sur des agents se distinguent des modèles traditionnels par leur capacité à capturer cette complexité en modélisant les interactions entre les agents individuels et les environnements dans lesquels ils évoluent. Contrairement aux approches macroéconomiques qui se concentrent sur des moyennes ou des agrégats, les MBA permettent d'analyser des phénomènes émergents résultant des comportements hétérogènes des agents (Epstein et Axtell, 1996).

Ce type de modélisation offre une approche holistique, intégrant à la fois des données quantitatives et qualitatives. Les agents peuvent être dotés de comportements spécifiques, tels que la maximisation de leur utilité, la coopération ou la compétition, ou encore la prise de décisions sous incertitude. Les interactions entre ces agents produisent des dynamiques sociales et économiques souvent non anticipées par les modèles analytiques classiques, rendant ainsi les MBA particulièrement efficaces pour comprendre des phénomènes complexes comme les inégalités économiques, les crises financières, ou encore les changements sociétaux.

3.1 Modélisation de l'inégalité économique

Les inégalités économiques constituent l'un des défis majeurs des sociétés modernes. Les écarts croissants de revenus et de richesses entre différentes couches de la population alimentent les débats politiques et sociaux sur la manière d'y remédier. Les MBA offrent une approche puissante pour étudier ces inégalités en représentant différents groupes sociaux comme des agents distincts, avec des comportements économiques spécifiques, des niveaux de revenus, et des accès différenciés à l'éducation, aux soins de santé ou à l'emploi.

Les MBA permettent d'analyser comment des décisions économiques prises à différents niveaux affectent la répartition des richesses à long terme. Par exemple, en modélisant les effets d'une réforme fiscale, il est possible d'étudier comment une taxation progressive impacte les différents groupes sociaux. Un agent représentant un individu à revenu élevé pourrait, par exemple, chercher à maximiser ses revenus nets en modifiant son comportement d'investissement, tandis qu'un agent représentant un individu à faible revenu pourrait voir ses choix de consommation modifiés par l'augmentation de ses allocations sociales.

Potentiel d'application à l'impact des politiques redistributives sur les inégalités

Les MBA permettent de simuler l'effet des politiques redistributives, telles que la taxation progressive ou les aides sociales, sur la répartition des richesses dans une société donnée. Ces simulations peuvent révéler si ces politiques parviennent réellement à réduire les inégalités ou si elles produisent des effets secondaires indésirables. Par exemple, il est possible de modéliser les effets d'une augmentation des impôts sur les revenus les plus élevés, tout en observant comment cela affecte les décisions d'investissement des ménages aisés. Parallèlement, le modèle peut également analyser les effets d'une augmentation des aides sociales sur les ménages à faible revenu et observer si ces aides améliorent leur qualité de vie ou si elles créent une dépendance économique. En intégrant des comportements hétérogènes et en simulant les interactions entre les différents agents économiques, ces modèles permettent d'identifier les conditions sous lesquelles les politiques économiques peuvent réduire les inégalités de manière durable. Ils peuvent également tester des scénarios alternatifs, tels que l'impact de l'éducation universelle ou de la hausse du salaire minimum, pour voir dans quelle mesure ces politiques influencent les écarts de revenus à long terme.

Autres potentiels d'application : Étude des dynamiques intergénérationnelles

Les modèles basés sur des agents peuvent aussi modéliser les dynamiques intergénérationnelles des inégalités économiques. Par exemple, en simulant l'effet des inégalités d'accès à l'éducation entre les générations, un modèle peut montrer comment les inégalités de revenus se perpétuent ou s'amplifient au fil du temps. En testant différentes politiques publiques, telles que les bourses d'études ou les subventions aux écoles publiques, il est possible d'analyser si ces mesures permettent réellement de briser le cycle de la pauvreté intergénérationnelle.

3.2 Prévision des crises économiques

L'une des applications les plus prometteuses des MBA réside dans la prévision des crises économiques. Les crises économiques, qu'elles soient d'origine financière, commerciale, ou même environnementale, sont des événements imprévisibles résultant de l'interaction de nombreux facteurs interdépendants. Les modèles économiques traditionnels, souvent basés sur des hypothèses d'équilibre et de rationalité parfaite, ont montré leurs limites pour prévoir ces événements de manière fiable. Les MBA, en revanche, permettent de modéliser les interactions entre banques, entreprises, consommateurs, et régulateurs, en intégrant des comportements irrationnels ou imprévisibles, ce qui les rend particulièrement utiles pour identifier des signaux précurseurs de crises.

Potentiel d'application à la modélisation des bulles spéculatives et des crises financières

Les crises financières, telles que la crise des subprimes de 2008, sont souvent le résultat d'une accumulation progressive de risques dans le système financier, tels que l'augmentation de la dette privée ou l'expansion incontrôlée du crédit (Gilbert & Troitzsch, 2005). Les MBA permettent de modéliser l'effet cumulatif des comportements individuels des acteurs financiers, en tenant compte des asymétries d'information, des effets de levier et des comportements de mimétisme. Par exemple, les banques peuvent être modélisées comme des agents qui décident de prêter en fonction des taux d'intérêt, des régulations bancaires, et des informations disponibles sur les emprunteurs.

Un MBA peut simuler l'apparition d'une bulle spéculative en observant comment l'augmentation de la dette des ménages, combinée à une baisse des régulations bancaires, peut conduire à une surchauffe du marché immobilier. Le modèle permet ensuite de tester différents scénarios de crise, tels qu'une augmentation soudaine des taux d'intérêt, et d'observer comment les banques, les investisseurs, et les ménages réagissent à ces chocs. Ces simulations permettent d'identifier les points de rupture du système financier, et de suggérer des politiques préventives pour éviter l'éclatement de la bulle.

Autres exemples : Préviation des crises de dettes souveraines

Les MBA peuvent également être utilisés pour modéliser les interactions entre les gouvernements et les marchés financiers dans le cadre des crises de dettes souveraines. En simulant le comportement des investisseurs internationaux, des banques centrales et des régulateurs, il est possible de prévoir les conditions dans lesquelles une crise de la dette pourrait survenir, comme ce fut le cas lors de la crise de la zone euro en 2010. Par exemple, un MBA peut modéliser l'effet d'une augmentation des déficits publics sur les taux d'intérêt des obligations souveraines et analyser comment cela affecte la capacité des gouvernements à rembourser leurs dettes.

Les MBA permettent également de tester l'efficacité des politiques de sortie de crise, telles que les plans d'austérité ou les programmes de rachat de dettes par les banques centrales. Ces simulations offrent aux décideurs des outils précieux pour anticiper les répercussions de ces politiques et ajuster leurs stratégies en fonction des dynamiques émergentes.

Conclusion

Les modèles basés sur des agents, et plus spécifiquement les agents artificiels intelligents, représentent un outil puissant pour la modélisation des mécanismes économiques et sociétaux. Grâce à leur flexibilité, leur capacité à intégrer des informations hétérogènes, et leur adaptabilité à des environnements dynamiques, les MBA permettent de reproduire la complexité des systèmes économiques contemporains. Contrairement aux approches traditionnelles, qui reposent souvent sur des hypothèses simplificatrices, les MBA permettent d'analyser des phénomènes émergents, tels que les crises économiques ou les inégalités intergénérationnelles, en modélisant les interactions entre agents individuels.

L'intelligence artificielle bio-inspirée et les techniques de soft computing enrichissent encore ces modèles en permettant de gérer des informations incertaines ou incomplètes, des caractéristiques omniprésentes dans les systèmes économiques et sociaux. Les simulations

basées sur des MBA offrent ainsi des outils puissants pour anticiper des crises, tester l'efficacité de politiques publiques, et mieux comprendre les dynamiques sociales complexes.

En conclusion, l'utilisation des MBA dans les champs de la gestion, de l'économie, et des politiques publiques permet d'améliorer significativement notre compréhension des systèmes économiques et sociaux modernes. L'intelligence artificielle, en intégrant des approches bio-inspirées et des techniques avancées de calcul, constitue un levier majeur pour relever les défis contemporains liés à la gestion des crises, à la réduction des inégalités, et à l'optimisation des processus décisionnels dans des environnements dynamiques et incertains.

Bibliographie

Abdallah et Al. (2021). Abdallah, W., Kanzari, D., Madani, K.. "Towards a Deep Reinforcement Approach for Crowd Flow Management", in Proceedings of the International Work-conference on Artificial Neural Networks (IWANN 2021), June 16 – 18, 2021, LNCS series, Vol. 12861, Springer, ISBN 978-3-030-85029-6, 2021, pp. 420 – 431. DOI: 10.1007/978-3-030-85030-2_35, 2021.

Abdallah et Al. (2022). Abdallah, W., Kanzari, D., Sallami, D., Madani, Ghedira, K.. "A Deep Reinforcement Learning Based Decision-Making Approach for Avoiding Crowd Situation within the case of Covid'19 Pandemic", Computational Intelligence, Vol. 38, N° 2, pp. 416 – 437. DOI: 10.1111/coin.12516, 2022.

Abdallah et Al. (2023). Abdallah, W., Kanzari, D., Madani, K.. "Agent Architecture for Evacuation Pedestrian's Crowded Public Places: Combination of Individual and Collaborative Reasoning", in Proceedings of the IEEE International Conference on Advances in Data-Driven Analytics and Intelligent Systems (IEEE/ADACIS 2023), November 23 – 25, 2023, Marrakesh, Morocco, 2023.

Abdallah, W. (2023). *Agents décisionnels adaptatifs aux contextes pour l'évacuation des foules*. Thèse de doctorat, Université de La Manouba, Codirection K. Madani (UPEC) K. Ghedira (Université de La Manouba), soutenue le 10 mai 2023.

Axelrod, R. (1997). *The Complexity of Cooperation: Agent-Based Models of Competition and Collaboration*. Princeton University Press.

Axelrod explore comment des comportements coopératifs émergent dans des environnements compétitifs, à travers des simulations basées sur des agents. Cet ouvrage est essentiel pour comprendre les dynamiques organisationnelles et les interactions sociales à grande échelle.

Chohra, A., Madani, K. (2018). "Biological Regulation and Psychological Mechanisms Models of Adaptive Decision-Making Behaviors: Drives, Emotions, and Personality", Transactions on Computational Collective Intelligence XXIX, Lecture Notes in Computer Science, Springer, N. Nguyen, R. Kowalczyk (Eds), Vol. 10840, pp 69–83, 2018.

Chohra, et Al. (2018). Chohra, A., Madani, K., Van der Wal, C. N., "Group Affect in Complex Decision-Making: Theory and Formalisms from Psychology and Computer Science", in Proceedings of the 10th International Conference on Computational Collective Intelligence (ICCCI 2018), 5 – 7 September, 2018, Bristol, UK, pp. 222 – 233.

Epstein, J. M., & Axtell, R. L. (1996). *Growing Artificial Societies: Social Science from the Bottom Up*. The Brookings Institution Press.

Epstein et Axtell introduisent les fondements de la modélisation sociale basée sur des agents. Leur travail est pionnier dans l'étude des sociétés artificielles et des dynamiques sociales émergentes, une approche cruciale pour la modélisation des mécanismes économiques et sociétaux.

Farmer, J. D., & Foley, D. (2009). "The economy needs agent-based modelling." *Nature*, 460, 685-686.

Cet article dans *Nature* soutient l'idée que les modèles basés sur des agents sont essentiels pour comprendre les dynamiques économiques non linéaires et les crises financières. Les auteurs appellent à une adoption plus large de ces techniques dans l'analyse des politiques économiques.

Gilbert, N., & Troitzsch, K. G. (2005). *Simulation for the Social Scientist*. Open University Press.

Cet ouvrage guide les chercheurs dans l'utilisation des simulations pour l'analyse des systèmes sociaux. Il couvre plusieurs méthodologies, y compris les MBA, pour modéliser les comportements complexes des agents dans des environnements économiques et sociaux.

Hopfield, J. J. (1982). "Neural networks and physical systems with emergent collective computational abilities", *Proceedings of the National Academy of Sciences*, no 79, 1982, p. 2554-2558.

Kaufmann, A. (1977). *Introduction à la théorie des sous-ensembles flous à l'usage des ingénieurs*, Vol. 1 Éléments théoriques de base, Masson, Paris 1977 (ISBN 2 225 45804 9).

Kouvelis, P., Chambers, C., & Wang, H. (2006). "Supply chain management research and production and operations management: Review, trends, and opportunities." *Production and Operations Management*, 15(3), 449-469.

Cet article examine les tendances récentes dans la recherche en gestion des chaînes d'approvisionnement et les opportunités d'optimisation. Il souligne l'importance des MBA pour la gestion en temps réel des stocks et l'anticipation des fluctuations de la demande.

LeBaron, B. (2006). "Agent-based computational finance." Dans Tesfatsion, L., & Judd, K. L. *Handbook of Computational Economics: Agent-Based Computational Economics* (Vol. 2). Elsevier.

Ce chapitre traite des modèles financiers basés sur des agents, soulignant l'importance des outils computationnels pour comprendre la dynamique des marchés financiers hétérogènes. Il couvre également les comportements irrationnels des investisseurs et l'analyse des crises financières

McCulloch, W. S. & Walter, P. (1943). "A logical calculus of the ideas immanent in nervous activity". *Bulletin of Mathematical Biophysics*, no 5, 1943, p. 115-133.

Michalewicz, Z. (1992). *Genetic Algorithms + Data Structures = Evolution Programs*. Springer.

Cet ouvrage combine les algorithmes génétiques avec des structures de données pour proposer des solutions aux problèmes d'optimisation. Les algorithmes évolutionnaires sont

particulièrement efficaces dans des environnements incertains, tels que ceux observés dans les marchés financiers et les chaînes d'approvisionnement.

Miller, J. H., & Page, S. E. (2007). *Complex Adaptive Systems: An Introduction to Computational Models of Social Life*. Princeton University Press.

Miller et Page présentent les systèmes adaptatifs complexes et expliquent comment les MBA peuvent être utilisés pour comprendre les comportements émergents dans les systèmes économiques et sociaux. Le livre explore également l'impact des politiques publiques sur ces dynamiques.

Rosenblatt, F. (1958). "The Perceptron : probabilistic model for information storage and organization in the brain". *Psychological Review*, no 65, 1958, p. 386-408.

Rumelhart, D. E. & Mc Clelland, J. L. (1986). *Parallel Distributed Processing: Exploration in the MicroStructure of Cognition*, Cambridge, MIT Press, 1986.

Tesfatsion, L., & Judd, K. L. (2006). *Handbook of Computational Economics: Agent-Based Computational Economics*. Elsevier/North-Holland, Vol. 2, 904 pages.

Cet ouvrage approfondit l'analyse de l'économie computationnelle basée sur des agents, en couvrant des sujets tels que l'évolution des comportements financiers, la dynamique des innovations technologiques et la conception de marchés. Les chapitres discutent également des complexités des systèmes économiques, souvent non linéaires et loin de l'équilibre

Zadeh, L. A. (1965). "Fuzzy sets", *Information and Control*. Vol. 8, 338-353.

Zadeh, L. A. (1994). "Fuzzy logic, neural networks, and soft computing." *Communications of the ACM*, 37(3), 77-84.

Un article fondamental qui introduit le concept de soft computing, en particulier les systèmes flous (fuzzy systems) et les réseaux neuronaux. Zadeh montre comment ces outils permettent de traiter des informations imprécises et incertaines, ce qui est essentiel pour la modélisation de systèmes économiques complexes.