

REPUBLICQUE DU BENIN



MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA
RECHERCHE SCIENTIFIQUE



UNIVERSITE NATIONALE DES SCIENCES,
TECHNOLOGIES, INGENIERIES ET MATHEMATIQUES
(UNSTIM)

INSTITUT NATIONAL SUPERIEUR DE TECHNOLOGIE
INDUSTRIELLE (INSTI-Lokossa)

Département de Génie Électrique et Informatique

Filière : Informatique et
Télécommunications

Discipline : Intelligence
artificielle

THEME : L'APPRENTISSAGE SUPERVISE, NON SUPERVISE, PAR
RENFORCEMENT

Groupe n° 6

Membre du groupe :

1. ASSOGBA Doriane
2. DOSSOU Aurel
3. HOUNDOKINNOU
Diègue
4. LOGBO Maurel
5. SOHOU Fernand

Sous la supervision de : M.
Pharès TCHIBOZO

Glossaire

❖ **Machine Learning (Apprentissage automatique)**

Branche de l'intelligence artificielle qui permet à un ordinateur d'apprendre à partir de données, sans être explicitement programmé. Le système découvre des modèles et améliore ses performances avec l'expérience.

❖ **Dataset (Jeu de données)**

Ensemble d'informations structurées utilisées pour entraîner un modèle de machine learning. Chaque ligne représente un exemple ou une observation, et chaque colonne correspond à une variable mesurée.

❖ **Features (Caractéristiques ou variables)**

Ce sont les éléments descriptifs d'un jeu de données. Elles représentent les informations que le modèle utilise pour apprendre.

Exemple : la température, l'humidité et la quantité de pluie peuvent être les *features* pour prédire la croissance du riz.

❖ **Target (Variable cible)**

C'est la valeur que le modèle doit prédire. Dans un apprentissage supervisé, elle est connue à l'avance pour chaque observation.

Exemple : le rendement du riz ou le prix d'une maison.

❖ **Loss Function (Fonction de perte)**

Mesure l'erreur entre la prédiction du modèle et la valeur réelle. Elle guide l'apprentissage en indiquant à quel point le modèle se trompe, afin qu'il s'améliore au fil des itérations.

Table des matières

Glossaire.....	i
Introduction	3
I. L'apprentissage supervisé	4
I-1 Principe fondamental	4
I-2 Les différentes étapes de l'apprentissage supervisé	4
I-3 Forces et Défis de l'Apprentissage Supervisé.....	5
A. Les Forces (Avantages)	5
B. Les Défis (Limites)	6
I-4 Exemple pratique.....	6
II. L'apprentissage non supervisé.....	7
II-1 Principe fondamental	7
II-2 Les étapes techniques de l'Apprentissage Non Supervisé	7
II-3 Forces et Défis de l'Apprentissage non Supervisé.....	8
A. Les Forces (Avantages)	8
III. L'apprentissage par renforcement	10
III-2 Notre Implémentation dans SmartSupport	10
Conclusion.....	12

Introduction

L'intelligence artificielle occupe aujourd'hui une place essentielle dans le monde moderne, et au cœur de ses avancées se trouve l'apprentissage automatique, ou *machine learning*. Cette discipline permet aux machines d'apprendre à partir de données et d'améliorer leurs performances sans être explicitement programmées. Parmi les approches les plus utilisées, on distingue trois grandes formes d'apprentissage : **l'apprentissage supervisé**, **l'apprentissage non supervisé** et **l'apprentissage par renforcement**. Chacune de ces méthodes repose sur une logique différente : apprendre à partir d'exemples déjà étiquetés, découvrir seule les structures cachées des données, ou encore apprendre par essais et erreurs à travers des interactions avec un environnement. Comprendre ces trois approches permet de saisir comment les systèmes intelligents parviennent à reconnaître des visages, recommander des produits ou battre des humains à des jeux complexes.

I. L'apprentissage supervisé

I-1 Principe fondamental

L'Apprentissage Supervisé est une méthode d'apprentissage automatique (Machine Learning) où **l'algorithme apprend à partir d'un jeu de données étiquetées**. On fournit à l'IA les entrées (X) et les sorties désirées (Y). L'IA, comme un élève, déduit la règle ou la fonction (f) qui permet de passer de X à Y. C'est un apprentissage "avec professeur". Le professeur montre l'image d'un chat et dit "Ceci est un chat". L'IA apprend par l'exemple. Une fois la règle apprise, l'IA doit être capable de faire des prédictions correctes sur de nouvelles données non étiquetées.

L'apprentissage supervisé est utilisé pour résoudre deux grandes catégories de problèmes :

- ❖ **La classification** : Prédire une catégorie ou une classe discrète. • Exemples : SPAM ou NON-SPAM, Chat ou Chien, Maladie A, B ou C.
- ❖ **La régression** : Prédire une valeur continue (un nombre). • Exemples : Le prix d'une maison, la température de demain, les ventes futures.

I-2 Les différentes étapes de l'apprentissage supervisé

1. Constitution du Dataset (préparation et étiquetage des données)

C'est la phase de création de notre corpus d'apprentissage (le Dataset). Elle consiste à :

- ✓ Collecter des **Features** et **Targets** : Rassembler les variables d'entrée (les features X) et les variables de sortie ou étiquettes (les targets Y).
- ✓ Nettoyage et Feature Engineering : Traitement des données manquantes, normalisation des valeurs, et potentiellement création de nouvelles features à partir des données existantes.

2. Séparation des Jeux de Données (Splitting)

Cette étape est cruciale pour évaluer la capacité de généralisation du modèle et éviter l'overfitting (surapprentissage). Il faut séparer le Dataset en deux grandes parties :

- ✓ **Training Set (Jeu d'Entraînement Ex :80%)** : La majorité des données, utilisées pour ajuster les paramètres du modèle.

- ✓ **Test Set (Jeu de Test Ex :20%)** : Une portion mise de côté, utilisée pour évaluer la performance finale sur des données inconnues.

3. Entraînement du Modèle (Fitting)

✓ **Optimisation et « Loss Function »** : L'algorithme utilise une fonction de coût (Loss Function) pour quantifier l'erreur de prédiction, puis un optimiseur (ex. : Descente de Gradient) pour ajuster ses poids et biais (weights and biases) et minimiser cette Loss.

✓ **Itérations (Époques)** : Le processus de calcul de la Loss et d'ajustement des paramètres est répété sur l'ensemble du Training Set pour affiner la fonction f.

4. Évaluation du Modèle (Validation et Métriques)

On mesure l'efficacité du modèle sur le Test Set pour juger de sa fiabilité.

- ✓ **Prédiction (Inference)** : Le modèle génère des sorties sur le Test Set.
- ✓ **Calcul des Métriques** : On utilise des indicateurs spécifiques : • Classification : Accuracy (Précision), Recall (Rappel), F1-Score. • Régression : Mean Squared Error (MSE) (Erreur Quadratique Moyenne), R-Squared (R2).
- ✓ **Déploiement** : Si les performances sont jugées robustes, le modèle est mis en production

I-3 Forces et Défis de l'Apprentissage Supervisé

Pour avoir une vue complète, il est essentiel de comprendre quand l'apprentissage supervisé est la meilleure solution et où ses limites se manifestent.

A. Les Forces (Avantages)

1. Haute Précision : Lorsque le Dataset est grand et bien étiqueté, les modèles supervisés (comme ceux utilisés pour la classification d'images ou la détection de fraude) sont les plus précis et les plus fiables.

2. Prédictions Claires : Ils sont parfaits pour les tâches où la sortie désirée est bien définie (une catégorie ou une valeur exacte).

3. Facilité d'Évaluation : La performance est facile à mesurer, car on peut directement comparer la prédiction du modèle à la vérité terrain (l'étiquette Y connue).

B. Les Défis (Limites)

- ✓ Dépendance à l'Étiquetage : C'est la limite principale. Obtenir des données étiquetées est souvent coûteux, prend du temps et peut nécessiter une intervention humaine experte (ex. : un médecin pour étiqueter des images médicales).
- ✓ Risque d'Overfitting (Surapprentissage) : Si le modèle est trop complexe ou si les données d'entraînement ne sont pas assez variées, il peut mémoriser le Training Set au lieu d'apprendre la règle générale. Dans ce cas, il performera mal sur le Test Set (les données inédites).
- ✓ Qualité des Données : La performance du modèle est directement limitée par la qualité des étiquettes. Une erreur dans l'étiquetage des données conduit à un modèle qui apprend des erreurs (Garbage In, Garbage Out)

I-4 Exemple pratique

Pour illustrer concrètement la méthodologie de l'apprentissage supervisé, nous allons simuler un cas de Classification : la détection de fraude bancaire. Le tableau suivant résume l'intégralité du cycle technique du Machine Learning supervisé, en associant chaque étape technique à son rôle précis et aux actions que nous allons réaliser dans notre simulation avec le jeu de données creditcard.csv.

N °	Nom Technique de l'Étape	Rôle/Termes Clés	Application dans la Simulation (Détection de Fraude Bancaire)
1	Constitution du Dataset (Feature Engineering)	Collecte des Features (\$X\$) et de la Target (\$Y\$) étiquetée. Nettoyage et Normalisation des données.	Charger le Dataset creditcard.csv. Définir la Target (\$Y\$) (colonne Class : 0 = Non-Fraude, 1 = Fraude).
2	Séparation des Jeux de Données (Splitting)	Diviser en Training Set et Test Set . Utiliser stratify pour gérer le déséquilibre des classes et garantir une bonne répartition des fraudes dans chaque ensemble.	Répartir les transactions en Entraînement et Test. Préparer le <i>Training Set</i> avec la technique SMOTE pour équilibrer les classes rares (les fraudes).
3	Entraînement du Modèle (Fitting)	L'algorithme ajuste ses Poids (Weights) et minimise la Loss Function . Utilisation d'un modèle de Classification (Régression Logistique).	Le modèle apprend la règle pour séparer une transaction frauduleuse d'une transaction normale, en utilisant le jeu d'entraînement équilibré .
4	Évaluation du Modèle (Validation et Métriques)	Mesurer la performance sur le <i>Test Set</i> via des Métriques spécifiques.	Calculer le Rappel (Recall) et le Faux Négatif pour s'assurer que le modèle détecte la majorité des fraudes réelles. Utiliser la Matrice de Confusion .

II. L'apprentissage non supervisé

II-1 Principe fondamental

L'Apprentissage Non Supervisé (Unsupervised Learning) est une méthode où l'algorithme apprend à partir d'un jeu de données NON étiquetées. On fournit à l'IA uniquement les entrées (X). L'IA travaille seule, sans "professeur" (Y), pour découvrir des structures, des patterns ou des relations cachées dans les données. C'est comme donner à l'IA un grand carton de jouets mélangés et lui demander de les trier en piles logiques, même si elle n'a jamais vu les jouets auparavant. L'objectif est de rendre les données complexes plus compréhensibles et exploitables pour la prise de décision.

L'apprentissage non supervisé est principalement utilisé pour deux tâches :

1. **Clustering (Regroupement)** : Identifier des groupes ou des segments naturels dans les données, où les membres de chaque groupe sont similaires entre eux. • Exemples : Segmentation de la clientèle (regrouper les clients par comportements d'achat), regroupement de documents par thème. • Algorithme phare : K-Means.
2. **Réduction de Dimensionalité (Feature Extraction)** : Réduire le nombre de variables (features) nécessaires pour décrire un ensemble de données sans perdre trop d'informations. • Exemples : Compresser des images, simplifier des jeux de données complexes. • Algorithme phare : Analyse en Composantes Principales (ACP) ou PCA.

II-2 Les étapes techniques de l'Apprentissage Non Supervisé

Bien que le processus soit différent (pas de comparaison Y), il est tout aussi structuré. Nous prenons ici l'exemple du Clustering K-Means :

N°	Étape Technique	Objectif Principal	Pourquoi c'est différent du Supervisé
1	Constitution du Dataset & Normalisation	Nettoyer les données d'entrée (X) et mettre les variables à la même échelle (sinon, la variable avec les plus grandes valeurs dominera l'algorithme).	Aucun étiquetage (Y) n'est nécessaire. L'accent est mis sur la Normalisation (ex. : StandardScaler) pour que les distances soient justes.
2	Détermination de K (Hyperparamètre)	Estimer le nombre optimal de groupes (<i>clusters</i>) à former. On utilise des méthodes statistiques comme la Méthode du Coude (<i>Elbow Method</i>).	C'est l'étape où l'on détermine le paramètre le plus crucial avant l'entraînement, car il n'y a pas de cible Y pour le guider.
3	Entraînement du Modèle (Fitting)	L'algorithme place des Centroïdes aléatoires et itère pour minimiser la distance des points à leur centre.	Le modèle apprend la structure interne des données par lui-même, sans feedback d'erreur externe.
4	Interprétation & Validation Interne	Analyser les caractéristiques de chaque groupe formé et valider si les groupes sont distincts et significatifs (ex. : visualisation).	La validation est interne (mesure de la cohésion des groupes) et non externe (pas de comparaison à une vérité terrain Y).

II-3 Forces et Défis de l'Apprentissage non Supervisé

Les avantages et inconvénients sont le miroir de ceux du supervisé.

A. Les Forces (Avantages)

- ✓ Exploration de Données : L'outil idéal pour les données non étiquetées (qui sont majoritaires dans le monde réel). Il permet de découvrir des relations ou des patterns inconnus.
- Gain de Coût et de Temps : Il élimine le coût et le temps considérables associés à l'étape d'étiquetage manuel.
- ✓ Réduction de dimensionalité : Il permet de simplifier les données (avec la PCA), rendant l'entraînement de futurs modèles (supervisés ou autres) plus rapide et plus efficace.

B. Les Défis (Limites)

1. Difficulté d'Évaluation : La principale limite. Sans étiquette Y, il est difficile de quantifier objectivement la qualité de l'apprentissage. Les résultats sont souvent subjectifs et demandent une validation humaine.

2. Nécessité d'Interprétation : Les résultats sont bruts (ex. : "vous avez trois groupes"). C'est à l'humain de nommer et de comprendre la signification de ces groupes (ex. : "Segment A = Jeunes acheteurs en ligne").
3. Sensibilité aux Paramètres : Les algorithmes sont très sensibles au choix initial des hyperparamètres (comme la valeur K dans K-Means) et à la manière dont les données sont normalisées, ce qui peut mener à des résultats instables.

III. L'apprentissage par renforcement

L'apprentissage par renforcement consiste à entraîner un agent à choisir les meilleures actions pour maximiser une récompense cumulée. Contrairement à l'apprentissage supervisé, il n'a pas besoin d'exemples corrects : il apprend par essais et erreurs, comme un humain qui apprend à jouer à un jeu. Un système de RL comprend quatre éléments essentiels :

- L'agent : celui qui apprend (dans notre cas, le chatbot SmartSupport).
- L'environnement : le système avec lequel l'agent interagit (les utilisateurs et leurs questions).
- Les actions : les réponses possibles que le chatbot peut donner.
- La récompense : le feedback de l'utilisateur (“oui”, “un peu”, “non”).

III-1 Principe fondamental

À chaque interaction :

- a. L'utilisateur envoie une question.
- b. L'agent (SmartSupport) cherche une réponse dans sa base de connaissances ou dans sa politique locale.
- c. L'utilisateur évalue la réponse en cliquant sur :
 - i. Oui : Récompense positive (+1)
 - ii. Un peu : Récompense neutre (0)
 - iii. Non : Récompense négative (-1)
- d. Le chatbot met à jour sa politique pour retenir quelles réponses sont bonnes ou mauvaises.
- e. Lors des prochaines conversations, il privilégie les réponses ayant obtenu les meilleures récompenses. Ce processus correspond à une amélioration continue basée sur le Q learning, une technique de RL où chaque action est associée à une valeur de qualité notée Q.

III-2 Notre Implémentation dans SmartSupport

✓ **Structure technique** : Notre chatbot a été développé avec : o asynccpg pour la connexion à la base de données PostgreSQL (hébergée sur Neon), o un fichier local policy.json servant de mémoire adaptative (la “politique” de l'agent).

✓ **Fonctionnement de l'apprentissage** : Le chatbot commence avec aucune connaissance réelle (réponses aléatoires ou basiques). À chaque réponse donnée,

il reçoit une évaluation de l'utilisateur. Cette évaluation est convertie en score (+1, 0, -1). Le score est enregistré dans Policy. Son, ce qui permet à SmartSupport d'apprendre à améliorer ses réponses au fil du temps.

✓ **Gestion des erreurs et exploration** : Quand le chatbot ne connaît pas la réponse ou reçoit trop de scores négatifs, il choisit parfois d'explorer une autre réponse (principe ϵ -greedy du RL). Sinon, il renvoie une réponse de secours : « Je ne sais pas encore comment répondre à ça Tu peux reformuler ? »

✓ **Base de données (Neon)** : La base contient les questions et réponses principales. Quand l'agent échoue à répondre correctement, il tente de trouver une question similaire avant d'utiliser une phrase par défaut.

Résultats obtenus : Après plusieurs interactions : SmartSupport apprend à reconnaître les formulations équivalentes (“Qui es-tu ?” et “Qui es-tu?”). Il corrige ses erreurs grâce à la normalisation du texte et à la mise à jour dynamique du fichier de politique. Il devient plus précis et personnalisé à l'utilisateur.

Conclusion

L'apprentissage automatique regroupe plusieurs approches complémentaires qui permettent aux machines d'apprendre à partir de données et d'expériences. L'apprentissage **supervisé** apprend à partir d'exemples déjà étiquetés, le **non supervisé** découvre seul les structures cachées dans les données, et l'apprentissage **par renforcement** progresse par essais et erreurs à travers ses interactions avec un environnement. Ces trois formes d'apprentissage constituent aujourd'hui le socle du développement de l'intelligence artificielle moderne, présente dans des domaines aussi variés que la santé, la finance, l'agriculture ou les transports. Comprendre leurs principes fondamentaux, c'est donc saisir comment les machines apprennent, s'adaptent et contribuent à transformer notre monde.