



---

## **OPTIMISATION DES SYSTEMES DE BUSINESS INTELLIGENCE DANS LES TELECOMMUNICATIONS PAR L'INTEGRATION DES TECHNIQUES DE DATA SCIENCE ET DES TECHNOLOGIES BIG DATA**

**Professeur Associe : KISUKULU KAYEMBELYUBA Don Yves**

**ASS. NZEMBA MUAKA Guylain**

**ASS. YOGO NGBABENDO Daddy**

**ASS. KALALA KAZADI Fils**

**Enseignants et Chercheurs à l'Institut Supérieur Pédagogique Technique de Kinshasa ISPT  
KIN, R.D.Congo**

---

### **Résumé**

Cet article traite de l'évolution des systèmes de Business Intelligence (BI) face à la montée en puissance des données massives dans les télécommunications. Il souligne les limites des approches traditionnelles et présente une approche hybride intégrant Data Science, Machine Learning et technologies Big Data pour renforcer la prise de décision. Le document explore les architectures classiques, les techniques d'apprentissage (supervisé et non supervisé), et propose un modèle orienté vers la prédiction et la segmentation des clients.

### **Abstract**

This paper addresses the evolution of Business Intelligence (BI) systems in the telecommunications industry in response to the exponential rise of big data. It highlights the limitations of traditional methods and introduces a hybrid approach combining Data Science, Machine Learning, and Big Data technologies to enhance decision-making. The article covers classical architecture, supervised and unsupervised learning techniques, and proposes a model geared towards prediction and customer segmentation.

**Mots-clés :** Business Intelligence, Telecommunications, Big Data, Machine Learning, Data Science.

**Digital Object Identifier (DOI):** <https://doi.org/10.5281/zenodo.20546329>

---



## 1 I. INTRODUCTION

Le développement rapide des technologies numériques a entraîné une production massive de données dans le secteur des télécommunications. Face à cette explosion, les méthodes traditionnelles de traitement de l'information ne suffisent plus. Les systèmes décisionnels classiques sont dépassés par les exigences de rapidité, de pertinence et de personnalisation dans la prise de décision. La problématique centrale de cette étude réside dans la capacité des entreprises télécoms à adapter leurs systèmes de Business Intelligence pour exploiter efficacement cette masse de données. Notre hypothèse repose sur l'idée que l'intégration des techniques de Data Science et de Machine Learning dans les processus BI permettrait non seulement d'améliorer la performance analytique, mais aussi de renforcer l'efficacité opérationnelle. À travers une méthodologie qualitative fondée sur une analyse documentaire approfondie et des cas d'application, nous examinerons comment les approches modernes transforment les systèmes BI dans ce secteur stratégique.

## 2 II. ORGANISATION

### 2.1 II. 1. Système décisionnel

#### 2.1.1 II.1.1. Définitions et composantes : ETL, entrepôt de données, tableaux de bord

Un système décisionnel (ou Business Intelligence - BI) regroupe un ensemble d'outils et de méthodes visant à transformer les données brutes en informations pertinentes, utiles à la prise de décision stratégique et opérationnelle. Ses composantes principales sont :

- **ETL (Extract, Transform, Load) :** Ce processus permet d'extraire les données de sources multiples, de les transformer selon les besoins métier (nettoyage, agrégation, normalisation), puis de les charger dans un entrepôt de données ;
- **Entrepôt de données (Data Warehouse) :** Il s'agit d'un référentiel centralisé, historisé, intégré, structuré par thème, et conçu pour l'analyse décisionnelle ;
- **Tableaux de bord et outils OLAP :** Ils permettent une visualisation dynamique des données sous forme de graphiques, d'indicateurs clés (KPI), et de rapports interactifs facilitant la navigation multidimensionnelle.

### 2.1.2 II.1.2. Architecture classique (Inmon, Kimball)

Deux principales approches dominent la conception des entrepôts de données :

- **Approche Inmon** : Top-down, elle commence par construire un Data Warehouse central, modélisé de façon normalisée. Les Data Marts en dérivent ;
- **Approche Kimball** : Bottom-up, elle privilégie la création de Data Marts orientés métier, modélisés selon des schémas en étoile ou en flocon, puis intégrés dans un entrepôt global.

L'approche d'Inmon se distingue par sa rigueur d'intégration et sa vision d'entreprise, tandis que celle de Kimball est plus pragmatique et orientée utilisateur.

### II.1.3. Limites des approches traditionnelles face au volume, variété et vitesse des données télécom

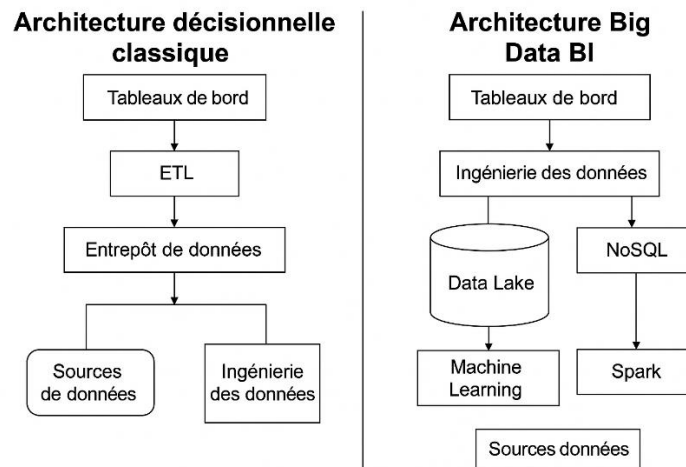
Les architectures décisionnelles traditionnelles ont été conçues pour des volumes modérés, des formats homogènes et des mises à jour périodiques. Or, le secteur des télécommunications génère des données caractérisées par les **5V du Big Data** :

- **Volume** : Aujourd'hui, les données stockées sont de taille colossale. Certains parlent de l'infobésité (obésité de l'information) ou de big bang des données numériques. Il y a donc une explosion des données, en particulier celles du web. Les données ne sont plus mesurées en mégaoctet (10<sup>6</sup>), gigaoctet (10<sup>9</sup>), ..., mais plutôt en zettaoctet (10<sup>21</sup>) ou en yottaoctet (10<sup>24</sup>) pour décrire, des milliards d'enregistrements issus de logs réseau, transactions mobiles, et données clients ;
- **Vélocité** : Les réseaux sociaux tels que Twitter, Instagram, tiktok et Facebook génèrent de flux de données en continu (streaming) nécessitant des traitements en quasi-temps réel (jusqu'au prochain cycle de production des données) ;
- **Variété** : C'est aussi une des caractéristiques remarquables des Big Data. En effet, les données proviennent des sources différentes et sont de natures variées (visuelle, auditive, graphique, etc.). Ces données peuvent être non structurées (SMS, Commentaires et publications Facebook, Tweets, audios, vidéos, etc.), semi-structurées (HTML, fichier JSON, XML, serveur log, etc.) et structurées (tables de la base des données relationnelles, par exemple, CRM) ;

- **Véracité** : incertitude sur la fiabilité des données, anomalies, bruit, doublons, informations contradictoires. Les erreurs peuvent être introduites soit par l'homme, soit par l'ordinateur. Ce qui fait que la fiabilité des données est notamment menacée, par exemple un acteur, dans un réseau social qui aime une publication aujourd'hui et la déteste le lendemain. La véracité va au-delà de l'intégrité des données, la véracité des données permet aux directions métiers de mieux les utiliser au quotidien ;
- **Valeur** : nécessité de transformer la donnée brute en information utile, à forte valeur ajoutée (score de churn, segmentation, prévisions). Il s'agit donc d'exploiter les données massives afin de pouvoir tirer profit des connaissances cachées dedans. C'est ces connaissances qui permettent à l'ordinateur de données à cette foule des données du sens. Les techniques telles que le Data mining est utilisé en Analyse des Big Data pour déterminer les connaissances cachées dans la foule des données.

Face à ces enjeux, les architectures BI classiques atteignent leurs limites et doivent être complétées par des technologies distribuées, scalables, et intelligentes : Hadoop, Spark, NoSQL, Data Lakes, et Machine Learning.

#### II.1.4. Illustration 1 – Architecture décisionnelle classique vs architecture Big Data BI



## II.2. Apprentissage artificiel et machine Learning

### II.2.1. Rappel sur l'IA et le ML: apprentissage supervisé vs non supervisé

L'intelligence artificielle (IA) regroupe les techniques permettant à des machines de simuler certains aspects de l'intelligence humaine. Le Machine Learning (apprentissage automatique) en est un sous-domaine clé qui permet à une machine d'apprendre automatiquement à partir des données. Deux types d'apprentissage sont principalement utilisés :

- **Apprentissage supervisé** : Également connu sous le nom de machine learning supervisé, l'apprentissage supervisé est une sous-catégorie de machine learning et d'intelligence artificielle. Il consiste à utiliser des jeux de données annotées pour entraîner les algorithmes à classer les données ou à prédire les résultats avec précision. Au fur et à mesure que les données d'entrée alimentent le modèle, on procède à une pondération jusqu'à ce que ce dernier soit correctement ajusté dans le cadre du processus de validation croisée. L'apprentissage supervisé permet aux entreprises de résoudre divers problèmes à l'échelle, comme le classement du courrier indésirable dans un dossier autre que leur boîte de réception. Il peut également être utilisé pour créer des modèles de machine learning de haute précision.

#### ➤ **Comment ça marche ?**

L'apprentissage supervisé utilise un ensemble d'apprentissage pour enseigner aux modèles à produire le résultat souhaité. Ce jeu de données d'entraînement comprend des entrées et des sorties correctes, ce qui permet au modèle de s'améliorer au fil du temps. L'algorithme mesure sa précision par le biais de la fonction de perte, en s'ajustant jusqu'à ce que l'erreur soit suffisamment réduite.

L'apprentissage supervisé permet de traiter deux types de problèmes lors de l'exploration de données, la classification et la régression :

- La classification utilise un algorithme pour attribuer avec précision des données de test à des catégories particulières. L'algorithme reconnaît des entités spécifiques dans le jeu de données et tente de tirer des conclusions sur la façon dont ces entités doivent être

étiquetées ou définies. Les algorithmes de classification courants sont les classificateurs linéaires, les machines à vecteurs de support (SVM), les arbres de décision, les k plus proches voisins et les forêts d'arbres décisionnels.

- La régression permet de comprendre la relation entre les variables dépendantes et indépendantes. Elle est couramment utilisée pour établir des projections, telles que le chiffre d'affaires d'une entreprise donnée. La régression linéaire, la régression logistique et la régression polynomiale sont des algorithmes de régression populaires.
- **Apprentissage non supervisé :** Contrairement à l'apprentissage supervisé, l'apprentissage non supervisé utilise des données non étiquetées. À partir de ces données, il découvre des modèles qui aident à résoudre les problèmes de regroupement ou d'association. Ceci est particulièrement utile lorsque les spécialistes du domaine ne sont pas sûrs des propriétés communes dans un jeu de données. Les algorithmes de regroupement courants sont des modèles hiérarchiques, k-moyennes et de mélange gaussien. L'algorithme découvre des structures cachées dans des données non étiquetées. Il est employé pour la segmentation et la détection d'anomalies.

## II.2.2. Algorithmes utilisés en télécom

Dans le secteur des télécommunications, plusieurs algorithmes de Machine Learning sont utilisés pour exploiter la richesse des données :

- **Régression logistique :**

C'est un algorithme de classification supervisée utilisé pour prédire un résultat binaire (0 ou 1) à partir d'un ensemble de variables explicatives. Elle est particulièrement adaptée pour la prédiction du churn (résiliation de contrat). La fonction logistique transforme une combinaison linéaire des variables en une probabilité :

$$P(y=1|x) = 1 / (1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)})$$

Cette probabilité peut ensuite être comparée à un seuil (par exemple, 0.5) pour prendre une décision (churn ou non churn).

*Utilisée pour la prédiction du churn (taux d'abandon), elle permet de modéliser la probabilité qu'un abonné quitte l'opérateur.*

**Exemple :** Prédiction du churn en utilisant les variables de consommation, plaintes et durée d'abonnement.

- **Forêts aléatoires (Random Forest) :**

Une forêt aléatoire est un ensemble d'arbres de décision entraînés sur des échantillons différents du dataset (bootstrap) et avec des sous-ensembles aléatoires de variables. Elle corrige le sur-apprentissage d'un arbre seul en moyennant les résultats de plusieurs arbres. L'algorithme peut être utilisé pour la classification (churn, fraude) ou la régression (prévision de revenus).

**Avantages :**

- Haute précision
- Résistance au bruit
- Capacité à gérer des variables catégorielles et numériques

*Utilisées pour la détection d'anomalies dans les réseaux, elles sont robustes et performantes même avec des variables bruitées.*

**Exemple :** *Détection d'anomalies sur le réseau à partir des logs techniques.*

- **K-means :**

L'algorithme de K-means est utilisé pour effectuer une segmentation non supervisée. Il cherche à partitionner les données en K groupes (clusters) distincts. Chaque cluster est représenté par un centroïde (moyenne des points du groupe).

Objectif : minimiser la variance intra-cluster

**Formule :**  $\arg \min \sum_{i=1 \text{ à } k} \sum_{x \in C_i} \|x - \mu_i\|^2$

Étapes :

1. Initialiser K centroïdes (aléatoirement ou par méthode heuristique).
2. Assigner chaque point au cluster dont le centroïde est le plus proche.
3. Recalculer les centroïdes.
4. Répéter jusqu'à convergence (les centroïdes ne changent plus).

*Méthode de clustering non supervisé servant à regrouper les clients en segments homogènes pour des campagnes marketing ciblées.*

**Exemple :** *Segmentation des clients selon les indicateurs RFM pour un ciblage marketing personnalisé*

- **Réseaux neuronaux :**

Un réseau de neurones est composé de couches de neurones artificiels, chacun calculant une sortie à partir d'une combinaison linéaire des entrées suivie d'une fonction d'activation non linéaire (ex. ReLU, Sigmoid, Tanh).

Sortie d'un neurone :  $a = \sigma(w^t x + b)$

où  $\sigma$  est une fonction d'activation.

Les réseaux peuvent être :

- à propagation avant (feedforward)
- ou récurrents (RNN, LSTM) pour les données séquentielles comme les séries de trafic réseau.

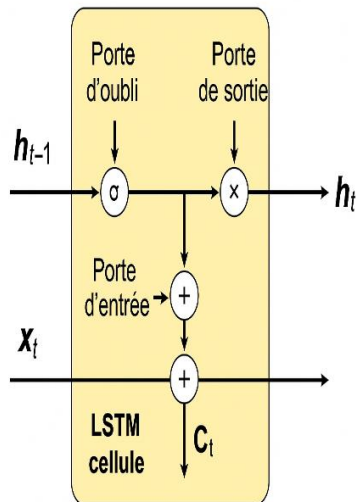
*Utilisés pour la prévision de la charge du réseau et l'optimisation de la bande passante, grâce à leur capacité à capter des patterns complexes.*

*Exemple : prédiction de la charge du réseau pendant les heures de pointe*

- **LSTM – Long Short-Term Memory**

Les LSTM sont une variante des réseaux neuronaux récurrents (RNN) conçue pour capturer les dépendances temporelles longues. Ils intègrent des portes de régulation :

- Porte d'oubli  $f_t$  : contrôle quelles informations de l'état précédent doivent être oubliées ;
- Porte d'entrée  $i_t$  : détermine quelles nouvelles informations ajouter à l'état courant ;
- Cellule mémoire  $C_t$  : maintient l'état de la séquence ;
- Porte de sortie  $o_t$  : décide quelle partie de l'état est transmise à la sortie.



**Formules typiques :**

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

- $x_t$  : entrée actuelle (ex. : trafic à l'instant t)
- $h_{t-1}$  : sortie précédente
- $W_f$  : poids de la porte d'oubli
- $W_i$  : poids de la porte d'entrée
- $b_f$  : biais associé
- $\sigma$  : fonction sigmoïde (résultat entre 0 et 1)
- $\tanh$  : active les valeurs dans l'intervalle [-1, 1]

**Exemple :**

Imagine un modèle LSTM qui prédit le **trafic d'une antenne 4G** :


- $x_t$  : trafic observé ce matin
- $h_{t-1}$  : prédiction de la veille
- $C_t$  : mémoire cumulative des pics/creux de trafic
- $h_t$  : trafic prédit pour cet après-midi

**II.2.3. Intégration dans les flux BI: scoring client, maintenance prédictive, détection de fraude**

L'intégration du Machine Learning dans les systèmes de Business Intelligence permet de passer d'une BI descriptive à une BI prédictive. Les modèles prédictifs peuvent être entraînés hors ligne puis déployés dans les pipelines décisionnels. Quelques exemples :

- **Scoring client** : attribuer une probabilité de churn ou un score d'appétence à chaque client.
- **Maintenance prédictive** : anticiper les défaillances d'équipements grâce à l'analyse de séries temporelles issues des capteurs réseau.
- **Détection de fraude** : analyser les comportements utilisateurs pour repérer automatiquement les transactions suspectes ou anormales.

## II.2.4. Illustration 2 – Pipeline de Machine Learning dans un système décisionnel télécom



## II.3. Création et applications

### II.3.1. Mise en œuvre Big Data : Hadoop, Spark, Hive, Kafka

La mise en œuvre des technologies Big Data constitue une étape essentielle dans la transformation des systèmes décisionnels des entreprises télécoms. Elle permet d'assurer la collecte, le stockage, le traitement et l'analyse en temps réel de données massives, hétérogènes et à forte vélocité. Voici les principales solutions utilisées :

- **Hadoop** : plateforme open source qui offre un système de fichiers distribué (HDFS) et le modèle MapReduce. Elle permet de stocker et traiter des données à grande échelle sur des clusters de serveurs ;
- **Spark** : moteur de calcul distribué en mémoire, très rapide, utilisé pour l'analyse itérative de gros volumes de données. Il est particulièrement adapté aux cas d'usage en machine learning, streaming et graphes ;
- **Hive** : outil de requêtage distribué qui permet d'exécuter des requêtes SQL sur des données stockées dans Hadoop. Il rend les analyses accessibles aux utilisateurs métiers sans connaissances techniques avancées ;
- **Kafka** : système de messagerie distribué conçu pour gérer des flux de données en temps réel. Il joue un rôle central dans l'ingestion et le transport de données vers les systèmes d'analyse et de BI.

### II.3.2. Cas pratiques

- **Analyse du churn client**

L'analyse du churn consiste à identifier les clients susceptibles de résilier leur abonnement. À cette fin, on entraîne un modèle de **régression logistique** supervisée sur un dataset clients contenant des caractéristiques telles que la durée d'abonnement, la fréquence d'utilisation, l'historique de plaintes et une étiquette binaire (résilié ou non). Ce modèle permet de calculer une probabilité de churn pour chaque client, et ainsi de cibler les campagnes de rétention.

- **Prévision de trafic réseau**

La gestion proactive des infrastructures réseau passe par la **prévision du trafic** à l'aide d'algorithmes adaptés aux données temporelles. Les **réseaux de neurones récurrents** et plus particulièrement les modèles **LSTM (Long Short-Term Memory)** sont utilisés pour anticiper les pics de trafic sur les différents nœuds du réseau, en exploitant les logs de trafic collectés en temps réel. Cela permet d'optimiser la bande passante, d'éviter la congestion et de planifier les maintenances préventives.

- **Segmentation client**

La segmentation vise à diviser la clientèle en groupes homogènes selon des critères comportementaux. L'algorithme de **K-means**, non supervisé, est souvent appliqué sur des variables RFM (Récence, Fréquence, Montant) extraites des habitudes de consommation. Cette segmentation permet ensuite d'ajuster les offres commerciales (forfaits, promotions, services personnalisés) à chaque segment identifié.

### II.3.3. Rôle des Data Lakes et APIs dans la modernisation BI

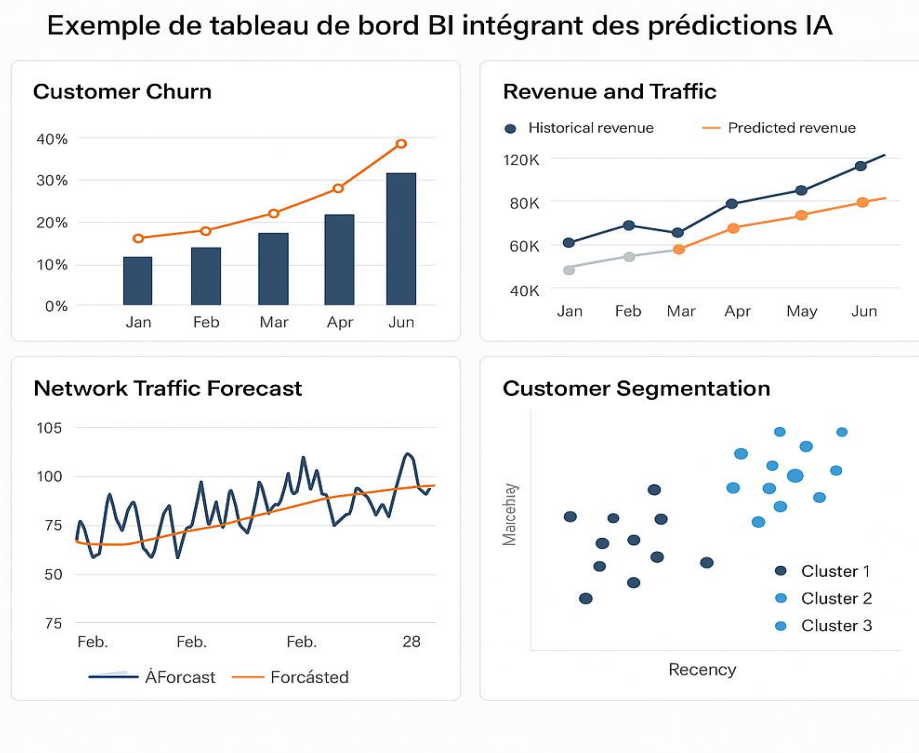
Les systèmes BI modernes dépassent le cadre des entrepôts de données traditionnels et s'appuient sur des architectures plus flexibles :

- **Data Lakes** : Ce sont des réservoirs massifs capables de stocker des données structurées, semi-structurées et non structurées dans leur format natif. Ils permettent de

centraliser tous les flux de données (logs, fichiers, événements, médias, etc.) et de les mettre à disposition pour l'analytique avancée, le Machine Learning ou la visualisation.

- **APIs (Application Programming Interfaces)** : Les APIs jouent un rôle crucial dans l'intégration continue des flux entre les applications transactionnelles, les plateformes de calcul distribuées, et les outils de BI. Elles permettent l'automatisation du scoring client, le déclenchement d'alertes en temps réel, et la mise à jour dynamique des tableaux de bord décisionnels.

### II.3.4. Illustration 3 – Exemple de tableau de bord BI intégrant des prédictions IA



## II.4. Votre contribution

### II.4.1. Proposition d'une architecture d'intégration BI-ML pour télécom

Afin d'optimiser la chaîne décisionnelle dans un environnement télécom, nous proposons une architecture intégrée combinant les techniques de Business Intelligence classiques et les outils avancés de Machine Learning. Cette architecture repose sur une structure en quatre zones distinctes, interconnectées par des APIs et des flux temps réel : ingestion, traitement, stockage et visualisation.

#### II.4.2. Illustration 4 – Architecture hybride BI + IA pour opérateurs télécom

Architecture modulaire comprenant quatre zones clés – ingestion, traitement, stockage et visualisation – conçue pour intégrer les flux de données massives et les algorithmes IA dans le système décisionnel des opérateurs télécom

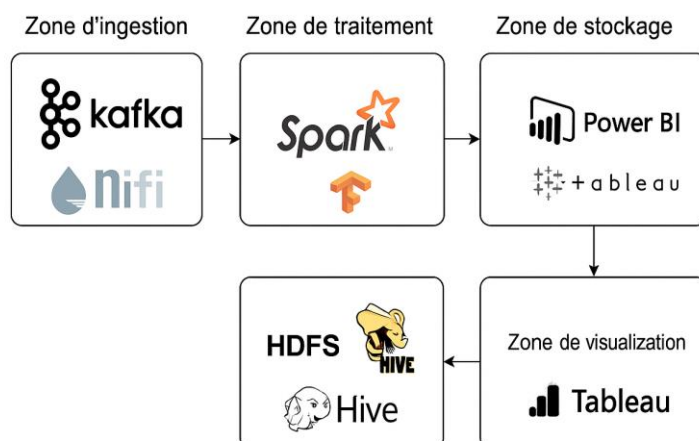


Figure 4 : Architecture hybride BI + IA pour opérateurs télécom

#### II.4. 3. Avantages attendus

L'implémentation d'une architecture hybride alliant **Business Intelligence traditionnelle** et **techniques avancées d'intelligence artificielle** permet aux opérateurs télécoms d'améliorer significativement leur performance organisationnelle, commerciale et technique. Voici les principaux bénéfices stratégiques, étayés par des cas d'usage concrets et des indicateurs mesurables :

- **Réduction du churn de 15 % par la détection proactive des désabonnements**

Grâce aux modèles de machine learning (ex. régression logistique, forêts aléatoires), l'entreprise peut prédire avec précision les clients à risque de résiliation en analysant :

- la fréquence de réclamations,
- la baisse d'activité (voix, data, SMS),
- les indicateurs de satisfaction client.

➤ **Résultat attendu :**

- Mise en œuvre de campagnes de fidélisation ciblées.
- Réduction du taux de résiliation mensuel de 18 % à moins de 15 % dans un délai de 6 mois.
- Amélioration de la valeur vie client (CLTV).

- **Personnalisation des offres commerciales via des modèles de recommandation**

L'intégration d'algorithmes collaboratifs (ex. KNN, SVD, deep learning) permet:

- D'analyser les préférences implicites (types d'abonnements, historique d'achat),
- De recommander des services ou produits individualisés (forfaits voix/données, options, appareils).

- **Impact opérationnel:**

- Augmentation du taux de conversion des campagnes SMS/USSD de 8 % à 14 %.
- Croissance du panier moyen mensuel par abonné (+7 à 10 %).

- **Optimisation des campagnes marketing et de la gestion des ressources réseau**

Les modules prédictifs et d'analyse comportementale permettent d'optimiser :

- Le **ciblage** des clients (segmentation RFM, K-means),
- Le **timing** (analyse temporelle),
- Le **canal de diffusion** (push via MoMo, SMS, email, etc.).

En parallèle, l'analyse prédictive du trafic réseau (via LSTM, Prophet) permet :

- D'anticiper les pics de charge,
- D'optimiser la **planification des investissements réseau** (CAPEX/OPEX),
- De réduire les **coûts d'indisponibilité** (maintenance préventive pilotée par IA).

- **KPI attendus:**

- Réduction du coût d'acquisition client (CAC) de 12 %.
- Amélioration du taux de disponibilité réseau > 99,8 %.
- Diminution des coûts d'appel vers le support client (moins de tickets liés à congestion).

### III. Bibliographie

#### ◆ Ouvrages et manuels

1. Kimball, R., Ross, M. (2013). *The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling* (3rd ed.). Wiley.
2. Inmon, W. H. (2020). *Building the Data Warehouse* (5th ed.). Wiley.
3. Géron, A. (2022). *Machine Learning avec Scikit-Learn, Keras et TensorFlow* (2e éd.). O'Reilly.

#### ◆ Articles scientifiques récents

4. Reinsel, D., Gantz, J., Rydning, J. (2022). *Data Age 2025: The Evolution of Data to Life-Critical*. IDC White Paper.
5. Nair, A., Tripathy, B. K. (2023). “Big Data Framework for Telecom Churn Prediction using Deep Learning”, *Journal of Big Data*, 10(22), pp. 1–15. <https://doi.org/10.1186/s40537-023-00790-z>
6. Kumar, A., Singh, P. (2022). “Integration of Business Intelligence and Data Science for Strategic Telecom Analytics”, *International Journal of Information Management Data Insights*, Vol. 2(1), pp. 14–28.
7. Wang, X., Li, Y., & Chen, G. (2023). “Real-time Stream Processing Architecture for Telecom Data using Kafka and Spark”, *IEEE Access*, 11, 105321–105337. <https://doi.org/10.1109/ACCESS.2023.3285063>
8. Al-Mallah, M., Dabbagh, A. (2024). “A Review of AI-driven BI Frameworks for 5G Telecom Operators”, *Future Internet*, 16(1), 15. <https://doi.org/10.3390/fi16010015>

#### ◆ Sources pratiques & guides techniques

9. Microsoft (2022). *Power BI for Telecom Analytics – Best Practices Guide*.
10. Databricks (2023). *Modern Data Stack for Telecoms: From ETL to Real-Time AI*.
11. Google Cloud (2023). *Architecture Reference for Telecom Data Lakes and ML Pipelines*.

#### ◆ Cours & présentations académiques

12. Kafunda, P. (2023). *Cours de Master : Data Science et Machine Learning appliqués au Système Décisionnel*, ISC Kinshasa.
13. Kafunda, P. (2023). *Diapositive – Data Science et Machine Learning: Introduction et applications*, Master ISC11.