

**Conception et réalisation d'un réseau de neurones artificiels pour  
l'évaluation des erreurs significatives dans le cadre des  
procédures d'audit analytiques (cas du groupe SAIDAL).  
Design and implementation of an ANN for the evaluation of  
significant errors in the context of analytical audit procedures (A  
case study of SAIDAL group).**

**Amirouche ARBANE <sup>1\*</sup>**

**Tassadit BOUSBAINE<sup>2</sup>**

<sup>1</sup> Université de Bouira, arbaneamirouche@gmail.com

<sup>2</sup> Université de Bouira, tassa86dz@yahoo.fr

Date de réception: 11/09/2019 Date de révision: 15/02/2020 Date d'acceptation: 01/03/2020

**Résumé**

L'auditeur face à l'ampleur et à la vitesse par laquelle évoluent les entreprises dans différents domaines, se retrouve confronté à une multitude de risque. L'objectif du présent article est de mettre en évidence la possibilité d'utilisation des RNA dans la détection des erreurs significatives. En outre la résolution de cette problématique ces cristalliser par la conception et la mise en œuvre d'un RNA multicouche prédicteur former et tester sur les données collecter des états financiers du groupe SAIDAL par le biais des procédures analytiques. Les résultats de l'étude ont révélé que l'utilisation des RNA associer aux capacités de calcul très élever dans les différentes phases d'audit offre aux auditeurs la possibilité de classifier et de prédire les zones dangereuses nécessitantes des procédures analytiques d'audit plus détailler. **Mots clés** : audit analytique, erreur significative, Réseau de neurones artificiels, régression logistique.

**Abstract**

The auditor, faced with the scale and speed with which companies evolve in different fields, is faced with a multitude of risks. Therefore the objective of this article is to highlight the possibility of using RNA in the detection of significant errors. In addition to solving this problematic these crystallize through the design and implementation of a multi-layer predictor RNA train and test on the data collect financial statements of the SAIDAL group through analytical procedures. The results of the study revealed that the use of ANNs associated with very high computing capabilities in the various audit phases offers auditors the ability to classify and predict the hazardous areas requiring audit analytical procedures to further detail.

**Keywords** : analytical audit, significant error, Artificial neural network, logistic regression.

\* Auteur correspondant:  
Email : arbaneamirouche@gmail.com

Arbane Amirouche,

**1. Introduction :**

L'audit basé sur l'exploration des résultats annoncés par les procédures analytiques via les réseaux de neurones artificiels, et une nouvelle approche parmi d'autres, qui s'articule sur les données réelles d'une durée déterminée pour simuler un comportement, une construction, une formalisation, et un état d'esprit à la fois nécessaire pour l'audit par le management des risques et à la résolution de problématiques issues de phénomène non structurable et non linéaire. Par coïncidence, plusieurs méthodes ont été développées pour être utilisées dans le cadre de l'audit via l'approche des risques, n'empêche qu'aucun d'entre elles n'a été identifiée comme méthode optimale, cependant, nous allons adopter toute au long de notre document de recherche une méthode de recherche qui va tester l'importance et l'efficacité des applications de l'intelligence artificielle via les réseaux de neurones artificiels dans la résolution du problème de la détection des erreurs potentiellement significative.

À la lumière de tout ce qui précède, une problématique principale peut être soulevée :

**Les réseaux de neurones artificiels, quel avenir pour les auditeurs dans la détection des erreurs potentiellement significatives ?**

Afin de répondre implicitement à la problématique principale soulever ci-dessus nous allons essayer de répondre aux questions suivantes :

- 1- L'adoption des réseaux de neurones artificiels par les auditeurs dans le procédé d'audit améliorera-t-il la qualité des travaux d'audit ?
- 2- Quels sont les algorithmes optimaux utilisés par les réseaux de neurones artificiels dans la détection des erreurs significative ?
- 3- Quelle est la logique d'analyse adopter par les auditeurs lors de la lecture des résultats de simulation apparier par les réseaux de neurones artificiels ?

Dans le but de transcender dans les hypothèses soutenues dans l'étude, nous devant définir l'importance de la recherche qui est principalement liée à la démonstration d'une possibilité d'utilisation des techniques basées sur les réseaux de neurones par les auditeurs lors de l'exécution du programme d'audit, dans la séquentialisation d'une démarche appropriée pour l'analyse de données financières de l'entreprise et la détection d'erreurs potentiellement signifiantes, ainsi déterminer l'importance de la démarche

dans l'amélioration du procédé d'audit et de la qualité de l'opinion émis par l'auditer dans le rapport d'audit présenter à la fin de la mission.

Pour aboutir aux objectifs appréhendés tout au long de l'introduction nous avons subdivisé le travail selon la démarche suivante :

## **2. Revue de la littérature**

La résolution de n'importe quelle problématique s'appuie principalement sur une base inviolable qui est une bonne maîtrise des aspects théorique du sujet partant des plus simples au plus difficile et cela pour une maîtrise conservatrice des variables interagissant les unes avec les autres dans le sujet.

### **2.1 Pourquoi les procédures d'audit analytique ?**

Plusieurs terminologies sont couramment utilisées pour décrire les procédures analytiques d'audit, tel l'audit analytique, procédures analytiques, examen analytique, preuve analytique ou procédures d'examen analytique (Eija, 2007, p. 334), dans cet article, nous avons utilisé les procédures analytiques comme terme générique permettant de reproduire toutes les preuves analytiques destinées aux auditeurs. La première fois que le terme procédures analytiques a été utilisé et qu'il a fait l'objet d'une discussion formelle, remonte à la publication officielle de l'AICPA apparu en 1972, cette définition initiale décrivait les procédures analytiques comme un examen de ratios, de tendances significatives, et d'enquête sur les fluctuations et les éléments douteux.

D'après Stringer (1975), la logique sous-jacente des procédures analytiques fait référence à la conformité des montants divulgués dans les états financiers avec les montants raisonnablement attendus sur la base de l'exercice passée et d'autres conditions connues qui fournissent des éléments de preuve aux fins de l'audit (Jana, 2015, p. 65). L'importance de ces procédures se cristallise par l'évaluation de l'information financière via l'analyse de ration plausible entre des données financières et non financières, elle englobe également toute enquête nécessaire sur les fluctuations ou relation identifier qui sont incompatibles avec d'autres informations pertinentes qui diffèrent des valeurs attendues. (CCury, 2018, p. 1). Selon la norme ISA 520, l'exécution des procédures analytiques comprend deux parties, la première prend en compte les comparaisons et relation afin d'identifier les oscillations, l'autre concerne les enquêtes sur les causes des

fluctuations et incohérences (Kritzinger, 2017, p. 224). Les procédures analytiques peuvent être effectuées dans les trois étapes du processus d'audit, de la planification à la phase de test (Chow, 2009, p. 2) et l'achèvement (Garlos, 2014, p. 27).

Il ressort clairement de ces définitions que les procédures analytiques prennent en considération la comparaison entre différentes rations réalisées et attendues, afin de détecter et enquêter sur les oscillations et fluctuations.

## **2.2 Réseau de neurones artificiel**

Vu l'importance du concept dans la démarche de l'article en cours nous allons essayer tout au long de cette partie d'examiner les éléments suivants :

### **2.2.1 Les réseaux de neurones artificiels : de quoi va-t-on parler ?**

Aujourd'hui, dans la littérature, de nombreux termes désignent le domaine des réseaux de neurones. Les RNA que le modèle manipulé, donc il serait mieux de dire « réseaux de neurones artificiels ». En effet, les réseaux de neurones biologiques (RNB) sont beaucoup plus complexes que les modèles mathématiques utilisés dans les réseaux de neurones artificiels, de ce fait les RNA sont constitués par l'interconnexion d'unité élémentaire de traitements d'informations, dont le principe de fonctionnement est calqué sur celui des neurones biologiques, un réseau possède des capacités de stockage et de traitement de l'information, imputable aux poids des connexions entre chaque neurone. Ces poids sont calculés par un processus d'adaptation également appelée apprentissage. (Davide, 2008, p. 81).

Le RNA est un paradigme de traitement de l'information inspiré de la façon dont les systèmes neurobiologiques, tel que le cerveau, traitent les informations. Donc l'élément-clé de ce paradigme est la nouvelle structure du système de traitement de l'information, il est composé d'un grand nombre d'élément de traitement hautement interconnectés (neurones). (Safna & Rekha, 2018, p. 241).

Par définition un neurone formel est une fonction algébrique non linéaire, paramétrée, à valeurs bornées. Il peut être caractérisé par :

- 1- La nature de ses entrées ( $x_1, x_2, \dots, x_i, \dots, x_n$ ), qui peuvent être les entrées du réseau ou les sorties d'autres neurones du même réseau.
- 2- La fonction d'entrée totale définissant le prétraitement (combinaison linéaire) effectué sur les entrées comme  $\sum W_i.x_i + b$ , dont  $W_i$  est le

poids synaptique attaché à l'entrée I et le b désigne le seuil d'activation (biais). (Bendaoud , 2014, p. 6)

- 3- Sa fonction d'activation est toujours comparée au seuil  $\theta$  de modélisation, cette comparaison est donnée par :

**Table N°1. Fonction d'activation comparées au seuil  $\theta$**

$$X = \sum_{i=1}^n x_i w_i$$

$$Y = \begin{cases} +1 & \text{si } X \geq \theta \\ -1 & \text{si } X < \theta \end{cases}$$

Étage	Signe	Sigmoïde	Linéaire
$Y^{\text{étage}} = \begin{cases} 1 & \text{si } X \geq \theta \\ 0 & \text{si } X < \theta \end{cases}$	$Y^{\text{signe}} = \begin{cases} +1 & \text{si } X \geq \theta \\ -1 & \text{si } X < \theta \end{cases}$	$Y^{\text{sigmoïde}} = \frac{1}{1 + e^{-\lambda(X - \theta)}}$	$Y^{\text{linéaire}} = X - \theta$


Source : (Mohammad & Youcef, 2017, p. 31).

Généralement un réseau de neurones artificiels est un ensemble d'interconnexions entre unités de calcul simple organiser en couche, et ayant pour fonction principale l'exécution de calculs complexes dans le but de trouver, par apprentissage, une relation non linéaire entre des données numériques et des paramétré.

### 2.2.2 Quelle architecture pour les RNA ?

La figure ci-dessous illustre les composants de base d'un réseau de neurones artificiels :

**Figure N°1. Architecture des RNA**



Source : (Singh & Ashima, 2014, p. 2).


La figure (1) permet l'identification des différents composants des RNA à savoir :

- **Les couches d'entrées** : la couche d'entrée est responsable du transfert des variables d'entrée aux couches cachées sans traitement.
- **Les couches cachées** : chaque couche cachée a pour tâche le traitement des variables d'entrées, puis leur transfert vers les couches de sorties. Pour ensuite, pondérez le nombre d'entrées connectées, et les ajoutez au total de toutes les entrées, tout en s'assurant que le total correspond au seuil pour enfin passez à la fonction d'activation.

- **Les couches de sorties** : les couches de sorties fonctionnent de la même manière que celui de la couche masquée. (Dilek & Seyma , 2015, p. 40)

En plus de ce qui précède les réseaux de neurones artificiels peuvent être composés de plusieurs couches comme illustrées sur la figure suivante :

**Figure N°2. Brève description de méthodologie proposée pour un réseaux de neurones artificiels à multi couche.**



**Source :** (Dilek & Seyma , 2015, p. 40)

Le fonctionnement d'un réseau de neurones artificiels à multi couche ne diffère pas du RNA simple, juste la déférence peut être constatée dans le nombre de couches cachées (hidden Layer).

### 2.2.3 Les algorithmes d'apprentissage utiliser dans les réseaux de neurones artificiels

Il existe plusieurs règles d'apprentissages qui peuvent être regroupées en trois catégories :

- **L'apprentissage Supervisé (ou à partir d'exemple)** : associé une réponse spécifique à signal d'entrée. (Nariman , 2016, p. 55)
- **L'apprentissage non supervisé** : dans cette technique, la classe d'apprentissage est formé d'un vecteur d'entrée uniquement.
- **L'apprentissage renforcé** : représente une technique nouvelle, qui a en commun avec l'apprentissage supervisé, la présence d'un superviseur régi par une mesure de degrés de performance (un grade ou score) qui juge l'évolution de l'apprentissage du réseau après quelques itérations. (Nariman , 2016, p. 55)

### 2.3 Utilisation des réseaux de neurones artificiels dans le processus d'audit via les procédures analytiques

Depuis que les réseaux de neurones à structure artificielle en fait leurs entrer aux sciences de gestion comme démarche analytique de prévision et

d'analyse de données, les auditeurs n'ont pas pu se tenir à l'égard de cette nouvelle démarche de management d'erreurs et de séquentialisation de données. Partant de ce qui y a été dit, nous allons tout au long de cette partie traiter les éléments suivants :

### **2.3.1 Panorama des applications des réseaux de neurones artificiels dans le domaine d'audit**

Accentuer sur les différentes recherches en audit et RNA qui ont été mené par les différents chercheurs du domaine, nous allons essayer à travers cette partie de mettre l'accent sur les éléments suivants :

**2.3.1.1 La détection d'erreurs significantes :** L'utilisation des réseaux de neurones artificiels pour la détection d'erreurs significatives dans le cadre des procédures analytiques d'audit, est considéré comme l'une des démarches les plus importantes utiliser par les auditeurs lors de la prédiction des valeurs futures ou de la classification de données pour utilisation durant la détection de cas inhabituel attacher à la déférence entre les résultats divulgués et les ratios attendus. (Kouskivara, 2003, p. 10)

**2.3.1.2 La Classification :** la classification est l'une des procédures d'audit. Visant à classifier les risques en zones ou à prioriser les activités qui nécessitent une amélioration. En général, les RNA, qui sont des classificateurs par nature, offrent, la capacité de tenir compte simultanément de plusieurs types d'éléments de preuve peuvent aider les auditeurs lors de l'évaluation des risques à porter des jugements. (Nariman , 2016, p. 151)

**2.3.1.3 L'évaluation du système de contrôle interne :** Dans un travail de recherche publié par Omid, Hussein (2012), des méthodes de data mining ont été utilisé pour aider les auditeurs à émettre leur opinion. Pour la première fois en Iran, cet article applique quatre techniques de classification de data mining, à savoir : réseau neuronal a couche multiple (MLP), réseau à fonction de base radiale (RBF) et régression logistique (LR), le vecteur d'entrée comprenait plusieurs variables quantitatives. Les résultats apportés par la recherche comportent une grande capacité des réseaux MLP à identifier la qualité de l'opinion d'audit. (omide, Hossein, & Zeinab, 2012, p. 11077)

**2.3.1.4 L'évaluation de la continuité de l'exploitation :** La continuité de l'exploitation est une opinion de l'auditeur destiné à l'entreprise auditée quand elle est susceptible de faire faillite, ou si elle s'expose à d'autres signes de détresse qui menace sa capacité à continuer, a cet égard

plusieurs recherches dans ce contexte ont été lancées depuis les années 90, L'une des plus importantes de ces études est celle de Wilson et Sharda (1990), le contenu de cette étude à comparer l'aptitude de prévision des RNA avec d'autres méthodes. De ce fait, cinq ratios financiers se sont déterminés comme données d'entrée au réseau. L'échantillon de l'étude comprend 129 entreprises américaines. Ces entreprises sont subdivisées en deux groupes : un groupe d'apprentissage, (qui comprend 74 entreprises dont 38 sont défaillantes et 36 saines), avec un échantillon de test 55 entreprises dont 27 sont en état de faillite et 28 en stabilité financière. Après la construction du modèle les chercheurs en constataient que le modèle de réseau pouvait prévoir exactement la situation de 22 entreprises dans l'ensemble de 27 en faillite, alors que les autres méthodes prévoient seulement 16. Les résultats du test en montraient que les RNA sont plus efficaces que les autres méthodes dans la détection de problèmes financiers dans les entreprises au stade précoce. (Nariman , 2016, p. 156).

**2.3.1.5 Le contrôle des comptes :** L'étude faite par Koskivaara (2000), avait pour objectif l'analyse de données mensuelle pour l'évaluation de la capacité des réseaux de neurones artificiels basé sur les algorithmes de rétropropagation. Pour l'élaboration du côté pratique nécessaire pour l'examinations de la problématique, Koskivaara utilise les données d'une entreprise finlandaise de taille moyenne. L'échantillon a été divisé en 60 balances dont l'échantillon de test comprend les 12 derniers mois. Le travail s'est édifié sur deux modèles qui ont montré une grande capacité de prédiction. Pour déterminer la convenance des RNA avec la décision de la révision de compte, le modèle du réseau a été examiné pour trouver les erreurs significatives en mettant des ventes fausses dans le cinquième mois. Par conséquent, l'erreur quadratique augmente simultanément avec la nouvelle donnée. Ce dernier signal une alarme d'avertissement à l'auditeur qui doit chercher les causes de cet écart. (Nariman , 2016, p. 155)

### **3. Etudes empirique : tester l'approche RNA au sein du groupe SAIDAL**

Afin de répondre aux exigences du document de recherche, nous allons toutes au long de cette étude empirique d'utiliser un modèle RNA pour



analyser un ensemble de ratios financiers calculer à l'aide des états financiers du groupe SAIDAL.

**3.1 Bref présentation du groupe SAIDAL :** les faits historiques les plus importants pour le groupe peuvent se résumer dans le tableau suivant :

**Table N°2. Historique du groupe SAIDAL**

1929	Création de la pharmacie par ordonnance présidentielle ayant pour but le monopole de l'état sur la fabrication et la commercialisation des produits pharmaceutiques à usages humains.
1971-1975	L'unité de production d'El Harrach est rachetée en deux étapes (1971 puis 1975) les unités de BIOTIC et PHARMAL.
1982	A la suite de la restructuration de la pharmacie centrale algérienne, par le décret 82/161 sa branche de production est promulguée en avril 1982 en entreprise de production nationale création de SAIDAL.
1988	La chaîne consécutive de rachat chez le groupe SAIDAL c'est encor rafraichie avec l'intégration officielle du projet antibiotique de Médéa qui appartenait à la SNIC (société nationale des industries chimiques).
1989	Suite à la mise en œuvre des réformes économiques le groupe SAIDAL devient une EPE entreprise publique économique avec autonomie de gestion.
1997	Le conseil de l'entreprise décide l'adoption d'une démarche de restructuration qui va métamorphoser l'entreprise en groupe industriel composé de 3 filiales (pharmal, biotique, Antibiotical).
2014	Aprêt la transformation vient la fusion par voit d'absorption des filiales ANTIBIOTICAL, PHARMAL, et BIOTIC détenues à 100 % par le groupe en 2014
Actuellement	Actuellement le portefeuille du groupe SAIDAL est constitué de 8 unités de production, 3 unités commerciales, d'une filiale détenue à 100 pourcents, et de 9 participations dont une seule majoritaire.

**Source :** établit par nous-même.

### 3.2. Méthodologie d'utilisation de la base de données quantitatives

Les 60 paramètres de la base de données quantitatives illustrer sur les annexes 1, 2 et 3 représentent la valeur initiale de l'échantillon utiliser dans les étapes de classification à l'aide du réseau de neurones artificiels. L'utilisation de cet échantillon de travail dans le document

de recherche a été subdivisé selon la démarche illustrer sur le tableau suivant :

**Table N° 3. Pourcentage adopté pour l'apprentissage et l'utilisation du RNA**

	Ratio	Taux d'analyse pour chaque phase				Taux d'analyse dans chaque groupe			Taux général des données d'analyse
		Apprentissage	Validation	Test					
6	Ratios de liquidité et de rentabilité	50 %	25%	25 %	18	10	4	4	100%
8	Ratios de financement	50 %	25 %	25 %	24	12	6	6	100 %
6	Ratios de d'exploitation	50 %	25 %	25 %	18	10	4	4	100 %

**Source :** établi par nous-même.

Pour conduire la recherche à terme nous avons identifié l'éditeur Pycharm comme environnement de développement intégrer appartenant au logicielle R capable de manipuler des matrices et de mettre en œuvre des algorithmes. L'avantage du programme et dans sa capacité à analyser et à tester des données pour édifier des modèles RNA exploitable dans la prédiction et la classification.

### 3.3 Conception du réseau de neurones artificiels à l'aide du langage de programmation python

La démarche de conception du réseau de neurones artificiels adéquat avec le problème de recherche s'est accentuée sur le langage de programmation python et l'éditeur de texte jupyter.

#### 3.3.1 Paramètres et nomenclature du modèle

Étant donné l'état de l'art la configuration du réseau doit porter sur le choix de la structure et des paramètres adéquats avec le problème de recherche pour garantir le succès des opérations liées au réseau (de l'apprentissage, au test, a la confirmation). Par conséquent les paramètres initiaux du RNA peuvent se traduire dans le tableau suivant :

**Table N° 4. Paramètres et nomenclature du RNA**


<b>Variable d'entrée</b>	<ul style="list-style-type: none"> <li>- Ratio de financement.</li> <li>- Ratio de liquidité et rentabilité.</li> <li>- Ratio d'exploitation.</li> </ul>
<b>Nomenclature</b>	<ul style="list-style-type: none"> <li>- Type du modèle RNA développer : RNA multicouche.</li> <li>- Fonction d'erreur: sparse_categorical_crossentropy.</li> <li>- Nombre de couches cachées : 3</li> <li>- Nombre neurones dans la (1,2,3) couche : 20, 15, 16.</li> <li>- Algorithme : rétro-propagation du gardien.</li> <li>- Pas d'apprentissage (learning rate) : 0.01.</li> <li>- Nombre d'itération (epochs) : variable (2000 à 3000 itérations).</li> <li>- Fonction d'activation : sigmoïde.</li> <li>- Couche de sortie: 1 couche.</li> </ul>
<b>Codification binaire</b>	<ul style="list-style-type: none"> <li>- 0 erreur significative.</li> <li>- 1 erreur modérée.</li> </ul>

Source : établi par nous-même.

### 3.3.2 Démarche d'implémentation du RNA

L'implémentation du RNA propre à notre étude s'est accentué sur la démarche suivante :

Figure N°3. Démarche d'implémentation du RNA



Source : établi par nous-même.

### 3.3.3 Codification du RNA

Après la phase de transfert de la base de données au de la population d'apprentissage vient la phase de formalisation du réseau, pendant cette étape nous avons préparé un code principal par lequel nous initialisant tout-ce qui doit être contenu dans le graphe à savoir la fonction de pré-activation, la

fonction d'activation, la fonction de calcul du cout (erreur), la fonction de calcul de la précision. Vu l'importance de cette phase nous pouvons détailler le code source utilisé dans la formalisation du RNA sur les figures (4), (5) et (6) comme suivant :

**Figure N°4. Importation des bibliothèques**

```
In [ ]: import numpy as np
import tensorflow as tf
import sys
import matplotlib.pyplot as plt
import pandas as pd
from sklearn.preprocessing import StandardScaler
```

**Source :** Extrait de l'éditeur de texte jupyter.

Dans la figure N°4 nous avons importé toutes les bibliothèques essentielles pour le bon fonctionnement du code RNA, à cet égard la première ligne du code (import numpy) nous permet d'importer une extension capable de manipuler des matrices et des tableaux multidimensionnels ainsi que les fonctions mathématiques qui s'opèrent sur ces tableaux, concernant le code import tensorflow et sklearn nous les avons utilisés pour faciliter l'apprentissage automatique du modèle. La bibliothèque matplotlib.pyplot écrite sur la quatrième ligne du code a pour objectif l'utilisation des différents graphes capables de suivre et d'afficher l'historique de l'apprentissage et du test. Quant à l'avant dernière ligne (import pandas) nous avons opté pour cette extension pour faciliter la manipulation des grandes quantités de données.

**Figure N°5. Configuration de l'architecture du modèle**

```
In [2]: model = tf.keras.models.Sequential()
#model.add(tf.keras.layers.Flatten(input_shape=[2]))
model.add(tf.keras.layers.Dense(24, activation="relu"))
model.add(tf.keras.layers.Dense(18, activation="relu"))
model.add(tf.keras.layers.Dense(18, activation="relu"))
model.add(tf.keras.layers.Dense(1, activation="sigmoid"))

WARNING: Logging before flag parsing goes to stderr.
W0129 21:25:20.471410 17708 deprecation.py:506] From c:\users\asus\appdata\local\programs\python\python37\lib\site-packages\tensorflow\python\ops\init_ops.py:1251: calling VarianceScaling.__init__ (from tensorflow.python.ops.init_ops) with dtype is deprecated and will be removed in a future version.
Instructions for updating:
Call initializer instance with the dtype argument instead of passing it to the constructor

In [ ]: model.compile(loss="binary_crossentropy",
optimizer = "adam",
metrics = ["accuracy"])
```

**Source :** Extrait de l'éditeur de texte jupyter.

La deuxième partie du code illustré sur la figure précédente nous permet de modéliser la structure initiale du RNA par la ligne de code (model = tf.keras.models.Sequential()) en premier lieu. Puis vient la phase d'identification des différentes couches cachées et fonction d'activation élaborée par les lignes de code (model.add(tf.keras.layers.Dense(24,

activation=relu), pour ensuite en finir par le calcul de l'erreur et de la précision.

**Figure N°6. Affichage de la courbe d'erreur/précision des données d'apprentissage/teste**

```
In [ ]: loss_cuve = history.history["loss"]
acc_cuve = history.history["acc"]
loss_val_cuve = history.history["val_loss"]
acc_val_cuve = history.history["val_acc"]
plt.plot(loss_cuve, label="Train")
plt.plot(loss_val_cuve, label="Val")
plt.legend(loc="upper left")
plt.title("loss")
plt.show()
plt.plot(acc_cuve, label="Train")
plt.plot(acc_val_cuve, label="Val")
plt.legend(loc="upper left")
plt.title("Accuracy")
plt.show()
```

**Source :** Extrait de l'éditeur de texte jupyter.

Le dernier parti du code a eu pour objectif l'enregistrement de l'évolution de l'erreur et de la précision des données de test et apprentissage dans des graphes pour ensuite les afficher à la fin.

### 3.4 Apprentissage et validation du modèle

Les résultats tirés de l'apprentissage du RNA peuvent être présentés sur le tableau suivant :

**Table N°5. Capacité prédictive du modèle selon la population de test**

Modèles					
Population d'estimation/apprentissage/Test : Par %.					
Population d'estimation apprentissage			Population d'estimation/Test		
Phase	MSE	Précision	MSE	Précision	
1	0.6701	0.5776	0.6396	0.799	
2	0.5880	0.6315	0.4724	0.887	
3	0.5270	0.6355	0.3977	0.899	
4	0.4597	0.7641	0.3289	0.899	
5	0.3751	0.9152	0.2374	0.998	
6	0.2891	0.9668	0.1533	0.983	
7	0.2182	0.9891	0.1080	0.991	
8	0.1709	0.9922	0.0801	0.9934	
9	0.1340	0.9934	0.0664	1.00	
10	0.0717	0.9951	0.0331	1.00	


**Source :** établi par nous-même.

Comme indique dans le tableau, la démarche d'apprentissage du RNA ces arrêter aux 10 stades d'apprentissage. Le réseau après 10 phases d'apprentissage a pu atteindre une erreur moyenne quadratique la moins élevée aussi bien pour l'échantillon d'apprentissage et celui de l'échantillon de test qui s'élèvent respectivement à 0.0717 et 0.0331, de plus la précision du modèle propre à notre recherche a atteint après la 10 phase d'entraînement une valeur qui s'élève à 0.9951 signifiants ainsi presque une classification complète de la population d'apprentissage. De plus la durée de traitement

confiné dans un intervalle de  $[2s, 4s]$ , tout c'est paramètres et indicateurs nous ont amené à choisir ce modèle comme RNA finale pour la classification et la détection des risques inhérents.

Pour vérifier la solidité de notre modèle et des analyses que nous avons avancées, nous pouvons représenter l'erreur et la précision dans les diagrammes suivants :

**Figure N°7. Courbe erreur et précision (Population apprentissage/ validation)**



**Source :** Extrait de l'éditeur de texte jupyter.

Les quatre courbes illustrées sur les figures précédentes reflètent l'évolution de l'erreur moyenne quadratique et de la précision (Accuracy) tout au long de la période d'entraînement sur les deux échantillons (apprentissage et test). Les deux diagrammes affirment que l'arrêt de l'apprentissage à la 10 phase est indispensable, vu qu'à partir de cette dernière l'erreur de test commence à enregistrer une augmentation suivie d'une précision stable. De ce fait le constat que nous avons fait nous a amenés à prendre la décision d'arrêter l'apprentissage pour éviter le surentraînement au le choix des hyperparamètres.

### 3.5 Implémentation du modèle RNA

Compte tenu des paramétrées cités ci-dessus, le réseau de neurones artificiels a simulé pendant la phase de test les prédictions suivantes :

**Table N°6. Résultats empiriques du modèle RNA**

8	Class	Ratio	X <sub>1</sub>	X <sub>2</sub>	T	Py	Cp	R	constat
2017	R.L.R	R.L.R4	0.024	(0.023)	0	0.304	-0.5	-0.5	E.S
2015	R.L.R	R.L.R4	0.041	(0.006)	0	0.598	-0.5	+0.5	E.M
2017	R.F	R.F1	1.311	(0.694)	0	0	-0.5	-0.5	E.S
2015	R.L.R	R.L.R2	(2.342)	(1.342)	0	0	-0.5	-0.5	E.S
2016	R.F	T.F8	1.098	0.098	1	0.989	+0.5	+0.5	E.M
2017	R.E	R.E5	0.633	(0.119)	0	0.001	-0.5	-0.5	E.S
2015	R.F	R.F5	0.118	(0,07)	0	0.036	-0.5	-0.5	E.S
2016	R.F	FRN	1.024	0.0242	1	0.550	+0.5	+0.5	E.M
2016	R.L.R	R.L.R4	0.058	(0.01)	0	0.544	-0.5	+0.5	E.S

2017	R.E	R.E2	0.249	0.1	1	0.974	+0.5	+0.5	E.M
2017	R.E	R.E1	0.614	0.262	1	0.996	+0.5	-0.5	E.M
2015	R.L.R	R.L.R6	0.07	(0.015)	0	0.466	-0.5	-0.5	E.S
<b>Nomenclature du tableau :</b> <b>X1, X2 :</b> désigne les entrées utiliser pour la généralisation. <b>R.F :</b> ratio financier. <b>R.L.R :</b> ratio de liquidité et de rentabilité. <b>R.E :</b> ratio d'exploitation.						<b>Py :</b> fait référence à la prédiction finale faite par le modèle RNA. <b>T :</b> les résultats réels appropriés pour chaque entré. <b>Cp :</b> classification attendue. <b>E.M :</b> erreur modérée <b>E.S :</b> erreur signifiante.			

**Source :** établit par nous-même à partir des résultats de RNA.

À partir des résultats d'apprentissage et test (table N°5 et 6), nous pouvons en conclure que :

L'utilisation des réseaux de neurones artificiels dans la classification et la détection des erreurs significatives nous a permis dans cette partie de détecter selon la règle principale de régression logistique (1 pour l'erreur modérée et 0 pour l'erreur significative) l'existence de 7 erreurs significatives répartie selon l'échantillon de test sur (R.L.R4/2017, R.E1/2017, R.L.R2/2015, R.E5/2017, R.F5/2015, R.L.R/2016, R.L.R6/2015).

Compte tenu des résultats retenus toutes au long de la phase de mise en œuvre du réseau de neurones artificiel, nous pouvons en conclure que l'auditeur doit dans le cas d'apparition d'erreurs significatives adopter d'autres démarches d'audit par lesquelles il élabore et planifier des procédures supplémentaires plus détaillées lui permettant d'enquêter sur les causes de ces prédictions et de prendre des décisions concernant ces dernières.

#### 4. Conclusion :

La détection des erreurs significatives par le procédé d'audit analytique s'installe durant ces deux dernières décennies parmi les problèmes les plus profonds auxquelles l'auditeur fait face lors de l'exécution du programme d'audit. Bien que ce problème n'a pas pu succomber aux méthodes statistiques d'analyse conventionnelles, plusieurs chercheurs sont parties vers l'utilisation d'autres méthodes plus avancées tels les réseaux de neurones artificiels basé sur l'apprentissage profond et la régression logistique. À ce titre, nous avons essayé tout au long de ce document de recherche de réutiliser le paradigme d'évaluation des erreurs significatives par les RNA avancé par les différents chercheurs (omide, Hossein, Sharda et autres) durant c'est dernière décennie, dans le but d'obtenir de nouvelles preuves qui nous permettront de renforcer cette thèse avancée et d'évaluer ces résultats dans l'environnement économique algérien. Par conséquent, l'étude nous a permis d'aliénées les résultats suivants :

- Parmi les règles essentielles à respecter lors de l'apprentissage d'un réseau de neurones artificiel l'utilisation d'un ensemble de données représentatif de la population général.

- L'efficacité et l'efficience du réseau de neurones artificiels dépend essentiellement du choix des paramètres (poids, fonction d'activation et fonction de pré-activation) fait par l'auditeur.
- Le procédé de l'audit analytique jumelé avec les RNA offre pour les auditeurs un outil d'analyse et de prédiction très performant.
- L'application de la démarche d'audit via les réseaux de neurones artificiels, exige des auditeurs une délimitation préliminaire des différentes zones dangereuses et zones modérées d'une manière binaire adaptée à la nouvelle méthode d'apprentissage automatique.
- Le modèle RNA propre à notre étude a été intégré à la démarche d'audit afin de prouver ses performances, à cet égard les résultats obtenus de l'échantillon de test, ont permis de prédire correctement 13 valeurs sur 20 ou un total de précision qui dépasse les 96%, par conséquent les RNA peuvent jouer un rôle très important dans la détection des erreurs inhérentes.
- L'apprentissage d'un réseau de neurones artificiel par l'algorithme de la descente du gradient permet de modéliser des modèles capables de faire des prédictions qui approche de la classification globale 100%.
- Bien que le choix des hyperparamètres des modèles d'apprentissage en profondeur tel que le nombre de couches cachées, la fonction d'activation, le taux d'apprentissage, ainsi que l'importance de la prédiction, soit connu. On ignore encore comment les machine apprennent et arrive à en déduire des conclusions sur la classification des risques en matière d'audit.

Pour finir, il faut savoir que la méthode d'évaluation basée sur les RNA dans l'environnement algérien est un paradigme nouveau qui peut-être adopter par les entreprises et bureaux d'audits dans le but de bénéficier des différentes méthodes de prédiction et d'analyse linéaire et non linéaire offerte par cette application de l'intelligence artificielle.

En plus de l'acquisition d'une expérience artificielle, le penchant vers l'adaptation de cette démarche nouvelle va permettre aux experts humains d'ouvrir la boîte noire des RNA et de ce fait il va leur offrir la possibilité de comprendre comment un modèle RNA arrive à apprendre est-il vont par conséquent acquérir des connaissances très avancées dans le domaine de l'extraction de relation entre variables non linéaires et phénomène non structurable. Mais à cet égard il faut savoir qu'un approfondissement de connaissance est nécessaire chez les auditeurs est différentes parties concernées pour utiliser la démarche RNA d'une manière optimale et



développer des méthodes de paramétrage qui vont permettre d'atteindre le choix des hyperparamètres essentielle et adapté aux problèmes de recherche. Par conséquent élargir le champ d'application de l'audit via les RNA par l'introduction de cette démarche dans d'autres types d'audits à savoir l'audit de conformité, l'audit des systèmes d'information, l'audit opérationnel, et l'audit fiscal.

## 5. Bibliographie

- Adrien, M. (2017). vers une Utilisation Synaptique de Composants Mémoire Innovants pour électronique Neuro-Inspirée. Thèse Doctoral Spécialité électronique, Université Paris-Saclay.
- Bendaoud , Y. (2014). Prédiction des Résistances Mécanique des Bétons à Base des Ciments Composées en Utilisant les Réseaux De Neurones Artificiel. Mémoire Magister Spécialité Système, université Constantine.
- CCury, D. (2018). Analytical Procedures. *Journal of Technical*, 18.
- Chow, D. (2009). *Analytical Procedures – A Powerful Tool For Auditors*. Consulté le Septembre 20, 2019, sur [www.hkiaat.org:www.hkiaat.org/images/uploads/articles/Analytical.pdf](http://www.hkiaat.org:www.hkiaat.org/images/uploads/articles/Analytical.pdf)
- Davide, P. (2008). Proposition de L'architecture Cortexioniste pour L'intelligence Comportemental de Créature Artificielles. Thèse Doctoral Spécialité informatique, Université Toulouse.
- Dilek, A., & Seyma , C. (2015). Prediction of Financial Crisis With Artificial Neural Network : An Empirical Analysis on Turkey. *International Journal of Financial Research*, 06(04).
- Eija, K. (2007). Integrating Analytical Procedures Into the Continuous AuditingEnvironnement. *Journal of Information Systems and Technology Management*, 1(3).
- Fekhi, N. (1989). L'apport des Réseaux de Neurones Artificiels Appliqués au Management des Risque Comme Outil de L'audit,. Thèse Doctorat spécialité management des Organisation, Université Tlemcen.
- Garlos, P. (2014). The Usefulness of Analytical Procédures : An Empirical Approach in the Auditing Sector in Portugal. *International Journal of Business and Social Research*, 04.
- Jana. (2015, October). The Application of Analytical Procedures in the Audit Process. Submitted in Fulfilment of the Requirements for the Degree MCom in Auditing, University of Pretoria.
- Kalkir , B., & Olgac, V. (2016). Performance Analysis of Various Activation Fonctions in Generalized MLP Arcitectures of Neural Networks.

- International Journal of Artificial Intelligence and Expert systems*, 01(01).
- Kouskivara, A. (2003). Artificial Neural Networks in Auditing : State of the Art., *Turky center for Computer Science*(509).
- Kritzinger, B. (2017). The Application of Analytical Procedures in the Audit Process: A South African Perspective. *South African Business Review*, 21.
- Kumar, K., & Clarence, T. (2011). Artificial Intelligence in Financial Distress Prediction. *Journal of Intelligent System*, 05.
- Mohammad, J., & Youcef, H. (2017). Application of Artificial Neural Networks in Information System of Management Accounting. *International Journal of Mechatronics, Electrical and Computer Technology*, 07.
- Nariman , Z. (2016). Modélisation de la relation Débit-MSE par les Modèles Régressifs et les réseaux de neurones Artificiels. mémoire de Master Spécialité Hydraulique, Ecole National Supérieur D'hydraulique.
- Nichlas, E. (2013). Analytical Procedures a Practice-base Approach. (S. o. auditing, Éd.)
- omide, P., Hossein, N., & Zeinab, A. (2012). Identifying Qualified Audit opinions by Artificial Neural Networks. *African Journal of Business Management*, 44(06).
- Safna , F., & Rekha, S. (2018). Artificial Neural Network Based Data Mining. *International Journal of Innovation Science*, 05(04).
- Sathyamoorthy, S. (2015). neural Networks in Data Mining. *International Journal of Engineering and Technology*, 02(09).
- Sibi, P., Allway, J. A., & Siddarth , P. (2005). Analyse of Different Activation Functions Using Back Propagation. *Journal of theoretical and Applied Information Technology*, 47(1).
- Singh, G., & Ashima. (2014). Neural Networks in Data Mining. *Journal of Engineering*, 04(3).
- Singh, R., & Olgac, V. (2014). Neural Networks in Data Mining. *Journal of Engineering*, 04(03), 112.
- Zahir , A. (2013). Identification des Systèmes Non Linéaire par les Réseaux de Neurones. Mémoire magister Spécialité Système, Université de Béjaia.

## 6. Annexes :

**Annexe N°1. Base de données (ratios de financement)**

<b>Ratios de financement</b>					
<i>Ratio de financement permanent = <math>\frac{\text{capitaux permanents}}{\text{Actifs non courants}}</math></i>					
Années	Capitaux permanents (1)	Actifs non courants (2)	$\frac{1}{2} \times 100$	Résultat	RNEt
2014	26079391337,35	13003229373,47	200,56%	---	R.F1
2015	28293754070,79	15767186133,72	179,44%	(21,12)	0
2016	33341294604,20	17744616003,75	187,89%	(12,67)	0
2017	40709593308,27	31047579920,35	131,12%	(69,44)	0
<i>Ratio de financement propre = <math>\frac{\text{capital propres}}{\text{Actifs non courants}}</math></i>					
Années	Capitaux propres (1)	Actifs non courants (2)	$\frac{1}{2} \times 100$	Résultat	R.F2
2014	17590664386,45	13003229373,47	135,27%	---	
2015	20465934577,15	15767186133,72	129,80%	(5,47)	0
2016	21194220542,46	17744616003,75	119,44%	(15,83)	0
2017	28110282781,27	31047579920,35	90,53%	(44,47)	0
<i>Ratio de solvabilité = <math>\frac{\text{somme des actifs}}{\text{Somme des dettes}}</math></i>					
Années	Somme des actifs (1)	Somme des dettes (2)	$\frac{1}{2} \times 100$	Résultat	R.F3
2014	31587704405,93	13997040019,48	225,6%	---	
2015	34921900820,68	14455966243,53	241,7%	16,1	1
2016	37607954210,58	17871345332,1	201,4%	(24,2)	0
2017	46959384006,72	18849101225,45	249,1%	23,5	1
<i>Ratio de financement extern = <math>\frac{\text{Somme des dettes}}{\text{Somme actifs}}</math></i>					
Années	Somme des dettes (1)	Totale des actifs (2)	$\frac{1}{2} \times 100$	Résultat	R.F4
2014	13997040019,48	31587704405,93	44,31%	---	
2015	14455966243,53	34921900820,68	41,39%	(2,92)	0
2016	17871345332,1	37607954210,58	47,52%	3,21	1
2017	18849101225,45	46959384006,72	40,13%	(4,18)	0
<i>Ratio d'indépendance financière = <math>\frac{\text{capitaux propres}}{\text{Somme des dettes}}</math></i>					
Années	Capitaux propres (1)	Somme de dettes (2)	Somme de dettes (2)	---	R.F5
2014	17590664386,45	13997040019,48	125,67%		
2015	20465934577,15	14455966243,53	141,57%	15,9	1
2016	21194220542,46	17871345332,1	118,59%	(7,08)	0
2017	28110282781,27	18849101225,45	149,13%	23,46	1
<i>Le fonds de roulement net = Capitaux Permanent – actif immobilises</i>					
Années	Capitaux Permanent (1)	Actif Immobilises (2)	1 – 2	---	R.F6
2014	17590664386,45	13003229373,47	4587435013,07		
2015	20465934577,15	15767186133,72	4698748443,43	111313436	1

2016	21194220542,46	17744616003,75	3449604538,71	(1137830475)	0
2017	28110282781,27	31047579920,35	2937297139,08	(1650137874)	0
<i>Le BFR = [actif circulant – Disponibilités] – [Dettes C.T – Dettes Financières]</i>					
Années	Actifs d'exploitation (1)	Dettes d'exploitation (2)	1-2	---	RF.7
2014	10367338316,26	13997040019,48	-3629701703,22		
2015	10148510066,42	14455966243,53	-4307456177,11	(677754473,89)	0
2016	10836504244,54	16413733668,12	-5577229424,12	(1947527720,9)	0
2017	10345527601,28	18849101225,45	-8503573624,17	(4873871920,95)	0
<i>trésorerie nette = FRN – BFR</i>					
Années	Actifs d'exploitation (1)	Dettes d'exploitation (2)	$\frac{1}{2} \times 100$	---	R.F8
2014	4587435013,07	-3629701703,22	8217136716,29		
2015	4698748443,43	-4307456177,11	9006204620,54	789067904,25	1
2016	3449604538,71	-5577229424,12	9026833962,83	809697246,54	1
2017	2937297139,08	-8503573624,17	11440870763,25	3223734046,96	1

Source : établi par nous-même à partir des états financiers du groupe SAIDAL.

## Annexe N°2. Base de données (Ratios de liquidité et de rentabilité)

Ratios de liquidité et de rentabilité					
<i>Ratio de liquidité général = <math>\frac{\text{actifs courants}}{\text{passifs courants}}</math></i>					
Années	Actifs courants (1)	Passifs courants (2)	$\frac{1}{2} \times 100$	Résultat	R.L.R1
2014	18584475032,46	5508313068,58	337,38%	---	
2015	19154714686,96	6682146749,89	286,65%	(50,73)	0
2016	19863338206,83	6266659605,92	316,96%	(20,42)	0
2017	15911804086,37	6249790698,45	254,59%	(82,79)	0
<i>Ratio de liquidité Réduite (Quick ratio) = <math>\frac{\text{actifs courants} - \text{les stocks}}{\text{passifs courants}}</math></i>					
Années	Actifs courants (1)	Passifs courants (2)	$\frac{1}{2} \times 100$	Résultat	R.L.R2
2014	12977558619,49	5508313068,58	235,59%	---	
2015	14188814667,83	6682146749,89	212,33%	(23,26)	0
2016	14243067606,28	6266659605,92	227,28%	(8,31)	0
2017	10622567798,29	6249790698,45	169,96%	(65,63)	0
<i>Ratio de liquidité Immédiate = <math>\frac{\text{Trésorerie}}{\text{Dettes C.T}}</math></i>					
Années	Trésorerie (1)	Dettes C.T (2)	$\frac{1}{2} \times 100$	Résultat	R.L.R3
2014	5198576727,01	5508313068,58	94,39%	---	
2015	5987644631,35	6682146749,89	89,60%	(4,79)	0
2016	6008273973,10	6266659605,92	95,87%	(1,48)	0
2017	5547716495,37	6249790698,45	88,76%	(5,63)	0
<i>Ratio de rentabilité des actifs = <math>\frac{\text{Résultat global}}{\text{Total des actifs}}</math></i>					
Années	Résultat global (1)	Total des actifs (2)	$\frac{1}{2} \times 100$	Résultat	R.L.R4

<b>2014</b>	1516528274,51	31587704405,93	4,801%	---	
<b>2015</b>	1443809602,14	34921900820,68	4,134%	(0,667)	<b>0</b>
<b>2016</b>	2098704713,91	37607954210,58	5,580%	0,779	<b>1</b>
<b>2017</b>	1146007865,45	46959384006,72	2,440%	(2,361)	<b>0</b>
<i>Ratio de rentabilité des capitaux propres = <math>\frac{\text{Résultat net}}{\text{Capitaux propres}}</math></i>					
<b>Années</b>	Résultats net (1)	Capitaux propres (2)	$\frac{1}{2} \times 100$	Résultat	R.L.R5
<b>2014</b>	1172407473,19	17590664386,45	6,664	---	
<b>2015</b>	1143817990,89	20465934577,15	5,588	(1,076)	<b>0</b>
<b>2016</b>	1459446837,32	21194220542,46	6,886	0,222	<b>1</b>
<b>2017</b>	1187575551,73	28110282781,27	4,224	(2,44)	<b>0</b>
<i>Ratio de rentabilité de l'exercice = <math>\frac{\text{Résultat total}}{\text{Capitaux propres}}</math></i>					
<b>Années</b>	Résultat global (1)	Capitaux propres (2)	$\frac{1}{2} \times 100$	Résultat	R.L.R6
<b>2014</b>	1516528274,51	17590664386,45	8,621	---	
<b>2015</b>	1443809602,14	20465934577,15	7,045	(1,576)	<b>0</b>
<b>2016</b>	2098704713,91	21194220542,46	9,902	1,281	<b>1</b>
<b>2017</b>	1146007865,45	28110282781,27	4,076	(4,545)	<b>0</b>

**Source :** établi par nous-même à partir des états financiers du groupe SAIDAL.

### Annexe N°3. Base de données (Ratios d'exploitation)

<b>Ratios d'exploitation</b>					
<i>ratio de rotation clients = <math>\frac{\text{En - cours Clients}}{\text{Chiffre d'affaire TTC}}</math></i>					
<b>Années</b>	<b>Cours clients (1)</b>	<b>Chiffre d'affaire TTC (2)</b>	$\frac{1}{2} \times 100$	<b>Résultat</b>	R.E1
<b>2014</b>	3448794401,79	9789025905,91	35,23%	---	
<b>2015</b>	3822680037,51	9984043757,71	38,28%	3,05	1
<b>2016</b>	3854232178,76	5791338867,81	66,55%	31,32	1
<b>2017</b>	3433549096,55	5591749511,00	61,40%	26,27	1
<i>ratio de rotation fournisseurs = <math>\frac{\text{EN - cours fournisseurs}}{\text{chiffre d'affaires TTC}}</math></i>					
<b>Années</b>	<b>Fournisseurs (1)</b>	<b>Chiffre d'affaires TTC (2)</b>	$\frac{1}{2} \times 100$	<b>Résultat</b>	R.E2
<b>2014</b>	1460434895,94	9789025905,91	14,91%	---	
<b>2015</b>	1931770182,61	9984043757,71	19,34%	4,43	1
<b>2016</b>	1266013920,23	5791338867,81	21,86%	6,95	1
<b>2017</b>	1393961106,29	5591749511,00	24,92%	10,01	1
<i>Ratio de capitaux propres = <math>\frac{\text{capitaux propres}}{\text{actifs Immobilisés}}</math></i>					
<b>Années</b>	<b>Capitaux propres (1)</b>	<b>Actifs immobilisés (2)</b>	$\frac{1}{2} \times 100$	<b>Résultat</b>	R.E3
<b>2014</b>	17590664386,45	13003229373,47	135,27%	---	
<b>2015</b>	20465934577,15	15767186133,72	129,80%	(5,47)	0
<b>2016</b>	21194220542,46	17744616003,75	119,44%	(15,83)	0
<b>2017</b>	28110282781,27	31047579920,35	90,53%	(44,74)	0

$\text{Ratio de rotation des l'ensemble des actifs} = \frac{C.A}{\text{actifs } G}$					
Années	C.A (1)	Actifs G (2)	$\frac{1}{2} \times 100$	Résultat	R.E4
2014	9789025905,91	31587704405,93	30,98%	---	
2015	9984043757,71	34921900820,68	28,58%	(2,4)	0
2016	5791338867,81	37607954210,58	15,39%	(15,59)	0
2017	5591749511,00	46959384006,72	11,90%	(19,08)	0
$\text{Ratio de rotation des actifs immobilisés} = \frac{C.A}{\text{actifs immobilisée}}$					
Années	C.A (1)	Actifs Immobilisée (2)	$\frac{1}{2} \times 100$	Résultat	R.E5
2014	9789025905,91	13003229373,47	75,28%	---	
2015	9984043757,71	15767186133,72	63,32%	(11,96)	0
2016	5791338867,81	17744616003,75	32,62%	(42,66)	0
2017	5591749511,00	31047579920,35	18,01%	(57,27)	0
$\text{Ratio d'integration} = \frac{\text{Valeur Ajoutée brute}}{\text{Total des produits}}$					
Années	Valeur Ajoutée brut (1)	Total des produits (2)	$\frac{1}{2} \times 100$	Résultat	R.E6
2014	6003372362,35	9836622190,20	61,030	---	
2015	5505373029,01	9972150634,01	55,207	(5,823)	0
2016	3829130322,74	6333585788,50	62,457	1,427	1
2017	2959715316,62	5369730612,06	55,118	(5,912)	0

Source : établit par nous-même à partir des états financiers du groupe SAIDAL.