



INDABAX 2022 Proceedings
INDABAX 2022 Côte d'Ivoire Proceedings
Second Conference of Intelligence Artificial on
Contribution of artificial intelligence to the development of
Côte d'Ivoire
December 20-21 2022
Université Félix Houphouët-Boigny
Cocody Abidjan, Côte d'Ivoire



Comité d'édition
Beman Hamidja KAMAGATE
Mamadou DIARRA

Table des matières

1	Avant propos.....	3
2	Présentation de la conférence	4
2.1	Participants et partenaires	4
2.2	Comité d'organisation	5
2.3	Comité scientifique.....	6
	Prof. Selam WAKTOLA, Netherlands Cancer Institute (Pays-Bas)	6
3	Différentes allocutions	7
3.1	Allocution du PCO	7
3.2	Allocution du Doyen de l'UFR MI.....	8
3.3	Allocution du Vice-Président de l'université.....	9
3.4	Listes des communications.....	10
3.5	Liste des conférences invitées.....	10
4	Programme de la conférence	11
5	Communications des universitaires.....	12
5.1	Contribution of artificial intelligence to the quality improvement of the agriculture and the environment in Cote d'Ivoire	12
5.2	Deep Learning for fake news detection in social media	17
5.3	Gestion intelligente de la consommation d'électricité à l'aide d'un système multi-agents et du processus de saut.....	24
4.	Conclusion	27

1 Avant propos

Le Conférence INDABAX, a débuté en 2018 en tant programme visant à renforcer les échanges d'expériences et d'expertises entre les chercheurs autour des thématiques de l'intelligence artificielle, de l'apprentissage machine et l'apprentissage profond. INDABAX vise à permettre à davantage de personnes de contribuer à l'avancée de l'intelligence artificielle sur notre continent. A ce jour, 25 pays organisent des évènements INDABAX chaque année.

La présente édition constitue la deuxième édition que le comité INDABAX Côte organise en collaboration avec l'Unité de Formation de Recherche de Mathématiques Informatique (UFR MI) de l'Université Félix Houphouët Boigny (UFHB) et du Centre National de Calcul de Côte d'Ivoire (CNCCI).

Le programme de cette édition, se décline en 03 communications scientifiques, sélectionnées parmi les 05 soumis, et des 04 conférences invitées présentées par des spécialistes de renommée internationale. Cette édition a aussi vu la réalisation d'une séance de formation sur le *Deep Learning* à l'endroit des étudiants et les enseignants-chercheurs. Il faut aussi noté la présence effective des entreprise CIE et SAH Analytics qui en plus des communications sur des cas d'utilisation en entreprise ont contribué à l'animation d'un panel d'expert sur le thème : « **Intelligence Artificielle et le développement de la Côte d'ivoire : Enjeux et Défis.** »

2 Présentation de la conférence

2.1 Participants et partenaires

2.2 Comité d'organisation

Dr. Ismael KONE, Université Virtuelle de Côte d'Ivoire (Côte d'Ivoire)
Dr. Louis Paul SEKA, Université Félix Houphouët-Boigny (Côte d'Ivoire)
Dr. Mamadou DIARRA, Université Félix Houphouët-Boigny (Côte d'Ivoire)
Dr. Abdoul MAIGA, Université Félix Houphouët-Boigny (Côte d'Ivoire)
Dr. Ida Brou ASSIE, Université Félix Houphouët-Boigny (Côte d'Ivoire)
Dr. Mohamed DIALLO, Université Félix Houphouët-Boigny (Côte d'Ivoire)
Dr. Issa Traoré, Institut de Recherche en Mathématiques (Côte d'Ivoire)
Dr. Beman Hamidja KAMAGATE, Ecole Supérieure Africaine des TIC (Côte d'Ivoire)
M. Medard KOUASSI, Université Félix Houphouët-Boigny (Côte d'Ivoire)
Dr. Kpinna Tiekoura COULIBALY, Ecole Supérieure Africaine des TIC (Côte d'Ivoire)
Dr. Ngolo KONATE, Université Félix Houphouët-Boigny (Côte d'Ivoire)
M. Stanislas ASSOHOON, Université Jean Lorougnon Guédé (Côte d'Ivoire)
M. Patrice BROU, Université Félix Houphouët-Boigny (Côte d'Ivoire)
M. Ibrahim BAKAYOKO, Université Félix Houphouët-Boigny (Côte d'Ivoire)
Dr. Bertin KAYE BI, Université Félix Houphouët-Boigny (Côte d'Ivoire)

2.3 Comité scientifique

Prof. Assohoun ADJE, Université Félix Houphouët-Boigny (Côte d'Ivoire)

Prof. ADOU KABLAN, Université Félix Houphouët-Boigny (Côte d'Ivoire)

Prof. Adama COULIBALY, Université Félix Houphouët-Boigny (Côte d'Ivoire)

Prof. Michel BABRI, Institut National Polytechnique H.B (Côte d'Ivoire)

Prof. Albert BIFET, Telecom Paris (France)

Prof. Vincent MONSAN, Université Félix Houphouët-Boigny (Côte d'Ivoire)

Prof. Selam WAKTOLA, Netherlands Cancer Institute (Pays-Bas)

Prof. Bernard DOUSSET, Université Paul Sabatier de Toulouse (France)

Prof. Souleymane OUMTANAGA, Institut National Polytechnique H.B (Côte d'Ivoire)

Prof. Abdelghani CHIBANI, Université Paris-Est Créteil (France)

3 Différentes allocutions

3.1 Allocution du PCO

Honorables invites

Chers participants

Honorables partenaires et sponsors

A l'orée de la quatrième révolution numérique, les acteurs majeurs de la transformation digitale que sont les chercheurs et enseignants chercheurs ont décidé à travers cette plateforme d'échange qu'est Indabax de porter la réflexion vers différents acteurs.

Aujourd'hui grâce à vos soutiens nous nous retrouvons à la deuxième Edition portant sur le thème : *Apport de l'intelligence artificielle au développement de la Cote d'Ivoire*

L'IA à travers ses différentes implémentations reste un vecteur de développement important dans l'économie numérique des états et la cote d'Ivoire ne compte pas rester en marge avec divers soutiens et initiatives auprès des instituts, unités des recherches. Cette conférence vise entre autres à :

- Créer un cadre de rencontre pour les acteurs de l'IA
- Construire des communautés dynamiques autour de l'IA
- Promouvoir l'apprentissage et la recherche dans le domaine de l'IA

Cette conférence bien qu'organisé au sein de l'UFR Mathématique Informatique sous la direction du Laboratoire de Mathématique et Informatique n'en demeure pas moins une collaboration entre acteurs de plusieurs Laboratoires et Institut de recherche.

L'objectif vise est de tisser des collaborations, entre les industriels et les universitaires dans le domaine de l'intelligence artificielle, qui permettront la réalisation de solutions informatiques intelligentes pour les industriels. Vue l'intérêt suscité par ces éditions, nous espérons convaincre les partenaires, à travers la réussite de cette deuxième édition, à contribuer à l'organisation des éditions prochaines, susciter plus d'engouement autour de l'intelligence artificielle chez les étudiants, les entreprises, les autorités publiques et faire de l'UFR Mathématiques et Informatique et l'université Félix Houphouët Boigny un pôle d'excellence en intelligence artificielle.

3.2 Allocation du doyen de l'UFR MI

Honorables invités,

Chers sponsors,

Chers participants,

En tant que doyen de l'UFR, je me réjouis de l'organisation de l'édition 2022 de la conférence IndabaX Côte d'Ivoire.

IndabaX est un programme panafricain existant depuis 2018, en vue de contribuer à l'émergence de communautés scientifiques avertis des enjeux liés à l'apprentissage automatique et aptes à développer des solutions innovantes dans ce domaine, pour que le continent africain ne reste pas en marge des évolutions technologiques en cours et à venir. En 2022, IndabaX a sponsorisé 25 pays d'Afrique, dont la Côte d'Ivoire.

Cette édition 2022 de la conférence Indabax sur l'intelligence artificielle (C2IA), qui nous réunit aujourd'hui, est organisée par le laboratoire « Mécanique et Informatique » de l'UFR Mathématiques et Informatique en partenariat avec le centre IDTDS (Intelligent Digital Transformation and Data Strategies) et le centre national de calcul de Côte d'Ivoire (CNCCI) et a pour thème : « Apport de l'Intelligence artificielle au développement de la Côte d'Ivoire ».

La conférence a pour objectif général la vulgarisation et le développement de l'intelligence artificielle en Côte d'Ivoire. En particulier, nous espérons que cette conférence devienne un cadre de rencontre de référence pour les acteurs de l'IA en Côte d'Ivoire, et permette de construire des communautés dynamiques sur l'intelligence artificielle (communautés de chercheurs, entreprises, ingénieur, étudiants, ...). Aussi, elle vise à promouvoir l'apprentissage et la recherche dans le domaine de l'intelligence artificielle dans les universités, vulgariser l'usage de l'intelligence artificielle dans nos entreprises et services publics et à attirer l'attention des autorités universitaires, administratives et politiques sur l'importance de soutenir les initiatives portant sur l'IA en Côte d'Ivoire.

Notre UFR a l'ambition de devenir un pôle d'expertise dans le domaine informatique au moins au tant qu'elle l'est dans le domaine des mathématiques, avec un rayonnement dans toute la planète connectée. Et cette conférence C2IA vise à faire connaître ce que l'UFR peut offrir de mieux dans le domaine de l'informatique.

Je vous souhaite la bienvenue à l'UFR Mathématiques et Informatique pour l'édition 2022 de la conférence IndabaX Côte d'Ivoire en espérant vivement qu'elle sera mémorable et edificatrice.

3.3

Monsieur le Ministre de l'enseignement supérieure et de la recherche scientifique ;

- Monsieur le Ministre de la Communication et de l'Economie Numérique ;
- Monsieur le Directeur d'UFR ;
- Mesdames et messieurs, les représentants des entreprises partenaires ;
- Mesdames et messieurs les communicants et panelistes à cette conférence ;
- Mesdames et messieurs les enseignants-chercheurs ;
- Chers étudiants.

C'est pour moi un plaisir immense de vous accueillir au sein de l'UFHB, dans le cadre de la deuxième édition de la conférence INDABAX.

Cette deuxième édition de la conférence INDABAX organisée en Côte d'Ivoire par le laboratoire « Mécanique et Informatique » de l'UFR Mathématiques et Informatique en partenariat avec le centre IDTDS (Intelligent Digital Transformation and Data Stratégies) a pour thème : « Apport de l'Intelligence artificielle au développement de la Côte d'Ivoire ».

L'objectif général visée est la vulgarisation et le développement de l'intelligence artificielle en Côte d'Ivoire. L'Université UFHB, se réjouit de son organisation et espère qu'elle permettra de consolider les activités de recherche et de formation relatives à l'intelligence artificielle d'une part, et d'autre part, de faciliter l'interaction avec le monde industriel sur les innovations possibles dans ce domaine aux bénéfices de la société ivoirienne. A en point douter une utilisation éthique de l'intelligence artificielle permettra d'accélérer la transformation digitale dans les secteurs d'activités et créer de la valeur ajoutée pour notre économie. C'est pourquoi, notre université ambitionne prendre toute sa place dans les formations des métiers du numérique afin de combler le déficit de compétences indispensables au rayonnement de notre économie.

Mesdames et messieurs, je vous vous souhaite à toutes et à tous, la bienvenue à l'Université Felix Houphouët Boigny pour l'édition 2022 de la conférence INDABAX Côte d'Ivoire en espérant vivement qu'elle sera mémorable et edificatrice.

3.4

- 1) Contribution of artificial intelligence to the quality improvement of the agriculture and the environment in Cote d'Ivoire
- 2) Gestion intelligente de la consommation d'électricité à l'aide d'un système multi-agents et du processus de saut
- 3) Fake news detection in social media: hybrid deep learning approaches

3.5 Liste des conférences invitées

- 1) Applications de IA aux domaine d la santé et de cartographie, SAH Analytics
- 2) Application de l'intelligence artificielle dans le domaine de l'économie, Marlène Koffi (Canada)
- 3) Endoscopic images and clinical data to assess the response of radiation therapy, Selam Waktola (Pays-Bas)

December 20 (Tuesday) (Amphi IRMA)		
8h30 – 09h	Ouverture	Discours PCO, Pdt UFHB, Directeur UFR MI, Directeur LAMI, Dir Cab MESRS
9h00 – 09h30	IPCI-AC2 predictor : un predicteur machine learning pour la détection des variants de Covid19	Stanislas Assohoun UjiLoG, Pasteur, LAMI
9h30 – 10h	HPC et l'Intelligence Artificielle: quel apport à la CIE	Jules KALA (CIE)
10h – 10h30	Contribution of artificial intelligence to the quality improvement of the agriculture and the environment in Cote d'Ivoire	Diarra Mamadou , LAMI
10h30 – 11h	Combining mm-algorithms and mcmc procedures for maximum likelihood estimation In Mallows-Bradley-Terry models	Amadou Sawadogo, Labo Maths et Applications
11h – 11h45	: Cocktail	
12h00 - 12h30	Applications de IA aux domaine d la santé et de cartographie	Sylla avec SAH Analytics
12h30 – 13h	Fake news detection in social media: hybrid deep learning approaches	Fatou Topka, LAMI ; LARIT, LASTIC
13h00 – 13h30	Application de l'intelligence artificielle dans le domaine de l'économie	Marlène koffi (Canada)
13h30 – 14h00	Endoscopic images and clinical data to assess the response of radiation therapy	Selam Waktola (Pays-bas)
14h30 – 15h30	Lunch	
15h30 – 16h	Gestion intelligente de la consommation d'électricité à l'aide d'un système multi-agents et du processus de saut	Diabagaté
16h00 – 17h30	Panel Discussion (IA et le développement de la Côte d'ivoire : Enjeux et Défis)	Animateur : Diarra Dir Pasteur, Babri, CIE, Sylla (Saha)
17h30	Closing	Prof Adou et Maitre cérémonie

5.1 Contribution of artificial intelligence to the quality improvement of the agriculture and the environment in Cote d'Ivoire

Contribution of artificial intelligence to the quality improvement of the agriculture and the environment in Cote d'Ivoire

MAMADOU Diarra ², AYIKPA Kacoutchy Jean ^{1,2,3}, BALLO Abou Bakary ², GOUTON Pierre ¹, ADOU Kablan Jérôme ²
ImVia, Université Bourgogne Franche-Comté, Dijon, FRANCE ¹,
LaMI, Université Felix Houphouët-Boigny, Abidjan, CÔTE D'IVOIRE ²
UREN, Université Virtuelle de Côte d'Ivoire, Abidjan, CÔTE D'IVOIRE ³

Abstract--In this competitive world, our developing countries face many challenges, especially in agriculture and the environment. In this perspective, research focuses on sustainable production, quality improvement of export crops and the environment. The research areas discussed in this paper contribute to using artificial intelligence to improve the quality of coffee, cocoa, flora while protecting the forest from bush fires.

Keywords--artificial intelligence, agriculture, environnement, plants, machine learning

INTRODUCTION

The main crops, coffee and cocoa, come from forest regions that suffer from clearing and bush fires. The cultivation techniques are generally traditional and lead to the destruction of forests and the shortening of fallow periods. To this end, certain shortcomings are noted such as land degradation, climate change, progressive desiccation and even savannahization.

To face the competition on the complex market, it is imperative to ensure an agriculture of the future by turning to digital technology, especially Artificial Intelligence (AI) with e-agriculture.

Artificial intelligence has made it possible to design decision support tools. Firstly, to preserve the forest as a means of maintaining climatic balance and promoting eco-tourism, a mathematical model has been built to predict bush fires. Then, for coffee and cocoa, models have been designed for the detection of diseases of these crops. Finally, for quality products, tools have been designed to evaluate the maturity of coffee beans and cocoa pods.

PROBLEMATICS

The objective of this study, is to push the studies using machine learning see deep learning for the improvement of the quality of agriculture and environment.

The studies carried out have focused on :

- Diseases and maturity of coffee and cocoa ;
- The exploration of the plant flora of the Ivory Coast and the prediction of bush fires.

MATERIALS AND METHODS

Experience 1 : Application based on Hybrid CNN-SVM and PCA-SVM Approaches for Classification of Cocoa Beans

Method

The digital images of cocoa beans used for the study were obtained at YAKASSE 1 (longitude: - 3.77374 latitude: 5.23841) village located near GRAND-BASSAM in Côte d'Ivoire. These cocoa bean samples were classified as follows:

- Category 1 beans: fermented and dried cocoa beans of superior quality.
- Category 2 beans: fermented and dried cocoa beans of intermediate quality.
- Category 3 beans: non-fermented and dried cocoa beans.

Once the data is obtained as shown in Fig. 1, we will proceed to the pre-processing that will extract the seeds from each image.

Method :




Fig. 1. Architecture of the Model for the Classification of Cocoa Beans

Results :

The results showed the robustness of the hybrid CNN-SVM model which obtained the best score with a value of 98.32% then the PCA-SVM based model had a score of 97.65% outperforming the standard CNN and SVM classification algorithms. Metrics such as accuracy, recall, F1 score, mean squared error (MSE), and MCC have allowed us to consolidate the results obtained from our different experiments [1][2].

Experience 2 : Experimental Evaluation of Coffee Leaf Disease Classification and Recognition Based on Machine Learning and Deep Learning Algorithms

Method :

Coffee plant diseases constitute a significant danger to world coffee production, and the greatest challenge is to detect these diseases as early as possible to save the crop. Traditional methods are most often based on visual observations, often with errors in diagnosing diseases. Machine Learning has become a tool that presents itself as an alternative for automatically identifying plant diseases[3][4]. Our study is to implement a robust method of classification and recognition of coffee leaf diseases using both classical machine learning and deep learning methods, so we set up a custom CNN. These methods were evaluated on the Arabica coffee leaf dataset known as JMuBEN.




Fig. 2: General architecture of our study method

Results

The results of the classical machine learning methods ranged from 81.03 to 100% and the best performance was obtained with SVM and Random Forest; while the deep learning. In comparison, these provided results between 97.37 and 100% with our CNN custom obtaining receiving accuracy with the lowest loss of 0.013%. Accuracy, precision score, recall, and MCC were employed as performance indicators to support this performance.

Experience 3 : Fusion RGB and HSV spaces for cocoa pod maturity identification using the Random Forest method

Method :

The search for quality cocoa beans is a major challenge to obtain better-finished products and this depends largely on the cocoa pod harvest. Collecting an unripe pod will prevent it from fermenting, so pods that are too ripe will start to sprout and result in a loss of income for the crop. Automating the process of determining the maturity of pods using computer vision will make it possible to answer the problem stated above. It is in this perspective that we propose a fusion of color spaces RGB (Red, Green, Blue) and HSV (Hue, Saturation, Value) which will allow the first time to constitute a new image with more characteristics on the pod and in a second time, we will apply the algorithm of the Random Forest to identify the maturity of the pods[4][5]. This technique would help to better plan harvests in order to optimize harvests and obtain better quality beans. We also performed maturity identification with the pod images in RGB and HSV spaces with the same detection algorithm in this case Random Forest.




Fig. 3 : Proposed architecture for cocoa pod maturity identification

Results :

These different experiments in the color space RGB, HSV, and fusion RGB and HSV gave the respective results of 93%, 91%, and 95%. These results showed that the RGB and HSV fusion achieved the best accuracy than the singular use of RGB and HSV space, showing that the technique is promising. Metrics such as accuracy, recall, F1 score, MSE, and MCC were used as well as the efficiency function of the performance measurement receiver in order to consolidate the results obtained from our different experiments.

Experience 4 : Automatic Identification of Ivorian Plants from Herbarium Specimens using Deep Learning

Method :

Plant identification is most often based on visual observations by botanists and systematists. Deep learning has become a tool that provides an alternative to automatic plant identification. Our study consists in implementing a method for plant recognition from herbarium specimens using deep learning classification methods. These methods were evaluated on the dataset of ten plant families from the national herbarium of Côte d'Ivoire. The proposed work uses CNN architectures such as DensNet-121, InceptionV3, VGG19, MobileNet, and ResNet101. The dataset contains 7543 images of herbarium specimens [7][8]. The database is structured in three parts: training, testing, and validation.

In this research, we used 10 plant families from the National Herbarium of Côte d'Ivoire. The data was obtained from the scanning of the library herbarium of the Centre National de Floristique. The following paragraph explains the data set used in our work. The images are from 10 plant families. The dataset has 7543 different species. Each species has an image. These images are all in jpeg format.




Fig.3. Workflow of our proposed method

Results ;

The accuracies obtained for the first scenario without preprocessing of herbarium specimen images are 76.94% for MobileNet, 77.77% for VGG19, and 77.96% for InceptionV3, 80.41% for ResNet101, and 83.47% for DensNet-121, respectively. The best performance was obtained with DensNet-121 with 83.47%. In the second scenario with preprocessing of herbarium specimens, the accuracies obtained were 82.80% for InceptionV3, 84.40% for VGG19, 85.53% for MobileNet, and 85.80% for ResNet101. The best accuracy was obtained with ResNet121 with 85.80%. From the analysis obtained, the results show that ResNet101 gives the best accuracy compared to the other architectures. In particular, the data preprocessing improves the prediction results, of the Convolutional Neural Network algorithms.

Experience 5 : Bushfire prediction and simulation tool

Method :

The purpose of this approach is to numerically simulate the reaction diffusion system of bushfire propagation in order to better understand the behavior of wildfires as a function of propagation parameter values. Based on appropriate numerical schemes, the input parameters are provided by the user and the model takes care of the output predictions. As a decision support tool an application is under development [9] [10].




Fig.3. Workflow of our proposed method in scenario 2

Results :

- Database of bushfire simulation data
- Visualization of prediction results using reports, tables and graphs

CONCLUSION

The production of cocoa and cocoa products is an area of research that requires the use of automated methods for the evaluation of the quality of the product with respect to the maturity of the products and the diseases of the plants for a better quality. Also, the automated methods can help to improve the quality of the environment by identifying the vegetal plants and preserve them by preventing bush fires. The results obtained in the different experiments have shown that the prediction scores are all higher than 92% and often better than the scores observed in the state of the art.

In perspectives, our studies will be extended to other export crops. Also new research areas can be explored such as in medicine, security, industry and education

REFERENCES

- [1] M. Elleuch, R. Maalej, et M. Kherallah, « A New Design Based-SVM of the CNN Classifier Architecture with Dropout for Offline Arabic Handwritten Recognition », *Procedia Computer Science*, vol. 80, p. 1712-1723, 2016, doi: [10.1016/j.procs.2016.05.512](https://doi.org/10.1016/j.procs.2016.05.512).
- [2] M. M. Oliveira, B. V. Cerqueira, S. Barbon, et D. F. Barbin, « Classification of fermented cocoa beans (cut test) using computer vision », *Journal of Food Composition and Analysis*, vol. 97, p. 103771, avr. 2021, doi: [10.1016/j.jfca.2020.103771](https://doi.org/10.1016/j.jfca.2020.103771).
- [3] J. Jepakoch, D. M. Mugo, B. K. Kenduiwo, et E. C. Too, « Arabica coffee leaf images dataset for coffee leaf disease detection and classification », *Data in Brief*, vol. 36, p. 107142, juin 2021, doi: [10.1016/j.dib.2021.107142](https://doi.org/10.1016/j.dib.2021.107142).*
- [4] S. Giraddi, S. Desai, et A. Deshpande, « Deep Learning for Agricultural Plant Disease Detection », in *ICDSMLA 2019*, vol. 601, A. Kumar, M. Paprzycki, et V. K. Gunjan, Éd. Singapore: Springer Singapore, 2020, p. 864-871. doi: [10.1007/978-981-15-1420-3_93](https://doi.org/10.1007/978-981-15-1420-3_93).
- [5] J. R. C. P. de Oliveira et R. Ap. F. Romero, « Transfer Learning Based Model for Classification of Cocoa Pods », in *2018 International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro, juill. 2018, p. 1-6. doi: [10.1109/IJCNN.2018.8489126](https://doi.org/10.1109/IJCNN.2018.8489126).
- [6] P. Li, Y. Huang, et K. Yao, « Multi-algorithm Fusion of RGB and HSV Color Spaces for Image Enhancement », in *2018 37th Chinese Control Conference (CCC)*, Wuhan, juill. 2018, p. 9584-9589. doi: [10.23919/ChiCC.2018.8483674](https://doi.org/10.23919/ChiCC.2018.8483674).
- [7] J. Unger, D. Merhof, et S. Renner, « Computer vision applied to herbarium specimens of German trees: testing the future utility of the millions of herbarium specimen images for automated identification », *BMC Evol Biol*, vol. 16, n° 1, p. 248, déc. 2016, doi: [10.1186/s12862-016-0827-5](https://doi.org/10.1186/s12862-016-0827-5).
- [8] S. J. Kho, S. Manickam, S. Malek, M. Mosleh, et S. K. Dhillon, « Automated plant identification using artificial neural network and support vector machine », *Frontiers in Life Science*, vol. 10, n° 1, p. 98-107, janv. 2017, doi: [10.1080/21553769.2017.1412361](https://doi.org/10.1080/21553769.2017.1412361).
- [9] https://fonsti.ci/laureat_d_appels/adou-kablan-jerome/
- [10] BROU, Akahoua David V. et ADOU, Kablan Jérôme. Modelling the Effect of Grassland Fuel Bed Structure on the Headfire Rate of Spread. *Combustion Science and Technology*, 2022, p. 1-18.

5.2 Deep Learning for fake news detection in social media

Deep learning for Fake news detection in social media

Fatoumata Wongbé Rosalie Tokpa¹, Kamagaté Beman Hamidja², , Vincent MONSAN¹ ,
OUMTANAGA Souleymane³

LaMI, Université Felix Houphouët-Boigny, Abidjan, CÔTE D'IVOIRE ¹
LaSTIC, Ecole Supérieure Africaine des TIC , Abidjan, Côte d'Ivoire ²

LaRIT, Institut Nationale Polytechnique Félix Houphouët Boigny, Yamoussoukro, Côte
d'Ivoire ³

Abstract

Nowadays, due to the proliferation of Fake News in social media, the notion of truthfulness of information becomes a key issue. Veracity detection must be able to classify information as true or false. Humanly this task is very difficult due to the huge amount of data in the web, hence the need to find machine learning algorithms that can effectively solve this problem. For fake news detection some neural network methods are trained and tested on one topic and perform poorly on others. In this paper, our contribution is to propose deep learning algorithms, which combine neural network methods. These hybridization algorithms are trained and tested successively on different data sets (Isot and Fakes) and give better results than the existing methods.

Keywords : Veracity, Fake News Detection, Social Networks, Artificial Intelligence, Deep Learning, Convolution Neural Network, Recurrent Neural Network

I. Introduction

The political, economic and cultural stakes and contradictions between members of a society lead interest groups to use them to manipulate the population by producing false information, in order to control the state of mind of the population, to maintain a climate of anxiety for the benefit of their own interests.

The increasing massification of the means of connection and the existence of a lot of content that produced instantaneously during real-time events, amplify the production of false information. It is imperative to find techniques to stop the spread of this scourge.

Several initiatives have been taken in this direction, such as fact-checking websites. The verification of information by these sites is manual and requires sufficient human and technical resources.

To remedy this, several approaches try to detect facts automatically to compensate for the slowness and difficulty of the manual approach [1].

For this reason, machine learning, and more specifically the neural network approach, is gaining interest in the information veracity detection research community [2] [3], as it is more suitable for processing large amounts of data, produced at high speed and with different formats and structures.

II. Related works

Given the presence of multi-modal data and the impact of the spread of fake news (FN), manual detection can no longer meet the need for FN detection on the web. Therefore, machine learning models can be of great help for the knowledge of the truth on the web in a reduced time.

Based on the literature, several machine learning models have been tested and evaluated on the same topic. These models suffer from overlearning and a bias towards the dataset specific to their topic of interest, so that they perform poorly on other topics. The hybridization approach seems to be more effective for detecting fake news.

Indeed, reference [4] focuses on the classification of FN. They propose a machine learning method combining a convolutional neural network CNN and a recurrent neural network LSTM. Their method evaluated using two databases. The first is FA-KES [8], consisting of 804 press articles on the war in Syria. The second is ISOT [7], consisting of 44,898 news articles on facts from Wikipedia and Polifact. With ISOT, they achieve an accuracy of over 90% and with FA-KES, they achieve an accuracy of 60%. In their work, they wanted to solve the problem of generalization of machine learning models by training their approach on ISOT and testing it on FA-KES. However, they did not take into account some parameters such as the regularization of the data and the appropriate choice of an activation function, which can improve the performance of the model and can give good performance. They obtain as a result for the generalization an accuracy of 50% and an accuracy of 48%.

III. Methodology

A. Definition of the problem and approach to solving it

Let A be a set of news articles consisting of N articles. Each article $a_{1 \leq i \leq N}$ is labelled 1 if it is true and labelled 0 if it is fake. Any article $a_{1 \leq i \leq N}$ is composed of M words $w_1, \dots, w_M$. However the problem in this work is to find a function S that by training on A best classifies a new article a_{new} into 0 for Fake and 1 for True. To solve this problem we can proceed by steps detailed in the following sections.

B. Datasets

For the evaluation of our models, we use accessible datasets such as ISOT [7] and FA-KES [8] described in the section II.

C. Data preprocessing

Dataset cleaning and splitting

In this step, for each dataset and for each article we perform the following steps

- Put the text of the article in lower case,
- Replace the line break and tab characters with a single space,
- Remove white space,
- Expand contracted words. Ex: can't become cannot,
- Delete digits,
 - Delete all characters that are neither numbers nor letters,
- Delete stopwords.

After the cleaning stage, both the ISOT and FA-KES sets were subdivided into two parts, 80% of the set was used for training and the remaining 20% for testing.

.

News articles embeddings

In this paper on classification of FN, we represent texts by numerical vectors. To get there we use one of the pre-trained methods of Glove [5].

In our case, we will train our numerical vectors using glove 100 dimensions. However, to use glove we need to define a fixed length of text to be digitized. As the news article contents are of variable length, we will use a fixed length Post Padding of 300, i.e. after the Padding each article will be composed of 300 words.

D. Fakes news classification

The models DeepCnnLstm and DeepCnnBilstm we propose are a concatenation of neural networks consisting of :

- Embedding layer
- Dropout layer
- Convolution layer
- Batch normalization layer
- Dropout layer
- Pooling layer
- Recurrent neural network layer (Bilstm for DeepCnnBilstm or Lstm for DeepCnnLstm)
- Two dense layers

1) Embedding layer

Let $D = [w_1, \dots, w_n]$, an news article of n words. Let $W_i \in \mathbb{R}^d$ the numerical representation of word w_i .

The output of this layer is a matrix $M = [W_1, \dots, W_n] \in \mathbb{R}^{n \times d}$, which is the concatenation W_i .

2) Convolution

We consider the result of the embedding layer obtained in the encoding layer which is the matrix $M \in \mathbb{R}^{n \times d}$. The filter is slide $f_j \in \mathbb{R}^{l \times d}$ over M with a window size l , by splitting M into ngrams of l -words $u_i \in \mathbb{R}^{l \times d}$, u_i is the concatenation of l words. For the filter f_j et for an l -words u_i , we obtain the characteristic c_i by computing as in (1).

$$c_i = f(<u_i, f_j > + b) \in \mathbb{R} \quad (1)$$

The bias $b \in \mathbb{R}$ and f is a nonlinear transformation. For this layer we choose the Elu function and zero bias.

Thus a filter f_j slipped over all l -words u_i produces a feature map C_j and show in (2).

$$C_j = (c_i) \in \mathbb{R}^{n-l+1}. \quad (2)$$

For a convolution layer, we use m filters for the extraction of various features. These m filters generate m differents features maps $C \in \mathbb{R}^{(n-l+1) \times m}$. Let C is a vector of the C_j , as in (3). They which are used by the next layer.

$$C = [C_1, \dots, C_m]. \quad (3)$$

3) Batchnormalization

Batch input normalization is a layer that refocuses and rescales each element in a batch. This method improves the accuracy and speed of training [9].

Formally given an input x and a batch size k , for batch normalization, we first calculate for each batch L of x formed, the mean μ_L and the variance σ_L^2 as in (5) and (6).

$$x = (x_1, \dots, x_N). \quad (4)$$

$$\frac{1}{k} \quad (5)$$

$$\mu_L = \overline{k} \sum_{i=1} x_i$$

$$\sigma_L^2 = \frac{1}{k} \sum_{i=1}^k (x_i - \mu_L)^2 \quad (6)$$

Then each element x_i in the batch is transformed into an element $\hat{x}_i$, where $\hat{x}_i$ is computed as in (7).

$$\hat{x}_i = \gamma * \frac{(x_i - \mu_L)}{\sqrt{\sigma_L^2 + \varepsilon}} + \beta, i \in [1, \dots, k] \quad (7)$$

In (7), ε is a small constant added to the denominator for numerical stability. γ and β are respectively the scale factor initialized to 1 and the offset factor initialized to 0. These two factors are updated automatically during training and can be disabled [10].

4) Dropout

Dropout is a regularization technique that solves the overfitting problem and also facilitates the combination of several neural network architectures [11]. Let l be a layer on which the dropout is applied, let Y^l be its output vector and let r be a vector of Bernoulli random variables, each of which has probability p . The dropout applied to this layer gives (8) and the input of the layer that follows is (9).

$$Y^l = r * Y^l \quad (8)$$

$$Z^{l+1} = WY^l + b^{l+1} \quad (9)$$

5) Pooling

This operation consists in reducing the size of the vector generated by the convolution layer while keeping the most important features. Here we apply a pooling operation MaxPooling1D.

6) Recurrent neural network

Unlike other neural networks, Lstm are suitable for sequential data such as words in a sentence that depend on each other [12].

An Lstm sequence is composed of cells linked by time steps t . The output of each cell controlled by a set of activation functions $\{f(t), i(t), o(t)\}$ also called gates. They have values in $\mathbb{R}^T$ where T is the dimension (the number of cells in the sequence) of the Lstm.

The Lstm receives at the input a sequence X and by a linear transformation produces a state vector H . This vector obtained by calculating at each step $t \in \{1, \dots, m\}$ the functions that are in (12).

$$X = (X_1, \dots, X_m) \quad (10)$$

$$H = (h_1, \dots, h_m) \quad (11)$$

$$\begin{aligned} f_t &= \sigma(w_{fh}h_{t-1} + w_{fX}X_t + b_f) \\ i_t &= \sigma(w_{ih}h_{t-1} + w_{iX}X_t + b_i) \end{aligned} \quad (12)$$

$$\tilde{c}_t = \tanh(w_{\tilde{c}h}h_{t-1} + w_{\tilde{c}X}X_t + b_{\tilde{c}})$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t$$

The weights w_{fh} , w_{fX} , w_{ih} , w_{iX} , w_{ch} , w_{cX} , w_{oh} , w_{oX} and biases b_f , b_i , b_c , b_o , are the parameters learned during the training of the network [13]. At each step t the cell receives an element X_t of the sequence and outputs h_t the state of this element. The final result of this LSTM layer is the output h_t of the last cell c_T . Such an LSTM layer processes the input in a single direction from left to right and can therefore only encode dependencies on elements that come earlier in the sequence. To overcome this problem, we use another LSTM layer that processes in the reverse direction, which will allow us to detect dependencies on elements later in the text by reading the input from right to left. The neural network resulting from this mechanism called a bidirectional LSTM [14].

The result of a bidirectional LSTM layer is the concatenation of outputs in both directions, as in (13).

$$H = [\vec{h}^{\rightarrow}_{T \rightarrow}, \overleftarrow{h}_{T \leftarrow}] \quad (13)$$

IV. EXPERIMENTATION AND EVALUATION

A. Experimental Framework

Models implementation in Keras

We built our model, DeepCnnBilstm, using the Keras sequential API. It consists of:

- Embedding layer uses the Glove method described above. It transforms all the 300d vectors obtained after post-padding into a matrix of dimension 300x100.
- A Dropout layer with probability 0.7
- A Conv1D convolution layer of 128 filters of size 3 and an ELu activation function,
- A Conv1D convolution layer of 128 filters of size 5 and an ELu activation function,
- A Batchnormalisation layer,
- A Dropout layer with probability 0.5
- A Bidirectional LSTM layer of 32 cells,
- A Concatenation layer
- A Dense layer of 32 neurons with a Relu activation function
- A dense layer of 1 neuron using the Sigmoid activation function for 1 or 0 classification.

In the case of DeepCnnLstm, we change Bidirectional LSTM layer of 32 cells by Lstm layer of 32 cells.

Compared Models

These models listed in Table I for the neural network models and in Table II for of others machine learning methods.

TABLE I. COMPARATIVE NEURAL NETWORK MODEL

Models	Description
Cnn-seul	simple convolution neural network
Lstm-seul	Simple recurrent neural network
Bilstm-seul	Simple bidirectional recurrent neural network
DeepCnnLstm	Our approach
DeepCnnBiLstm	Our approach
Hybrid CNN-RNN	Reference [4]

B. Results

We implemented the Cnn, Lstm, Bilstm models by proposing DeepCnnBilstm and DeepCnnLstm models.

The training was done on 10 epochs and a batch-size of 64. These parameters are those used by Reference [4].

TABLE IV. RESULTS OF NEURAL NETWORK MODELS ON THE FA-KES DATASET

Model	Accuracy	Precision	Recall	F1-score
Cnn_seul	0.50	0.55	0.50	0.52
LSTM_seul	0.50	0.51	0.50	0.50
Bilstm_seul	0.53	0.56	0.73	0.63
Cnn_Lstm	0.60	0.59	0.60	0.59
Cnn_Bilstm	0.59	0.62	0.73	0.67
DeepCnnLstm	0.63	0.62	0.98	0.76
DeepCnnBilstm	0.68	0.64	0.88	0.74

TABLE V. RESULTS OF NEURAL NETWORK MODELS ON THE ISOT DATASET

Model	Accuracy	Precision	Recall	F1-score
Cnn_seul	0.99	0.99	0.99	0.99
LSTM_seul	0.98	0.98	0.98	0.98
Bilstm_seul	0.99	0.99	1	0.99
Cnn_Lstm	0.99	0.99	0.99	0.99
DeepCnnLstm	0.99	1	0.99	0.99
DeepCnnBiLstm	0.99	0.99	1	0.99

TABLE VIII. RESULTS OF GENERALIZATION

Models	Accuracy	Precision	Recall	F1-score
Cnn_Lstm [15]	0.50	0.48	0.48	0.46
DeepCnnLstm	0.52	0.55	0.67	0.60
DeepCnnBiLstm	0.54	0.53	0.93	0.67

C. Discussions

In previous work, fake news detection models trained and tested only on the same subject. This does not really allow evaluating performance of a model on another subject. Thus like Reference [4], our proposed models are tested on another subject than the training subject. In the results, the performance of DeepCnnBilstm and DeepCnnLstm outperformed those of [4]. This shows that our models are better suited for generalization than the methods we mentioned. In other words, our approach is better at detecting Fake News on different topics.

In contrary to Reference [4] our models use more layers, which makes its execution time a bit longer. In addition, they use an Embedding layer, and it recompiled each time when we have to deal with another dataset so it often loses its optimal weights during this reset. Nevertheless, ours generalizes better because the accuracy, precision, recall and F1-score values are higher.

V-CONCLUSION AND FUTURES WORKS

Detection of fake news remains a hot topic as it continues to proliferate in our society. Detection techniques with neural networks have been proposed, but they are better suited to the training dataset than to any other dataset. To contribute in this area, we proposed machine learning algorithms consisting of a hybridization of neural networks called DeepCnnBilstm and DeepCnnLstm. These models are mainly composed of CNN and RNN. They have been trained

and tested on different subjects. DeepCnnBilstm outperforms some models and can be considered as an interesting method to detect fake news.

However, a news article on the web may contain both textual and image features. Thus for future work, this aspect should be considered and the proposed models should be embaded in API, so that it can be used by web developer to detect fake news.

REFERENCES

- [1] W. Y. Wang, « “Liar, Liar Pants on Fire”: A New Benchmark Dataset for Fake News Detection », *arXiv preprint arXiv:1705.00648*, 2017. [4]
- [2] R. Cooley, B. Mobasher, et J. Srivastava, « Web mining: information and pattern discovery on the World Wide Web », in *Proc. Ninth IEEE International Conference on Tools with Artificial Intelligence*, Newport Beach, CA, USA, 1997, p. 558-567. doi: 10.1109/TAI.1997.632303.[11]
- [3] H. Chen et M. Chau, « Web mining: Machine learning for web applications », *Ann. Rev. Info. Sci. Tech.*, vol. 38, n° 1, p. 289-329, sept. 2005, doi: 10.1002/aris.1440380107.[12]
- [4] J. A. Nasir, O. S. Khan, et I. Varlamis. Fake news detection: A hybrid CNN-RNN based deep learning approach. *International Journal of Information Management Data Insights*, 2021, vol. 1, no 1, p. 100007. [15]
- [5] J. Pennington, R. Socher, et C. Manning, « Glove: Global Vectors for Word Representation », in *Proc. 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar, 2014, p. 1532-1543.[25]
- [6] H. Allcott et M. Gentzkow, « Social Media and Fake News in the 2016 Election », *Journal of Economic Perspectives*, vol. 31, n° 2, p. 211-236, mai 2017, doi: 10.1257/jep.31.2.211.[38]
- [7] University of Victoria, “Fake news detection datasets”, [online] Available at: <https://www.uvic.ca/ecs/ece/isot/datasets/fake-news/index.php/> [Accessed December 2021].[39]
- [8] F. K. Abu Salem, R. Al Feel, S. Elbassuoni, M. Jaber, et M. Farah, « FA-KES: A Fake News Dataset around the Syrian War ». In *Proc. International AAAI conference on web and social media*. 2019. p. 573-582.[40]
- [9] N. Bjorck, C. P. Gomes, B. Selman, et K. Q. Weinberger, « Understanding Batch Normalization », in *Advances in Neural Information Processing Systems*, 2018, vol. 31. [43]
- [10] « BatchNormalization layer », [online] Available at: https://keras.io/api/layers/normalization_layers/batch_normalization/ [Accessed 27 August 2022].[44]
- [11] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, et R. S. Salakhutdinov, « Dropout: A Simple Way to Prevent Neural Networks from Overfitting », juin 2014.[45]
- [12] S. Hochreiter et J. Schmidhuber, « Long Short-Term Memory », *Neural Computation*, vol. 9, n° 8, p. 1735-1780, nov. 1997, doi: 10.1162/neco.1997.9.8.1735.[49]
- [13] A. Gulli, A. Kapoor, et S. Pal, *Deep Learning with TensorFlow 2 and Keras: Regression, ConvNets, GANs, RNNs, NLP, and more with TensorFlow 2 and the Keras API, 2nd Edition*. Packt Publishing Ltd, 2019.[50]
- [14] A. Graves, S. Fernández, et J. Schmidhuber, « Bidirectional LSTM Networks for Improved Phoneme Classification and Recognition », in *proc. International conference on artificial neural networks*. Springer, Berlin, Heidelberg, 2005. p. 799-804. doi: 10.1007/11550907_126.[51]

5.3 Gestion intelligente de la consommation d'électricité à l'aide d'un système multi-agents et du processus de saut

Gestion intelligente de la consommation d'électricité à l'aide d'un système multi-agents et du processus de saut

Amadou Diabagaté¹, Yazid Hambally Yacouba²

Faculty of Mathematics and Computer Science, Félix Houphouët Boigny University, Côte d'Ivoire

Email : ahmadou.diabagate@gmail.com¹, yazid.hambally@gmail.com²

Résumé — Le compteur intelligent peut traiter les données des capteurs dans un réseau résidentiel. Ces capteurs transmettent différents paramètres ou données de mesure (indice, puissance, température, tension, etc.) au compteur intelligent. Toutes ces données de mesure peuvent parvenir de différentes manières au compteur intelligent. De plus, la collecte de ces données vers un système central est une préoccupation importante qui doit prendre en compte l'intégrité des données et la protection de la vie privée. Une modélisation des objets de mesure du smart grid est proposée tout en mettant en évidence les modifications apportées à ces objets tout au long du processus de traitement des données. L'utilisation des systèmes multi-agents dans le domaine de l'énergie électrique est une approche proposée dans le cadre de ce travail. C'est également le cas de l'innovation introduite par l'utilisation du processus de saut dans le traitement des données de la consommation d'électricité.

Ce travail se veut une approche pragmatique pour évaluer la consommation d'électricité au niveau des ménages, des bâtiments et des quartiers grâce à des méthodes d'agrégation basées sur le processus de saut pour le traitement des données des consommateurs d'électricité à travers la mise en œuvre d'un système centralisé. Une analyse du comportement de la consommation des clients est aussi proposée à partir du suivi de la consommation d'électricité des différents appareils connectés à un compteur intelligent. Une simulation a été mise en place pour montrer l'application des méthodes d'agrégation proposées sur des données de consommation d'électricité.

Mots-clés — réseau électrique intelligent, système multi-agents, processus de saut, agrégation, analyse des données d'électricité

1. Introduction

La fracture énergétique devient de plus en plus importante dans le monde et les prix d'électricité augmentent régulièrement au détriment des consommateurs. Cette situation interpelle donc à la mise en œuvre de nouveaux services susceptibles de favoriser la maîtrise de la consommation d'électricité.

Les compteurs intelligents grâce à leurs fonctionnalités constituent un atout pour le développement des sites de production d'électricité photovoltaïque. Les consommateurs d'électricité pourront aussi être des producteurs et obtenir des compensations pour le supplément d'électricité produite et utilisée pour le besoin des autres clients. La transition énergétique milite à l'intégration des technologies facilitant l'utilisation des énergies renouvelables dans les infrastructures d'électrification. L'énergie solaire est en effet une ressource particulièrement disponible et peu exploitée sur le continent africain.

Le réseau intelligent « smart grid » cherche à automatiser et à améliorer l'intervention de tous les acteurs des réseaux électriques (producteurs, gestionnaires de réseaux, fournisseurs, consommateurs) pour une meilleure maîtrise de la gestion de l'électricité. Le but étant de produire au mieux l'électricité nécessaire pour le besoin des clients en se basant sur la bonne connaissance de leur consommation car l'énergie électrique produite ne se conserve pas. Les réseaux intelligents permettront ainsi la mise en place de modèles de tarification incluant de nouvelles offres qui favoriseront l'élasticité du prix attendu par les consommateurs.

Les travaux s'inscrivent dans la recherche des voies et moyens permettant d'amorcer une réflexion sur le développement des réseaux électriques en Afrique en présentant les réseaux électriques intelligents et en proposant la conception d'un système informatique permettant d'améliorer les réseaux électriques traditionnels pour en faire des réseaux électriques intelligents.

Tout au long de ce travail, nous avons cherché à simplifier la gestion des données des systèmes électriques intelligents en justifiant l'utilisation de la date d'arrivée des données de mesure dans le système de stockage central. Ce choix constitue une optimisation du traitement des données tant au niveau des compteurs intelligents qu'au niveau du système de centralisation des données, notamment en raison du volume important de ces données. Un système multi-agents a été également conçu pour la gestion des données d'électricité. Les objectifs sont atteints en collectant, en ordonnant et en centralisant les données de ces systèmes intelligents en amont de l'analyse de leurs données.

2. Système multi-agents proposé

Pour mettre en évidence les différentes composantes du réseau intelligent, nous avons choisi de le présenter comme un système multi-agents. Cette approche nous permettra de présenter les différents agents (capteurs, compteurs intelligents, système central et autres composants actifs) et leurs interactions. Cette modélisation profitera de tous les avantages d'un système multi-agents dont :

- la modularité grâce au partage d'informations entre agents ;
- la fiabilité grâce à la redondance ;
- la rapidité d'exécution grâce au parallélisme d'exécution des tâches effectuées par les différents agents ;
- la facilité de maintenance lors de l'ajout d'un nouveau composant au sein du réseau intelligent

Les différents agents du système sont les suivants :

Désignation de l'agent	Tâches
Agent Capteur (AC)	Activation du capteur (AAC) Désactivation du capteur (ADC) Transmission des données du capteur au compteur intelligent (ATDC)
Agent Compteur Intelligent (ACI)	Réception des données du capteur intelligent (ARDCI) Echange de données avec le compteur intelligent (AEDCI)
Agent Système Central Gestion Electricité (ASCGE)	Sous Agent Traitement Données Système Central (ATDSC)
	Sous Agent Analyse Données Système Central (AADSC)
	Sous Agent Echange Données Système Central (AEDSC)
	Sous Agent Consultation Données Système Central (ACDSC)
Agent Client Electricité (ACE)	Gestion de l'alimentation électrique du client (AGAE) Consultation de la consommation d'électricité (ACCE) Echange de données avec le client (AEDC)

Agent Distributeur Electricité (ADE)	Gestion de la distribution d'électricité (AGDE) Echange de données avec le distributeur d'électricité (AEDD)
Agent Gestionnaire Réseaux Transport (AGRT)	Gestion du transport d'électricité (AGTE) Echanges de données avec le transporteur d'électricité (AEDT)
Agent Producteur Electricité (APE)	Gestion de la production d'électricité (AGP) Echanges de données avec le producteur d'électricité (AEDP)

Tableau 1 : Liste des agents du système

Cette architecture met en évidence tous les agents du système multi-agents. Il permet de distinguer les agents en contact avec l'environnement extérieur sans pour autant être précis sur les autres agents du système. Elle a également le mérite de donner une vue d'ensemble de toutes les interactions entre les agents.




figure 1 : Architecture multi-agents détaillé

3. Méthodes d'agrégation temporelle, par zone et par usage des données du système de comptage intelligent à l'aide du processus de saut

Le processus de saut permet de modéliser l'agrégation des données du système de comptage intelligent. En effet, les données de consommation sont enregistrées à des temps successifs et réguliers. Aussi, l'état présent d'un compteur intelligent est indépendant de l'état antérieur à chaque intervalle de temps correspondant à la période entre deux collectes successives des données de consommation d'électricité. Les agrégations de données sont alors modélisées par le processus de saut comme suit :

Soient :

n : le nombre d'enregistrement de données ;

X_n : la consommation d'électricité entre T_{n-1} et T_n à l'instant t ;

$\mathbb{1}_A(t) = \begin{cases} 1 & \text{si } t \in A = [T_{n-1}, T_n[\\ 0 & \text{sinon} \end{cases}$, $\mathbb{1}$ est une fonction binaire qui permet de

constater un changement d'état dans le système ;

M : le nombre fini d'évènements au bout duquel le processus de comptage se termine.

Le calcul de la consommation d'électricité d'un compteur intelligent à un instant t est défini alors par :

$$Z_t = \sum_{n=1}^M X_n \mathbb{1}_{[T_{n-1}, T_n]}(t)$$

$T_n - T_{n-1} = H$, H étant le pas de temps d'enregistrement des données de consommation pour un compteur donné. Dans le cas du processus de saut $T_n - T_{n-1}$ peut ne pas être constante contrairement au cas particulier des compteurs intelligents.

Le calcul du cumul de la consommation d'électricité d'un compteur intelligent jusqu'à l'instant t est :

Soit Y_t , la consommation totale d'électricité jusqu'à l'instant t .

$$Y_t = \sum_{n=1}^M X_n \mathbb{1}_{T_n < t}$$

Y_t est un processus de saut, les valeurs X_n du système de comptage intelligent étant différentes.

Soit k l'indice d'un compteur intelligent quelconque et Z_t^k la consommation d'électricité à l'instant t .

L'agrégation temporelle des données du compteur intelligent à l'instant t est obtenu comme suit :

$Z_t^k = \sum_{n=1}^M X_n^k \mathbb{1}_{[T_{n-1}^k, T_n^k]}(t)$, X_n^k étant la consommation d'électricité du compteur intelligent k entre T_{n-1}^k et T_n^k à l'instant t .

Soit N le nombre de compteurs intelligents du système de comptage et S_N la consommation totale d'électricité de l'ensemble de ces compteurs à l'instant t

$S_N = \sum_{k=1}^N Z_t^k$ représente l'agrégation des données de l'ensemble des N compteurs intelligents à l'instant t .

Soit k l'indice d'un compteur intelligent quelconque et Y_t^k la consommation totale d'électricité jusqu'à l'instant t .

L'agrégation temporelle des données du compteur intelligent jusqu'à l'instant t est définie par :

$$Y_t^k = \sum_{n=1}^M X_n^k \mathbb{1}_{T_n^k < t}$$

Soit N le nombre de compteurs intelligents du système de comptage et R_N la consommation totale d'électricité de l'ensemble de ces compteurs jusqu'à l'instant t

$R_N = \sum_{k=1}^N Y_t^k$ représente l'agrégation des données de l'ensemble des N compteurs intelligents jusqu'à l'instant t

4. Conclusion

Ce travail a permis de définir le cadre d'utilisation des données des compteurs intelligents. Il a permis de concevoir des structures de données basées sur une étude

comparative des fonctionnalités des compteurs intelligents. La spécificité des données dans un système de comptage a conduit à la mise en place de méthodes d'agrégation de données pour faciliter le traitement et l'analyse de ces données. La complexité de la gestion des données des systèmes de comptage intelligent est mise en évidence par la proposition d'une approche globale qui inclut un cas concret de mise en œuvre.

Les limites de ce travail résident dans l'absence de mise en œuvre du système de comptage. Cependant, des questions relatives à la mise en œuvre d'un système de comptage intelligent ainsi qu'à celle du traitement des données sont présentées. La conception proposée permet de traiter les données collectées au niveau d'une maison et d'un quartier.

L'originalité de ce travail réside dans la présentation d'un mécanisme de traitement des données des compteurs intelligents, l'agrégation de ces données par le processus de saut, la détermination de la loi décrivant le comportement des utilisateurs sur la consommation d'électricité et enfin la réalisation d'une simulation sur des données issues de compteurs intelligents existants. Le manque d'informations sur les systèmes de comptage intelligent rend toute étude comparative difficile. En effet, la mise en œuvre de ces systèmes reste fermée même si certaines fonctionnalités sont bien connues des utilisateurs.

References

- [1] Yazid Hambally Yacouba, Amadou Diabagaté, Abdou Maiga, Adama Coulibaly, "Multi- agent System for Management of Data from Electrical Smart Meters", International Journal of Information Technology and Computer Science(IJITCS), Vol.13, No.1, pp.18-43, 2021. DOI: 10.5815/ijitcs.2021.01.02
- [2] Yazid Hambally Yacouba, Amadou Diabagaté, Michel Babri and Adama Coulibaly, "Design, Aggregation and Analysis of Power Consumption Data using the Jump Process" International Journal of Advanced Computer Science and Applications(IJACSA),12(5), 2021. <http://dx.doi.org/10.14569/IJACSA.2021.0120567>

Machine Learning for Economic Development Application to Education Policies

Marlene Koffi

Based on joint work with Arbour and Oreopoulos, UoT

December 20, 2022

- School is an integral part of children's lives: they spend a third of their waking time there (Hofferth and Sandberg, 2001)
- Article 28 of the 1989 UNICEF Convention on the Rights of the Child states that "education is the right of every child. It should be available, accessible, acceptable, and of adequate quality, fair, with equal access for girls and boys"
- In search of what, or who, in school makes a difference in children's learning, researchers have come to the conclusion that it is teachers who make the most impactful (Rivkin, Hanushek, and Kain, 2005)
- Identifying variables that predict teacher's quality is essential for teacher promotion, accountability, professional development, and for understanding the mechanisms behind education production function

- 1910-60s: teacher evaluations primarily based on **personal** (e.g. education, experience, demeanor) [Goe et al. 2008]
- 1960-80s: greater focus on **classroom activity and lessons**, experimental and correlational studies (e.g. quality of feedback, classroom management, homework) [Hattie, 1999; Brophy et al, 1996]
- 1980-90s: evaluations based on detailed **classroom observation**, aggregating across multiple categories (e.g. environment of the classroom, rapport, frequency and quality of engagement, feedback, etc.) [Brophy et al., 2008]
 - Lack of predictive power for teacher quality...
- 2000-20s: **teacher value-added**: Aggregate students test scores, but not explained by students characteristics [e.g. Harris and Sass, 2009]

*Lack of consensual findings on what makes a good teacher
 identify the best actionable tools ⇒ Raise the need for a more h
 to predict high-quality teachers based on their observable chara
 is central to subsequent discussions on policies and their under*

Conditions are ripe for applying ML to predict teacher effectiveness

- Computers may be able to better predict **patterns** than humans
- New techniques have made this easier to do
 - Supervised techniques can be used for *reducing dimensionality* by objectively identifying which observed characteristics best predict outcomes, which can be clustered into similar categories, and which matter least
 - Unsupervised techniques can be used for processing data that would be too difficult for humans to assess (e.g. video, audio, text) to find patterns that can be used for accurate prediction
- Prediction methods do not involve costly, timely, and subjective ratings (the CLASS rating system requires 17-25 hours of training)

- Wide variance in phys. features of human voice; e.g., frequency, continuity, volume, brightness, speed, pitch, ...
- Humans convert these physical features to perceptual features like emotion like anger, confidence, happiness, tenderness, male/female, dominating, ...
- Small number of studies have tried to make the connection
 - music (Friberg et al. 2014)
 - passion and masculinity from politicians (Dietrich and Juelin 2012, Anderson and Klofstad 2012)
 - trust (Klofstad and Peters (2012)
- Studies on audio and education
 - Some story teller's voices easier to pay attention to (Lyberg et al. 2015)
 - Slower speech increases language comprehension (Haake et al. 2015)
Native-English-speaking TAs increase accessibility of lectures

(Pickering, 2001)

- Potentially a key factor of the teaching-learning process (R
2016)
 - 50% to 90% of time spent listening to the teacher
 - Some voices found to be more effective (Schmidt et al., 19
 - Affects comprehension (e.g., speed in Lyberg-Åhlander et al
frequency of pauses in Schmidt et al., 1998)
- Could change perceptions and behavior (Amir and Levine-Y
- Corresponds to different ways of teaching
 - proportion of time spent speaking
 - interruptions

- Explore predictive power of physical features in teacher voice value-added
- Compare predictive power with that from classroom observation assessments
- Focus on top and bottom value-added teachers
- Generate hypothesis on what could possibly matters in evaluating teachers' quality

- Obtain data with classroom recordings and value added es
 - Convert videos to audio files and isolate teacher's voice
 - Convert teacher voice to physical feature variables
 - Train computer to predict VA based on these variables
 - Examine predictive power of audio variables
 - Train computer to predict VA based on human assessor ob
- Examine predictive power of these variables and compare w

- Largest study of classroom teaching ever conducted, sponsored by the Bill & Melinda Gates Foundation
- Began in 2009-10, lasting 2-4 years
- 6 large U.S. school districts
- 315 schools
- 3,000 volunteer teachers, Gr 4-9, Math and ELA
- 6,500 sections
- 45,000 students
- 11,541 videos of 1,470 consenting MET teachers

Student achievement outcomes: test scores; students surveyed

Survey could be an interesting alternative for a similar study

- Once the teacher is identified → select a clip of 15 seconds
- We extract features from the voice (≈ 30 variables + high)


Full list


- Pitch: how *high* the voice is
- Spectral centroid: how *bright* the voice is
- Zero-crossing rate: how *smooth* the voice is
- spectral bandwidth, amplitude, spectral flatness, tempo roll, root-mean sqr. energy mel-frequency cepstrum (1-20)
- Most variables are extracted as vectors $\Rightarrow$ compute the mean and the distribution $\Rightarrow$ include the variance

From the overall 30-minute segment, we measure the proportion of words spoken by the teacher (v.s. students)


Apply ML algorithm for predictions: Penalized logistic, SVM, XGBoost, NN

Model





*The teacher's voice could be as informative as CLASS scores w
more expensive and time consuming to collect*



Similar findings when:

- Using different teacher videos (same teacher)
- Combining video recordings (same teacher)
- Using different recordings as additional data/group splitting (biased error estimates (accuracy= 0.634**))
- Taking the mean values of features from different recordings (0.617**)
- Conditioning on math and ELA classes separately (ELA = 0.647**)
- Conditioning on female teachers only (85(Women = 0.664
- Extending to teachers in other deciles top/bottom 10% (0.560**) vs. CLASS (accuracy= 0.566**) top/bottom 25% (0.550**) vs. CLASS (accuracy= 0.532**)
- Manually varying the timestamps where voice and classroom were captured
- Take multiple timestamps
- Take random timestamps
- Take the mean values of features from different timestamps
- Use voice segments found by the computer (useful to extend to diarization)
- Checking for bias: regress predicted probability on gender

0.9747)

- Hire human evaluator to rate the teachers based on the voice and the machine findings
- According to evaluators: psychological features weigh more
 - Psychological features (e.g. warm, competent): 66%
 - Technical features (e.g. pitch, speed): 33%
 - → inferred psychological traits from voice Word cloud Regression
- Conditional logit model: most important variables to explain the choice
 - (–) authoritarian
 - (+) communicative, competent, stern, warm
 - technical features have low predictive power

■ Overall

- The future will be in decision-making using AI at firm levels, government level and for public policy.
- Africa and Cote d'Ivoire especially will need to catch up and in this sense.

■ Overall

- The future will be in decision-making using AI at firm levels, government level and for public policy.
- Africa and Cote d'Ivoire especially will need to catch up and in this sense.

■ ML for education

- Make a difference in our education system just by recording
- Targeting policy for training and capacity reinforcement

■ Overall

- The future will be in decision-making using AI at firm levels, government level and for public policy.
- Africa and Cote d'Ivoire especially will need to catch up and in this sense.

■ ML for education

- Make a difference in our education system just by recording
- Targeting policy for training and capacity reinforcement

■ How to benefit more?

- Foster collaboration between government, universities and p
Collect data and Facilitate data access for researchers.
Question related to ethics, privacy, and fairness.



Thank you

For a student i in group g on year t , estimate

$$y_{igt} = \beta + \bar{x}_{gt}\gamma + \vartheta y_{i,t-1} + \lambda y_{g,t-1} + \epsilon_{igt}$$

characteristics

teacher score

x_{it} : ethnicity, age, gender, special education, free lunch

Let the students of teacher j in group g on year t be represented by N_{jgt} .

The value-added of teacher j is

$$VA_j = \frac{1}{|N_{jgt}|} \sum_{i \in N_{jgt}} \hat{g}_{igt}$$

Ministère de l'

IPCI-SC2-Prediction

ASSOHOUNE. S





- ❑ **Décembre 2019, A**
chinoises, Province
- ❑ **11 mars 2020, La m**
causé par le virus **SA**
- ❑ **A la date 20-12-202**
d'ivoire) [2]

❑ Tous les virus, y compris

➤ Facilité de propagation

➤ Gravité de la maladie

➤ Réduire la persistance

➤ ...

- ❑ Institut Pasteur de diagnostic biologique

- ❑ L'IPCI lance son pr et biologie comput

Métagénomique

variants du virus ci

❑ **Missions du pole**

- **Mission 1:** Séquençage des génomes de S
- **Mission 2:**
 - Conception du séquençage des génomes de S
 - Assignment de la mission d'Ivoire

Objectif Général:

Com



- Implémenter un modèle (SNPs) issues d'isolats





❑ Séquençage NGS



Clin

wet

dry

SNP
map

❑ Réseau de Neurone







Tâche 1





Tâche 1



Prétraitement Des Données

- Binarisation
- Labelisation
- Splitage [70,15,15]
- Equilibrage de classes

Technologies






Résultats 1 et 2




Résultat

Résultat 2-1: Classifieur ANN1 de




Résultat 2-2: Classifieur A



Résultat 2: Prédiction de

Proportion des variants



Résultat 3 : Data shari

Institute information

Originating lab:

De

Address:

Ins

**Sample ID given by the
originating laboratory:**

CC

Submitting lab:

Mo

Address:

Ins

**Sample ID given by the
submitting laboratory:**

hC

Authors:

Ar

Ma

Fra

Submitter information

Submitter:

Sta



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



H3ABioNet

Pan African Bioinformatics Network

African Union



JE VOUS RE

L'intelligence

AR

IV

accompagnement
de données

SaH Analytics
consultants

descriptive



Que s'est-il passé da

Le Security Operations
Le SOC est une plateforme
de collecte, de corrélation
principal du SOC puisse

SaH Analytics a des re

- Détecter
- Analyser
- Rémedier
- Surveiller

En Temps réel votre sé

SaH Analytics Inc
à des **données**
services basés s


RÉALISATIONS

L'application web et Ap
COVID a été mise en pl
l'impression de certific
personnes ayant passé

full_vaccinated_count

% of Full V

● Other





Le but u
population
fournis



Criteres

Gouvernement

- **La géolocalisation**
- **La situation administrative**
- **Les infrastructures**
- **l'état des infrastructures**
- **Le nombre de voisins**
- **La population voisine**
- **Le nombre de voisins défavorisés;**
- **La distance entre l**

Santé

Mathématique

Selectionner un thème

Executer

HPCC

01

Qu'est ce que le HPC?

02

Structure et Architecture d

03

Composition d'un HPC

04

Conception d'un HPC

05

Qu'est ce que l'IA



Qu'est ce c

Description

Le **HPC**, ou c
ou HPC)

C'est l'utilis
pour résoudre

Le HPC est
simulation
divertissem



Les supercalculateurs
conçus pour exécuter



Ils peuvent être équipés de
disques durs, de cartes de
communication



Le HPC utilise énormément de
calculs sur plusieurs processeurs
les temps de calcul



Composition

01

Serveurs de calcul

05

Logiciels

- Note importante -

Il est important de noter
en place un système HP
un projet complexe et
qu'il peut être nécessaire
appel à des experts en in
haute performance pou
bien cette tâche

US

Qu'est ce c



Description

L'intelligence

programmes

L'IA peut être

l'image, la tr

Elle peut éga

quantités de

L'IA est un d

et les consé



Le Deep Le



Le Deep Le

- La valeur

Le HPC et DL

- Grand vo
- Grand vo

Les même m

- Le techn



Structure d

Les processus

Calcul du gradient local

Moyenne globale des gradients

Répéter



HPDA (Fusio

HPDA, ou analyse de données
l'intelligence artificielle et a
noter:

1. **Augmentation de l'effi**
2. **Amélioration de la pré**
3. **Meilleure grande scala**
4. **Amélioration de la pris**
5. **De nouvelles opportur**

En somme le HPDA met à la
depuis des complexes et gr

01

Coût de l'infrastructure
de calcul

02

Demande en éner

03

Transfert de donn

1. **Traitement**
2. **Amélioration**
3. **Innovation**
4. **Optimisation**

En résumé, la
données de m
de créer de n



Application

**La CIE fait face à des problèmes
diverses dont le HPC propose
des solutions optimales**



**Traitement de large volume
de données**

- Facturation
- Supply Chain
- Gestion financière



Application


La CIE dispose :

- d'un data center
- d'une base logicielle à
- d'un réseau privé interne

**Ces éléments constituent
l'infrastructure HPC, et p
de calcul offert par cell**

MER

Endoscopic assess the



SUMMARY


My interests lie in solving real-world problems by extracting insights from large datasets in intelligent driverless car systems. Published author of several international conference publications.


WORK EXPERIENCE

- | | |
|---------------------|---|
| Sept 2022 – Present | Senior Data Scientist, Microsoft <ul style="list-style-type: none">□ Building advanced AI models for healthcare |
| Jul 2022 – Present | Clinical Research Associate, Microsoft <ul style="list-style-type: none">□ Developing explainable AI models |
| Jul 2021 – Jul 2022 | Research Fellow in AI for Healthcare, Microsoft <ul style="list-style-type: none">□ Developed AI models for medical image analysis |
| Feb 2020 – Jul 2021 | Postdoc - AI in Radiology, Microsoft <ul style="list-style-type: none">□ Developed multiple AI models for medical image analysis |


EDUCATION

Endoscopic image





Doubtful response with complete re



Motivation:

- Experienced Endoscopists: AU
- AI Model: AU

Aim:

- Accurate response evaluation in patients diagnosed treated with
- The aim is to evaluate the accuracy of endoscopic images and clinical

DATASET

Number of patients: 226(~4 im

- Complete response: 109
- Non-complete response: 117


Age, median (IQR), year
Sex, <i>n</i> (%)
Male
Female
Clinical T-stage, <i>n</i>(%)
1–2
3
4
Clinical N-stage, <i>n</i>(%)
0
1
2
Neoadjuvant treatment, <i>n</i>(%)
5 × 5 Gy + prolonged waiting interval
CRT
Adjuvant chemotherapy, <i>n</i>(%)
Yes

Clinical Features


- age
- sex
- clinical T-stage
- clinical N-stage
- neoadjuvant treatment
- time between restaging endoscopy and surgery


Clinical featur

Feature importance



Tree







Comparison of Model by Classification



- Top results achieved models in natural object recognition on the ImageNet Large Scale Visual Recognition competition.
 - **EfficientNet** is one of the recent convolutional network architectures that achieve a good trade-off between accuracy and efficiency as compared to the previous models.
 - **ResNet** design is able to stabilize gradient flow, avoiding gradient explosion or vanishing problems.
 - **MobileNet** separates convolution into depthwise and pointwise convolutions, compresses the model, and keeps the accuracy level.
- **Deep learning model construction**
 - **Endoscopic image only**
 - **Endoscopic image and selected color channels**



C



ROC curve of EfficientNet-B2 for t

Endoscopic Imag



Results:

- Deep learning on endoscopy and chemoradiation.
- This study shows that deep learning models can assist endoscopists in chemoradiation studies are required.
- The trained models could be used in clinical studies where medical experts are scarce.

RFE: Haak, H.E., Gao, X., Maas, M., **Waktola**, S.
endoscopic images to assess the response of rectal