

Article

Application mobile intelligente pour l'identification des produits et l'aide à la décision d'achat dans le commerce local à Butembo, RDC

Kavusa Kasoko^{1,2}, Takenga Claude³, Mayala Lemba Francis¹

¹ Domaine des Sciences Economiques et de Gestion, Université Pédagogique Nationale, B.P. 8815, Kinshasa 1, République Démocratique du Congo

² Domaine des Sciences Economiques et de Gestion, Université de l'Assomption au Congo, B.P. 104, Butembo, République Démocratique du Congo

³ Domaine des Sciences Juridiques, Politiques et Administratives, Université Officielle de Ruwenzori, B.P. 560, Butembo, République Démocratique du Congo

Correspondant : jgkasoko@gmail.com

Citation : Kasoko, K., Takenga, C. et Lemba, M.F, Application mobile intelligente pour l'identification des produits et l'aide à la décision d'achat dans le commerce local à Butembo, RDC. *Etincelle*. 2026, Vol. 26, no. 2. <https://doi.org/10.61532/rime262129>

Reçu: 05 juillet 2026

Accepté: 14 juillet 2026

Publié: 16 juillet 2026

Note de l'éditeur: Ishango-uac reste neutre en ce qui concerne les revendications juridictionnelles dans les cartes géographiques publiées et les affiliations institutionnelles des auteurs.



Copyright: © 2026 par les auteurs. Soumis pour une publication en libre accès selon les termes et conditions de la licence Creative Commons Attribution (CC BY) (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: La transformation numérique du commerce constitue un levier important pour améliorer l'accès à l'information et soutenir la décision d'achat. Dans les marchés locaux encore peu numérisés, les consommateurs rencontrent des difficultés à identifier rapidement les produits disponibles, à comparer les prix et à localiser les points de vente les plus avantageux. Cette problématique est particulièrement visible à Butembo, en République démocratique du Congo, où l'information commerciale reste dispersée et peu structurée. La présente recherche propose une application mobile intelligente capable d'identifier automatiquement des produits à partir d'images capturées par smartphone et d'orienter l'utilisateur vers des offres pertinentes. La solution combine vision par ordinateur, apprentissage profond embarqué, TensorFlow Lite, géolocalisation et recommandation multicritère. MobileNetV2 a été retenu en raison de son compromis entre performance et légèreté sur terminaux mobiles. Les expérimentations menées sur 948 images réparties en 53 catégories montrent une exactitude de 87 %, une précision pondérée de 86 %, un rappel pondéré de 87 % et un score F1 pondéré de 85 %. Ces résultats attestent la faisabilité technique d'un système embarqué de reconnaissance de produits et de recommandation géolocalisée adapté aux environnements à ressources limitées. Ils doivent toutefois être complétés par une étude utilisateur afin de mesurer l'effet réel de l'application sur le temps de recherche, la qualité des décisions d'achat et l'appropriation par les commerçants.

Mot clés : Apprentissage profond, MobileNetV2, vision par ordinateur, TensorFlow Lite, application mobile, aide à la décision, commerce numérique, géolocalisation.

1. Introduction

L'accès à une information fiable et pertinente constitue l'un des facteurs déterminants de la qualité des décisions économiques prises par les consommateurs. Dans les économies fortement numérisées, les technologies numériques améliorent la transparence des marchés en facilitant la comparaison des prix, des caractéristiques des produits et des services proposés par les vendeurs (Laudon & Traver, 2019). Cette dyna-

mique reste cependant limitée dans plusieurs villes africaines où le commerce de proximité repose encore largement sur des mécanismes traditionnels d'échange et sur une information peu centralisée.

La ville de Butembo occupe une place stratégique dans l'économie de l'Est de la République démocratique du Congo. Son dynamisme commercial s'appuie sur un réseau dense de petites et moyennes entreprises intervenant dans divers secteurs d'activité. Malgré cette vitalité, les consommateurs doivent souvent visiter plusieurs commerces avant de trouver un article, d'en connaître le prix réel ou d'identifier une offre compatible avec leur budget. Cette situation accroît les coûts de recherche et limite la capacité de comparaison.

Ce problème rejoint la théorie de l'asymétrie d'information proposée par Akerlof (1970), selon laquelle l'efficacité d'un marché dépend de la qualité de l'information disponible pour les acteurs. Lorsque certaines informations essentielles sont difficiles d'accès, les consommateurs prennent des décisions moins optimales et supportent des coûts supplémentaires. Dans le contexte de Butembo, une solution mobile capable de rapprocher l'information du consommateur peut donc contribuer à une meilleure transparence commerciale.

Parallèlement, les progrès de l'intelligence artificielle ont transformé la capacité des systèmes informatiques à analyser des données complexes. Les réseaux neuronaux convolutifs ont démontré leur efficacité dans les tâches de reconnaissance visuelle (LeCun et al., 2015). Le développement d'architectures légères, comme MobileNetV2, rend désormais possible l'exécution de modèles de Deep Learning sur smartphone, avec des exigences réduites en mémoire et en calcul (Sandler et al., 2018). Les travaux récents sur l'IA embarquée et l'Edge Deep Learning confirment également l'intérêt des modèles compacts pour les dispositifs à ressources limitées (Deng, 2019; Xu et al., 2025).

La présente étude vise à exploiter ces avancées afin de développer une application mobile intelligente capable d'identifier automatiquement des produits et d'assister les consommateurs dans leur décision d'achat. Elle répond à la question suivante : dans quelle mesure une application mobile basée sur l'apprentissage profond embarqué peut-elle améliorer l'identification des produits et soutenir l'accès à l'information commerciale dans le commerce local à Butembo ?

L'hypothèse générale est que l'intégration de la vision par ordinateur, de la géolocalisation et d'un module de recommandation dans une application mobile améliore l'accès à l'information commerciale. Trois hypothèses opérationnelles guident l'étude : H1, l'identification automatique des produits peut réduire le temps de recherche d'information ; H2, la recommandation géolocalisée peut améliorer l'accès aux points de vente pertinents ; H3, MobileNetV2 offre des performances compatibles avec les contraintes matérielles des smartphones utilisés dans le contexte étudié. Les deux premières hypothèses devront être renforcées ultérieurement par une évaluation utilisateur, tandis que la troisième est examinée par les performances expérimentales du modèle.

2. Revue de littérature

Les systèmes d'aide à la décision occupent une place importante dans les applications contemporaines du commerce numérique. Les systèmes de recommandation permettent aux utilisateurs d'effectuer des choix plus pertinents à partir de données disponibles, en filtrant les options et en les ordonnant selon leur intérêt pour l'utilisateur (Ricci et al., 2015). Dans des contextes instables ou peu structurés, l'intégration de facteurs contextuels améliore également la pertinence des recommandations, comme le montrent des travaux récents sur les recommandations contextualisées en environnement de ressources limitées (Mpia et al., 2023).

Dans le domaine de la vision par ordinateur, les réseaux neuronaux convolutifs ont profondément amélioré la reconnaissance d'images en permettant l'apprentissage

automatique de caractéristiques visuelles complexes (Goodfellow et al., 2016; Le Cun et al., 2015). Toutefois, leur déploiement sur smartphone reste conditionné par la mémoire disponible, la puissance de calcul et la consommation énergétique. Les architectures légères répondent à cette contrainte en réduisant le nombre de paramètres et les opérations nécessaires à l'inférence.

MobileNetV2 constitue l'une de ces architectures légères. Elle repose sur des convolutions séparables en profondeur et des blocs résiduels inversés, ce qui diminue le coût computationnel tout en conservant une bonne capacité de représentation visuelle (Sandler et al., 2018). Cette logique rejoint les travaux sur les systèmes d'apprentissage profond embarqués, qui montrent que des modèles légers peuvent produire des résultats fiables dans des environnements à ressources limitées, notamment lorsqu'ils sont couplés à des dispositifs locaux ou à des plateformes mobiles (Deng, 2019; Mpia et al., 2025; Xu et al., 2025).

La plupart des travaux existants portent sur des contextes fortement numérisés ou sur des domaines spécialisés tels que la santé, la surveillance ou l'Internet des objets. Peu d'études analysent l'usage combiné de la reconnaissance visuelle, de la géolocalisation et de la recommandation commerciale dans les marchés locaux africains, où les données sont souvent peu abondantes, hétérogènes et rarement mises à jour. C'est dans ce vide scientifique et pratique que s'inscrit la présente recherche.

Le tableau 1 situe la contribution de l'étude par rapport aux principaux travaux mobilisés. Il montre que la présente recherche ne se limite pas à la reconnaissance d'images : elle associe l'identification automatique des produits à une logique de recommandation géolocalisée et à une base d'information commerciale locale.

Tableau 1 : Synthèse critique des travaux mobilisés

Auteur(s)	Technologie ou approche	Domaine	Apport principal	Limite au regard de cette étude
Akerlof (1970)	Asymétrie d'information	Économie des marchés	Montre l'effet du manque d'information sur la qualité des décisions	N'intègre pas de solution numérique de réduction de l'asymétrie
LeCun et al. (2015)	Réseaux neuronaux profonds	Vision par ordinateur	Établit le rôle du Deep Learning dans la reconnaissance visuelle	Ne traite pas le commerce mobile local
Ricci et al. (2015)	Systèmes de recommandation	Commerce numérique	Formalise les approches de recommandation et de personnalisation	N'intègre pas l'identification visuelle de produits
Sandler et al. (2018)	MobileNetV2	Vision embarquée	Propose une architecture légère adaptée aux terminaux mobiles	Pas d'application directe à l'aide à l'achat local
Mpia et al. (2023)	Recommandation contextualisée	Environnement instable	Montre l'importance des facteurs contextuels dans les recommandations	Domaine de l'employabilité, non du commerce

Mpia et al. (2025)	Deep Learning léger embarqué	Système intelligent à ressources limitées	Illustre la faisabilité d'un pipeline léger en contexte contraint	Domaine audio, non reconnaissance de produits
Xu et al. (2025)	Edge Deep Learning	Vision par ordinateur embarquée	Synthétise les enjeux de l'IA sur périphérie et des modèles légers	Perspective générale, non centrée sur Butembo
Présente étude (2026)	MobileNetV2 + TensorFlow Lite + Flutter + géolocalisation	Commerce local à Butembo	Identifie les produits et recommande des points de vente selon prix, distance et disponibilité	Base de données limitée et prix à actualiser dynamiquement

3. Méthodologie

Cette étude s'inscrit dans une démarche de recherche appliquée fondée sur la conception, le développement et l'évaluation expérimentale d'un prototype fonctionnel. La méthodologie comprend quatre étapes : la collecte des données commerciales locales, l'entraînement du modèle de reconnaissance, le développement de l'application mobile et l'évaluation du système par des métriques de classification.

La collecte de terrain a permis de constituer une base de données locale regroupant les images des produits, les prix pratiqués par les points de vente, les informations de disponibilité et les coordonnées géographiques des commerces. Après nettoyage et prétraitement, le jeu de données final comprend 948 images réparties en 53 catégories de produits. La distribution des exemples par classe est présentée à la figure 1.

3.1. Protocole de collecte des images

Les images ont été collectées entre janvier et mars 2026 dans différents commerces de Butembo, avec l'autorisation préalable des commerçants concernés. Les produits ont été photographiés individuellement dans leur environnement réel de vente afin de rapprocher la base d'apprentissage des conditions futures d'utilisation de l'application. Chaque image a ensuite été vérifiée manuellement afin d'éliminer les doublons, les images floues et les captures dont la qualité était insuffisante pour l'entraînement.

3.2. Critères de sélection des 53 catégories

Les 53 catégories retenues correspondent aux produits fréquemment observés dans les commerces de proximité. La sélection a été guidée par trois critères : la fréquence d'apparition du produit dans les magasins visités, son importance dans les achats quotidiens et la disponibilité d'un nombre minimal d'images exploitables pour l'entraînement. Cette stratégie favorise la pertinence pratique du prototype tout en reconnaissant la limite d'un jeu de données encore modeste.

3.3. Conditions de prise de vue

Les photographies ont été réalisées à l'aide de smartphones Android de milieu de gamme afin de reproduire les conditions réelles d'usage. Les prises de vue ont été effectuées sous différents niveaux d'éclairage, avec des angles d'observation variés et des distances comprises approximativement entre 30 cm et 100 cm. Cette diversité vise à améliorer la robustesse du modèle face aux variations rencontrées dans les points de vente.

3.4. Augmentation des données

Afin d'améliorer la capacité de généralisation du modèle et de limiter le risque de surapprentissage, plusieurs techniques d'augmentation artificielle ont été appliquées durant l'entraînement : rotations aléatoires, variations de luminosité, zoom, translations et inversions horizontales. Ces transformations accroissent la diversité des exemples présentés au réseau, sans toutefois remplacer la nécessité d'un élargissement réel de la base d'images.

La figure 1 montre un déséquilibre entre les classes : certaines catégories disposent d'un nombre élevé d'images, alors que d'autres restent faiblement représentées. Cette caractéristique explique en partie l'écart observé plus loin entre les métriques pondérées et les métriques macro.




Figure 1 : Distribution des produits dans la base de données

Le jeu de données a été réparti en trois sous-ensembles : 663 images pour l'entraînement (70 %), 142 images pour la validation (15 %) et 143 images pour le test (15 %). Une stratégie de transfert d'apprentissage a été utilisée à partir des poids préentraînés de MobileNetV2. L'optimiseur Adam a été retenu avec un taux d'apprentissage initial de 0,001 et un entraînement sur quinze époques.

3.5. Modélisation et fonctions utilisées

Le traitement des images repose sur l'opération de convolution, qui permet d'extraire des caractéristiques visuelles à partir de noyaux appliqués sur l'image d'entrée.

$$S(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n)$$

Dans cette équation, I représente l'image d'entrée, K le noyau de convolution et S la carte de caractéristiques obtenue.

$$\text{ReLU}(x) = \max(0, x)$$

La couche de sortie utilise la fonction Softmax afin d'associer à chaque classe une probabilité normalisée.

$$P(y_i) = \frac{\exp(z_i)}{\exp(z_1) + \dots + \exp(z_K)}$$

Ici, $P(y_i)$ désigne la probabilité de la classe i , z_i le score produit par le réseau pour cette classe et K le nombre total de classes. Ces mécanismes permettent au modèle d'apprendre automatiquement les caractéristiques discriminantes des produits étudiés.

Afin d'identifier l'architecture la plus adaptée au contexte de cette étude, plusieurs modèles ont été évalués sur le même jeu de données. Les résultats sont présentés et interprétés ci-dessous afin de justifier le choix méthodologique de MobileNetV2 et de préciser les limites liées à la taille et au déséquilibre du corpus d'images.

Tableau 2 : Comparaison des architectures évaluées

Architecture	Exactitude / Accuracy (%)
EfficientNetB0	8
MLP	14
ResNet50	33
CNN simple	84
MobileNetV2	87

Le tableau 2 montre que MobileNetV2 obtient la meilleure exactitude (87 %), devant le CNN simple (84 %). Cette proximité indique que les architectures légères sont plus adaptées au volume de données disponible que les modèles plus complexes dans cette configuration. Les faibles performances d'EfficientNetB0, du MLP et de ResNet50 ne doivent donc pas être interprétées comme une faiblesse intrinsèque de ces architectures, mais plutôt comme l'effet probable d'un corpus limité, déséquilibré et d'un paramétrage expérimental orienté vers l'embarqué.

Tableau 3 : Performances globales du modèle MobileNetV2

Métrique	Valeur (%)
Accuracy / exactitude	87
Précision pondérée	86
Rappel pondéré	87
F1-score pondéré	85

Le tableau 3 confirme la cohérence des performances globales de MobileNetV2. L'exactitude de 87 %, associée à une précision pondérée de 86 %, un rappel pondéré de 87 % et un F1-score pondéré de 85 %, suggère une bonne capacité de reconnaissance pour les classes les mieux représentées. Ces résultats appuient le choix du modèle pour une application mobile, tout en restant dépendants de la qualité et de la diversité des images d'entraînement.

Tableau 4 : Analyse des métriques macro

Métrique	Valeur (%)
Macro-précision	78
Macro-rappel	81
Macro F1-score	78

Pris ensemble, les tableaux 2, 3 et 4 montrent que le choix de MobileNetV2 est justifié dans le contexte de l'étude. Cependant, la performance globale ne suffit pas à

garantir une reconnaissance homogène de toutes les catégories. L'amélioration du système devra donc porter sur l'équilibrage du jeu de données, l'augmentation ciblée des images et la poursuite des tests en conditions réelles d'utilisation.

La figure 2 présente l'évolution de l'exactitude durant l'entraînement. La progression conjointe des courbes d'apprentissage et de validation suggère une convergence stable du modèle. L'écart final entre les deux courbes reste contenu, même si un léger écart indique la nécessité d'une validation sur une base externe plus large.




Figure 2 : Évolution de l'accuracy sur les ensembles d'apprentissage et de validation

La figure 3 facilite la comparaison visuelle des architectures évaluées. Elle confirme que MobileNetV2 offre le meilleur compromis dans la configuration expérimentale retenue. Le terme « précision » figurant dans l'image doit être compris ici comme l'exactitude globale rapportée dans le tableau 2.




Figure 3 : Comparaison des architectures évaluées

Ces résultats suggèrent que les architectures plus complexes ne garantissent pas systématiquement de meilleures performances lorsque le volume de données d'entraînement demeure limité. Dans ce cas, MobileNetV2 apparaît comme le meilleur compromis entre capacité de généralisation, légèreté computationnelle et adaptation aux environnements mobiles contraints.

4. Réalisation du système

4.1. Architecture générale

L'application repose sur une architecture multicouche intégrant une interface utilisateur Flutter, un moteur de reconnaissance visuelle basé sur MobileNetV2, un module de recommandation géolocalisée et une base de données locale. L'objectif est de permettre à l'utilisateur d'identifier un produit à partir d'une image capturée par smartphone et d'obtenir des informations utiles à la décision : prix, disponibilité, proximité et points de vente recommandés.

La figure 4 synthétise cette architecture. Elle montre l'enchaînement entre l'utilisateur, l'application mobile, le module d'intelligence artificielle, le moteur de recommandation, le GPS, la base de données et l'affichage final des résultats.




Figure 4 : Architecture générale du système

Comme l'illustre la figure 4, le processus débute par l'acquisition d'une image à l'aide de la caméra. L'image est prétraitée puis analysée par le modèle MobileNetV2. Les informations associées au produit identifié sont extraites de la base locale, puis combinées aux coordonnées de l'utilisateur pour produire une recommandation contextualisée.

4.2. Processus d'identification et de recommandation

La figure 5 détaille le flux opérationnel du système, depuis la capture de l'image jusqu'à l'affichage des recommandations. Elle permet de distinguer le cas où le produit est reconnu et celui où le système invite l'utilisateur à reprendre ou améliorer la capture.




Figure 5 : Processus d'identification et de recommandation

Après la capture, l'image est redimensionnée et normalisée avant d'être soumise au modèle MobileNetV2 converti au format TensorFlow Lite. Si le produit est reconnu, son identifiant sert à interroger la base de données pour récupérer le nom, le prix, la disponibilité et les magasins qui le commercialisent. Le module GPS fournit ensuite la position de l'utilisateur, ce qui permet de calculer les distances et de classer les options disponibles.

4.3. Algorithme de recommandation géolocalisée

La distance entre la position de l'utilisateur et les points de vente est calculée à l'aide de la formule de Haversine, couramment utilisée pour estimer la distance orthodromique entre deux coordonnées géographiques.

$$d = 2R \cdot \arcsin\left(\sqrt{\sin^2(\Delta\varphi/2) + \cos(\varphi_1)\cos(\varphi_2)\sin^2(\Delta\lambda/2)}\right)$$

Dans cette équation, R représente le rayon moyen de la Terre, φ_1 et φ_2 les latitudes, λ_1 et λ_2 les longitudes, $\Delta\varphi$ la différence de latitude et $\Delta\lambda$ la différence de longitude. Les commerçants sont ensuite classés selon un score combinant la distance, le prix et la disponibilité du produit. Cette approche transforme la reconnaissance visuelle en information directement exploitable pour la décision d'achat.

5. Résultats

Le modèle MobileNetV2 a été entraîné à partir des images collectées sur le terrain en utilisant le transfert d'apprentissage. Après quinze époques, les performances sur l'ensemble de test sont présentées au tableau 5. Ce tableau reprend les indicateurs essentiels pour apprécier la capacité du modèle à reconnaître correctement les produits.

Tableau 5 : Résultats de l'entraînement et du test du modèle MobileNetV2

Métrique	Valeur (%)
Accuracy / exactitude	87
Précision pondérée	86
Rappel pondéré	87
F1-score pondéré	85

Les résultats montrent que MobileNetV2 atteint une exactitude globale de 87 % sur l'ensemble de test. La proximité entre la précision, le rappel et le F1-score pondérés indique un comportement relativement équilibré du modèle. En revanche, les métriques macros plus faibles rappellent que certaines classes demeurent moins bien représentées, ce qui peut affecter la stabilité du modèle pour les produits rares.

Les essais réalisés sur des smartphones Android de milieu de gamme indiquent que le système reste compatible avec des terminaux à ressources limitées. L'utilisation de TensorFlow Lite favorise l'exécution locale de l'inférence, réduit la dépendance à une connexion Internet permanente et améliore la réactivité du système. Ces observations sont cohérentes avec les travaux sur l'apprentissage profond mobile et l'Edge Deep Learning (Deng, 2019; Xu et al., 2025), ainsi qu'avec des expériences récentes de systèmes légers en contexte contraint (Mpia et al., 2025).

6. Discussion

6.1. Interprétation des résultats

Les résultats obtenus démontrent que MobileNetV2 constitue une solution pertinente pour une application mobile intelligente destinée au commerce local. L'exactitude de 87 % indique que le modèle identifie correctement la majorité des produits présents dans la base de test. Toutefois, cette performance ne doit pas être confondue avec une validation complète de l'impact économique de l'application : elle prouve d'abord la faisabilité technique de la reconnaissance embarquée.

6.2. Comparaison avec les études antérieures

Les performances obtenues sont cohérentes avec les travaux de Sandler et al. (2018), qui soulignent l'intérêt de MobileNetV2 pour les environnements mobiles. Elles rejoignent également les analyses de Deng (2019) et de Xu et al. (2025) sur la possibilité d'exécuter localement des tâches complexes de reconnaissance visuelle sur des dispositifs à ressources limitées. La contribution spécifique de cette étude réside dans l'intégration simultanée de la reconnaissance de produits, de la géolocalisation et de la recommandation commerciale dans un contexte africain peu numérisé.

Le tableau 6 présente un positionnement de la présente recherche par rapport aux références vérifiées. Il évite de comparer directement des exactitudes issues de jeux de données différents et privilégie une comparaison par apport scientifique et technique.

Tableau 6 : Positionnement de l'étude par rapport aux travaux antérieurs

Étude	Objet principal	Apport retenu	Lien avec la présente étude
Sandler et al. (2018)	MobileNetV2	Architecture légère pour vision embarquée	Justifie le choix du modèle de reconnaissance
Deng (2019)	Deep Learning sur mobile	Synthèse des défis matériels et logiciels du déploiement mobile	Appuie l'exécution locale sur smartphone

Mpia et al. (2023)	Recommanda- tion contextuali- sée	Importance des facteurs locaux dans les systèmes de recomman- dation	Renforce la logique de recom- mandation adaptée au con- texte
Mpia et al. (2025)	Système léger en contexte con- traint	Pipeline IA embarqué à faible la- tence	Confirme l'intérêt des solu- tions IA légères en environne- ment limité
Xu et al. (2025)	Edge Deep Learning	Revue des modèles légers et du calcul en périphérie	Appuie le choix de l'inférence locale
Présente (2026)	étude de produits et recommanda- tion géolocalisée	Reconnaissance Prototype mobile adapté au com- merce local de Butembo	Contribution appliquée à un marché local africain

6.3. Limites de l'étude

Plusieurs limites doivent être prises en compte dans l'interprétation des résultats. Premièrement, le jeu de données demeure limité au regard du nombre de catégories, ce qui peut restreindre la capacité de généralisation du modèle. Deuxièmement, le déséquilibre entre certaines classes explique les performances plus faibles des métriques macro. Troisièmement, les variations d'éclairage, les changements d'emballage et les occultations partielles peuvent affecter la qualité de la classification en conditions réelles. Quatrièmement, l'évolution rapide des prix dans le commerce local nécessite un mécanisme fiable de mise à jour des données. Les tests fonctionnels et de compatibilité réalisés sur plusieurs smartphones Android ont confirmé le bon fonctionnement des principales fonctionnalités (capture, classification, recommandation, GPS et TensorFlow Lite), tandis que les utilisateurs ont jugé l'application simple d'utilisation, rapide et utile pour localiser les points de vente grâce à l'intégration de Google Maps. Ces résultats confirment la faisabilité technique et une première appréciation positive du prototype, sans pour autant démontrer son impact réel sur la réduction du temps de recherche, l'amélioration des décisions d'achat ou la satisfaction des utilisateurs. Une évaluation à plus grande échelle, fondée sur des tests d'utilisabilité et des mesures quantitatives, sera nécessaire pour valider ces effets.

6.4. Implications scientifiques et perspectives

Sur le plan scientifique, cette étude confirme la pertinence du transfert d'apprentissage et des architectures légères de Deep Learning pour des environnements à ressources limitées. Sur le plan pratique, elle montre qu'un outil mobile peut contribuer à réduire les asymétries d'information dans les marchés locaux africains. Les perspectives concernent l'élargissement de la base de données, l'intégration d'un mécanisme collaboratif de mise à jour des prix, l'évaluation de l'expérience utilisateur et l'exploration de modèles multimodaux combinant image, texte, localisation et données transactionnelles.

7. Conclusion

Cette recherche avait pour objectif de développer une application mobile intelligente capable d'identifier automatiquement des produits et d'assister les consommateurs dans leurs décisions d'achat à Butembo. Les résultats expérimentaux montrent que l'apprentissage profond embarqué, en particulier MobileNetV2 déployé avec TensorFlow Lite, peut être utilisé efficacement pour la reconnaissance de produits sur smartphone.

Au-delà de son apport technologique, l'étude propose une réponse concrète à l'asymétrie d'information qui caractérise plusieurs marchés locaux. En associant identification visuelle, informations commerciales et géolocalisation, l'application peut favoriser une meilleure transparence du marché et améliorer l'expérience d'achat. Néanmoins, l'impact réel sur le comportement des consommateurs et l'appropriation par les commerçants devra être évalué par des tests utilisateurs et par une mise à jour dynamique des données commerciales.

Les perspectives futures portent sur l'extension de la base de données des produits, la mise à jour automatique des prix, la participation directe des commerçants et l'intégration de modèles multimodaux plus avancés. Cette contribution ouvre ainsi une voie pertinente pour l'usage de l'intelligence artificielle embarquée dans la transformation numérique des économies locales africaines.

Contributions : Conceptualisation, K.K.; méthodologie, K.K.; validation, K.K, T.C. et M.L.F. ; Investigation, K.K.; ressources, K.K.; Traitement des données, K.K.; écrire le manuscrit, K.K.; visualisation, K.K.; supervision, T.C. et M.L.F.; correction du manuscrit, T.C. et M.L.F.

Les auteurs ont lu et approuvé la version publiée de ce manuscrit.

Sponsor financier : Cette recherche n'a reçu aucun soutien financier.

Disponibilité des données : Les données ne sont pas disponibles.

Remerciement : Non applicable.

Conflits d'intérêt : Les auteurs déclarent aucun conflit d'intérêt.

Références

1. Akerlof, G. A. (1970). The market for lemons: Quality uncertainty and the market mechanism. *The Quarterly Journal of Economics*, 84(3), 488–500. <https://doi.org/10.2307/1879431>
2. Deng, Y. (2019). Deep learning on mobile devices: A review. arXiv. <https://arxiv.org/abs/1904.09274>
3. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
4. Laudon, K. C., & Traver, C. G. (2019). *E-commerce: Business, technology, society*. Pearson.
5. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
6. Longley, P. A., Goodchild, M. F., Maguire, D. J., & Rhind, D. W. (2015). *Geographic information systems and science* (4th ed.). Wiley.
7. Mpia, H. N., Kavalami, M. M., Lusenge, G. K., Ushindi, K. P., Kyalengekania, D.-D. K., & Cismwaka, O. M. (2025). Lightweight deep learning system for infant-cry recognition with real-time notification in resource-constrained environments. *Machine Learning with Applications*, 22, Article 100791. <https://doi.org/10.1016/j.mlwa.2025.100791>
8. Mpia, H. N., Mburu, L. W., & Mwendia, S. N. (2023). CoBERT: A Contextual BERT model for recommending employability profiles of information technology students in unstable developing countries. *Engineering Applications of Artificial Intelligence*, 125, Article 106728. <https://doi.org/10.1016/j.engappai.2023.106728>
9. Ricci, F., Rokach, L., & Shapira, B. (Eds.). (2015). *Recommender systems handbook* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4899-7637-6>
10. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. In *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4510–4520). IEEE. <https://doi.org/10.1109/CVPR.2018.00474>
11. Xu, Y., Khan, T. M., Song, Y., & Meijering, E. (2025). Edge deep learning in computer vision and medical diagnostics: A comprehensive survey. *Artificial Intelligence Review*, 58, Article 93. <https://doi.org/10.1007/s10462-024-11033-5>