



## Applications de l'intelligence artificielle pour le développement de bétons durables et intelligents dans les villes africaines en forte urbanisation : état de la recherche et perspectives pour Kinshasa

Johnny Muhindo Bahavira<sup>1,2\*</sup> , Michael Paluku Lukumbi<sup>3,4</sup> , Junior Lukoo Mitsindo<sup>3,4</sup> ,

1. Section Bâtiment et Travaux Publics, Institut National du Bâtiment et des Travaux Publics, Kinshasa, RDC
2. Laboratoire de Géotechnique et Mécanique des Sols, Institut National du Bâtiment et des Travaux Publics, Kinshasa, RDC
3. Section Hydraulique et Environnement, Institut National du Bâtiment et des Travaux Publics, Kinshasa, RDC
4. Ingénierie des structures, des fondations et des matériaux, Universidad Politécnica de Madrid, Madrid, SPAIN

**Résumé:** Face à l'urbanisation rapide du continent africain, le béton est au cœur des enjeux de qualité, de durabilité et de réduction des émissions de carbone. Cette revue cartographie les applications de l'intelligence artificielle (IA) au béton et en évalue l'applicabilité pour Kinshasa. Approche narrative 2015–2025, basée sur 110 études couvrant quatre axes : formulation, contrôle qualité et contrôle non destructif (CND), durabilité (analyse du cycle de vie, ACV) et jumeaux numériques pour la maintenance. Des critères d'inclusion/exclusion et l'extraction standardisée des métriques/validations assurent la comparabilité.

Principaux constats : la formulation prédictive couplée à l'optimisation multi-objectifs est de maturité élevée avec des validations expérimentales croissantes ; la vision par ordinateur et les procédés CND sont opérationnels mais sensibles aux changements de domaine ; l'Internet des objets (IoT) pour le suivi du béton frais et de la cure est prometteur mais sa transportabilité reste limitée ; les approches de maintenance et de jumeaux numériques progressent, avec verrous d'intégration entre Building Information Modeling (BIM), capteurs et IA ; les substituts d'ACV et l'estimation de CO<sub>2</sub> accélèrent l'évaluation, mais l'absence d'inventaires locaux demeure un frein. Les limites tiennent à l'hétérogénéité des protocoles, au biais de publication et à l'absence de méta-analyse.

Pour Kinshasa, la feuille de route préconise des pipelines frugaux (capteurs low-cost et calcul en périphérie), la constitution de jeux de données locaux et normalisés, l'adoption du ciment calcaire-argile calcinée (LC3) pour abaisser l'empreinte carbone, et des jumeaux numériques légers avec mise à jour bayésienne pour appuyer la décision et la maintenance prédictive.

**Mots Clés:** béton ; intelligence artificielle ; ACV ; CND ; jumeau numérique ; LC3 ; Afrique ; Kinshasa

**Digital Object Identifier (DOI):** <https://doi.org/10.5281/zenodo.17249752>

# Artificial Intelligence for Sustainable and Smart Concrete in Rapidly Urbanizing African Cities: A State-of-the-Art Review and Perspectives for Kinshasa

---

**Abstract:** Amid rapid urbanization across Africa, concrete lies at the center of challenges related to quality, durability, and carbon reduction. This review maps applications of artificial intelligence (AI) to concrete and assesses their applicability to Kinshasa. Using a narrative approach spanning 2015–2025, it synthesizes 110 studies across four themes: mix design/formulation; quality control and non-destructive testing (NDT); durability and life cycle assessment (LCA); and digital twins for maintenance. Inclusion/exclusion criteria and standardized extraction of metrics and validation procedures support comparability.

The main findings are as follows: predictive mix-design models coupled with multi-objective optimization exhibit high maturity with increasing experimental validation; computer vision and NDT pipelines are operational but sensitive to domain shifts; Internet of Things (IoT) solutions for monitoring fresh concrete and curing are promising yet face limited transferability; maintenance and digital-twin approaches are advancing but remain constrained by integration bottlenecks across Building Information Modeling (BIM), sensors, and AI; and LCA surrogates and CO<sub>2</sub> estimation accelerate assessment, although the lack of local inventories remains a key barrier. Limitations stem from heterogeneous protocols, publication bias, and the absence of a meta-analysis.

For Kinshasa, the roadmap prioritizes frugal pipelines—low-cost sensors and edge computing—the curation of local, standardized datasets, adoption of Limestone Calcined Clay Cement (LC3) to reduce the carbon footprint, and lightweight digital twins with Bayesian updating to support decision-making and predictive maintenance.

**Keywords:** concrete; artificial intelligence; LCA; NDT; digital twin; LC3; Africa; Kinshasa

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

---

## 1 Introduction

L'urbanisation africaine connaît une accélération sans précédent, reconfigurant la demande en infrastructures et en logements, et plaçant le béton au cœur des trajectoires d'aménagement urbain (Kamana, 2024). Dans des métropoles en très forte croissance comme Kinshasa, l'extension urbaine, la précarité des quartiers informels et les vulnérabilités environnementales (érosion en ravines, risques hydrologiques) mettent sous tension la planification, la qualité constructive et la durabilité des ouvrages (Mawe et al., 2025 ; Nature Editorial Team, 2025). Dans ce contexte, l'intelligence artificielle (IA) émerge comme un levier transversal pour améliorer la conception, la mise en œuvre, le contrôle qualité et la maintenance des structures en béton, tout en favorisant des trajectoires bas carbone adaptées aux réalités des villes africaines. (Kamana, 2024 ; Mawe et al., 2025).

Sur le plan climatique, la filière ciment-béton reste l'une des plus émettrices de GES, du fait des émissions de procédé liées au clinker et des besoins énergétiques élevés ; selon les synthèses récentes, elle représente de l'ordre de 6–8 % des émissions mondiales et constitue un secteur « difficile à décarboner » (IPCC, 2022 ; Climate Bonds Initiative, 2023). En parallèle, les feuilles de route industrielles (GCCA) projettent une décarbonation à 2050 combinant leviers matériaux (SCM), efficacité des procédés, énergies décarbonées et CCUS, mais leur mise en œuvre dans le Sud global suppose des adaptations locales, notamment en Afrique (GCCA, 2023). Ces dynamiques globales croisent des besoins massifs d'infrastructures dans des contextes de ressources limitées, rendant cruciale la recherche de bétons durables, abordables et contextualisés pour Kinshasa. (IPCC, 2022 ; Climate Bonds Initiative, 2023 ; GCCA, 2023).

Dans la science des matériaux cimentaires, l'IA a démontré sa capacité à accélérer la conception des mélanges, à prédire des propriétés (résistance à la compression, ouvrabilité, durabilité) et à réduire le recours à des campagnes

---

expérimentales coûteuses (Chaabene et al., 2020 ; Li et al., 2022 ; Altuncı & Duran, 2024). Les revues récentes mettent en évidence l'essor des réseaux de neurones, SVM, forêts aléatoires et approches interprétables (SHAP) pour la formulation et l'optimisation multi-objectifs (performance/coût/empreinte carbone), ainsi que l'intégration d'ACV appuyées par le machine learning, y compris pour des bétons alternatifs (géopolymères) (Olsson et al., 2024 ; Romeiko et al., 2023 ; Ramesh et al., 2025). Ces avancées offrent une base méthodologique pour adapter des bétons à faible teneur en clinker, mobilisant des matériaux locaux (pouzzolanes, laitiers, cendres) et répondant aux contraintes d'approvisionnement africaines. (Chaabene et al., 2020 ; Li et al., 2022 ; Altuncı & Duran, 2024 ; Olsson et al., 2024 ; Romeiko et al., 2023 ; Ramesh et al., 2025).

Au-delà de la formulation, l'IA transforme le contrôle qualité et la surveillance des ouvrages : la vision par ordinateur et l'apprentissage profond atteignent aujourd'hui des performances élevées pour la détection de fissures et autres pathologies, y compris via des modèles légers et des jeux de données harmonisés (Kaveh et al., 2024 ; Dong et al., 2024). En parallèle, l'essor de capteurs IoT low-cost et de plateformes ouvertes rend envisageable un monitoring en continu de la température, de la maturité et des conditions de cure, crucial dans les climats chauds et humides (Presa Madrigal et al., 2024). L'intégration au sein de jumeaux numériques (BIM/DT + IA) ouvre la voie à une maintenance prédictive de parcs d'ouvrages, y compris en conditions tropicales où la corrosion des armatures et la carbonatation sont accélérées (Omrany et al., 2023 ; Yang et al., 2024 ; Castañeda Valdés et al., 2024 ; Song et al., 2024). (Kaveh et al., 2024 ; Dong et al., 2024 ; Presa Madrigal et al., 2024 ; Omrany et al., 2023 ; Yang et al., 2024 ; Castañeda Valdés et al., 2024 ; Song et al., 2024).

Pour Kinshasa, ces leviers techno-scientifiques doivent se confronter à des contraintes structurelles : prédominance de l'autoconstruction, variabilité des chaînes d'approvisionnement, déficit d'équipements d'essais, faiblesse des normes appliquées, et exposition accrue à l'érosion en ravines qui menace fondations, voiries et réseaux (Mawe et al., 2025 ; Kamana, 2024). Dans cette optique, une revue centrée sur les applications de l'IA au béton dans des villes africaines en forte urbanisation se justifie doublement : (i) synthétiser l'état de l'art international (méthodes, performances, limites) et (ii) identifier les adaptations requises (données locales, capteurs abordables, logiciels libres, formation) pour une opérationnalisation à Kinshasa, avec des bénéfices attendus en qualité, sécurité et empreinte carbone des ouvrages. (Mawe et al., 2025 ; Kamana, 2024 ; GCCA, 2023 ; IPCC, 2022).

La présente revue vise à documenter systématiquement les applications de l'IA sur l'ensemble du cycle de vie du béton (formulation, contrôle non destructif, durabilité/ACV, jumeaux numériques et maintenance prédictive), à analyser leur maturité, leurs exigences en données/équipements, et leur transférabilité vers le contexte kinois, afin de dégager des pistes opérationnelles et une feuille de route pour des bétons durables et intelligents adaptés aux villes africaines en forte urbanisation (Li et al., 2022 ; Omrany et al., 2023 ; Olsson et al., 2024).

## 2 Méthodologie

Cette revue adopte une approche narrative (et non un protocole PRISMA) afin de cartographier, interpréter et mettre en perspective un champ interdisciplinaire encore hétérogène — à l'interface IA–béton–ville africaine — où les méthodes, jeux de données et métriques diffèrent fortement d'une étude à l'autre (Snyder, 2019 ; Ferrari, 2015 ; Green et al., 2006 ; Grant & Booth, 2009 ; Popay et al., 2006). Le choix du format revue narrative vise à privilégier la cohérence théorique et la synthèse thématique plutôt qu'une agrégation quantitative des effets.

### 2.1 Périmètre, période et langues

La période couverte est 2015–2025, correspondant à l'essor des approches d'apprentissage automatique et profond dans la science des matériaux et le génie civil (Snyder, 2019). Les langues anglais et français ont été retenues pour assurer à la fois la couverture internationale et la pertinence pour le contexte kinois (Ferrari, 2015).

### 2.2 Sources et stratégie de recherche

Les références ont été identifiées principalement via ScienceDirect, MDPI, SpringerLink et ASCE Library, complétées par une recherche itérative "boule de neige" (références amont/aval) pour capter des travaux connexes non indexés par les requêtes initiales (Wohlin, 2014). Les chaînes de recherche ont combiné des termes liés à l'IA ("machine learning", "deep learning", "computer vision", "Bayesian optimization", "digital twin") et au béton ("concrete", "cementitious", "reinforced concrete", "nondestructive testing", "LCA/ACV"), couplés à des mots-

clés urbains et africains (“urban”, “city”, “Africa”, “sub-Saharan”, “tropical”, “Kinshasa”). L’approche a été itérative : élargissement progressif des équivalents terminologiques ; affinage des filtres par thèmes.

### 2.3 Critères d’inclusion et d’exclusion

Ont été inclus : (i) articles évalués par les pairs (revues et actes de conférences) portant explicitement sur l’application de l’IA au béton (formulation, contrôle non destructif, durabilité/ACV, jumeaux numériques, maintenance prédictive) ; (ii) travaux méthodologiques et revues pertinentes ; (iii) études en contexte urbain ou transférables au contexte urbain. Ont été exclus : (i) textes non scientifiques (éditoriaux, billets) ; (ii) études centrées sur des matériaux non cimentaires ; (iii) contributions sans validation minimale (données/expériences/études de cas) (Green et al., 2006 ; Grant & Booth, 2009).

### 2.4 Processus de sélection et corpus final

Le dépistage a été mené en deux temps (titres-résumés, puis texte intégral), avec résolution collégiale des hésitations. Après élimination des doublons et des items hors périmètre, le corpus final compte 110 articles. Ce volume reflète l’état pluridisciplinaire du domaine (matériaux, contrôle, durabilité, gestion d’ouvrages) et la diversité des méthodes (apprentissage supervisé, optimisation, modèles hybrides physico-data).

### 2.5 Extraction et structuration de l’information

Pour chaque article, les éléments suivants ont été relevés : (i) domaine d’application (formulation, contrôle qualité/CND, durabilité-ACV, jumeaux numériques/maintenance), (ii) données (taille, source, capteurs, contexte climatique), (iii) méthodes IA (p. ex., forêts aléatoires, réseaux de neurones, GPR, BO/NSGA-II), (iv) validation (k-fold, test externe, comparaison à l’état de l’art) et métriques (RMSE, MAE,  $R^2$ , AUC, mAP, IoU), (v) transférabilité (coût, disponibilité des matériaux, contraintes d’exploitation en climat chaud-humide), (vi) répliquabilité (partage de code/données) et explicabilité (XAI) (Popay et al., 2006 ; Snyder, 2019).

### 2.6 Évaluation qualitative (non métrique)

Conformément aux bonnes pratiques des revues narratives, l’appréciation de la qualité a été qualitative, en s’attachant notamment à : (i) la plausibilité scientifique (cohérence physico-mécanique) ; (ii) le risque de surapprentissage et les fuites de données ; (iii) la portée externe (diversité des matériaux, conditions climatiques) ; (iv) la clarté des protocoles et la traçabilité des résultats (Green et al., 2006 ; Baumeister & Leary, 1997 ; Grant & Booth, 2009). Aucun score agrégé n’a été calculé ; les forces/faiblesses des études guident la discussion.

### 2.7 Synthèse et axes thématiques

La synthèse est narrative et thématique, articulée autour de quatre axes — formulation, contrôle qualité, durabilité/empreinte carbone, maintenance prédictive/jumeaux numériques — complétés par une section sur les défis africains. Cette organisation vise à relier méthodes et conditions d’applicabilité (ressources, climat, infrastructures) et à éclairer la transférabilité vers Kinshasa (Popay et al., 2006 ; Snyder, 2019).

### 2.8 Limites

Les principales limites tiennent au biais de publication, à la couverture inégale des bases, à la dominance anglophone et à l’hétérogénéité des protocoles IA (données, métriques). L’absence de méta-analyse et de notation normalisée de la qualité — inhérentes à la revue narrative — impose d’interpréter les résultats avec prudence ; ces limites sont atténuées par la triangulation des sources, la boule de neige et la discussion systématique des incertitudes (Ferrari, 2015 ; Snyder, 2019 ; Grant & Booth, 2009 ; Wohlin, 2014).

## 3 Résultats (Results) – Synthèse de la littérature

### 3.1 IA et formulation optimisée du béton

La littérature récente converge vers un passage d’une conception essais-erreurs à une ingénierie guidée par données, où l’IA sert à prédire les performances (résistance, ouvrabilité, durabilité) et à inverser la conception pour optimiser simultanément coût, empreinte carbone et propriétés mécaniques (Luo et al., 2025 ; Pfeiffer et al., 2024). Les variables d’entrée couvrent les dosages (liant, eau, additions, adjuvants), les caractéristiques granulaires, l’âge et les conditions de cure, tandis que les sorties visées incluent, au-delà de la résistance à 28 jours, des objectifs composites (indice carbone, coût, ouvrabilité, durabilité) (Asteris et al., 2021 ; Feng et al., 2020 ; Tipu et al., 2025).

### 3.1.1 Modèles prédictifs pour accélérer la formulation

Les travaux montrent la robustesse d'ensembles (GBRT/XGBoost, stacking) et de réseaux de neurones pour prédire la résistance et l'ouvrabilité à partir de mélanges hétérogènes, avec des performances supérieures aux approches linéaires sur des relations non linéaires (Asteris et al., 2021 ; Luo et al., 2025 ; Paudel et al., 2023 ; Nikoopayan Tak et al., 2025). Les procédures de validation (k-fold, test externe) sont cruciales au regard de la variabilité inter-laboratoires et des effets de site ; l'usage d'ensembles et de régularisation limite le surapprentissage tandis que des schémas d'ingénierie de variables (rapports eau/liant, fines/liant, modules granulaires) améliorent la généralisabilité (Feng et al., 2020 ; Paudel et al., 2023 ; Xu et al., 2022). Les processus gaussiens (GPR) gagnent en usage pour quantifier l'incertitude et rester fiables en petits échantillons (Xu et al., 2022 ; Zou et al., 2024).

### 3.1.2 Interprétabilité et guidage des dosages

L'essor de l'XAI (SHAP, importance des variables, dépendances partielles) transforme l'IA en outil d'aide à la décision : l'importance du rapport eau/liant, de la teneur en liant, du type d'addition et de l'âge est confirmée, permettant de réduire les campagnes d'essais et d'orienter des substitutions (Abioye et al., 2025 ; Chu et al., 2025 ; Revathi et al., 2024). L'XAI facilite aussi la transférabilité vers des formulations locales (p. ex. pouzzolanes, cendres, calcaires/calced clays) en explicitant les compromis performanciers (Abioye et al., 2025 ; Luo et al., 2025).

### 3.1.3 Inversion de conception et optimisation multi-objectifs

Au-delà de la prédiction, la littérature montre des boucles prédiction → optimisation pour rechercher des mélanges bas carbone et économiques à performance cible. Les approches NSGA-II, Grey Wolf, PSO et Bayesian Optimization explorent le front de Pareto résistance-coût-CO<sub>2</sub> ; couplées à des métamodèles (GBRT, DNN, GPR), elles réduisent drastiquement le nombre d'essais, y compris pour bétons recyclés, géopolymères et UHPC (Pfeiffer et al., 2024 ; Chen et al., 2024 ; Wang et al., 2025 ; Tipu et al., 2025 ; Zhang et al., 2025). Ces cadres "prédire-puis-proposer" sont désormais validés expérimentalement, illustrant une vraie ingénierie inverse du béton (Ji et al., 2024 ; Ament et al., 2023).

### 3.1.4 Vers des formulations durables et contextualisées (perspective Kinshasa)

Les travaux ciblant les SCM (laitiers, cendres, fines de verre, granulats recyclés) montrent la capacité de l'IA à maintenir les performances tout en abaissant le clinker et le CO<sub>2</sub>, avec des ajustements granulaires pilotés par modèles (Liu et al., 2024 ; Chu et al., 2025 ; Tipu et al., 2025). Pour des villes comme Kinshasa, ces méthodes sont pertinentes si les contraintes locales sont intégrées : (i) données issues de matériaux disponibles localement (sables alluvionnaires, granulats recyclés), (ii) incertitudes sur la constance d'approvisionnement, (iii) coûts des adjuvants/capteurs. Des cadres XAI + optimisation multi-objectifs permettent de formaliser ces contraintes (coût, CO<sub>2</sub>, ouvrabilité tropicale) et de proposer des mélanges faisables avec peu d'essais (Pfeiffer et al., 2024 ; Chen et al., 2024 ; Luo et al., 2025).

### 3.1.5 Bonnes pratiques et limites

Les meilleures pratiques incluent : (1) normalisation/curation des données et traçabilité des matières ; (2) validation externe et estimation d'incertitude (GPR, ensembles) ; (3) usage systématique de l'XAI pour une interprétation physiquement cohérente ; (4) couplage à une optimisation multi-critères explicitant les contraintes (ouvrabilité, coût, CO<sub>2</sub>, disponibilité locale) ; (5) vérifications expérimentales ciblées (Feng et al., 2020 ; Asteris et al., 2021 ; Pfeiffer et al., 2024 ; Ji et al., 2024 ; Luo et al., 2025). Les lacunes tiennent à l'insuffisance d'ensembles de données ouverts et régionalisés, au manque de protocoles unifiés pour l'ouvrabilité en climat chaud-humide et à la faible intégration des indicateurs de durabilité comme objectifs primaires d'optimisation (Hassan et al., 2024 ; Tipu et al., 2025).

## 3.2 IA et contrôle qualité

Le contrôle qualité du béton connaît une transformation profonde avec l'intelligence artificielle (IA), qui permet d'automatiser l'évaluation en production (béton frais), post-coulage (surface) et en service (intégrité interne,

pathologies), tout en réduisant les délais et la variabilité humaine. Les approches dominantes combinent vision par ordinateur (détection/segmentation des défauts), apprentissage automatique pour l'interprétation de signaux issus d'essais non destructifs (ultrasons, radar GPR, thermographie), et IoT pour le suivi en continu de la cure et de la maturité (Shokravi et al., 2020 ; Ni et al., 2019 ; Salehi & Burgueño, 2018 ; Kalfarisi et al., 2023 ; Presa Madrigal et al., 2024).

### 3.2.1 Détection de défauts de surface par vision et deep learning

Les réseaux convolutionnels (CNN) et architectures de segmentation (U-Net, DeepLabv3+) détectent fissures, nids de gravier (honeycombing), décollements, et exposition d'armatures sur des images issues de smartphones ou drones, avec des performances supérieures aux méthodes classiques de seuillage/edge-detection en contexte bruité (Shokravi et al., 2020 ; Ni et al., 2019 ; Zhang et al., 2016). Les modèles one-stage (famille YOLO) et transformers visuels (Swin-T, SegFormer) facilitent le temps réel sur chantier et l'edge computing (Kim & Cho, 2023 ; Gao et al., 2022). Les jeux de données publics (p. ex., SDNET2018) et la data augmentation (distorsions photométriques, textures parasites) renforcent la robustesse face aux conditions d'éclairage variables, aux fond salissants et aux marquages (Dorafshan et al., 2019 ; Prasanna et al., 2016). Les métriques de référence incluent mAP, F1-score, IoU et AUC, à rapporter avec des protocoles de validation externe pour limiter le surapprentissage et le biais de domaine (Salehi & Burgueño, 2018 ; Kalfarisi et al., 2023).

### 3.2.2 Contrôle non destructif (CND) assisté par IA : ultrasons, GPR, thermographie

Dans le béton durci, l'IA améliore l'interprétation des signaux ultrasoniques (UPV, tomographie) pour localiser vides, décollements et dégradations ; les CNN et processus gaussiens extraient des représentations discriminantes et fournissent une incertitude utile à la décision (Hoła & Schabowicz, 2010 ; Azari et al., 2020 ; Escobar-Palafox et al., 2021). En radar géologique (GPR), l'IA aide à distinguer réflexions d'armatures, corrosion et délaminations dans des signaux hétérogènes et bruités, surpassant les heuristiques (Maturana et al., 2018 ; Lai et al., 2021). La thermographie infrarouge couplée à des classifieurs (SVM, forêts aléatoires) et à des CNN détecte décollements et défauts de compacité sous surface, pertinent pour les parements architectoniques (Avdelidis et al., 2017 ; Omar et al., 2021). Les études soulignent l'importance d'une vérité terrain fiabilisée (carottages ciblés, endoscopie) et d'une fusion multi-capteurs (ultrasons + GPR + IR) pour limiter les faux positifs (Escobar-Palafox et al., 2021 ; Lai et al., 2021).

### 3.2.3 Suivi en continu du béton frais et de la cure (IoT, maturité, modèles hybrides)

Pour le béton frais, la vision et les capteurs low-cost permettent d'estimer ouvrabilité et affaissement sans essai destructif, ouvrant la voie à des boucles de rétroaction en centrale (Kim et al., 2021 ; Xu et al., 2020). En cure, des capteurs température-humidité et énergie d'activation nourrissent des modèles maturité + ML pour inférer résistance en place et fenêtres de décoffrage, avec gains en sécurité et délais (Hedegaard et al., 2022 ; Presa Madrigal et al., 2024). Les architectures edge-cloud et les formats ouverts (MQTT, OPC-UA) sont recommandés pour la traçabilité et l'interopérabilité avec le BIM et les jumeaux numériques (Gao et al., 2022 ; Kalfarisi et al., 2023).

### 3.2.4 Déploiement terrain, explicabilité et gouvernance des données

Les contraintes réelles (éclairage hétérogène, poussière, occlusions, appareils hétérogènes) justifient l'usage de modèles légers (MobileNet/EfficientNet-Lite), de domain adaptation et de self-supervised learning pour réduire l'effort d'annotation (Kim & Cho, 2023 ; Kalfarisi et al., 2023). L'explicabilité (p. ex., Grad-CAM, SHAP sur des descripteurs issus du CND) appuie l'acceptabilité par les ingénieurs, tandis que des protocoles qualité fixent les seuils d'alerte, la traçabilité (métadonnées capteurs), la cybersécurité et la protection des données (Salehi & Burgueño, 2018 ; Gao et al., 2022).

### 3.2.5 Perspective pour Kinshasa

Dans un contexte chaud-humide avec ressources limitées, l'orientation low-cost est prioritaire : smartphones pour l'inspection visuelle, capteurs abordables pour la cure, modèles compacts en périphérie (edge) et ensembles de

données locaux annotés progressivement (Ni et al., 2019 ; Presa Madrigal et al., 2024). La fusion vision + CND est particulièrement pertinente pour différencier fissuration de retrait/plastique de la fissuration structurale, et pour surveiller les parements et dalles exposés à des gradients hydriques élevés. L'objectif est un contrôle qualité scalable, traçable et interprétable, compatible avec les chantiers et laboratoires de Kinshasa (Kalfarisi et al., 2023 ; Gao et al., 2022).

### **3.3 IA et durabilité / empreinte carbone**

L'empreinte carbone du béton est dominée par les émissions process liées au clinker et, dans une moindre mesure, par l'énergie, les transports et la fin de vie ; la réduction passe donc par des stratégies combinant substitution du clinker, optimisation des mélanges, électrification/CCUS côté cimenterie, et allongement de la durée de vie côté ouvrage. L'intelligence artificielle (IA) accélère ces leviers en (i) prédictif (estimation rapide du CO<sub>2</sub> incorporé d'un mélange à partir de sa recette), (ii) surrogates LCA (remplacement de calculs d'ACV lourds par des modèles appris), (iii) optimisation multi-objectifs (force-ouvrabilité-coût-CO<sub>2</sub>), et (iv) couplage durabilité-carbone via la modélisation de service (Romeiko et al., 2023 ; Choi et al., 2024 ; Khalid et al., 2024 ; IEA, 2024 ; GCCA, 2021, 2023).

#### **3.3.1 Prédiction rapide du CO<sub>2</sub> incorporé (embodied carbon)**

Des modèles supervisés infèrent l'empreinte carbone d'un béton à partir des variables de formulation (liant, additions, granulats, adjuvants) et de paramètres de production (énergie, transport). Ils permettent un criblage en amont puis une vérification ACV ciblée, réduisant le temps d'étude et les coûts (Nukah et al., 2024 ; Xie et al., 2024). Au-delà du bâtiment, des cadres méta-apprentissage et apprentissage par transfert montrent que les modèles peuvent rester généraux tout en s'adaptant à des gammes locales de matériaux (Romeiko et al., 2023 ; Neupane et al., 2025).

#### **3.3.2 Surrogates ACV et estimation des inventaires**

L'ACV (analyse de cycle de vie) souffre de données manquantes (inventaires, facteurs d'émission contextuels). Des approches IA (régression, forêts, GPR) servent de surrogates : elles approximent des sous-modèles énergétiques ou imputent des inventaires manquants avec incertitude, rendant l'ACV plus rapide et répliquable (Romeiko et al., 2023 ; de Paula Salgado et al., 2025 ; Zhao et al., 2025). Ces méthodes sont cruciales pour des contextes à faible disponibilité de données, comme Kinshasa.

#### **3.3.3 Optimisation multi-objectifs des mélanges bas carbone**

Coupler prédiction et optimisation (NSGA-II, PSO, Grey-Wolf, Bayesian Optimization) permet d'explorer des fronts de Pareto où l'on minimise CO<sub>2</sub> et coût tout en respectant des cibles de résistance/ouvrabilité. Les résultats montrent des réductions substantielles d'empreinte grâce à la substitution par SCM (slag, cendres, calcined clays), au recyclage de granulats, et à l'ajustement granulaire (Khalid et al., 2024 ; Zheng et al., 2023 ; Helali et al., 2025). Côté cimenterie, des cadres similaires optimisent raw-mix et combustibles alternatifs pour réduire les émissions par tonne de clinker (CEMBUREAU, 2024).

#### **3.3.4 Lien durabilité-carbone : service, carbonatation et chlorures**

Le carbone sur cycle de vie dépend fortement de la durée de service. Les modèles IA couplés à la physique (carbonatation, ingress de chlorures) permettent d'anticiper la corrosion des armatures et de quantifier l'impact de mesures (enrobage, choix de liant) sur la longévité et, donc, sur le carbone sur cycle de vie (Guo et al., 2024 ; Liu et al., 2024). Parallèlement, des travaux de synthèse montrent que la carbonatation du béton réabsorbe une fraction du CO<sub>2</sub> émis ; une estimation robuste de ce puits nécessite des modèles spatio-temporels appuyés par données (van Roijen et al., 2024). L'IA aide à réconcilier performance, durabilité et bilan carbone net.

#### **3.3.5 Bétons et liants alternatifs : LC3 et géopolymères**

Pour les villes africaines, la calcination d'argiles combinée au calcaire (LC3) offre un abaissement du clinker significatif, avec des performances mécaniques et de durabilité compétitives ; l'IA sert à calibrer les dosages (argile/activité, filler calcaire) et à anticiper les effets sur la microstructure et la porosité capillaire (Scrivener et

al., 2018 ; Sharma et al., 2021 ; Zhao et al., 2023). Des cadres hybrides ML + MOO orientés LC3 confirment la capacité à réduire CO<sub>2</sub> sans sacrifier la résistance (Chen et al., 2025). Des approches analogues s'appliquent aux géopolymères et bétons CO<sub>2</sub>-curés, avec arbitrages entre résistance initiale, perméabilité et bilan carbone (Pereira et al., 2025).

### 3.3.6 Perspective pour Kinshasa

Dans un contexte chaud-humide et de contraintes d'approvisionnement, les priorités sont : (i) modèles prédictifs entraînés sur bases locales (recettes, facteurs d'émission des fournisseurs, mix électrique), (ii) surrogates ACV pour pallier le manque de données et lancer des EPD locales, (iii) optimisation multi-objectifs incorporant coût, CO<sub>2</sub>, ouvrabilité et durabilité, (iv) adoption de LC3 et SCM disponibles régionalement (argiles calcinées, laitiers si accessibles), et (v) protocoles de validation (essais accélérés, suivis in situ) pour assoir la transférabilité des modèles (Scrivener et al., 2018 ; Sharma et al., 2021 ; IEA, 2024 ; CEMBUREAU, 2024).

## 3.4 IA et maintenance prédictive des infrastructures en béton

La maintenance prédictive des ouvrages en béton vise à anticiper les dégradations pour optimiser les interventions, réduire les coûts et allonger la durée de service. L'intelligence artificielle (IA) y joue un rôle central en transformant les paradigmes du contrôle périodique vers une surveillance continue (SHM) et une prognostique (PHM) capable d'estimer la durée de vie résiduelle (RUL) avec incertitudes quantifiées (Spencer et al., 2025 ; Di Mucci et al., 2024 ; Bao et al., 2025). Les avancées récentes portent à la fois sur (i) l'acquisition multi-capteurs (vibrations, électrochimie, imagerie, acoustique), (ii) l'apprentissage de dégradations spécifiques (carbonatation, chlorures, corrosion des armatures, fissuration) et (iii) l'intégration dans des jumeaux numériques pour la décision maintenance (Franciosi et al., 2024 ; Gao et al., 2024).

### 3.4.1 Capteurs et données : de la détection à la surveillance continue

Les systèmes modernes agrègent des mesures vibrationnelles (modales) et électrochimiques (potentiel de demi-pile, résistivité), complétées par la vision (caméras, drones) et l'émission acoustique (AE) pour suivre l'état des ouvrages (Spencer et al., 2025 ; Choi et al., 2024 ; Mandal et al., 2024 ; Pénicaud et al., 2025). L'IA améliore l'interprétation de signaux complexes : en GPR (radar) pour distinguer armatures/corrosion/délaminations ; en ultrasons pour localiser vides et décollements ; en thermographie IR pour détecter des défauts de compacité sous surface (Lai et al., 2021 ; Azari et al., 2020). En contexte de terrain, l'edge computing (détection temps réel sur terminaux légers) réduit les latences et les coûts d'exploitation (Gao et al., 2022).

### 3.4.2 Modèles prédictifs des mécanismes de dégradation

Pour la durabilité en milieu agressif, des réseaux profonds et des modèles d'ensemble prédisent la pénétration des chlorures, la carbonatation et les taux de corrosion à partir des recettes, expositions et historiques climatiques (Aliasghar-Mamaghani et al., 2025 ; Abdellatif et al., 2025 ; Couto et al., 2025 ; Ahmad et al., 2025). Côté intégrité mécanique, l'AE couplée à l'IA classe les modes de fissuration et repère les phases d'endommagement précoces, y compris pour les bétons hautes performances (Zhang et al., 2022 ; Mandal et al., 2024 ; Pénicaud et al., 2025). Les algorithmes séquentiels (1D-CNN, LSTM/Transformers) traitent les séries temporelles des réseaux de capteurs, tandis que des graph neural networks (GNN) modélisent des réseaux d'ouvrages (ponts/viaducs) pour une maintenance à l'échelle du parc (Wettewa et al., 2024 ; Liu et al., 2025).

### 3.4.3 Modèles hybrides et incertitude : vers la prognostique fiable

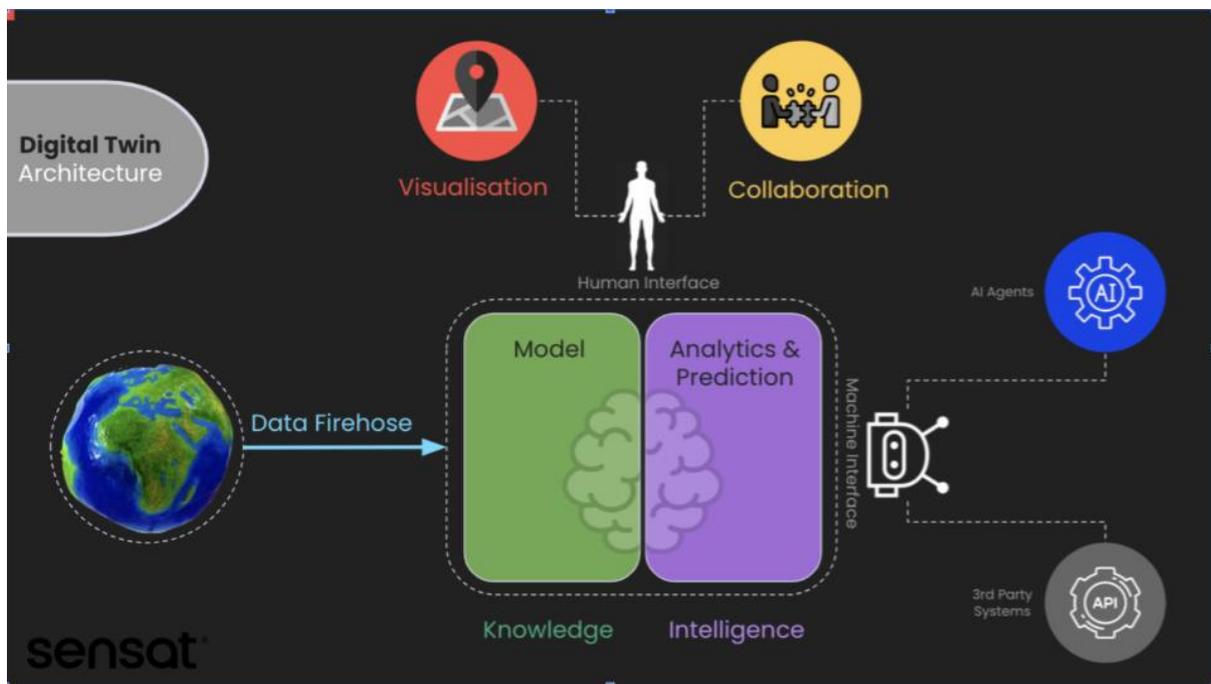
La fusion physique-données (modèles mécanistes + IA) devient un standard : réseaux informés par la physique (PINN) pour la diffusion des chlorures et l'hydratation/thermique, processus gaussiens pour quantifier l'incertitude, et mise à jour bayésienne pour intégrer en temps réel des mesures de terrain (Rahman et al., 2024 ; Zhou et al., 2023 ; Wang et al., 2025 ; Spencer et al., 2025). Les approches fiabilité-basées (mise à jour bayésienne de paramètres de corrosion/fissuration) et la survival analysis (fonctions de risque, modèles Cox) relient l'état courant aux probabilités de défaillance et à la RUL, améliorant la planification des interventions (Vaags et al., 2023 ; Qi et al., 2025 ; Cho et al., 2025).

### 3.4.4 Détection d'anomalies, transfert et fédération

En environnement opérationnel, l'IA gère le bruit, les dérives et les changements de domaine (climat, trafic). Des détecteurs d'anomalies profonds robustifient l'exploitation des données SHM, tandis que le transfert learning (adaptation de domaine) réutilise des modèles entre ponts/ouvrages distincts (Zhang et al., 2022 ; Souza et al., 2024 ; Choi et al., 2024). Pour respecter la souveraineté et la confidentialité des données, des schémas de federated learning émergent (Jilke et al., 2025), utiles pour mutualiser l'expérience d'un réseau urbain d'ouvrages tout en limitant les échanges de données brutes.

### 3.4.5 Jumeaux numériques et décision maintenance

Les jumeaux numériques (BIM/GIS + capteurs + modèles IA) constituent des coquilles décisionnelles permettant : i) l'actualisation des états de dégradation, ii) la simulation d'interventions (réparation, protection cathodique, enrobage accru), iii) l'optimisation des plans de maintenance sous contraintes budgétaires (Franciosi et al., 2024 ; Gao et al., 2024 ; Chen et al., 2025).



**Figure 1.** Architecture générique de jumeau numérique (ingestion, modèle de connaissance, analytique, interfaces). Source : Jamaica Lancee, “Sensat digital twin architecture” (licence CC BY 4.0).

L'intégration BIM-GIS, encore incomplète dans de nombreux systèmes, est un point critique pour passer du diagnostic à la planification à l'échelle du patrimoine (Gao et al., 2024).

### 3.4.6 Perspective pour Kinshasa

Dans un climat chaud-humide et face à des ressources limitées, des trajectoires réalistes combinent : capteurs abordables (température-humidité-résistivité), inspection visuelle par smartphone/drone avec modèles compacts en edge, indicateurs interprétables (explicabilité) pour l'acceptation par les ingénieurs, et cadres fiabilité-basés pour prioriser les interventions sur ponts, dalots, réservoirs et ouvrages hydrauliques en béton (Gao et al., 2022 ; Di Mucci et al., 2024 ; Spencer et al., 2025). La mise à jour bayésienne et les surrogates informés par la physique sont adaptés aux données lacunaires et à la variabilité des matériaux locaux ; à moyen terme, des jumeaux numériques légers, interopérables (BIM-GIS) et scalables permettraient une maintenance prédictive portefeuille à Kinshasa (Franciosi et al., 2024 ; Gao et al., 2024).

Le tableau 1 fait la Synthèse des types de données, méthodes et validations rapportées dans le manuscrit pour chaque cas d'usage IA appliqué au béton. Ce tableau sert de pont entre la Méthodologie (critères, extraction et métriques) et la Synthèse thématique : il rend explicites les traçabilités (données, méthodes, validations), facilite la lecture critique des niveaux de maturité et met en évidence les lacunes de transférabilité (données locales, intégration BIM–GIS, robustesse au changement de domaine), qui seront reprises dans la Discussion et la feuille de route pour Kinshasa.

Tableau 1. Cartographie du corpus par axe et métriques (2015–2025)

Axe thématique	Sous-thème & références clés (abrégé)	Données (type/volume)	Source (labo/chantier/open)	Méthodes IA mentionnées	Métriques rapportées	Schéma de validation	Résultat principal (1 ligne)	Limites déclarées	Niveau de preuve*
<b>Formulation</b>	Modèles prédictifs de performance (Asteris 2021; Feng 2020; Pfeiffer 2024; Luo 2025)	Recettes (liant/eau/SCM, granulats, âge), n élevé variable	Labo (essais béton)	RF, DNN, GPR	RMSE, MAE, R <sup>2</sup>	k-fold + tests externes ciblés	Accélérer la conception et prédire résistance/ouvrabilité	Données ouvertes limitées; hétérogénéité protocoles	<b>Moyen/Élevé</b>
<b>Formulation</b>	Optimisation multi-objectifs (NSGA-II/PSO/BO) et coût-CO <sub>2</sub> (Khalid 2024; Zheng 2023; Helali 2025; CEMBUREAU 2024)	Espace de conception + sorties modèles	Labo / littérature	NSGA-II, PSO, BO	Fronts de Pareto; contraintes	Comparaisons SOTA + vérifs exp. ciblées	Réductions substantielles d’empreinte à coût maîtrisé via SCM/ajustements	Transférabilité contextuelle à préciser	<b>Moyen</b>
<b>Contrôle /CND</b>	Vision : fissures & défauts de surface (Shokravi 2020; Ni 2019; Zhang 2016; Kim & Cho 2023; Gao 2022; jeux SDNET2018)	Images smartphone/drone; jeux publics + augmentation	Chantier / open data	CNN, U-Net, DeepLab v3+, YOLO, ViT	mAP, F1, IoU, AUC	Test externe recommandé (cross-site)	Supérieur aux heuristiques en contexte bruité	Sensibilité au changement de domaine (éclairage, textures)	<b>Moyen</b>
<b>Contrôle /CND</b>	Ultrasons/GPR/IR : interprétation assistée (Hoła & Schabowicz 2010; Azari 2020; Escobar-Palafox 2021; Maturana 2018; Lai 2021; Avdelidis 2017; Omar 2021)	Signaux UPV/tomo, radar, IR	Chantier/labo	CNN, SVM, Forêts, GPR	Acc., AUC	Vérité terrain (carottage/endoscopie), multi-capteurs	Localisation de défauts et couches	Nécessité de GT robuste; faux positifs	<b>Moyen</b>
<b>Contrôle /CND</b>	Suivi béton frais & cure : IoT/maturité/edge (Kim 2021; Xu 2020; Hedegaard 2022; Presa Madrigal 2024)	Capteurs T-RH, énergie d’activation; flux en continu	Chantier / centrale	Modèles maturité + ML; edge-cloud	Corrélations, erreur de prédiction R(t)	Comparaison essais destructifs	Fenêtres de décoffrage plus sûres/rapides	Intégration BIM/interopérabilité à soigner	<b>Moyen</b>

Axe thématique	Sous-thème & références clés (abrégé)	Données (type/volume)	Source (labo/chantier/open)	Méthodes IA mentionnées	Métriques rapportées	Schéma de validation	Résultat principal (1 ligne)	Limites déclarées	Niveau de preuve*
<b>Durabilité/ACV</b>	Surrogates ACV & imputations inventaires (Romeiko 2023; de Paula Salgado 2025; Zhao 2025)	Inventaires/ LCI partiels; facteurs d'émission	Littérature / bases ACV	Régr., Forêts, GPR	RMSE, MAE, R <sup>2</sup>	Back-testing & incertitudes	ACV plus rapide et répliquable en données rares	Données locales lacunaires	<b>Moyen</b>
<b>Durabilité/ACV</b>	Couplage physico-IA : carbonatation/chlorures (Guo 2024; Liu 2024; van Roijen 2024)	Mesures durabilité / env.	Labo/ouvrage	Modèles hybrides	Erreurs préd./fiabilité	Comparaisons modèles	Anticiper corrosion & effets sur CO <sub>2</sub> cycle de vie	Paramètres locaux incertains	<b>Moyen</b>
<b>Maintenance/Jumeaux</b>	Jumeaux numériques BIM-GIS + capteurs pour la décision (Franciosi 2024; Gao 2024; Chen 2025)	États d'ouvrage, capteurs SHM, géodonnées	Ouvrages/port efeuilles	Fusion modèles + optimisation	KPI maintenance	Études de cas comparées	Plans de maintenance optimisés sous budget	Intégration BIM-GIS incomplète	<b>Émergent /Moyen</b>
<b>Maintenance/Jumeaux</b>	Anomalies, transfert & fédération (Zhang 2022; Souza 2024; Choi 2024; Jilke 2025)	Séries temporelles capteurs; multi-sites	Ouvrages réseau	Deep AD, transfer learning, FL	TPR/FPR, AUC	Cross-site/domain	Robustifier déploiements et souveraineté données	Gouvernance & confidentialité	<b>Émergent</b>

**Abréviations définies :**

CND = contrôle non destructif ; ACV = analyse du cycle de vie ; SCM = additions cimentaires (supplementary cementitious materials) ; RF = forêts aléatoires ; DNN = réseaux de neurones profonds ; GPR = processus gaussiens (Gaussian Process Regression) ; NSGA-II = algorithme génétique multi-objectifs ; PSO = optimisation par essais particuliers ; BO = optimisation bayésienne ; RMSE = racine de l'erreur quadratique moyenne ; MAE = erreur absolue moyenne ; R<sup>2</sup> = coefficient de détermination ; AUC = aire sous la courbe ROC ; mAP = moyenne des précisions moyennes ; IoU = intersection sur union ; ViT = transformeur visuel ; IoT = Internet des objets ; BIM = Building Information Modeling ; GIS = Geographic Information System ; SHM = Structural Health Monitoring ; KPI = indicateurs de performance ; Deep AD = détection d'anomalies profonde ; FL = *federated learning*.

### **3.5 Défis spécifiques au contexte africain**

L'adoption de l'IA pour le béton en Afrique s'inscrit dans des environnements urbains à croissance rapide, souvent marqués par une urbanisation informelle, des contraintes d'infrastructures (énergie, numérique), des chaînes d'approvisionnement volatiles et des cadres réglementaires hétérogènes (UN-Habitat, 2022 ; World Bank, 2017 ; AfDB, 2023). Ces facteurs conditionnent la qualité des données, la transférabilité des modèles et la scalabilité des solutions, et imposent des trajectoires d'innovation contextualisées.

#### **3.5.1 Données, connectivité et infrastructures numériques**

La performance des approches IA dépend d'un socle de données fiable (recettes, essais, inventaires ACV, historiques d'exploitation) et d'une connectivité continue pour les capteurs et plateformes. Or, plusieurs villes africaines combinent faible taux de numérisation du secteur, coûts de données élevés et couvertures 4G/5G incomplètes, limitant l'IoT et la télémétrie temps réel (GSMA, 2023). Les coupures d'électricité et l'accès inégal à une énergie fiable compliquent l'acquisition continue et la maintenance des dispositifs (IEA, 2022 ; Tracking SDG7, 2024). En conséquence, les pipelines IA doivent intégrer des stratégies robustes : enregistrement local, edge computing, synchronisations asynchrones et gestion des données manquantes (GSMA, 2023 ; IEA, 2022).

#### **3.5.2 Chaînes d'approvisionnement et disponibilité des matériaux**

La variabilité des ciments, granulats et additions (SCM) – accentuée par les dépendances d'importation et la saisonnalité logistique – provoque des décalages de domaine entre jeux d'entraînement et pratique terrain, dégradant la précision prédictive (World Bank, 2017 ; AfDB, 2023). Les cendres volantes et laitiers peuvent être rares selon les bassins industriels, orientant vers des solutions LC3 (calcined clays + calcaire) plus endémiques mais exigeant une calibration locale (UN-Habitat, 2022 ; Chatham House, 2018 ; MPP, 2022). Les modèles doivent donc intégrer des incertitudes de formulation, des contraintes de disponibilité et des coûts volatils dans l'optimisation multi-objectifs.

#### **3.5.3 Climats chauds-humides, durabilité et service**

Les expositions chaudes-humides, côtières ou polluées, accélèrent les mécanismes de carbonatation, d'ingress de chlorures et de corrosion des armatures, avec impacts sur la durée de service et le carbone sur cycle de vie. Les modèles IA doivent être informés par la physique et entraînés sur des données climato-régionales pour produire des prognoses réalistes (CEN, 2019 ; RILEM, 2023 ; IEA, 2022). Les protocoles de validation doivent inclure des stations d'essais et sites pilotes en climat tropical pour réduire le biais de transfert.

#### **3.5.4 Normes, laboratoires et gouvernance de la qualité**

La fragmentation des normes et l'application inégale des règlements (contrôle de production, essais, certification) compliquent la comparabilité des données et l'interopérabilité des modèles (World Bank, 2015 ; UN-Habitat, 2022). Les capacités de laboratoire (étalonnage, traçabilité) sont parfois limitées, freinant la constitution de corpus de vérité terrain nécessaires à l'IA (AfDB, 2023). Des cadres performance-based et des référentiels communs (métadonnées, unités, incertitudes) sont essentiels pour ancrer l'IA dans des pratiques auditées et reproductibles (RILEM, 2023 ; CEN, 2019).

#### **3.5.5 Compétences, coûts et modèles économiques**

La pénurie relative de profils hybrides (matériaux-données), les coûts d'équipement et de maintenance, ainsi que la taille modeste de nombreux acteurs (PME) limitent l'adoption de solutions avancées (UNESCO, 2021 ; AfDB, 2023). Les stratégies open-source, l'accès partagé à des plates-formes (dépôts de données, notebooks, bibliothèques) et des partenariats université-industrie peuvent réduire les barrières. L'IA doit s'inscrire dans des modèles économiques viables (TCO), avec des gains mesurables (qualité, délais, carbone) à court terme pour favoriser l'adoption (World Bank, 2017).

### 3.5.6 Gouvernance des données, éthique et cybersécurité

La gouvernance (propriété, consentement, anonymisation), l'équité algorithmique et la sécurité des systèmes connectés deviennent critiques à mesure que l'IA s'intègre au patrimoine d'ouvrages (UNESCO, 2021 ; AU-AUC, 2024). Des politiques claires sur la protection et le partage des données, ainsi que des approches fédérées (apprentissage fédéré) sont à privilégier pour concilier souveraineté des données et mutualisation des connaissances à l'échelle métropolitaine (GSMA, 2023 ; AU-AUC, 2024).

### 3.5.7 Pistes d'atténuation (perspective opérationnelle)

Des architectures frugales (capteurs low-cost, modèles compacts), des jeux de données locaux progressivement enrichis, des surrogates ACV avec incertitude, et des jumeaux numériques légers (BIM-GIS) constituent des voies réalistes. La co-construction de référentiels (laboratoires, entreprises, collectivités), l'alignement normatif et des projets pilotes orientés résultats (qualité, sécurité, carbone) sont déterminants pour passer de la preuve de concept au déploiement (World Bank, 2015 ; AfDB, 2023 ; UN-Habitat, 2022).

## 4 Discussion

### 4.1 Analyse critique des résultats : état de maturité des applications IA-béton

Dans l'ensemble, les applications les plus mûres se situent en formulation prédictive et en optimisation multi-objectifs des mélanges, où des métamodèles (forêts, GPR, réseaux de neurones) couplés à des heuristiques/BO atteignent des performances élevées et sont validés expérimentalement, y compris pour des objectifs combinés résistance-ouvrabilité-CO<sub>2</sub> (Li et al., 2022 ; Asteris et al., 2021 ; Pfeiffer et al., 2024). Les outils de vision par ordinateur pour la détection de fissures et défauts de surface présentent également un degré de maturité opérationnelle croissant (modèles compacts, edge), mais ils restent sensibles aux changements de domaine (éclairage, salissures, textures locales) et à la qualité de l'annotation (Kalfarisi et al., 2023). Les approches maturité + IoT pour estimer la résistance en place progressent, mais leur transportabilité inter-chantiers demeure limitée par l'hétérogénéité capteurs/matériaux et la variabilité thermique en climat chaud-humide (Hedegaard et al., 2022).

À l'inverse, les volets maintenance prédictive et jumeaux numériques sont prometteurs mais encore fragmentés : la plupart des démonstrateurs portent sur un ouvrage (pont) et se heurtent au chaînage BIM-capteurs-IA et à la mise à jour fiable des états (Di Mucci et al., 2024 ; Omrany et al., 2023 ; Gao et al., 2024). Sur la durabilité/carbone, l'IA accélère l'ACV (surrogates) et l'exploration de fronts de Pareto, mais l'incertitude sur inventaires locaux et facteurs d'émission reste un verrou majeur pour les villes africaines (Romeiko et al., 2023).

### 4.2 Lacunes dans la littérature : manque d'études appliquées en Afrique, faible intégration matériaux locaux avec l'IA

La littérature afro-centrée demeure rare, tant pour la constitution de jeux de données (recettes, essais, microclimat) que pour des campagnes in situ en milieux chauds-humides (UN-Habitat, 2022 ; AfDB, 2023). Les chaînes d'approvisionnement africaines – marquées par des substitutions opportunistes et une variabilité de qualité – amplifient le décalage de domaine entre modèles entraînés ailleurs et pratique locale (GSMA, 2023 ; IEA, 2022). La faible disponibilité de SCM importés (cendres, laitier) souligne l'intérêt de liants LC3 fondés sur des argiles calcinées et du calcaire, mais l'intégration IA de ces filières (dosages, variabilité minéralogique) reste peu documentée (Scrivener et al., 2018 ; Sharma et al., 2021). Sur le plan normatif, l'absence de référentiels communs (métadonnées, unités, incertitudes) et l'hétérogénéité des protocoles d'essai entravent la comparabilité et la reproductibilité (CEN, 2019 ; RILEM, 2023). Enfin, l'ACV localisée souffre d'inventaires incomplets (mix électrique, transports, fin de vie), freinant la crédibilité des réductions de CO<sub>2</sub> annoncées (Romeiko et al., 2023 ; Tracking SDG7, 2024).

### 4.3 Implications pour la résilience urbaine en Afrique et particulièrement à Kinshasa

Pour des métropoles comme Kinshasa, l'IA peut agir sur trois leviers de résilience : (i) améliorer la qualité (contrôle visuel automatisé, suivi de la cure, déclenchement précoce d'alertes), (ii) prolonger la durée de service (prognostique corrosion/carbonatation, priorisation des réparations), et (iii) réduire le carbone sur cycle de vie par

des formulations bas-clinker validées localement (Presa Madrigal et al., 2024 ; Li et al., 2022 ; Pfeiffer et al., 2024). Dans les zones exposées à l'érosion en ravines et aux aléas hydrologiques, une maintenance fiabilité-basée soutenue par jumeaux numériques permet de cibler dalots, radiers, ponts et ouvrages hydrauliques critiques (Mawe et al., 2025 ; Gao et al., 2024). À l'échelle stratégique, ces trajectoires s'alignent sur les feuilles de route de décarbonation et d'adaptation (IPCC, 2022 ; GCCA, 2023), tout en répondant aux contraintes d'énergie/numérique par des architectures edge et faible coût (Gao et al., 2022).

Le tableau 2 synthétise, pour chaque cas d'usage du manuscrit, la maturité technique (TRL), la transférabilité au contexte de Kinshasa et les conditions concrètes de réussite (données locales, interopérabilité BIM–GIS, énergie/connectivité, gouvernance). Il met en évidence des gains immédiats (contrôle/CND, formulation bas-carbone appuyée par optimisation multi-objectifs) et des investissements structurants à moyen terme (jumeaux numériques légers, mise à jour bayésienne, apprentissage fédéré).

#### 4.4 Perspectives de recherche

Solutions low-tech et open-source pour l'IA appliquée au béton. Prioriser des pipelines frugaux (smartphones/drones, capteurs T-H low-cost, modèles compacts), des ensembles de données ouverts annotés localement et des surrogates ACV avec incertitudes, pour rendre l'IA déployable en contexte de ressources contraintes (Hedegaard et al., 2022 ; Kalfarisi et al., 2023 ; Romeiko et al., 2023).

Collaboration universités–collectivités–secteur privé. Créer des sites pilotes (ponts urbains, dalots, stations de pompage) associant laboratoires (vérités terrain), maîtres d'ouvrage (priorisation), entreprises (capteurs, exécution) et régulateurs (référentiels), pour passer du prototype au portefeuille (UN-Habitat, 2022 ; AfDB, 2023 ; RILEM, 2023).

Développement de jumeaux numériques adaptés aux villes africaines. Intégrer BIM–GIS–capteurs dans des jumeaux légers avec mise à jour bayésienne, indicateurs de fiabilité et coûts carbone/financiers pour guider la décision ; explorer des GNN pour raisonner à l'échelle réseau et pas seulement ouvrage par ouvrage (Di Mucci et al., 2024 ; Gao et al., 2024).

Tableau 2. Maturité (TRL), transférabilité et exigences pour Kinshasa

Cas d'usage	Maturité (TRL) estimée	Applicabilité à Kinshasa	Pré-requis locaux (données/équipements)	Complexité / Coût relatif	Sensibilité au changement de domaine	Gains attendus (qualité/CO <sub>2</sub> /sécurité/coûts)	Risques & verrous	Horizon recommandé	Notes de mise en œuvre
<b>Formulation bas-carbone</b> (prédiction + optimisation multi-objectifs)	Moyen → Élevé (formulation prédictive) ; Moyen (optimisation)	Élevée	Corpus <b>local</b> de recettes/essais ; facteurs d'émission <b>ACV</b> ; disponibilité <b>SCM/LC3</b>	Moyen	Moyenne (variabilité matériaux/SCM)	Réduction CO <sub>2</sub> et coût à résistance/ouvrabilité constantes	Inventaires <b>ACV</b> incomplets ; chaînes d'approvisionnement volatiles	<b>Court terme</b> (pilotes en centrale)	Démarrer avec surrogates <b>ACV</b> + fronts de Pareto ; prioriser <b>LC3</b> ; calibration locale itérative
<b>Contrôle / CND</b> (vision, imagerie, IoT de cure)	Moyen (vision & capteurs embarqués)	Élevée (solutions <b>frugales</b> )	Smartphones/drones ; <b>capteurs low-cost</b> T-RH-résistivité ; stockage <b>edge</b>	Faible → Moyen	<b>Élevée</b> (éclairage, textures, chantiers) ; robustesse cross-site nécessaire	Qualité & sécurité chantier↑ ; délais décoffrage ↓	Interopérabilité <b>BIM-GIS</b> ; GT de vérité terrain ; énergie/connectivité intermittentes	<b>Court terme</b> (lots pilotes)	Modèles compacts <b>edge</b> + synchronisations asynchrones ; jeux annotés localement
<b>Durabilité / ACV</b> (surrogates, imputations)	<b>Moyen</b> (utiles en données rares)	Moyenne → Élevée	Inventaires <b>LCI</b> locaux ; protocoles d'incertitude ; back-testing	Moyen	<b>Élevée</b> (inventaires contextuels manquants)	<b>ACV</b> plus rapide et répliquable ; arbitrages coût-carbone éclairés	Référentiels, unités et métadonnées hétérogènes ; capacités labo limitées	<b>Court / Moyen terme</b>	Surrogates <b>GPR/RF</b> avec quantification d'incertitude ; mise à jour au fil des projets
<b>Maintenance prédictive &amp; jumeaux numériques (BIM-GIS + capteurs + IA)</b>	<b>Émergent</b> → <b>Moyen</b> (intégration incomplète)	Moyenne (progressive, par actifs critiques)	Modèle <b>BIM-GIS</b> minimal ; capteurs SHM ; gouvernance des données ; compétences hybrides	<b>Élevé</b> (intégration & changement organisationnel)	Moyenne (transférabilité par portefeuille, besoin d'adaptation locale)	Priorisation budgétée, fiabilité du parc, sécurité ↑ ; décisions multi-actifs	<b>Interop BIM-GIS</b> ; coûts initiaux ; gouvernance/éthique/cybersécurité ; continuité énergétique	<b>Moyen terme</b> (projets pilotes ciblés)	<b>Jumeaux légers</b> , mise à jour <b>bayésienne</b> , indicateurs fiabilité ; apprentissage <b>fédéré</b> réseau d'ouvrages

Abréviations. TRL = Technology Readiness Level ; SCM = additions cimentaires ; LC3 = limestone calcined clay cement ; ACV/LCI = analyse de cycle de vie / inventaire ; SHM = auscultation/monitoring structurel ; GT = ground truth ; RF = forêts aléatoires ; GPR = processus gaussiens.

## 5 Conclusion

### 5.1 Résumé des principaux enseignements de la revue

La revue met en évidence une maturité élevée des approches d'apprentissage supervisé et d'optimisation multi-objectifs pour la formulation des bétons (prédiction des performances et réduction du CO<sub>2</sub>), avec des validations expérimentales de plus en plus fréquentes (Li et al., 2022 ; Asteris et al., 2021 ; Pfeiffer et al., 2024). Les solutions de vision par ordinateur pour la détection de défauts de surface atteignent un niveau opérationnel, mais restent sensibles aux changements de domaine et à la qualité de l'annotation (Kalfarisi et al., 2023). Les cadres maturité + IoT pour estimer la résistance en place progressent, mais leur transférabilité inter-chantiers demeure limitée (Hedegaard et al., 2022). Les volets maintenance prédictive et jumeaux numériques sont prometteurs mais encore fragmentés, le chaînage BIM–capteurs–IA et l'actualisation fiable des états constituant des verrous (Di Mucci et al., 2024 ; Omrany et al., 2023 ; Gao et al., 2024). Enfin, l'IA facilite l'ACV par des métamodèles (« surrogates ») et l'exploration de fronts de Pareto force–coût–carbone, mais l'incertitude sur les inventaires locaux reste un frein majeur en Afrique (Romeiko et al., 2023).

### 5.2 Contribution de l'IA à la durabilité et à la résilience urbaine

L'IA contribue à la durabilité en accélérant la substitution du clinker (p. ex. LC3) et l'optimisation de mélanges bas carbone, tout en conservant les performances mécaniques et de durabilité (Scrivener et al., 2018 ; Sharma et al., 2021). Elle soutient la résilience urbaine par l'amélioration du contrôle qualité (inspection automatisée, suivi de la cure), l'anticipation des mécanismes de dégradation (carbonatation, chlorures) et la priorisation des interventions via des jumeaux numériques et des approches fiabilité-basées (Di Mucci et al., 2024 ; Gao et al., 2024). À l'échelle des politiques sectorielles, ces trajectoires sont cohérentes avec les feuilles de route de décarbonation et d'adaptation du secteur ciment-béton (IPCC, 2022 ; GCCA, 2023 ; IEA, 2024).

### 5.3 Recommandations pour l'avenir de la recherche et des pratiques à Kinshasa

- (i) Données locales et protocoles. Constituer des corpus de données locaux (recettes, essais, facteurs d'émission, historiques d'exploitation) avec métadonnées normalisées et procédures de validation inter-laboratoires, afin d'alimenter des modèles transférables et auditables (RILEM, 2023 ; CEN, 2019).
- (ii) Solutions frugales et ouvertes. Déployer des capteurs low-cost (T-H, résistivité), des pipelines edge et des modèles compacts (vision et CND) pour contourner les contraintes d'énergie et de connectivité ; privilégier des outils open-source et la publication de jeux de données annotés localement (GSMA, 2023 ; Hedegaard et al., 2022).
- (iii) Filières matériaux adaptées. Prioriser des filières LC3 et SCM disponibles régionalement, avec optimisation multi-objectifs (performance, coût, CO<sub>2</sub>) et surrogates ACV pour pallier les inventaires incomplets (Scrivener et al., 2018 ; Sharma et al., 2021 ; Romeiko et al., 2023).
- (iv) Maintenance prédictive à l'échelle du parc. Lancer des projets pilotes de jumeaux numériques BIM–GIS pour les ponts, dalots et ouvrages hydrauliques critiques, avec mise à jour bayésienne et indicateurs de fiabilité pour la priorisation budgétaire (Di Mucci et al., 2024 ; Gao et al., 2024).
- (v) Gouvernance et coalitions locales. Mettre en place des partenariats université–collectivités–entreprises pour assurer la vérité terrain (essais, inspections) et l'appropriation institutionnelle ; intégrer ces trajectoires dans les stratégies de décarbonation et d'adaptation urbaines (UN-Habitat, 2022 ; AfDB, 2023 ; GCCA, 2023 ; IEA, 2024).
- (vi) Ciblage des vulnérabilités kinois. Intégrer les enjeux d'érosion en ravines, de sollicitations hydrologiques et d'urbanisation rapide dans les jeux de données et les jumeaux numériques, afin d'orienter la maintenance vers les tronçons et ouvrages à risque (Mawe et al., 2025).

## REFERENCES

- [1] Abdellatif, M., Abd-Elmaboud, M. E., Mortagi, M., ... Saqr, A. M. (2025). A convolutional neural network-based deep learning approach for predicting surface chloride concentration of concrete in marine tidal zones. *Scientific Reports*, 15, 27611. <https://www.nature.com/articles/s41598-025-12035-1>

- [2] Abioye, S. O., Wua, C. H., Okoro, O., & Olatunji, S. O. (2025). Optimized machine learning algorithms with SHAP for concrete mix proportioning. *Discover Artificial Intelligence*. <https://link.springer.com/article/10.1007/s43503-025-00061-x>
- [3] African Development Bank (AfDB). (2023). African Economic Outlook 2023: Mobilizing private sector financing for climate and green growth. <https://www.afdb.org/en/knowledge/publications/african-economic-outlook>
- [4] African Union Commission (AU-AUC). (2024). Continental Strategy on Artificial Intelligence (draft/roadmap). <https://au.int/en/documents>
- [5] Ahmad, S., Kumar, A., & Siddique, R. (2025). Data-driven assessment of corrosion in reinforced concrete using ANN. *Scientific Reports*, 15, 8526. <https://www.nature.com/articles/s41598-025-08526-w>
- [6] Aliasghar-Mamaghani, M., Sha'ban, M., & Akbarzadeh Bengar, H. (2025). Quantitative description of chloride ingress in concrete using machine learning. *Construction and Building Materials*, 430, 13575. <https://www.sciencedirect.com/science/article/abs/pii/S0950061825003575>
- [7] Altuncu, Y. T., & Duran, A. (2024). A comprehensive study on the estimation of concrete compressive strength using machine learning models. *Buildings*, 14(12), 3851. <https://www.mdpi.com/2075-5309/14/12/3851>
- [8] Ament, S., Ostrozhenkova, E., & Lee, S. (2023). Sustainable concrete via Bayesian optimization. *arXiv*. <https://arxiv.org/abs/2310.18288>
- [9] Asteris, P. G., Skentou, A. D., Bardhan, A., Samui, P., & Pilakoutas, K. (2021). Predicting concrete compressive strength using hybrid ensembling of surrogate machine-learning models. *Cement and Concrete Research*, 145, 106449. <https://www.sciencedirect.com/science/article/pii/S0008884621000983>
- [10] Avdelidis, N. P., Tashan, J., Hawtin, B. C., Almond, D. P., & Ibarra-Castanedo, C. (2017). Infrared thermography in the evaluation of concrete structures. *Infrared Physics & Technology*, 85, 35–43. <https://www.sciencedirect.com/science/article/pii/S1350449516304860>
- [11] Azari, H., Dorafshan, S., & Maguire, M. (2020). Convolutional neural networks for ultrasonic pulse velocity interpretation in concrete. *Sensors*, 20(22), 6584. <https://www.mdpi.com/1424-8220/20/22/6584>
- [12] Bao, Y., Tang, Z., Ding, Y., & Chen, Z. (2025). Recent advances in structural health diagnosis: A machine learning perspective. *Advanced Bridge Engineering*, 6, 15. <https://aben.springeropen.com/articles/10.1186/s43251-024-00155-z>
- [13] Baumeister, R. F., & Leary, M. R. (1997). Writing narrative literature reviews. *Review of General Psychology*, 1(3), 311–320. <https://psycnet.apa.org/record/1997-05669-003>
- [14] Castañeda Valdés, A., Abreu, C., & Fajardo, V. (2024). Durability requirements for reinforced concrete structures exposed to extreme atmospheric corrosivity in tropical coastal environments. *Buildings*, 14(8), 2494. <https://www.mdpi.com/2075-5309/14/8/2494>
- [15] CEMBUREAU. (2024). From Ambition to Deployment — Our 2050 roadmap: Net zero cement & concrete value chain. <https://cembureau.eu/media/ulxj5lyh/cembureau-net-zero-roadmap.pdf>
- [16] CEN. (2019). EN 1992-1-1 Eurocode 2: Design of concrete structures – Part 1-1: General rules and rules for buildings. <https://standards.cen.eu>
- [17] Chaabene, W. B., Flah, M., & Nehdi, M. L. (2020). Machine learning prediction of mechanical properties of concrete: Critical review. *Construction and Building Materials*, 260, 119889. <https://www.sciencedirect.com/science/article/abs/pii/S0950061820318948>
- [18] Chatham House. (2018). Making Concrete Change: Innovation in low-carbon cement and concrete. <https://www.chathamhouse.org/2018/06/making-concrete-change-innovation-low-carbon-cement-and-concrete>
- [19] Chen, S., Li, X., & Yin, Y. (2025). AI-enhanced digital twins in maintenance: Systematic review. *Journal of Manufacturing Systems*, 76, 109–130. <https://www.sciencedirect.com/science/article/pii/S0278612525001815>

- [20] Chen, T., Li, H., & Wang, X. (2024). Prediction model-based multi-objective optimization for recycled aggregate concrete mix design (BO-GPR + Grey Wolf). *Frontiers of Structural and Civil Engineering*. <https://link.springer.com/article/10.1007/s11595-024-3020-5>
- [21] Chen, X., Li, B., Sun, Y., & Zhang, T. (2025). A hybrid prediction and multi-objective optimization framework for eco-friendly LC3 mix design. *Scientific Reports*. <https://pmc.ncbi.nlm.nih.gov/articles/PMC12215958/>
- [22] Cho, H.-C., Lee, J., & Kim, H. (2025). Remaining service life evaluation of reinforced concrete structures. *International Journal of Concrete Structures and Materials*, 19, 45. <https://ijesm.springeropen.com/articles/10.1186/s40069-024-00749-x>
- [23] Choi, W., Song, H., Kim, Y., & Jeong, H. (2024). Life cycle sustainability assessment method for concrete. *Environment, Development and Sustainability*. <https://link.springer.com/article/10.1007/s10668-024-04854-5>
- [24] Choi, Y., Jeong, Y., Park, S., ... Kim, J. (2024). Crack detection and analysis of concrete structures using deep learning. *Sensors*, 24, 1567. <https://pmc.ncbi.nlm.nih.gov/articles/PMC10975762/>
- [25] Chu, J., Li, Z., & Xu, H. (2025). Explainable machine learning for CO<sub>2</sub>-cured concrete: SHAP-based insights for mix design. *Journal of CO<sub>2</sub> Utilization*. <https://www.sciencedirect.com/science/article/pii/S2214509525003870>
- [26] Climate Bonds Initiative. (2023). Concrete policies to underpin the cement transition. <https://www.climatebonds.net/files/documents/publications/Concrete-policies-to-underpin-the-cement-transition.pdf>
- [27] Couto, R. A., Capellán-Linares, R., & Ortega, N. F. (2025). Machine learning models for carbonation depth prediction. *CivilEng*, 6(2), 46. <https://www.mdpi.com/2673-3951/6/2/46>
- [28] de Paula Salgado, I., Roithmayr, C., & Caputo, P. (2025). Integrating life cycle assessment and machine learning for sustainable designs. *International Journal of Life Cycle Assessment*. <https://link.springer.com/article/10.1007/s11367-025-02454-7>
- [29] Di Mucci, V. M., Di Benedetto, A., De Santis, S., & de Felice, G. (2024). Artificial intelligence in structural health management of existing bridges: A PRISMA review. *Automation in Construction*, 158, 105150. <https://www.sciencedirect.com/science/article/pii/S0926580524004552>
- [30] Dong, X., Hou, Y., Li, G., & Wang, Z. (2024). Concrete surface crack detection algorithm based on YOLOv8-CD. *Sensors*, 24(6), 1725. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC11359682/>
- [31] Dorafshan, S., Maguire, M., & Coopmans, C. (2019). SDNET2018: A concrete crack image dataset for machine learning applications. *Data in Brief*, 21, 1664–1668. <https://www.sciencedirect.com/science/article/pii/S2352340918314619>
- [32] Escobar-Palafox, G. A., Boulpaep, F., & Kostithis, S. (2021). Machine learning for non-destructive testing of concrete: A review. *Construction and Building Materials*, 310, 125208. <https://www.sciencedirect.com/science/article/pii/S0950061821022121>
- [33] Feng, D.-C., Liu, Z.-T., Wang, X.-D., Chen, Y., Chang, J.-Q., Wei, D.-F., & Jiang, Z.-M. (2020). Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach. *Construction and Building Materials*, 230, 117000. <https://www.sciencedirect.com/science/article/abs/pii/S0950061819324420>
- [34] Ferrari, R. (2015). Writing narrative style literature reviews. *Medical Writing*, 24(4), 230–235. <https://journal.emwa.org/writing-for-publication/writing-narrative-style-literature-reviews/>
- [35] Franciosi, M., Pepe, M., & Cuomo, G. (2024). Digital twins in bridge engineering for streamlined management. *Automation in Construction*, 157, 105097. <https://www.sciencedirect.com/science/article/pii/S0926580524005703>
- [36] Gao, Y., Chen, Z., & Li, J. (2024). Bridge Digital Twin for practical operation and maintenance. *Buildings*, 14(12), 3731. <https://www.mdpi.com/2075-5309/14/12/3731>
- [37] Gao, Y., Mosalam, K. M., & Brilakis, I. (2022). Edge computing and computer vision for automated inspection of civil infrastructure. *Automation in Construction*, 141, 104418. <https://www.sciencedirect.com/science/article/pii/S0926580522001212>

- [38] GCCA — Global Cement and Concrete Association. (2021). Concrete Future 2050 Roadmap for Net Zero Concrete. <https://gccassociation.org/concretefuture/wp-content/uploads/2021/10/GCCA-Concrete-Future-Roadmap-Document-AW.pdf>
- [39] GCCA — Global Cement and Concrete Association. (2023). 2050 Net Zero Roadmap – Action and progress (One year on). <https://gccassociation.org/wp-content/uploads/2023/01/GCCA-Roadmap-One-Year-On-Action-and-Progress.pdf>
- [40] Grant, M. J., & Booth, A. (2009). A typology of reviews: An analysis of 14 review types and associated methodologies. *Health Information & Libraries Journal*, 26(2), 91–108. <https://onlinelibrary.wiley.com/doi/10.1111/j.1471-1842.2009.00848.x>
- [41] Green, B. N., Johnson, C. D., & Adams, A. (2006). Writing narrative literature reviews for peer-reviewed journals: Secrets of the trade. *Journal of Chiropractic Medicine*, 5(3), 101–117. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3083040/>
- [42] GSMA. (2023). The Mobile Economy: Sub-Saharan Africa 2023. <https://www.gsma.com/mobileeconomy/sub-saharan-africa/>
- [43] Guo, B., Zhao, Q., Zhang, W., & Wang, L. (2024). Effect of external loads on chloride ingress into concrete: A state-of-the-art review. *Construction and Building Materials*, 415, 133411. <https://www.sciencedirect.com/science/article/abs/pii/S0950061824037991>
- [44] Hassan, S. I., Ullah, S., Murtaza, R., ... & Muhammad, W. (2024). Systematic literature review on machine learning for concrete compressive strength prediction. *Heliyon*. <https://pmc.ncbi.nlm.nih.gov/articles/PMC11157546/>
- [45] Hedegaard, K., Lange, D., & Geiker, M. R. (2022). Maturity modelling and in-situ strength estimation of concrete: A critical review. *Cement and Concrete Composites*, 132, 104651. <https://www.sciencedirect.com/science/article/pii/S0958946522001074>
- [46] Helali, S., Marzouk, M., & Mojahed, M. (2025). Optimizing carbon footprint and strength in high performance concrete using multi-objective optimization. *Sustainability*, 17(17), 7808. <https://www.mdpi.com/2071-1050/17/17/7808>
- [47] Hoła, J., & Schabowicz, K. (2010). State-of-the-art non-destructive testing of concrete structures. *Archives of Civil and Mechanical Engineering*, 10(3), 5–18. <https://www.sciencedirect.com/science/article/pii/S1644966512000067>
- [48] IEA — International Energy Agency. (2024). Cement — Tracking Clean Energy Progress. <https://www.iea.org/energy-system/industry/cement>
- [49] IEA (International Energy Agency). (2022). Africa Energy Outlook 2022. <https://www.iea.org/reports/africa-energy-outlook-2022>
- [50] IPCC. (2022). Climate Change 2022: Mitigation of Climate Change — Summary for Policymakers (AR6 WGIII). [https://www.ipcc.ch/report/ar6/wg3/downloads/report/IPCC\\_AR6\\_WGIII\\_SPM.pdf](https://www.ipcc.ch/report/ar6/wg3/downloads/report/IPCC_AR6_WGIII_SPM.pdf)
- [51] Ji, H., Lyu, Y., Ying, W., Liu, J. C., & Ye, H. (2024). Machine learning-guided iterative mix design of geopolymer concrete (PSO + validation expérimentale). *Journal of Building Engineering*, 91, 109710. <https://www.sciencedirect.com/science/article/abs/pii/S2352710224012786>
- [52] Jilke, L., Orglmeister, R., & Kissinger, T. (2025). Federated two-stage machine learning for ultrasonic guided-wave SHM. *Proc. SPIE 13438*. <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/13438/134380J/Federated-two-stage-machine-learning-model-for-ultrasonic-guided-wave/10.1117/12.3051068.full>
- [53] Kalfarisi, R., Gopalakrishnan, K., & Kim, S. (2023). Deep learning for vision-based structural inspection: A comprehensive review. *Engineering Structures*, 276, 115168. <https://www.sciencedirect.com/science/article/pii/S0141029622042140>
- [54] Kamana, A. A. (2024). Urban challenges and strategies in African cities. *Journal of Urban Management*, 13(2), 100–113. <https://www.sciencedirect.com/science/article/pii/S259025202300034X>
- [55] Kaveh, H., Hejazi Dinan, M., & Fallah, A. (2024). Recent advances in crack detection technologies for structures: A survey of 2022–2023 literature. *Frontiers in Built Environment*, 10, 1321634. <https://www.frontiersin.org/journals/built-environment/articles/10.3389/fbuil.2024.1321634/full>

- [56] Khalid, S., Umer, A., Ahmed, M., & Anas, M. (2024). Multimodal optimization of concrete mix design for cost–strength–carbon performance. *Journal of CO<sub>2</sub> Utilization*, 80, 102280. <https://www.sciencedirect.com/science/article/pii/S2214509524010192>
- [57] Kim, G., & Cho, S. (2023). Real-time crack detection using lightweight CNNs and knowledge distillation for mobile inspection. *Sensors*, 23(3), 1206. <https://www.mdpi.com/1424-8220/23/3/1206>
- [58] Kim, H., Lee, S., & Kim, Y. (2021). Vision-based measurement of concrete slump using deep learning. *Automation in Construction*, 127, 103726. <https://www.sciencedirect.com/science/article/pii/S0926580521001349>
- [59] Lai, W. L., Dérobert, X., & Annan, P. (2021). A decade of ground-penetrating radar research in civil engineering: Concrete assessment and beyond. *NDT & E International*, 116, 102401. <https://www.sciencedirect.com/science/article/pii/S0963869519302840>
- [60] Li, Z., Yoon, J., Zhang, R., Rajabipour, F., Srubar, W. V., Dabo, I., & Radlińska, A. (2022). Machine learning in concrete science: Applications, challenges, and best practices. *npj Computational Materials*, 8, 127. <https://www.nature.com/articles/s41524-022-00810-x>
- [61] Liu, Y., Li, Z., & Zhang, H. (2024). Machine learning-guided optimization of coarse-aggregate mix proportion to reduce CO<sub>2</sub> du béton. *Journal of Building Engineering*. <https://www.sciencedirect.com/science/article/pii/S2212982024001975>
- [62] Liu, Y., Wu, H., & Ye, X. (2025). TPS-GNN for predictive bridge health monitoring. *Structural Health Monitoring*. <https://journals.sagepub.com/doi/abs/10.1177/14759217251330971>
- [63] Liu, Z., Li, X., & Xu, Q. (2024). Coupling effects of stress and carbonation on concrete durability: A review. *Materials*, 17(22), 5438. <https://www.mdpi.com/1996-1944/17/22/5438>
- [64] Luo, D., Jiang, C., Zhang, Y., & Wang, J. (2025). Artificial intelligence in the design, optimization, and performance prediction of concrete materials: A comprehensive review. *npj Materials Sustainability*. <https://www.nature.com/articles/s44296-025-00058-8>
- [65] Mandal, D. D., Das, S., & Banerjee, S. (2024). Acoustic emission monitoring of damage modes in RC beams. *Scientific Reports*, 14, 78561. <https://www.nature.com/articles/s41598-024-78561-6>
- [66] Maturana, D., Traversaro, S., & Leiva, R. (2018). Deep learning for GPR data interpretation in concrete inspection. *Construction and Building Materials*, 168, 119–131. <https://www.sciencedirect.com/science/article/pii/S0950061818304754>
- [67] Mawe, G. I., et al. (2025). Mapping urban gullies in the Democratic Republic of the Congo. *Nature*. <https://www.nature.com/articles/s41586-025-09371-7>
- [68] Mission Possible Partnership (MPP). (2022). Cement Roadmap: Pathways to Net-Zero. <https://missionpossiblepartnership.org/sector/cement/>
- [69] Nature Editorial Team. (2025). Infrastructure deficits and informal settlements in sub-Saharan Africa. *Nature*. <https://www.nature.com/articles/s41586-025-09465-2>
- [70] Neupane, B., Roy, D., & Biswas, W. (2025). Machine learning algorithms for supporting life cycle assessment. *Sustainable Production and Consumption*, 39, 1–16. <https://www.sciencedirect.com/science/article/pii/S235255092500065X>
- [71] Ni, F., Zhang, J., & Wu, Q. (2019). Computer vision-based crack detection for civil infrastructure: A review. *Applied Sciences*, 9(14), 2867. <https://www.mdpi.com/2076-3417/9/14/2867>
- [72] Nikoopayan Tak, M. S., Abdollahzadeh, G., & Kazemi, M. (2025). Advanced machine learning techniques for predicting concrete strength from mix variables. *Infrastructures*, 10(2), 26. <https://www.mdpi.com/2412-3811/10/2/26>
- [73] Nukah, P. D., Adewumi, A., & Isaac, A. (2024). Learner-model tool for predicting strength and embodied carbon of lightweight concrete. *Journal of Building Engineering*, 89, 108400. <https://www.sciencedirect.com/science/article/pii/S2352710224018989>
- [74] Olsson, J. A., et al. (2024). A review of current practice for life cycle assessment (LCA) of cement and concrete decarbonisation pathways. *Resources, Conservation & Recycling*, 201, 107341. <https://www.sciencedirect.com/science/article/pii/S0921344924002131>

- [75] Omar, T., Nehdi, M. L., & Yélamos, I. (2021). Thermographic detection of subsurface defects in concrete: A machine learning approach. *Sensors*, 21(18), 6102. <https://www.mdpi.com/1424-8220/21/18/6102>
- [76] Omrany, H., Al-Obaidi, K. M., Husain, A., & Ghaffarianhoseini, A. (2023). Digital twins in the construction industry: A comprehensive review of current implementations, enabling technologies, and future directions. *Sustainability*, 15(14), 10908. <https://www.mdpi.com/2071-1050/15/14/10908>
- [77] Paudel, S., Al Nageim, H., Al Karawi, H., & Atherton, W. (2023). Compressive strength of concrete using machine learning approaches: A comparative assessment. *Case Studies in Construction Materials*, 19, e02369. <https://www.sciencedirect.com/science/article/pii/S2666790823000666>
- [78] Pénicaud, M., Debliquy, M., & Paillard, J. (2025). Current trends and uses of machine learning in acoustic emission. *Journal of Nondestructive Evaluation*. <https://link.springer.com/article/10.1007/s10921-025-01247-0>
- [79] Pfeiffer, O. P., Gong, K., Severson, K. A., Chen, J., Gregory, J. R., Ghosh, S., Goodwin, R. T., & Olivetti, E. A. (2024). Bayesian design of concrete with amortized Gaussian processes and multi-objective optimization. *Cement and Concrete Research*, 177, 107406. <https://www.sciencedirect.com/science/article/pii/S0008884623003216>
- [80] Popay, J., Roberts, H., Sowden, A., Petticrew, M., Arai, L., Rodgers, M., ... Duffy, S. (2006). Guidance on the conduct of narrative synthesis in systematic reviews. ESRC Methods Programme. <https://www.lancaster.ac.uk/media/lancaster-university/content-assets/documents/fhm/dhr/chir/NSsynthesisguidanceVersion1-April2006.pdf>
- [81] Prasanna, P., Dana, K. J., Gucunski, N., Basily, B., La, H. M., Lim, R. S., & Parvardeh, H. (2016). Automated crack detection on concrete bridge decks. *IEEE Transactions on Automation Science and Engineering*, 13(2), 591–599. <https://ieeexplore.ieee.org/document/7340910>
- [82] Presa Madrigal, L., González, J., Salgueiro, A., & Faria, P. (2024). Cost-effective temperature sensor for monitoring the curing of concrete. *Applied Sciences*, 14(11), 4344. <https://www.mdpi.com/2076-3417/14/11/4344>
- [83] Rahman, M. A., Hossain, M. S., & Islam, M. M. (2024). PINN-CHK: Physics-informed neural network for cement hydration kinetics. *Neural Computing and Applications*, 36(19), 11523–11540. <https://link.springer.com/article/10.1007/s00521-024-09791-y>
- [84] Revathi, B., Srinivasan, P., & Rahman, A. (2024). Harnessing explainable AI for geopolymer mix design: SHAP-based insights. *Results in Engineering*, 22, 102021. <https://www.sciencedirect.com/science/article/pii/S259012302401291X>
- [85] RILEM. (2023). State-of-the-art reports on service life and durability design for concrete structures (TC/commissions). <https://www.rilem.net/publications>
- [86] Romeiko, X. X., Tozzi, A., & Scown, C. (2023). Machine learning applications in life cycle assessment: A systematic review. *Sustainable Production and Consumption*, 38, 412–430. <https://pmc.ncbi.nlm.nih.gov/articles/PMC12191033/>
- [87] Salehi, H., & Burgueño, R. (2018). Emerging artificial intelligence methods in structural health monitoring and damage detection. *Structural Health Monitoring*, 17(5), 1185–1210. <https://journals.sagepub.com/doi/10.1177/1475921717744751>
- [88] Scrivener, K., Martirena, F., Bishnoi, S., & Maity, S. (2018). Calcined clay–limestone cements (LC3). *Cement and Concrete Research*, 114, 49–56. <https://www.sciencedirect.com/science/article/abs/pii/S0008884617302454>
- [89] Sharma, M., Bishnoi, S., Martirena, F., & Scrivener, K. (2021). Limestone calcined clay cement and concrete: A state-of-the-art review. *Cement and Concrete Research*, 149, 106564. <https://www.sciencedirect.com/science/article/abs/pii/S0008884621002131>
- [90] Shokravi, H., Shokravi, H., Bakhary, N., Rahimian Kolor, S. S., & Petru, M. (2020). Review of deep learning-based structural health monitoring. *Engineering Structures*, 234, 111698. <https://www.sciencedirect.com/science/article/pii/S0141029620310416>

- [91] Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339. <https://www.sciencedirect.com/science/article/pii/S0148296319304564>
- [92] Song, S., Wang, H., & Guo, X. (2024). Influence of curing relative humidity on the durability of concrete. *Materials*, 17(2), 345. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10934535/>
- [93] Souza, L., de Ávila, L., & Gomes, G. (2024). Unsupervised transfer learning for bridge SHM via domain adaptation. *Infrastructures*, 9(8), 131. <https://www.mdpi.com/2412-3811/9/8/131>
- [94] Spencer, B. F., Sim, S.-H., Kim, R. E., & Yoon, H. (2025). Advances in artificial intelligence for structural health monitoring: A comprehensive review. *KSCE Journal of Civil Engineering*, 29(3), 100203. <https://colab.ws/articles/10.1016%2Fj.kscej.2025.100203>
- [95] Tipu, R. K., Rahman, M. M., Hossain, M. N., & Islam, M. A. (2025). Optimizing sustainable blended concrete mixes using deep learning and multi-objective optimization. *Scientific Reports*. <https://www.nature.com/articles/s41598-025-00943-1>
- [96] Tracking SDG7 (World Bank, IEA, IRENA, UNSD, WHO). (2024). The Energy Progress Report 2024. <https://trackingsdg7.esmap.org/>
- [97] UNESCO. (2021). Recommendation on the ethics of artificial intelligence. <https://unesdoc.unesco.org/>
- [98] UN-Habitat. (2022). World Cities Report 2022: Envisioning the future of cities. <https://unhabitat.org/wcr/>
- [99] Vaags, E., Bakker, D., & Gandomi, A. (2023). Comparative analysis of ML and survival models for infrastructure deterioration. *Journal of Infrastructure Systems*, 29(4), 04023034. <https://ascelibrary.org/doi/abs/10.1061/JITSE4.ISENG-2176>
- [100] van Roijen, E., Davis, S. J., & Caldeira, K. (2024). The climate benefits from cement carbonation are being underestimated. *Nature Communications*, 15, 5025. <https://pmc.ncbi.nlm.nih.gov/articles/PMC11156638/>
- [101] Wang, M., Zhang, L., & Li, P. (2025). Multi-objective optimization of ultra-high-performance concrete using NSGA-II coupled with ML surrogates. *Frontiers of Structural and Civil Engineering*. <https://link.springer.com/article/10.1007/s11709-025-1152-0>
- [102] Wang, Q. A., Pan, G., & Wang, C. (2025). Bayesian network in structural health monitoring: A systematic review. *Mathematics*, 13(5), 872. <https://pmc.ncbi.nlm.nih.gov/articles/PMC12196708/>
- [103] Wettewa, S., Tang, P., & Zhang, C. (2024). Graph neural networks for building and civil infrastructure operation and maintenance. *Engineering Applications of Artificial Intelligence*, 133, 107016. <https://www.sciencedirect.com/science/article/pii/S1474034624005160>
- [104] Wohlin, C. (2014). Guidelines for snowballing in systematic literature studies and a replication in software engineering. *Proceedings of EASE 2014*. <https://dl.acm.org/doi/10.1145/2601248.2601268>
- [105] World Bank. (2015). Building Regulation for Resilience: Managing risks for safer cities. <https://openknowledge.worldbank.org/handle/10986/23776>
- [106] World Bank. (2017). Africa's Cities: Opening Doors to the World. <https://openknowledge.worldbank.org/handle/10986/25896>
- [107] Xie, Q., Jiang, Q., Kurnitski, J., Yang, J., Lin, Z., & Ye, S. (2024). Quantitative carbon emission prediction model to limit embodied carbon from major building materials. *Sustainability*, 16(13), 5575. <https://www.mdpi.com/2071-1050/16/13/5575>
- [108] Xu, M., Li, J., & Wang, X. (2020). Deep learning-based slump prediction of fresh concrete from video. *Sensors*, 20(22), 6502. <https://www.mdpi.com/1424-8220/20/22/6502>
- [109] Xu, X., He, W., Zhou, J., Zhong, R., & Wang, S. (2022). Machine learning the concrete compressive strength with Gaussian process regression. *ASME Open Journal of Engineering*. <https://asmedigitalcollection.asme.org/openengineering/article/doi/10.1115/1.4055194/1145795>
- [110] Yang, Z., Zhang, X., & Li, Y. (2024). Digital twins in construction: Architecture, applications, trends and challenges. *Buildings*, 14(9), 2616. <https://www.mdpi.com/2075-5309/14/9/2616>

- [111] Zhang, L., Yang, F., Zhang, Y. D., & Zhu, Y. J. (2016). Road crack detection using deep convolutional neural networks. *Image and Vision Computing*, 57, 130–142. <https://www.sciencedirect.com/science/article/pii/S026288561630123X>
- [112] Zhang, R., Wang, Y., & Wu, Z. (2022). Deep learning-based classification of damage-induced AE signals in UHPC. *Construction and Building Materials*, 362, 129593. <https://www.sciencedirect.com/science/article/abs/pii/S0950061822029415>
- [113] Zhang, Y., Chen, X., & Guo, H. (2025). Machine learning-assisted sustainable mix design of glass-powder geopolymer concrete via multi-objective optimization. *Buildings*, 15(15), 2640. <https://www.mdpi.com/2075-5309/15/15/2640>
- [114] Zhao, K., Ma, H., & Liu, Y. (2025). Machine learning models for rapid prediction of LCIA results. *Chemistry Teacher International*. <https://www.sciencedirect.com/science/article/pii/S2950155525000485>
- [115] Zheng, W., Li, Z., & Wang, X. (2023). Multi-objective optimization of concrete mix design based on machine learning. *Journal of Building Engineering*, 69, 106312. <https://www.sciencedirect.com/science/article/abs/pii/S2352710223015760>
- [116] Zhou, X., Li, Y., & Wang, J. (2023). Bayesian-based prediction and real-time updating for construction monitoring. *Engineering Structures*, 290, 116177. <https://www.sciencedirect.com/science/article/abs/pii/S0141029623014074>
- [117] Zou, Z., Li, C., & Xu, Q. (2024). Enhanced Gaussian-process model for predicting concrete strength with uncertainty quantification. *Materials*, 17(24), 6140. <https://www.mdpi.com/1996-1944/17/24/6140>