

Application de l'analyse d'images par deep learning à la détermination de la composition de granulats recyclés

Jean David LAU HIU HOONG

Laboratoire des Sciences de l'Ingénieur pour l'Environnement (LaSIE), UMR CNRS 7356, La Rochelle Université

RESUME À travers le programme Horizon 2020, l'Union Européenne promeut l'économie circulaire en incitant ses états membres à recycler au moins 70% de leurs déchets du BTP. Ces déchets sont concassés pour obtenir des granulats recyclés (GR). Ces derniers sont un mélange de béton, pierres naturelles, terre cuite, grains bitumineux et d'autres matériaux (e.g. verre et bois). Leur composition est variable et la norme NF EN 933-11 préconise un tri manuel pour la déterminer. Cependant, ce tri est chronophage et n'est réalisé que ponctuellement sur les plateformes de recyclage. Notre travail vise à déterminer la composition de GR de manière rapide et automatisée. Nous faisons appel à l'analyse d'images par *deep learning* et notamment aux réseaux de neurones convolutifs (RNC). Les RNC analysent les images de GR et identifient la nature de chaque grain afin de donner la composition des GR. Une base de données labellisée d'environ 36 000 images de grains individuels triés a été créée pour l'apprentissage des RNC. Le meilleur RNC est maintenant capable de classer correctement 97% des grains. Nous proposons aussi un moyen d'estimer la masse des granulats grâce à des facteurs de forme. Nous avons comparé la composition d'un échantillon de GR obtenue par notre méthode et par le tri manuel. Il y a moins de 1,5% d'écart de proportion massique pour la majorité des natures de GR testées.

Mots-clés *Deep learning*, réseaux de neurones convolutifs, granulats recyclés, analyse d'images, économie circulaire

I. INTRODUCTION

Dans un contexte de développement durable et d'économie circulaire, l'Union Européenne a incité ses états membres à recycler au moins 70 % de leurs déchets du BTP d'ici cette année à travers le programme Horizon 2020. Une enquête (Ministère de l'Environnement, de l'Énergie et de la Mer, 2017a, 2017b) a montré qu'en 2014, 227,5 Mt de déchets ont été produits par le secteur du BTP en France (70% de la totalité des déchets). 155,9 Mt (69 %) ont été recyclés principalement dans la construction routière et pour le remblaiement de carrières. Cependant, 70 Mt ont quand même été déposés sur des sites de stockage alors qu'une optimisation du recyclage des déchets du BTP permettrait de préserver nos ressources naturelles.

Obtenus à partir du concassage de déchets inertes de démolition, les granulats recyclés (GR) sont des mélanges de granulats de béton, pierres naturelles, terre cuite, grains bitumineux et d'autres matériaux (e.g. verre, bois et acier). La composition des GR est variable car elle dépend des chantiers d'origine et de la technique de concassage utilisée (Akbarnezhad et al., 2013; Guimaraes et al., 2007). Cette variabilité de la composition limite la valorisation de GR dans des applications comme la fabrication de béton, pour lesquelles l'utilisation de matériaux de qualité contrôlée est essentielle. Le remplacement des granulats naturels (GN) par les GR dans le béton a tendance à diminuer ses propriétés mécaniques et de durabilité (Bravo et al., 2018; Kou et al., 2012; Omary et al., 2018). Cependant, utilisés dans la construction routière, les GR peuvent même surpasser les GN (Hou et al., 2019; Lancieri et al., 2006; Mahieux et al., 2017; Turcry et al., 2016). La littérature montre que la composition des GR influence leurs propriétés. À cause de cette contrainte, actuellement, les GR sont surtout utilisés pour la construction routière car la norme qui régit la formulation de béton (NF EN 206+A1) est plus restrictive.

Afin de valoriser les GR comme produits à valeur ajoutée, il est essentiel de suivre leur composition de près. Actuellement, la norme NF EN 933-11 recommande un tri manuel pour déterminer cette composition. Néanmoins, ce tri est chronophage et n'est réalisé que ponctuellement sur les plateformes de recyclage. Notre travail se focalise sur le développement d'une méthode novatrice afin de déterminer la composition de GR en quasi-temps réel et de manière automatisée.

Nous faisons appel au *deep learning* qui est une forme de *machine learning* dans laquelle des réseaux de neurones profonds (RNP) analysent différents types de données pour les modéliser. Le type de RNP utilisé pour la classification d'images est le réseau de neurones convolutifs (RNC). Afin de classifier des objets, le RNC doit être entraîné sur un grand ensemble d'images labellisées.

Pour notre étude, nous avons créé une base de données qui contient environ 36 000 images de GR pour l'apprentissage d'un RNC de la littérature et d'une version modifiée de celui-ci pour avoir de meilleures performances. Ces derniers analysent des images de GR pour donner leur composition. Afin de déterminer la masse de chaque grain, nous avons évalué des produits facteurs de forme-masse volumique pour chaque type de grain en supposant que tous les grains d'une même nature ont la même forme et masse volumique. Nous avons aussi comparé notre méthode au tri manuel.

II. METHODES ET MATERIAUX

A. Architectures de réseaux de neurones convolutifs testées

Dans cette étude, nous avons testé un RNC de référence, le *Residual Network* (ResNet) développé par (He et al., 2015). En outre, nous avons modifié l'architecture du ResNet afin d'améliorer sa précision (M-ResNet). Le principe de fonctionnement d'un réseau de neurones convolutifs (RNC) est détaillé dans (LeCun et al., 2015).

L'étape essentielle pour le bon fonctionnement des RNC est leur apprentissage, qui est composé de deux étapes : l'entraînement et la validation. Pendant la première étape, les paramètres du RNC sont optimisés afin d'améliorer sa capacité à prédire la nature des grains. Ensuite, les

images dans l'ensemble de validation testent la capacité du RNC à se généraliser, c'est-à-dire à classer correctement des images différentes de celles vues pendant l'entraînement. Les paramètres du RNC ne sont pas mis à jour pendant la validation.

B. Création de la base de données

La base de données des granulats recyclés (GR) utilisée pour l'apprentissage des réseaux de neurones convolutifs (RNC) contient des images des grains individuels classés selon leur nature. La création de cette base de données est décrite ci-dessous :

- **Préparation des échantillons et tri manuel.** Les GR utilisés dans cette étude ont été prélevés à Planète Recyclage (filiale de l'Entreprise Charrier), une plateforme de recyclage à La Rochelle. Initialement de coupure 0/31,5 mm, ces GR ont été tamisés pour enlever la coupure 0/4 car les grains inférieurs à 4 mm sont trop petits pour être identifiés (idem norme NF EN 933-11). Puis, les GR sont rincés afin d'enlever les fines qui les recouvrent et qui limitent leur identification. Ensuite, ils sont triés manuellement. La norme définit les étapes du tri manuel et les classes de constituants des GR. Cependant, les éléments de certaines classes sont visuellement très hétérogènes et pas adaptés pour la classification d'images par RNC. Donc, certaines classes ont été divisées en sous-classes qui sont visuellement plus homogènes. Le Tableau 1 donne les classes de la norme et les sous-classes correspondantes. La [Figure 1](#) montre des exemples d'éléments présents dans chaque sous-classe. Selon la norme, tout grain ayant une trace de mortier devrait être classé comme un "grain de béton" (Rc), même si la partie "pierre naturelle" (Ru) est celle qui est la plus visible. De ce fait, les éléments de la classe Rc présentent toujours une certaine hétérogénéité.

- **Dispositif de photographie.** Un dispositif (Figure 2) a été développé pour photographier les GR. Il est constitué d'un appareil photo Fujifilm X-T20 (1) fixé sur un statif (2), deux lampes LED (3), une plaque en plastique transparente (4) sur laquelle sont placés les grains et un fond (5) d'une couleur différente (e.g. bleu) de celles des GR. De plus, une pièce de 5 centimes est utilisée comme référence pour faire la conversion entre pixels et millimètres. Environ 43 kg de GR de coupure 4/31,5, soit plus de quatre fois la masse minimale de prise d'essai (10 kg) de la norme NF EN 933-11, ont été photographiés avec ce dispositif.

- **Extraction de grains individuels.** Après avoir pris une photo, la masse de l'ensemble des grains sur l'image a été mesurée. Plus de 360 photos ont été prises et un logiciel basé sur la morphologie mathématique, qui a été développé au laboratoire, a été utilisé pour extraire plus de 36 000 grains individuels. Les données géométriques (longueur des axes mineure et majeure et aire projetée) de chaque grain ont aussi été obtenues. Elles sont utilisées pour caractériser la forme des granulats. Certaines sous-classes (Rc, Ru01, Ru02, Ru04, Ru05, Rb01, Rb02, Ra) ont entre 2 000 et 6 000 grains. Toutefois, d'autres (Ru03, Ru06, Rg, X01-X05) en ont moins de 1 100 parce qu'ils sont difficiles à trouver sur les plateformes de recyclage. Cette distribution inégale peut affecter la précision des RNC. Ce problème est mitigé avec l'augmentation de données.

- **Augmentation de données.** Dans la base de données, il est préférable d'avoir le même nombre d'éléments dans chaque sous-classe pour éviter que le RNC soit biaisé (favorise une sous-classe aux dépens des autres). Afin de pallier le manque d'éléments dans certaines sous-classes, on utilise des techniques d'augmentation de données (addition aléatoire de bruit « sel et poivre », rotation du grain et correction gamma). Cependant, ces augmentations sont limitées.

Chaque image de la base de données est soumise à ces modifications jusqu'à ce que le nombre d'images par sous-classe atteigne 2 000 pour l'ensemble d'entraînement et 500 pour l'ensemble de validation. Certaines sous-classes (Ru03, Ru06, Rg and X02-X05) n'ont pas été utilisées pour créer la base de données parce qu'elles ne contiennent pas suffisamment d'éléments (un élément serait répété de très nombreuses fois). Donc, la base de données utilisée pour l'apprentissage des RNC contient 22 500 images : 2 500 images (ensemble d'entraînement et de validation) dans chacune de ces 9 sous-classes : Rc, Ru01, Ru02, Ru04, Ru05, Rb01, Rb02, Ra and X01. Il faut noter que les grains dans l'ensemble de validation sont différents de ceux de l'ensemble d'entraînement. La [Figure 3](#) montre un extrait de la base de données de GR.

Tableau 1. Classes de granulats recyclés selon la norme NF EN 933-11 et sous-classes correspondantes

Classe NF EN 933-11	Sous-classe	Description
Rc	Rc	Grains de béton
Ru	Ru01	Pierres claires (e.g. calcaire)
	Ru02	Pierres grises (e.g. basalte et d'autres de couleurs similaires)
	Ru03	Pierres grenues claires (majorité de quartz et de feldspath)
	Ru04	Pierres siliceuses colorées ou sombres et angulaires
	Ru05	Pierres alluvionnaires claires
	Ru06	Ardoise
Rb	Rb01	Terre cuite
	Rb02	Carreaux de céramique
Ra	Ra	Grains bitumineux
Rg	Rg	Verre
X	X01	Bois
	X02	Plastiques
	X03	Acier
	X04	Papier et carton
	X05	Autres



Figure 1. Exemples d'éléments dans chaque sous-classe

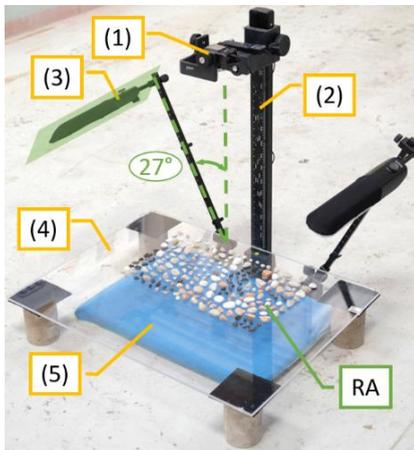


Figure 2. Dispositif de photographie

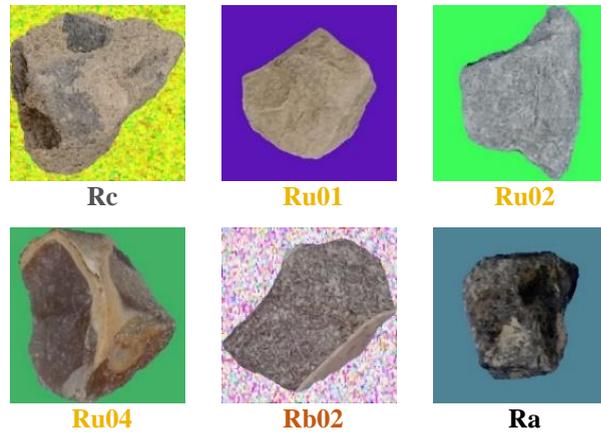


Figure 3. Extrait de la base de données

C. Méthode d'évaluation des produits facteur de forme-masse volumique des granulats

Comme décrit ci-dessus, un réseau de neurones convolutifs (RNC) entraîné pourra prédire la nature d'un granulat recyclé (GR) à partir de son image. De plus, les données géométriques (longueur des axes mineure et majeure et aire projetée) de chaque grain sont aussi disponibles. La Figure 4 montre un GR et les données géométriques du grain. Selon la norme NF EN 933-11, la composition des GR obtenue par tri manuel est donnée en termes de proportions massiques. Afin de pouvoir comparer notre méthode avec le tri manuel, on doit estimer la masse des grains qui sont soumis à l'analyse d'images. Notre approche est similaire à celle proposée par (Mora et al., 1998). La masse m_i d'un grain i peut être exprimée comme dans l'équation (1).

$$m_i = S_i \times L_{min,i} \times F_k \times \rho_k \quad (1)$$

Où S_i est l'aire projetée (cm^2) et $L_{min,i}$ est l'axe mineur (cm). F_k et ρ_k sont respectivement le facteur de forme et la masse volumique, supposés constants pour tous les grains appartenant à la sous-classe k . Vu qu'il serait trop chronophage de peser chaque grain individuellement, nous avons mesuré la masse globale de l'ensemble des grains de chaque photo j d'une sous-classe k donnée, notée M_{jk} . Le produit entre F_k et ρ_k (produits facteur de forme-masse volumique) peut être évalué, pour chaque sous-classe k , comme dans l'équation (2).

$$F_k \cdot \rho_k = \frac{\sum_j M_{jk}}{\sum_{i,j} (S_{i,j} \times L_{min,i,j})} \quad (2)$$

Où $\sum_{i,j} (S_{i,j} \times L_{min,i,j})$ est la somme entre l'aire projetée et l'axe mineure pour tous les grains i dans tous les j photos de la sous-classe k . Une fois déterminée, $F_k \rho_k$ peut être utilisé pour estimer la masse d'autres GR.

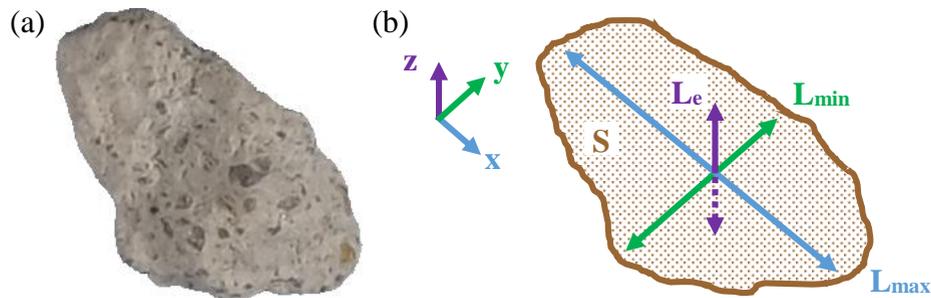


Figure 4. (a) Grain original et (b) Données géométriques du grain

III. RESULTATS ET DISCUSSION

A. Classification d'images de granulats recyclés

Un ResNet de référence et une version modifiée (M-ResNet) ont été testés. Dans un réseau de neurones convolutifs (RNC), la convolution est l'opération qui extrait les traits visuels (bordures, contours, etc) permettant la classification des images. La convolution standard est coûteuse en termes de mémoire et de temps de calcul. La principale différence dans le M-ResNet est l'utilisation d'un autre type de convolution, la *depthwise separable convolution* (DSC) (Howard et al., 2017). La DSC est moins coûteuse que la convolution standard et permet donc au M-ResNet d'extraire plus de traits tout en conservant un nombre de paramètres à entraîner équivalent à celui du ResNet. En particulier, cette modification améliore les performances du réseau à différentes échelles spatiales.

La base de données contenant 22 500 images a été utilisée pour entraîner les deux réseaux pendant 250 itérations. Pour les deux architectures, la précision à l'entraînement atteint 100%. La différence réside dans la précision à la validation. En essayant de prédire la nature des grains qui n'ont pas été utilisés pour modifier ses paramètres (ensemble de validation), le ResNet de référence n'atteint une précision à la validation que de 92,0%. Tandis que M-ResNet atteint une précision à la validation de 97,1%. Ce dernier est donc notre RNC le plus performant. De ce fait, il sera utilisé pour le reste de l'étude.

B. Produits facteur de forme-masse volumique

Afin d'estimer la masse de chaque grain, les produits facteur de forme-masse volumique ont été déterminés pour les 9 sous-classes utilisées pour l'apprentissage des RNC grâce à l'équation (2). Les résultats sont présentés dans le [Tableau 2](#).

Tableau 2. Produits facteur de forme-masse volumique ($F.\rho$) des 9 sous-classes utilisées pour l'apprentissage des RNC

Sous-classe	Rc	Ru01	Ru02	Ru04	Ru05	Rb01	Rb02	Ra	X01
$F.\rho$ (g/cm ³)	0,746	0,658	0,782	0,624	0,873	0,517	0,555	0,853	0,141

La détermination de $F.\rho$ repose sur l'hypothèse forte que dans une sous-classe donnée tous les grains ont la même forme et la même masse volumique. En réalité, ce n'est pas toujours le cas. Effectivement, la forme des grains dépend fortement de la technique de concassage utilisée (Guimaraes et al., 2007). De plus, dans une sous-classe donnée, on pourrait avoir des variations de la masse volumique, en particulier dans le cas des grains de béton ayant différentes proportions de

mortier. Nous n'avons pas encore abordé les variations de masses volumiques des Rc. Néanmoins, nous avons utilisé nos 36 000 grains pour obtenir des $F. \rho$ les plus représentatifs possibles.

C. Comparaison entre le tri manuel et l'analyse d'images par deep learning

Afin d'évaluer la performance de l'analyse d'images par *deep learning*, la composition de 3 kg de granulats recyclés (GR) de coupure 4/31,5 a été évaluée. Certes, cette masse de GR est inférieure à celle recommandée par la norme (10 kg). Toutefois, pour évaluer toute la méthode *deep learning* (DL) nous avons voulu utiliser de GR différents de ceux présents dans la base de données et qui contiennent des grains de chacune des 9 sous-classes utilisées pour l'apprentissage des RNC.

À titre comparatif, la composition de cet échantillon a été déterminée par le tri manuel (TM) et la méthode DL. Pour DL, la sous-classe des GR a été déterminée en utilisant le M-ResNet et la masse des grains a été évaluée grâce aux produits facteur de forme-masse volumique correspondants comme indiqué dans l'équation (1). Les résultats sont illustrés sur la Figure 5. Globalement, on a de bons résultats : il y a moins de 1,5% de différence entre TM et DL pour les pourcentages massiques de Ru02, Ru04, Ru05, Rb01, Rb02, Ra et X01. En revanche, DL prédit 5,6% de Rc en moins et 4,2% de Ru01 en plus. Cela est dû au fait que certains grains de béton ressemblent à des grains de calcaire. En outre, ces derniers sont utilisés comme granulats de béton.

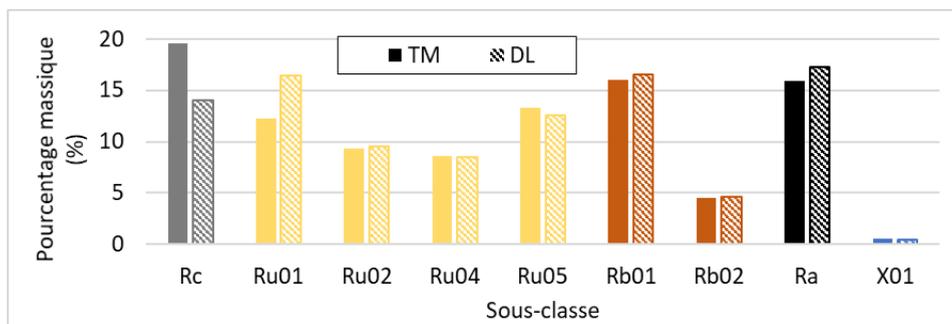


Figure 5. Comparaison entre tri manuel (TM) et *deep learning* (DL)

IV. CONCLUSION ET PERSPECTIVES

Le but de cette étude est d'améliorer la valorisation des granulats recyclés (GR) en proposant une méthode novatrice afin d'obtenir leur composition en quasi-temps réel par un processus automatisé. Notre méthode est basée sur le *deep learning* et notamment l'analyse d'images par des réseaux de neurones convolutifs (RNC). Une base de données comprenant 36 000 images de GR individuels a été créée pour l'apprentissage des RNC. Un réseau de la littérature (ResNet) a été testé, mais il n'a pas dépassé une précision à la validation de 92,0%. Nous l'avons modifié (M-ResNet) afin d'améliorer ses performances. La version modifiée a atteint une précision à la validation de 97,1%.

La composition de GR obtenue par le tri manuel normalisé (NF EN 933-11) étant une composition massique, nous avons proposé une méthode pour évaluer la masse des granulats. En supposant que tous les grains d'une même sous-classe ont les mêmes forme et masse volumique, nous avons évalué des produits facteur de forme-masse volumique pour chacune des 9 sous-classes utilisées pour l'apprentissage de RNC. Cependant, dans une sous-classe donnée, tous les grains

n'ont pas forcément les mêmes formes et masses volumiques. Nous envisageons d'utiliser un autre réseau de neurones afin de trouver une corrélation directe entre l'image des grains et leur masse.

La performance de notre méthode a été évaluée en la comparant au tri manuel. La composition d'un échantillon de GR a été déterminée par ces deux méthodes. Nous obtenons des différences de proportions massiques inférieures à 1,5%, sauf pour le béton et le calcaire où ces valeurs sont de 5,6% et 4,2% respectivement. Pour pallier ce problème, nous proposons d'augmenter le nombre d'images dans la base de données. En outre, d'autres méthodes sont à l'étude pour mieux faire la différence entre les sous-classes Rc et Ru.

Enfin, pour rendre cette méthode viable d'un point de vue industriel et ainsi remplacer le tri manuel, nous travaillons sur son automatisation complète afin de diminuer le temps requis pour l'acquisition et l'extraction des images des grains. Ainsi, notre outil pourrait être placé sur une plateforme de recyclage, en sortie du concasseur ou du cribleur pour suivre la composition des GR en continu. Il pourrait aussi être développé comme un banc de caractérisation utilisable par le personnel technique.

REFERENCES

- Akbarnezhad, A., Ong, K.C.G., Tam, C.T., Zhang, M.H., 2013. Effects of the Parent Concrete Properties and Crushing Procedure on the Properties of Coarse Recycled Concrete Aggregates. *Journal of Materials in Civil Engineering* 25, 1795–1802. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0000789](https://doi.org/10.1061/(ASCE)MT.1943-5533.0000789)
- Bravo, M., de Brito, J., Evangelista, L., Pacheco, J., 2018. Durability and shrinkage of concrete with CDW as recycled aggregates: Benefits from superplasticizer's incorporation and influence of CDW composition. *Construction and Building Materials* 168, 818–830. <https://doi.org/10.1016/j.conbuildmat.2018.02.176>
- Guimaraes, M.S., Valdes, J.R., Palomino, A.M., Santamarina, J.C., 2007. Aggregate production: Fines generation during rock crushing. *International Journal of Mineral Processing* 81, 237–247. <https://doi.org/10.1016/J.MINPRO.2006.08.004>
- He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep Residual Learning for Image Recognition, in: *Proceedings of the IEEE, Institute of Electrical and Electronics Engineers, Conference on Computer Vision and Pattern Recognition*. pp. 770–778.
- Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H., 2017. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.
- Hou, Y., Mahieux, P.-Y., Lux, J., Turcry, P., Aït-Mokhtar, A., 2019. Qualification of the residual reactivity of compacted recycled aggregates, in: *ICSBM 2019, 2nd International Conference of Sustainable Building Materials*. Eindhoven, Netherlands.
- Kou, S.-C., Poon, C.-S., Wan, H.-W., 2012. Properties of concrete prepared with low-grade recycled aggregates. *Construction and Building Materials* 36, 881–889. <https://doi.org/10.1016/J.CONBUILDMAT.2012.06.060>

Lancieri, F., Marradi, A., Mannucci, S., 2006. C&D waste for road construction: long time performance of roads constructed using recycled aggregate for unbound pavement layers, in: Waste Management and the Environment III, WIT Transactions on Ecology and the Environment, Vol 92. WIT Press, pp. 559–569. <https://doi.org/10.2495/WM060571>

LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. *Nature* 521, 436–444. <https://doi.org/10.1038/nature14539>

Mahieux, P.-Y., Turcry, P., Ferber, V., Chateau, L., 2017. Caractérisation de granulats recyclés à haute valeur ajoutée, in: 35ème Rencontres Universitaires de Génie Civil, Association Universitaire de Génie Civil (AUGC). Nantes, France.

Ministère de l'Environnement, de l'Énergie et de la Mer, 2017a. Bilan 2014 de la production de déchets en France.

Ministère de l'Environnement, de l'Énergie et de la Mer, 2017b. Entreprises du BTP : 227,5 millions de tonnes de déchets en 2014.

Mora, C.F., Kwan, A.K.H., Chan, H.C., 1998. Particle size distribution analysis of coarse aggregate using digital image processing. *Cement and Concrete Research* 28, 921–932. [https://doi.org/10.1016/S0008-8846\(98\)00043-X](https://doi.org/10.1016/S0008-8846(98)00043-X)

Omary, S., Ghorbel, E., Wardeh, G., Nguyen, M.D., 2018. Mix Design and Recycled Aggregates Effects on the Concrete's Properties. *Int J Civ Eng* 16, 973–992. <https://doi.org/10.1007/s40999-017-0247-y>

Turcry, P., Mahieux, P.-Y., Hamdoun, H., Chateau, L., Ferber, V., 2016. Projet Recyment: Etude de la réactivité des bétons concassés : application aux graves non traitées et au traitement des sols – Rapport final. ADEME. 100.