

# Des réseaux de neurones pour la caractérisation automatique des granulats recyclés

Jérôme Lux<sup>1</sup>, Jean David Lau Hiu Hoong<sup>2</sup>, Pierre-Yves Mahieux<sup>1</sup>, Philippe Turcry<sup>1</sup>

<sup>1</sup> LaSIE Laboratoire des Sciences de l'Ingénieur pour l'Environnement, UMR CNRS 7356. Université de La Rochelle.

<sup>2</sup> AQC Agence Qualité Construction, 11bis Avenue Victor Hugo 75116 Paris

## RESUME

Les granulats recyclés proviennent du concassage de déchets inertes du BTP. Ce sont des matériaux complexes constitués de granulats de différentes natures (béton, pierres naturelles, bitume, briques, etc.). Afin d'accroître l'utilisation de ces matériaux aussi bien dans le secteur des TP que dans la fabrication de béton, il est nécessaire d'être en mesure de garantir la qualité des granulats. Nous proposons ici une nouvelle architecture de réseau de neurones permettant l'automatisation du processus de caractérisation des granulats recyclés. Le prototype développé permet de déterminer la composition massique ainsi que la granulométrie et éventuellement d'autres paramètres morphologiques à partir d'images 2D d'un flux de granulats. Les résultats obtenus montrent que cette approche peut remplacer avantageusement les essais de granulométrie et de tri manuel préconisés par les normes actuelles. Le réseau de neurones permet en effet d'estimer la masse de chaque type de granulats avec une erreur de l'ordre de 2%.

## Mots-clefs

Granulats recyclés, réseaux de neurones, analyse d'image, économie circulaire.

## I. INTRODUCTION

Les granulats recyclés (GR) sont des matériaux produits sur plateformes de recyclage à partir de déchets inertes issus des chantiers de construction et de démolition du BTP. Ces matériaux sont constitués de granulats de différentes natures (béton de démolition, granulats naturels, terre cuite, briques etc.), présents en proportions variables d'une campagne de concassage à l'autre, ce qui induit une certaine variabilité de leurs propriétés physiques, chimiques et mécaniques.

Le recyclage des déchets inertes du BTP est un moyen de diminuer l'extraction de granulats naturels. De plus, les granulats de béton recyclés, qui constituent généralement une phase majoritaire dans les GR, sont également susceptibles de minéraliser du CO<sub>2</sub>. Cette carbonatation a un double avantage ; elle améliore les caractéristiques du béton de GR (Hou, 2021; Zhan et al., 2014; N. Zhang et al., 2020) et permet de réduire le bilan carbone de la production des GR (Hou et al., 2022). La mise en œuvre de prototypes industriels pour accélérer la carbonatation a par ailleurs fait l'objet de travaux dans le cadre du projet national FASTCARB (Torrenti et al., 2022).

Actuellement, les GR sont surtout utilisés par le secteur des travaux routiers comme un matériau alternatif aux graves naturelles (couche de forme, assises de chaussée, remblais). Des résultats obtenus dans le cadre du projet ADEME RECYMENT (Mahieux et al., 2017) ont d'ailleurs montré que les performances mécaniques de graves constituées de GR issus d'une filière classique de recyclage sont au moins équivalentes voire même supérieures à celles de granulats naturels.

Il est également possible d'incorporer des GR dans le béton selon les préconisations de la norme NF EN 206+A2/CN. Les GR doivent dans ce cas répondre à certaines contraintes, notamment en termes de compositions, ce qui peut largement limiter leur taux de substitution. Le remplacement de tout ou partie des granulats naturels par des GR dans le béton s'accompagne généralement d'une diminution des performances mécaniques et des indicateurs de durabilité (Bravo et al., 2018, 2015; Medina et al., 2015; Omary et al., 2018, 2016; Salgues et al., 2016; Schmitt et al., 2016).

Ces études montrent le lien entre la composition des GR et leurs propriétés physico-chimiques. Il est donc important d'être en mesure de caractériser de manière précise et rapide la composition des GR afin de garantir leur qualité. Actuellement, la composition des GR est réalisée par un tri manuel sur un échantillon représentatif selon la norme NF EN-933-11. Cette opération fastidieuse n'est en pratique réalisée que ponctuellement, par exemple après chaque campagne de concassage, et ne permet pas un monitoring continu de la qualité des GR produits, ce qui peut être un frein à leur valorisation dans des produits nécessitant un contrôle rigoureux de leur composition, comme le béton.

Dans des travaux antérieurs (Lau Hiu Hoong et al., 2020), nous avons montré qu'il était possible de déterminer la nature des granulats recyclés à partir de photos en utilisant des réseaux de neurones convolutifs profonds. La méthode proposée permettait d'obtenir un taux moyen de bonnes classifications (justesse) supérieur à 97%, tout en proposant une classification beaucoup plus fine que celle proposée par la norme (16 classes contre 6 dans la NF EN 933-11). La composition massique était déterminée grâce à une approche géométrique basée sur des facteurs de forme supposés constant pour chaque classe.

Nous proposons dans cet article une nouvelle architecture de réseau de neurones permettant de déterminer, outre la classe, la masse et le masque binaire de chaque granulat à partir d'une simple photo 2D. Nous détaillons également les bases de données utilisées qui contiennent plus de 60000 photos de granulats labélisés avec les masses associées. Nous développons enfin un prototype qui démontre que le processus de caractérisation peut être entièrement automatisé dans des conditions industrielles réalistes, à partir d'un flux vidéo de granulats défilant sur un tapis convoyeur.

## II. Matériels et méthodes

### A. Architecture du réseau de neurones

Des travaux récents montrent que les réseaux de neurones peuvent prédire la masse d'objets individuels ou en amas à partir d'images 2D. Une première approche consiste à déterminer un certain nombre de caractéristiques géométriques par analyse d'image et de les utiliser comme données d'entrées de perceptron multi-couches (Abdel-Sattar et al., 2021; L. Zhang et al., 2020). Cette approche est cependant limitée puisqu'elle dépend d'un nombre restreint de caractéristiques

choisies arbitrairement. L'utilisation de réseau de neurones convolutif est une alternative beaucoup plus générale lorsque l'on dispose d'images du matériau à caractériser. Dans (M. Hamdan et al., 2019; Miura et al., 2020), un module de régression est ajouté à la sortie d'un réseau de classification afin de prédire la masse de matières végétales. Dans ces travaux, il n'y a cependant qu'un seul type de matériau et une masse globale par image peut donc être calculée sans segmentation préalable. Une approche plus sophistiquée est mise en œuvre dans (Standley et al., 2017), afin de déterminer la masse d'objets courants provenant de l'API Marketplace Web Service d'Amazon. L'architecture proposée est constituée de deux modules connectés qui prédisent la masse volumique et le volume d'un objet respectivement.

La masse volumique apparente d'un objet est fortement corrélée à la nature de l'objet, qui peut être déterminée à partir d'une image par un réseau de neurone convolutif (Lau Hiu Hoong et al., 2020). Cependant, la masse volumique peut malgré tout varier dans une large mesure. On trouve par exemple différents types de granulats naturels dans les granulats de béton recyclés. La porosité de certaines pierres naturelles peut également être très variable (par exemple dans le cas des granulats calcaires). Nous faisons ici l'hypothèse que certaines caractéristiques texturales visibles sur une photo reflètent cette variabilité et qu'un réseau de neurones est donc capable de les apprendre.

Le volume d'un granulat dépend quant à lui de la forme du granulat, qui est fonction de sa nature et du concassage réalisé. Dans ce travail, nous ne disposons que d'une seule caméra et il est donc impossible d'accéder à des paramètres volumétriques. L'objectif est donc d'entraîner un réseau de neurones à estimer des caractéristiques volumétriques à partir d'informations 2D.

Pour développer une architecture adaptée, nous exprimons le volume comme le produit entre l'aire projetée du granulat  $A$  par une épaisseur équivalente  $T$ . La masse s'écrit alors comme suit :

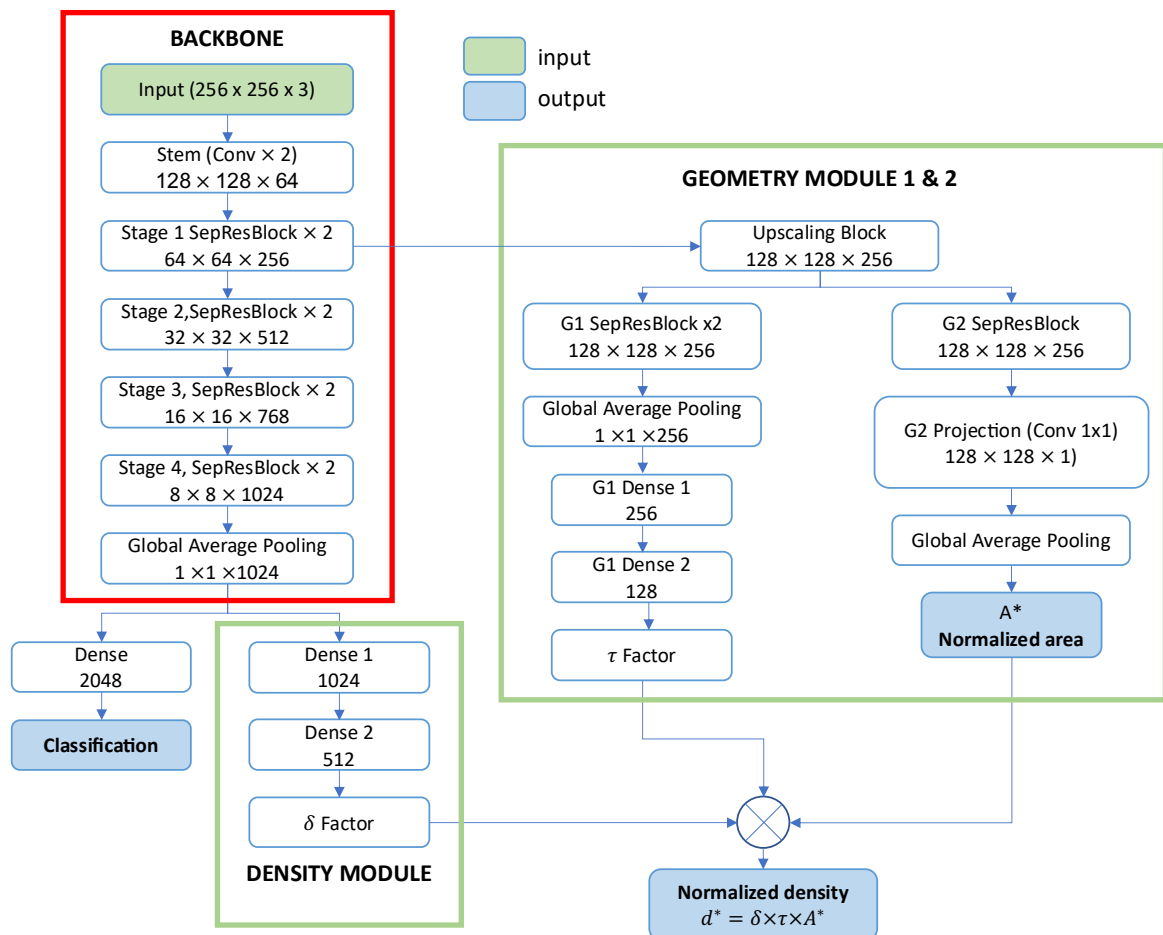
$$m = \rho \times T \times A \quad \text{Eq. 1}$$

L'aire projetée est facilement mesurable puisqu'elle correspond aux pixels d'un granulat (appelé masque binaire). L'épaisseur équivalente ainsi que la masse volumique ne sont par contre pas directement accessibles indépendamment. Connaissant la masse réelle d'un grain et son aire, on ne connaît en effet que le produit  $\rho \times T$ . Cette formulation est cependant intéressante pour définir l'architecture du réseau.

Le réseau proposé appelé RACNET (*Recycled Aggregate Characterization NETWORK*) est construit autour de deux modules attachés à différents niveaux d'un réseau convolutif existant (FIGURE 1) et permet de déterminer la classe d'un granulat ainsi que sa masse. L'architecture est construite de telle manière à ce que la masse soit le produit de trois facteurs : un facteur noté  $\delta$  fortement corrélé à la classe, un facteur  $\tau$  qui est peu corrélé au réseau de classification et  $A^*$  qui est l'aire normalisée du granulat. Le facteur  $\delta$  est prédit par un module attaché directement à la sortie d'un réseau de classification existant. Le module combine les caractéristiques du réseau de classification pré-entraîné au moyen de couches denses afin de déterminer un facteur qui sera donc fortement corrélé à la classe. Un deuxième module (GEOMETRY) est attaché à la sortie du premier bloc du réseau de base. Le module GEOMETRY n'utilise donc que les caractéristiques de bas niveau du réseau de base. Ce module est constitué d'un premier bloc de *d'upsampling* permettant d'avoir une résolution spatiale importante. Un premier sous-module constitué d'une suite de blocs convolutifs connectés à des couches denses permet de prédire le facteur  $\tau$ . Ce facteur sera donc très peu lié au

réseau de classification (et donc à la nature du granulat), mais dépendra d'autres caractéristiques pertinentes calculées sur des images à forte résolution. Le deuxième sous-module permet de segmenter le granulat à l'aide d'un bloc convolutif suivi d'une projection vers une image de profondeur unitaire et une activation de type sigmoïde (les pixels du granulat seront représentés par des valeurs proches de 1 et ceux du fond par des valeurs proches de 0). L'aire normalisée est alors obtenue par moyenne cette image.

Le réseau de base peut être n'importe quel type de réseau de classification, comme par exemple ResNet, ResNeXt, RegNet ou EfficientNet (He et al., 2016; Radosavovic et al., 2020; Tan and Le, 2019; Xie et al., 2017). Dans ce travail, nous avons utilisé un réseau que nous avons développé, basé sur des blocs résiduels (SepResBlock) constitués de couches de convolutions séparables (Lau Hiu Hoong et al., 2020). Ce réseau montre en effet de meilleures performances que des réseaux de tailles similaires comme EfficientNetB3 or RegNetY1.6GF pour la tâche étudiée. L'implémentation proposée possède environ 13,7M de paramètres, ce qui en fait un réseau assez léger.



**FIGURE 1 :** Architecture du RACNET. Les boîtes bleues indiquent les sorties pour lesquelles les fonctions pertes sont calculées.

### B. Normalisation des valeurs cibles

Le réseau de neurones prend en entrée des images de dimension  $L_d \times L_d$  (en pixels). Dans ce travail  $L_d = 256$  pixels, des travaux antérieurs ayant en effet montré qu'une augmentation de la résolution au-delà de cette valeur n'entraînait pas d'amélioration sensible de la performance du réseau de classification (Hoong, 2021). Les prédictions du réseau sont indépendantes de la dimension réelle des images, puisque la résolution n'est pas un paramètre d'entrée. Les valeurs cibles pour l'apprentissage doivent donc ramené en pixels et être normalisée.

La valeur cible du sous-module GEOMETRY 2 sera l'aire en pixels  $A_d = A \times R^3$ , normalisée par la surface de l'image :

$$A^* = \frac{A_d}{L_d^2} \quad \text{Eq. 2}$$

Si on note  $V_d$  le volume discrétisé du granulat en voxels,  $R$  la résolution (pixels/cm) et  $\rho$  la masse volumique ( $\text{g/cm}^3$ ), alors la masse peut s'écrire :

$$m = \rho \times \frac{V_d}{R^3} \quad \text{Eq. 3}$$


En multipliant la masse par la résolution, on obtient une valeur qui dépend de la taille en pixel et non de la taille réelle du grain. On normalise ensuite par le volume de l'image en voxel et on définit ainsi la valeur cible  $d^*$  :

$$d^* = \frac{m \times R^3}{L_d^3} = \delta \times \tau \times A^* \quad \text{Eq. 4}$$

$d^*$  a la dimension d'une masse volumique et sera donc appelée masse volumique normalisée.

### C. Base de données

Dans ce travail, deux bases de données ont été utilisées. La première base D1 contient environ 38000 images de granulats individuels de fraction 4/31,5, avec des résolutions de 10 ou 23 pixels/mm selon la taille des grains. Les images ont été acquises avec un appareil photo Fuji XT-20 sur un statif avec fond bleu (Lau Hiu Hoong et al., 2020). La seconde base de données D2 est constituée de granulats 4/40 photographiés sur un tapis convoyeur par une caméra linéaire de 8192 pixels (Figure 2). La résolution des images est de 28,7 pixels/mm. La base contient pour l'instant 540 images de dimension 8192×4096 pixels pour un total d'environ 20000 granulats labélisés.



*FIGURE 2 : dispositif d'acquisition des images de granulats recyclés. Un convoyeur vibrant (à droite) fait tomber les granulats sur un tapis convoyeur et les fait passer sous une caméra linéaire.*

La norme NF EN 933-11 définit 6 classes de granulats : Ra (granulats bitumineux), Rc (béton), Rb (briques, céramique, carrelage, etc.), Ru (pierres naturelles), Rg (verre) et X (autres). La classification que nous proposons contient quant à elle 15 classes, ce qui permet de distinguer par exemple les différents types de pierres naturelles. Le TABLEAU 1 présente les correspondances entre les deux classifications, ainsi que le nombre de granulats dans chaque classe. Les classes contenant peu d'éléments (lignes grisées) ne seront pas utilisées pour l'apprentissage des réseaux.

**TABLEAU 1.** Nombre d'éléments dans chaque classe et correspondance entre classification de la norme et classification utilisée pour l'apprentissage des réseaux de neurones.

NF EN 933-11	Sous-classes	Description	Nombre d'éléments
Ra	Ra	Granulats bitumineux	5988
Rb	Rb01	Terre cuite	4546
	Rb02	Carreaux de céramique	2550
Rc	Rc	Granulats de béton	16909
Rg	Rg	Verre	53
Ru	Ru01	Pierres claires (e.g. calcaire)	9766
	Ru02	Pierres grises (e.g. basalte et d'autres de couleurs similaires)	6212
	Ru03	Pierres grenues claires (majorité de quartz et de feldspath)	1238
	Ru04	Pierres siliceuses colorées ou sombres et angulaires	3868
	Ru05	Pierres alluvionnaires claires	4422
	Ru06	Ardoise	1104
X	X01	Bois	1019
	X02	Plastique	487
	X03	Acier	306
	X04	Papier et carton	96

<b>TOTAL</b>	<b>58564</b>
--------------	--------------

Outre la classe et le masque de chaque granulat, la base de données contient également des informations sur la masse des granulats. Comme il est impossible de peser chaque granulat indépendamment, nous pesons la masse totale de petits lots de granulats (présents une image ou une série d'images). Ces granulats sont de même classe et proviennent d'un même lot. Il est donc possible de calculer un facteur de forme pour calculer la masse des granulats individuels en connaissant la masse totale de chaque lot (Lau Hiu Hoong et al., 2020). Cette méthode conserve la masse mesurée, en la distribuant à chaque grain selon sa géométrie. Environ 1800 granulats ont toutefois été pesés individuellement afin de valider cette approche. On montre que l'erreur moyenne absolue en pourcentage (ou MAPE, *mean average absolute error*) est inférieure à 25% pour environ 60% des granulats. De manière générale, les erreurs plus élevées ne concernent que les granulats les plus légers. Les masses ainsi estimées permettent de calculer les valeurs cibles  $d^*$  pour l'apprentissage du réseau.


#### D. Apprentissage

Même avec des techniques d'augmentation d'images (Lau Hiu Hoong et al., 2020), les classes grisées dans le TABLEAU 1 n'ont pas assez d'éléments pour être utilisées pour l'apprentissage. Nous utilisons donc un ensemble d'entraînement constitué de 55926 granulats répartis de manière la plus homogène possible sur 11 classes. Un ensemble de validation contenant 5592 éléments est également utilisé pour suivre les performances du réseau sur des éléments qui ne sont utilisés pour l'apprentissage, ce qui permet de vérifier un éventuel sur-apprentissage.

Le réseau de classification est pré-entraîné et reste ensuite gelé durant l'entraînement des modules du RACNET. Ce réseau obtient un taux de bonne classification de plus de 95% pour l'ensemble des classes. Nous utilisons un optimiseur Adam avec un taux d'apprentissage initial de  $1.10^{-3}$  et une taille de lot de 32 images. Le taux d'apprentissage est divisé par deux lorsque la fonction perte ne diminue pas pendant 5 époques consécutives. L'apprentissage s'arrête lorsque la fonction perte ne diminue plus pendant 20 époques consécutives.

La fonction perte optimisée lors de l'apprentissage est la somme des erreurs moyenne absolues en pourcentage sur l'aire normalisée  $A^*$  et la masse volumique normalisée  $d^*$ .

Les courbes d'entraînement et de validation sont présentées sur la FIGURE 3. Les MAPE minimales sur l'ensemble de validation sont de l'ordre de 8% pour  $d^*$  et 1% pour  $A^*$ . On ne note pas de sur-apprentissage notable.



**FIGURE 3 :** Courbes présentant l'évolution de la fonction perte pour la cible  $d^*$  (a) et  $A^*$  (b). Les courbes bleues correspondent à l'ensemble d'entraînement, tandis que les résultats sur l'ensemble de validation apparaissent en orange.

## II. Résultats et discussion

### A. Performances sur l'ensemble test

L'ensemble test est constitué de 4970 granulats provenant des bases D1 et D2, mais qui n'ont pas été utilisés pour l'apprentissage du réseau. Ils représentent une masse d'environ 6,14kg. Le réseau de classification présente une justesse de plus de 95% sur l'ensemble des classes testées. Afin d'évaluer les performances de l'estimation de masse du RACNET, nous utilisons la MAPE calculée sur chaque classe, mais également l'erreur absolue en pourcentage calculée sur la masse totale de chaque classe (notée  $TM\_APE$ ). L'estimation de la masse totale par classe est en effet la mesure prise en compte dans la norme EN 933-11. Le tableau synthétise ces résultats et présente également la masse réelle (GT) et prédite (PRED) de chaque classe.

Classe	$M_{GT}$ (g)	$M_{PRED}$ (g)	MAPE (%)	$TM\_APE$ (%)
Ra	383,1	393	5,68	2,56
Rb01	514,1	509	6,93	1,00
Rb02	891	885,7	8,64	0,60
Rc	933,4	901,4	7,87	3,43
Ru01	946,2	939,6	7,24	0,70
Ru02	417,4	412,5	6,30	1,17
Ru03	159,8	155,3	5,93	2,80
Ru04	527,1	533,1	8,50	1,13
Ru05	886	883,5	6,84	0,29
Ru06	56,7	57,5	6,05	1,36
X01	425,7	457,1	23,23	7,37
<b>Moyenne</b>			<b>8,47</b>	<b>2,04</b>



<b>Total</b>	<b>6141</b>	<b>6127</b>	<b>0,21</b>
--------------	-------------	-------------	-------------

Les résultats sont très encourageants et permettent d'envisager une application industrielle. Il est remarquable que l'erreur commise sur la masse totale ne soit que de 0,21%, soit 14g sur plus de 6kg de granulats. L'erreur sur la masse totale de chaque classe est inférieure à la MAPE car il y a un effet de compensation entre les masses sur- et sous- évaluées. Il n'en reste pas moins que l'ensemble des estimations montre une erreur inférieure à 5% sauf pour la classe X01 (bois). Cela est lié au plus faible nombre de granulats dans cette classe, mais aussi à leur plus grande diversité en termes de formes et de tailles.

### *B. Application industrielle*

Le modèle RACNET à l'inconvénient de traiter des images de granulats individuels. Le prototype que nous avons mise en œuvre fait l'acquisition continue d'images de granulats passant sur un tapis convoyeur à l'aide d'une caméra linéaire. Afin de traiter ce flux de données, nous utilisons un réseau léger de segmentation d'objets qui prédit le masque de chaque granulat sur une image de faible résolution. Les granulats sont ensuite extraits sur l'image haute résolution afin d'être finalement fournis au RACNET. Le réseau de segmentation utilisé est basé sur un resunet-a (Diakogiannis et al., 2020). La Figure 4 montre un exemple de granulats identifiés en sortie de réseau. Il est intéressant de souligner que l'image segmentée peut être utilisée afin de réaliser une caractérisation géométrique des granulats, puisque l'on dispose pour chacun de son masque binaire. Une analyse granulométrique peut ainsi être réalisée conjointement à la caractérisation de la nature des granulats. La technologie développée pourrait donc remplacer deux essais réalisés manuellement.



**FIGURE 4 :** segmentation d'une image contenant de nombreux granulats. Chaque granulat est coloré pour mieux l'identifier. Les contours sont en noir.

Afin de valider l'approche complète, depuis la détection des granulats jusqu'à la prédiction de masse et de classe, nous utilisons un échantillon de 3kg de GR 0/20 provenant de la plateforme de

recyclage Valosphère à La Rochelle, appartenant à notre partenaire industriel Spie batignolles malet. Les granulats sont photographiés sans tri préalable sur le dispositif d'acquisition, puis ils sont triés manuellement selon la norme NF EN 93-11 et la masse de chaque classe est pesée.

2596 granulats ont été détectés par le réseau de segmentation sur les 77 photos obtenues. Les résultats du tri manuel (notés GT) ainsi que les prédictions du RACNET (notées PRED) sont présentés dans le Tableau 2 en termes de masse et de fraction massique. Les lignes en gras correspondent au classement de la norme.

Si on ne considère que le classement EN 933-11, l'écart entre notre méthode et le tri manuel est au maximum 1,5 point en termes de composition massique et l'erreur sur la masse totale n'est que de 2%. Ces résultats remarquables sont une indication que notre méthode pourrait avantageusement remplacer le tri manuel pour caractériser les GR. Si on analyse le détail des sous-classes, on note des erreurs plus élevées sur certaines classes contenant peu de granulats mal détectés (Ru03 par exemple), mais également des confusions entre le béton (Rc) certaines pierres naturelles comme le calcaire (Ru01). Ces confusions s'expliquent par le fait que les granulats de béton recyclés contiennent eux-mêmes des pierres naturelles avec une proportion parfois faible de mortier. L'augmentation du nombre d'images prises sur tapis pour les classes faiblement représentées pourraient permettre d'améliorer encore les prédictions.

**TABLEAU 2 : résultats d'un tri manuel et de la prédiction du RACNET pour les classes de la norme et les sous-classes définies dans ce travail.**

Classe	Sous-classe	$M_{GT}$ (g)	$M_{PRED}$ (g)	%GT	%PRED
Ra		9,7	6,3	0,3%	0,2%
Rb		357,4	317,5	12,0%	10,4%
	Rb01	299,9	230,5	10,1%	7,6%
	Rb02	57,5	87	1,9%	2,9%
Rc		1880,1	1913,1	63,0%	62,8%
Ru		730,0	792,8	24,5%	26%
	Ru01	601,0	694,2	20,1%	22,8%
	Ru02	60,3	82	2,0%	2,7%
	Ru03	13,8	2,6	0,5%	0,1%
	Ru04	10,2	1	0,3%	0,03%
	Ru05	44,8	13	1,5%	0,4%
X + Rg		6,6	16,6	0,2%	0,5%
TOTAL		2984	3046	100%	100%

## II. Conclusion

Dans cet article, nous avons présenté une nouvelle architecture de réseau de neurones appelée RACNET permettant la détermination de la masse et de la nature des granulats recyclés à partir d'images 2D. Nous avons construit une base de données contenant environ 60000 images de granulats labélisés ainsi que leurs masses. Nous avons montré que le réseau permettait de

déterminer la masse totale de chaque classe de granulats avec une erreur moyenne de 2% sur un ensemble test contenant environ 6kg de granulats.

Une comparaison avec un tri manuel réalisée dans des conditions d'utilisations réalistes a montré un très bon accord entre les deux approches, puisque l'écart maximum entre les fractions massiques des différentes classes de la norme EN 933-11 était de 1,5 point.

Le passage du prototype à un dispositif de laboratoire ou de terrain pourrait permettre un gain de temps substantiel, mais surtout un monitoring continu de la composition, de la granulométrie ainsi que de la qualité des granulats recyclés.

Il serait selon nous intéressant que cette avancée technologique s'accompagne d'une évolution de la norme, qui pourrait s'ouvrir à de nouvelles méthodes de classification voir à une prise en compte plus fine de la nature des granulats. Cela permettrait d'augmenter la part de déchets inertes valorisés sous formes de granulats recyclés tout en favorisant leur utilisation dans des produits à plus haute valeur ajoutée.

## REFERENCES

- Abdel-Sattar, M., Aboukarima, A.M., Alnahdi, B.M., 2021. Application of artificial neural network and support vector regression in predicting mass of ber fruits (*Ziziphus mauritiana* Lamk.) based on fruit axial dimensions. *PLOS ONE* 16, e0245228. <https://doi.org/10.1371/journal.pone.0245228>
- 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>
- Bravo, M., de Brito, J., Pontes, J., Evangelista, L., 2015. Mechanical performance of concrete made with aggregates from construction and demolition waste recycling plants. *Journal of Cleaner Production* 99, 59–74. <https://doi.org/10.1016/J.JCLEPRO.2015.03.012>
- Diakogiannis, F.I., Waldner, F., Caccetta, P., Wu, C., 2020. ResUNet-a: a deep learning framework for semantic segmentation of remotely sensed data. *ISPRS Journal of Photogrammetry and Remote Sensing* 162, 94–114. <https://doi.org/10.1016/j.isprsjprs.2020.01.013>
- He, K., Zhang, X., Ren, S., Sun, J., 2016. Identity Mappings in Deep Residual Networks, in: Leibe, B., Matas, J., Sebe, N., Welling, M. (Eds.), *Computer Vision – ECCV 2016*. Springer International Publishing, pp. 630–645.
- Hoong, J.D.L.H., 2021. Contribution à la valorisation de granulats recyclés : développement d'une méthode d'identification et de quantification automatisée basée sur le deep learning et évaluation de leur capacité de stockage de CO<sub>2</sub> (phdthesis). Université de La Rochelle.
- Hou, Y., 2021. Contribution au développement de la valorisation des déchets inertes du BTP : Étude de la carbonatation des granulats recyclés compactés (Thèse de doctorat).
- Hou, Y., Mahieux, P.-Y., Turcry, P., Lux, J., Aït-Mokhtar, A., Nicolai, A., 2022. Plateforme de recyclage de déchets inertes du BTP : un puits de carbone « gris » ? *Academic Journal of Civil Engineering* 40, 96–99. <https://doi.org/10.26168/ajce.40.1.24>
- Lau Hiu Hoong, J.D., Lux, J., Mahieux, P.-Y., Turcry, P., Aït-Mokhtar, A., 2020. Determination of the composition of recycled aggregates using a deep learning-based image analysis. *Automation in Construction* 116, 103204. <https://doi.org/10.1016/j.autcon.2020.103204>

- M. Hamdan, D. Rover, M. Darr, J. Just, 2019. Mass Estimation from Images using Deep Neural Network and Sparse Ground Truth, in: 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA). Presented at the 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA), pp. 1987–1992. <https://doi.org/10.1109/ICMLA.2019.00318>
- Mahieux, P.-Y., Turcry, P., Hamdoun, H., Amiri, O., Ferber, V., Chateau, L., 2017. Projet RECYMENT : Réactivité physico-chimique de graves recyclées utilisées en technique routière. *Academic Journal of Civil Engineering* 35, 256–259. <https://doi.org/10.26168/ajce.35.1.62>
- Medina, C., Zhu, W., Howind, T., Frías, M., Sánchez de Rojas, M.I., 2015. Effect of the constituents (asphalt, clay materials, floating particles and fines) of construction and demolition waste on the properties of recycled concretes. *Construction and Building Materials* 79, 22–33. <https://doi.org/10.1016/J.CONBUILDMAT.2014.12.070>
- Miura, Y., Sawamura, Y., Shinomiya, Y., Yoshida, S., 2020. Vegetable Mass Estimation based on Monocular Camera using Convolutional Neural Network, in: 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Presented at the 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC), IEEE, Toronto, ON, Canada, pp. 2106–2112. <https://doi.org/10.1109/SMC42975.2020.9282930>
- Omary, S., Ghorbel, E., Wardeh, G., 2016. Relationships between recycled concrete aggregates characteristics and recycled aggregates concretes properties. *Construction and Building Materials* 108, 163–174. <https://doi.org/10.1016/j.conbuildmat.2016.01.042>
- 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>
- Radosavovic, I., Kosaraju, R.P., Girshick, R., He, K., Dollár, P., 2020. Designing Network Design Spaces. arXiv:2003.13678 [cs].
- Salgues, M., Souche, J.-C., Devillers, P., Garcia-Diaz, E., 2016. Influence of initial saturation degree of recycled aggregates on fresh cement paste characteristics: consequences on recycled concrete properties. *European Journal of Environmental and Civil Engineering* 22, 1146–1160. <https://doi.org/10.1080/19648189.2016.1245630>
- Schmitt, L., Mai-Nhu, J., Djerbi Tegguer, A., Rougeau, P., Saillio, M., 2016. Durability of concrete structures incorporating recycled aggregates, in: *Fib Symposium, Fédération Internationale Du Béton (International Federation for Structural Concrete) 2016, Performance-Based Approaches for Concrete Structures*. Cape Town, South Africa.
- Standley, T., Sener, O., Chen, D., Savarese, S., 2017. image2mass: Estimating the Mass of an Object from Its Image, in: Levine, S., Vanhoucke, V., Goldberg, K. (Eds.), *Proceedings of the 1st Annual Conference on Robot Learning, Proceedings of Machine Learning Research*. PMLR, pp. 324–333.
- Tan, M., Le, Q., 2019. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, in: *Proceedings of the 36th International Conference on Machine Learning*. Presented at the International Conference on Machine Learning, PMLR, pp. 6105–6114.
- Torrenti, J.M., Amiri, O., Barnes-Davin, L., Bougrain, F., Braymand, S., Cazacliu, B., Colin, J., Cudeville, A., Dangla, P., Djerbi, A., Doutreleau, M., Feraille, A., Gueguen, M., Guillot, X., Hou, Y., Izoret, L., Jacob, Y.-P., Jeong, J., Hiu Hoong, J.D.L., Mahieux, P.-Y., Mai-Nhu, J., Martinez, H., Meyer, V., Morin, V., Pernin, T., Potier, J.-M., Poulizac, L., Rougeau, P., Saadé, M., Schmitt, L., Sedran, T., Sereng, M., Soive, A., Dos Reys, G.S., Turcry, P., 2022. The FastCarb project: Taking advantage of the accelerated carbonation of recycled

- concrete aggregates. *Case Studies in Construction Materials* 17, e01349.  
<https://doi.org/10.1016/j.cscm.2022.e01349>
- Xie, S., Girshick, R., Dollár, P., Tu, Z., He, K., 2017. Aggregated Residual Transformations for Deep Neural Networks, in: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. pp. 5987–5995. <https://doi.org/10.1109/cvpr.2017.634>
- Zhan, B., Poon, C.S., Liu, Q., Kou, S., Shi, C., 2014. Experimental study on CO<sub>2</sub> curing for enhancement of recycled aggregate properties. *Construction and Building Materials, International Conference on Sustainable Construction Materials & Technologies* 67, 3–7.  
<https://doi.org/10.1016/j.conbuildmat.2013.09.008>
- Zhang, L., Wang, J., Duan, Q., 2020. Estimation for fish mass using image analysis and neural network. *Computers and Electronics in Agriculture* 173, 105439.  
<https://doi.org/10.1016/j.compag.2020.105439>
- Zhang, N., Duan, H., Miller, T.R., Tam, V.W.Y., Liu, G., Zuo, J., 2020. Mitigation of carbon dioxide by accelerated sequestration in concrete debris. *Renewable and Sustainable Energy Reviews* 117, 109495. <https://doi.org/10.1016/j.rser.2019.109495>