



HAL
open science

Pizzaïolo Dataset : Des Images Synthétiques Ontologiquement Explicables

Grégory Bourguin, Arnaud Lewandowski

► **To cite this version:**

Grégory Bourguin, Arnaud Lewandowski. Pizzaïolo Dataset : Des Images Synthétiques Ontologiquement Explicables. 24ème conférence francophone sur l'Extraction et la Gestion des Connaissances, EGC 2024, Explain'AI., Jan 2024, Dijon, France. hal-04401953

HAL Id: hal-04401953

<https://hal.science/hal-04401953>

Submitted on 18 Jan 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution - NonCommercial 4.0 International License

Pizzaïolo Dataset : Des Images Synthétiques Ontologiquement Explicables

Grégory Bourguin*, Arnaud Lewandowski**

LISIC, Laboratoire Informatique Signal et Image de la Côte d’Opale
50 rue Ferdinand Buisson - 62228 - Calais CEDEX
<https://lisic-prod.univ-littoral.fr/>

* gregory.bourguin@univ-littoral.fr

** arnaud.lewandowski@univ-littoral.fr

Résumé. Les travaux issus du mouvement XAI ont souligné la nécessité d’inventer des modèles d’IA explicables du point de vue de leurs utilisateurs. Une approche prégnante vise à concevoir des modèles qui réifient les concepts et raisonnements du domaine d’application. En Vision par Ordinateur, les travaux qui expérimentent la création de ces nouvelles IA ont souligné l’intérêt de datasets synthétiques dédiés à des domaines spécifiques, proposant des représentations visuelles simples, et mettant en oeuvre des concepts et raisonnements non ambigus, explicites, et plus ou moins complexes. Nos travaux en XAI s’inscrivent dans cette mouvance et nous avons créé le *Pizzaïolo Dataset* : un ensemble d’exemples générés à partir d’une ontologie sous forme d’images synthétiques de pizzas annotées pour expérimenter la conception d’IA explicables. L’objectif de ce papier est de présenter le *Pizzaïolo Dataset*, et de le mettre librement à disposition de la communauté des chercheurs.

1 Introduction

Les travaux issus du mouvement XAI (eXplainable AI) ont permis de mettre en exergue la nécessité d’inventer des modèles d’IA qui soient non seulement interprétables, mais aussi explicables du point de vue de leurs utilisateurs. Les utilisateurs ne sont généralement pas des spécialistes en IA, mais des spécialistes de leur domaine d’application. Pour qu’un utilisateur puisse comprendre une explication, il faut qu’elle concorde avec sa connaissance, c’est à dire qu’elle manipule des concepts qui lui sont accessibles, voire qu’elle utilise un raisonnement en adéquation avec sa propre façon de penser.

Nous nous intéressons au domaine de la Vision par Ordinateur. Pour répondre à ce besoin, de nombreux travaux de recherche visent à expliquer les modèles d’IA existants en faisant ressortir les concepts du domaine auxquels ils sont dédiés (Fel et al., 2023). D’autres approches ont pour but de créer des modèles d’IA directement conçus pour manipuler les concepts du domaine visé. On peut en particulier citer les approches CBM (Concept Based/Bottleneck Models) (Losch et al., 2019; Koh et al., 2020), ainsi que les approches Neuro-Symboliques dont l’objectif est de mettre en oeuvre un raisonnement plus explicable du point de vue des utilisateurs (Barbiero et al., 2023; Han et al., 2023).

Les expérimentations autour de ces nouvelles IA explicables nécessitent des jeux de données (datasets) particuliers : ils doivent contenir des exemples qui reflètent exclusivement et explicitement des raisonnements qui manipulent des concepts spécifiques au domaine d'application. Si certains travaux utilisent des jeux de données réels (Liu et al., 2015), ceux qui focalisent sur le raisonnement sémantique tirent généralement parti de datasets synthétiques, c.à.d. contenant des exemples générés qui mettent en oeuvre des propriétés visuelles simples (Kottur et al., 2019; Seo et al., 2018) pour représenter des concepts et raisonnements non ambigus (Barbiero et al., 2023). Plusieurs travaux récents ont démontré l'intérêt résultant d'un dataset construit à partir d'une ontologie (Ribeiro et Leite, 2021; Agafonov et Ponomarev, 2022). En effet, les ontologies ont pour objet la réification des connaissances (concepts et raisonnements) liées à un domaine utilisateur. Une ontologie permet donc de générer un dataset contrôlé qui représente explicitement les concepts et raisonnements souhaités.

Dans le cadre de nos propres travaux sur la construction d'IA explicables (Bourguin et al., 2021), nous avons créé le *Pizzaïolo Dataset* (Bourguin et Lewandowski, 2023), un jeu de données permettant la classification d'images synthétiques de pizzas générées à partir d'une variation de l'ontologie des Pizzas (Horridge, 2011). Sa création a été motivée par le fait que nous n'avons pas pu trouver d'autre dataset qui réponde à nos besoins, c'est à dire : libre, totalement basé sur (et fourni avec) une ontologie aux concepts et descriptions de classes plus ou moins complexes, mettant en oeuvre différentes propriétés ontologiques, et proposant plusieurs types d'annotations (labels, segmentation sémantique, bounding boxes, segmentation d'instances) qui permettent des expérimentations dans diverses tâches (classification multi-class/multi-label, génération d'explications, ...).

L'objectif de ce papier est de présenter le *Pizzaïolo Dataset*¹, et de le mettre publiquement à disposition de la communauté des chercheurs pour qu'ils puissent librement l'utiliser dans leurs propres travaux. Nous fournissons en sus le module Python *Pizzaïolo*² que nous avons créé pour l'occasion et avec lequel ce dataset a été généré.

2 Le Pizzaïolo

La figure 1 donne un aperçu des images synthétiques qui composent le *Pizzaïolo Dataset*. D'une manière générale, on peut constater que ces images sont étiquetées à partir de définitions du domaine (définitions ontologiques de classes : recettes, caractéristiques). Ces étiquettes sont destinées à expérimenter la création d'IA (ontologiquement explicables) dans des tâches de classification multi-classes (ex. nom/recette de pizza : **Fiorentina**, etc.), et/ou multi-label (ex. nom de pizza + caractéristiques : **VegeratianPizza**, **SpicyPizza**, etc.).

Les images sont constituées d'un assemblage d'éléments graphiques libres³ qui représentent la base/pâte d'une pizza recouverte d'un ensemble d'icônes correspondant à des toppings (anchois, olives, etc.), et éventuellement d'une icône de drapeau qui indique le pays d'origine de la (recette de) pizza. Toutes les images ont été générées grâce au module Python *Pizzaïolo*² que nous avons développé et rendu disponible sur *GitHub*. Cette partie vise à expliciter les principaux mécanismes du processus de génération mis en oeuvre.

1. <https://zenodo.org/records/10165941>

2. <https://github.com/SysReIC/pizzaïolo>

3. <https://www.flaticon.com/>

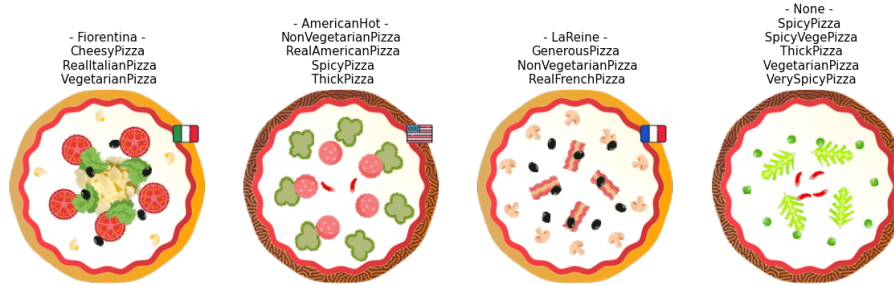


FIG. 1 – Exemples d'images synthétiques de pizzas générées par Pizzaiolo. Les étiquettes ont été calculées selon les descriptions du domaine (classes ontologiques) et à partir des concepts (base, toppings, pays d'origine) présents sur l'image : la 1ère étiquette correspond au nom (recette) de la pizza générée, les autres étiquettes en soulignent diverses caractéristiques. Les 3 premières images ont été générées à partir d'une "recette ontologique" (classes **Fiorentina**, **AmericanHot** et **LaReine**), la 4ème résulte d'une génération aléatoire (étiquetée par **None**).

2.1 Ontologies des Pizzas Allégées : Pizzaiolo Ontology

2.1.1 Concepts Généraux

La génération des exemples est contrôlée par la *Pizzaiolo Ontology*, une adaptation de la fameuse ontologie des *Pizzas* (Horridge, 2011). Cette ontologie introduit le concept de **Pizza** constituée d'une base (**hasBase.PizzaBase**) et de toppings (**hasTopping.PizzaTopping**) plus ou moins épicés (**hasSpiciness.Spiciness**). En résultent les descriptions suivantes :

Pizza \equiv Food \sqcap (\exists hasBase.PizzaBase) \sqcap (\exists hasTopping.PizzaTopping)

PizzaBase \sqsubseteq Food

PizzaTopping \sqsubseteq Food \sqcap \exists hasSpiciness.Spiciness

Mild \sqsubseteq Spiciness ; **Medium** \sqsubseteq Spiciness ; **Hot** \sqsubseteq Spiciness

La classe **PizzaBase** est spécialisée en 2 sous-classes :

DeepPanBase \sqsubseteq PizzaBase

ThinAndCrispyBase \sqsubseteq PizzaBase

La classe **PizzaTopping** est spécialisée en 6 catégories principales qui permettent de caractériser/étiqueter les pizzas qui les utilisent (pizza au fromage, végétarienne, épicée, etc.) :

CheeseTopping \sqsubseteq PizzaTopping

FruitTopping \sqsubseteq PizzaTopping

MeatTopping \sqsubseteq PizzaTopping

SeafoodTopping \sqsubseteq PizzaTopping

VegetableTopping \sqsubseteq PizzaTopping

SpicyTopping \equiv PizzaTopping \sqcap (\exists hasSpiciness.Medium) \sqcup (\exists hasSpiciness.Hot)

Ces catégories de toppings donnent elles-mêmes naissance à un total de 16 sous-classes supplémentaires de **PizzaTopping** qui correspondent aux types des éléments visuels (anchois, olives, etc.) qui sont disposés sur les images de pizzas générées. Ces 16 sous-classes sont issues d'une sélection parmi les 32 sous-classes de **PizzaTopping** de l'ontologie des Pizzas originelle

que nous avons allégée en retirant les classes de toppings (comme les coulis) qui auraient inutilement complexifié les images synthétiques. La liste complète est donnée en figure 4.

On trouve ainsi par exemple :

AnchovyTopping \sqsubseteq SeafoodTopping \sqcap (\exists hasSpiciness.Mild)
PeperoniSausageTopping \sqsubseteq MeatTopping \sqcap (\exists hasSpiciness.Medium)
JalapenoPepperTopping \sqsubseteq VegetableTopping \sqcap (\exists hasSpiciness.Hot)

On peut enfin ajouter que l'ontologie utilise de plus la propriété **hasCountryOfOrigin** qui a pour *domain* **Pizza** et pour *range* une instance de **Country** parmi **America**, **England**, **France** et **Italy**, ce qui permet d'indiquer le pays d'origine d'une "recette" de pizza.

2.1.2 Recettes de Pizzas (sous-classes de NamedPizza)

A partir de ces concepts et propriétés, l'ontologie décrit 15 "recettes" qui correspondent à **15 sous-classes de NamedPizza** (elle-même sous-classe de **Pizza**). Chacune de ces classes possède une description précise utilisée par *Pizzaïolo* pour générer les images du dataset. Inversement, ces descriptions permettent d'inférer si (et d'expliquer pourquoi) une pizza "inconnue" est une instance de ces sous-classes. La liste complète est donnée en figure 4.

A titre d'exemple, on trouve la description de la pizza **Napoletana** définie par :

Napoletana \equiv Pizza \sqcap (\forall hasCountryOfOrigin.Italy)
 \sqcap (\exists hasTopping.AnchovyTopping) \sqcap (\exists hasTopping.OliveTopping)
 \sqcap (\forall hasTopping.(AnchovyTopping \sqcup OliveTopping))
 \sqcap (\exists hasBase.ThinAndCrispyBase) \sqcap (\forall hasBase.ThinAndCrispyBase)

2.1.3 Étiquettes Ontologiques Supplémentaires

L'ontologie proposée décrit **11 sous-classes de Pizza supplémentaires** qui permettent de caractériser des instances de pizza par inférence. La liste de ces 11 classes supplémentaires est donnée en figure 4. Leur intérêt est de fournir des étiquettes correspondant à des raisonnements ontologiques plus complexes que la "simple" identification des recettes à partir des instances de concepts (base, toppings, pays) constituant une instance de pizza.

Certaines définitions impliquent un raisonnement basé sur les super-classes (catégories) de toppings (**MeatTopping**, **SpicyTopping**, etc.) citées dans la partie 2.1.1.

Par exemple :

VegetarianPizza \equiv Pizza
 $\sqcap \neg$ (\exists hasTopping.SeafoodTopping)
 $\sqcap \neg$ (\exists hasTopping.MeatTopping)
SpicyPizza \equiv Pizza \sqcap (\exists hasTopping.SpicyTopping)
SpicyVegePizza \equiv VegetarianPizza \sqcap SpicyPizza

D'autres définitions forcent à prendre en compte le nombre de toppings générés :

GenerousPizza \equiv Pizza \sqcap (≥ 8 hasTopping.OliveTopping)
VerySpicyPizza \equiv SpicyPizza
 \sqcap (≥ 8 hasTopping.SpicyTopping) \sqcup (≥ 4 hasTopping.(\exists hasSpiciness.Hot))




FIG. 2 – Exemples de représentation visuelle des concepts constituant les pizzas.

2.2 Génération d'Image Ontologique et Aléatoire

La génération des exemples par *Pizzaiolo* se base sur les concepts de la *Pizzaiolo Ontology* et sur des tirages aléatoires "contrôlés" pour obtenir des variations conformes aux descriptions ontologiques du domaine. L'ontologie est manipulée grâce à Owlready2 (Lamy, 2017).

2.2.1 Les Images

Les images générées ont une taille de 224*224 pixels. Elles utilisent toutes le même fond pour aider une IA à focaliser sur les concepts présents (base, toppings, pays). La figure 2 présente des exemples de représentations visuelles des concepts constituant les pizzas. Les sous-classes de **PizzaBase** sont caractérisées par des contours différents. Les toppings sont générés aléatoirement en suivant quelques règles pour garantir la lisibilité. Les éléments visuels pouvant être amenés à se chevaucher, nous avons fixé un ordre de génération pour les sous-classes de **PizzaTopping** de manière à ce que les éléments les plus gros (ex. **ParmesanTopping**) ne recouvrent pas les plus petits (ex. **OliveTopping**). Leur position est tirée aléatoirement entre 2 cercles (min et max) aux rayons fixés en fonction de la classe de topping. Le nombre d'instances est choisi aléatoirement dans un intervalle aux bornes fixées en fonction de la classe de topping. L'orientation est définie aléatoirement. Lorsqu'un pays d'origine (**Country**) est spécifié, il est représenté par une icône de drapeau apposée sur le bord de la pizza.

2.2.2 Annotations

Chaque image générée est accompagnée d'annotations destinées à la création d'IA mettant en oeuvre diverses modalités. Pour ce faire, nous avons intégré plusieurs types d'annotations qui sont représentées dans l'exemple en figure 3. On trouvera pour chaque exemple :

- le **type de pizza** générée (sous-classe de **NamedPizza**, ou **None** si pizza aléatoire)
- l'ensemble des **étiquettes ontologiques** qui caractérisent la pizza (sous-classes de **Pizza**)
- la liste des **concepts** constituants (sous-classe de **PizzaBase**, sous-classes de **PizzaTopping**, instance de **Country**)
- l'ensemble des **bounding boxes** (pour la détection d'instances de concepts)
- l'ensemble des **contours** (pour la segmentation d'instances de concepts)
- le masque de **segmentation sémantique** pour tous les concepts constituants

Pizzaïolo Dataset : Génération d'Images Synthétiques Ontologiquement Explicables

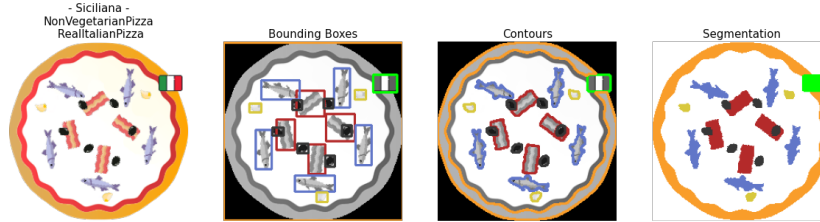


FIG. 3 – Les différents types d'annotations générés pour chaque pizza.

L'ensemble des annotations prend en compte le clipping entre instances de concepts. Par exemple, dans le cas où un **AnchovyTopping** se trouve coupé en 2 par le chevauchement d'un **HamTopping**, cet **AnchovyTopping** donne naissance à 2 bounding boxes et 2 contours, chacun(e) soulignant une partie de l'élément initial.

3 Le Pizzaïolo Dataset

Le *Pizzaïolo Dataset* (Bourguin et Lewandowski, 2023) est constitué de **4800 exemples** générés par *Pizzaiolo* et étiquetés conformément à la *Pizzaïolo Ontology*. Ce dataset contient :

- la *Pizzaïolo Ontology* en OWL 2 : format *.xml*
- les **images** synthétiques de pizzas : format *.png*
- les **bounding boxes** des concepts : 1 fichier *.json* par image
- les **contours** des concepts : 1 fichier *.json* par image
- la **segmentation sémantique** globale : 1 fichier *.txt* par image
- le **descriptif détaillé** de l'ensemble des exemples (étiquettes, types de concepts, décomptes, noms des fichiers d'annotations, etc.) : 1 fichiers *.csv*

La figure 4 offre le détail de la répartition des étiquettes et des concepts au sein du dataset. Le site du projet propose une répartition équilibrée en 3 sous-ensembles pour l'entraînement, la validation et les tests. Il est à noter que le module *Pizzaiolo* permet de transformer aisément les bounding boxes du *Pizzaïolo Dataset* vers le format YOLO.

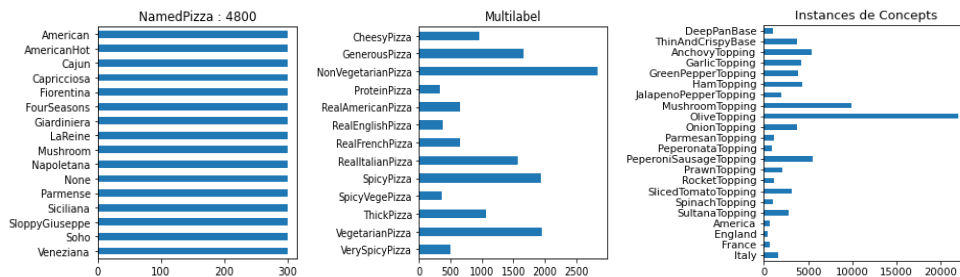


FIG. 4 – Répartition des étiquettes et des instances de concepts au sein du *Pizzaïolo Dataset*.

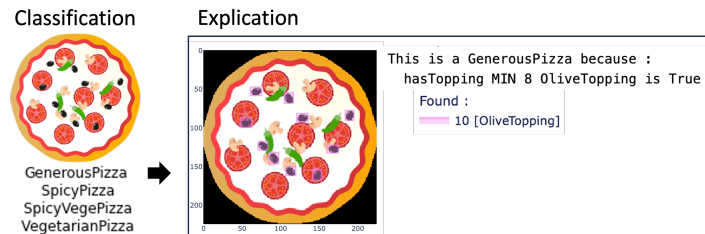


FIG. 5 – Exemple d'utilisation du Pizzaiolo Dataset dans le projet OntoClassifier (?).

4 Conclusion

Dans le but d'aider la recherche en XAI nous proposons le *Pizzaiolo Dataset* fondé sur la *Pizzaiolo Ontology*. Ce dataset présente des étiquettes qui correspondent à des descriptions de classes simples et complexes. Les annotations disponibles permettent d'envisager des tâches diverses et des modalités variées. Nous fournissons en sus le module *Pizzaiolo* qui permet au besoin de générer de nouveaux exemples. Nous avons utilisé ces outils avec succès dans nos propre travaux pour la création de classifieurs automatiques ontologiquement explicables : l'approche est exposée dans (Bourguin et al., 2021) et la figure 5 donne un exemple des derniers résultats obtenus. Nous espérons que ce dataset et ses outils aideront les chercheurs à inventer de nouvelles IA qui soient explicables du point de vue de leur domaine d'application.

Références

- Agafonov, A. et A. Ponomarev (2022). An Experiment on Localization of Ontology Concepts in Deep Convolutional Neural Networks. In *The 11th International Symposium on Information and Communication Technology, SoICT 2022, Hanoi, Vietnam, December 1-3, 2022*, pp. 82–87. ACM.
- Barbiero, P., G. Ciravegna, F. Giannini, M. E. Zarlenga, L. C. Magister, A. Tonda, P. Lio, F. Precioso, M. Jamnik, et G. Marra (2023). Interpretable Neural-Symbolic Concept Reasoning. In A. Krause, E. Brunskill, K. Cho, B. Engelhardt, S. Sabato, et J. Scarlett (Eds.), *International Conference on Machine Learning, ICML 2023, 23-29 July 2023, Honolulu, Hawaii, USA*, Volume 202 of *Proceedings of Machine Learning Research*, pp. 1801–1825. PMLR.
- Bourguin, G. et A. Lewandowski (2023). Pizzaiolo Dataset (1.0.0) [Data set]. Zenodo. <https://doi.org/10.5281/zenodo.10165941>.
- Bourguin, G., A. Lewandowski, M. Bouneffa, et A. Ahmad (2021). Towards Ontologically Explainable Classifiers. In I. Farkas, P. Masulli, S. Otte, et S. Wermter (Eds.), *Artificial Neural Networks and Machine Learning - ICANN 2021 - 30th International Conference on Artificial Neural Networks, Bratislava, Slovakia, September 14-17, 2021, Proceedings, Part II*, Volume 12892 of *Lecture Notes in Computer Science*, pp. 472–484. Springer.

- Fel, T., A. Picard, L. Béthune, T. Boissin, D. Vigouroux, J. Colin, R. Cadènc, et T. Serre (2023). CRAFT : Concept Recursive Activation FacTORIZATION for Explainability. In *IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR 2023, Vancouver, BC, Canada, June 17-24, 2023*, pp. 2711–2721. IEEE.
- Han, Z., L.-W. Cai, W.-Z. Dai, Y.-X. Huang, B. Wei, W. Wang, et Y. Yin (2023). Abductive subconcept learning. *Science China Information Sciences* 66(2), 122103.
- Horrige, M. (2011). Protégé OWL Tutorial | OWL research at the University of Manchester. <http://owl.cs.manchester.ac.uk/publications/talks-and-tutorials/protg-owl-tutorial/>.
- Koh, P. W., T. Nguyen, Y. S. Tang, S. Mussmann, E. Pierson, B. Kim, et P. Liang (2020). Concept bottleneck models. In H. D. III et A. Singh (Eds.), *Proceedings of the 37th International Conference on Machine Learning*, Volume 119 of *Proceedings of Machine Learning Research*, pp. 5338–5348. PMLR.
- Kottur, S., J. M. F. Moura, D. Parikh, D. Batra, et M. Rohrbach (2019). CLEVR-Dialog : A Diagnostic Dataset for Multi-Round Reasoning in Visual Dialog.
- Lamy, J.-B. (2017). Owlready : Ontology-oriented programming in Python with automatic classification and high level constructs for biomedical ontologies. *Artificial Intelligence in Medicine* 80, 11–28.
- Liu, Z., P. Luo, X. Wang, et X. Tang (2015). Deep Learning Face Attributes in the Wild. In *2015 IEEE International Conference on Computer Vision, ICCV 2015, Santiago, Chile, December 7-13, 2015*, pp. 3730–3738. IEEE Computer Society.
- Losch, M. M., M. Fritz, et B. Schiele (2019). Interpretability Beyond Classification Output : Semantic Bottleneck Networks. *CoRR abs/1907.10882*.
- Ribeiro, M. d. S. et J. Leite (2021). Aligning Artificial Neural Networks and Ontologies towards Explainable AI. In *Thirty-Fifth AAAI Conference on Artificial Intelligence, AAAI 2021, Thirty-Third Conference on Innovative Applications of Artificial Intelligence, IAAI 2021, The Eleventh Symposium on Educational Advances in Artificial Intelligence, EAAI 2021, Virtual Event, February 2-9, 2021*, pp. 4932–4940. AAAI Press.
- Seo, P. H., A. Lehrmann, B. Han, et L. Sigal (2018). Visual Reference Resolution using Attention Memory for Visual Dialog.

Summary

Research works in the XAI movement have emphasized the need to invent AI models that are explainable from their users’ perspective. A prevalent approach aims to design models that reify the concepts and reasoning of the application domain. In Computer Vision, studies experimenting with the creation of these new AIs have highlighted the importance in working with synthetic datasets. These datasets propose simple visual representations, and implement explicit non-ambiguous concepts and reasoning of varying complexity. Our own work in XAI aligns with this trend, and we have created the *Pizzaïolo Dataset*, a set of samples generated from an ontology in the form of synthetic annotated pizzas images. This dataset is designed for experimenting with the development of explainable AI. The purpose of this paper is to present the *Pizzaïolo Dataset* and to make it freely available to the research community.