



**HAL**  
open science

# Réseaux de neurones à convolution pour la segmentation de vaisseaux sanguins rétiniens – Des patchs aux images de taille réelle

Taibou Birgui-Sekou, Moncef Hidane, Olivier Julien, Hubert Cardot

## ► To cite this version:

Taibou Birgui-Sekou, Moncef Hidane, Olivier Julien, Hubert Cardot. Réseaux de neurones à convolution pour la segmentation de vaisseaux sanguins rétiniens – Des patchs aux images de taille réelle. *Reconnaissance des Formes, Image, Apprentissage et Perception (RFIAP)*, Jun 2018, Marne-la-Vallée, France. hal-01895868

**HAL Id: hal-01895868**

**<https://hal.science/hal-01895868>**

Submitted on 8 Mar 2022

**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.

# Réseaux de neurones à convolution pour la segmentation de vaisseaux sanguins réiniens – Des patches aux images de taille réelle

T. BIRGUI SEKOU<sup>1,3</sup>

M. HIDANE<sup>1,3</sup>

J. OLIVIER<sup>1,3</sup>

H. CARDOT<sup>2,3</sup>

<sup>1</sup> INSA Centre Val de Loire, Blois

<sup>2</sup> Université de Tours, Tours

<sup>3</sup> LIFAT EA 6300, Tours

taibou.birgui\_sekou@insa-cvl.fr

## Résumé

La segmentation d'images est une procédure importante dans de nombreux systèmes de diagnostic médical. Appliquée à des images microscopiques de rétines pour détecter des vaisseaux, elle contribue au diagnostic de maladies comme la rétinopathie diabétique et le glaucome. Ce papier présente un modèle de segmentation basé sur les réseaux de neurones à convolution (RNC). L'apprentissage de ce type de modèles requiert souvent des bases de données de taille considérable. Face à des bases de données de taille réduite, comme dans notre cas, une technique d'apprentissage consiste à trouver une bonne initialisation des poids. Ainsi, le RNC proposé dans cet article est appris en deux étapes : *i*) le modèle est appris sur des patches extraits des images de la base de données, *ii*) il est affiné sur les images de taille réelle. Une étude expérimentale est faite sur deux bases d'images publiques.

## Mots Clef

Segmentation de vaisseaux sanguins réiniens, réseaux de neurones à convolution, segmentation d'images médicales.

## Abstract

Image segmentation has become an important procedure in various medical diagnostic systems. Its application to microscopic retinal images in order to detect vessels can help in the diagnostic of diseases such as diabetic retinopathy and glaucoma. This paper presents a segmentation model based on fully convolutional neural networks. For the training to be efficient, these models need a tremendous training samples. Unfortunately this is often difficult to satisfy in the medical field. Consequently, the proposed model is learned in two phases : *i*) training on large number of patches extracted from the training images, *ii*) fine-tuning on the full-size images. Experiments are carried out on two well known datasets.

## Keywords

Retinal vessel segmentation, fully convolutional neural networks, medical image segmentation.

## 1 Introduction

La segmentation d'une image permet de mettre en avant ses régions d'intérêts et d'en faciliter l'étude. Sur des images de rétines, l'intérêt porte souvent sur l'étude de la morphologie des vaisseaux sanguins. Cette dernière permet de diagnostiquer et de suivre le traitement de diverses maladies, dont la rétinopathie diabétique et le glaucome qui font partie des grandes préoccupations actuelles des systèmes de santé publique [1, 2]. Comme mentionné dans [3], la rétinopathie diabétique est la cause majeure de cécité chez l'adulte. En outre, ces maladies ont un impact sur des aspects physiques et émotionnels chez le patient [4].

La segmentation manuelle est une tâche fastidieuse qui nécessite une expertise élevée. De plus, elle est sujet à des variabilités inter- et intra-praticiens. La segmentation automatique de vaisseaux sanguins à partir d'images de rétines a fait l'objet de plusieurs propositions au cours de cette dernière décennie. Le papier de Fraz et al. [5] récapitule les méthodes les plus importantes de la littérature, datant d'avant 2012. L'article [6] fournit un état de l'art plus récent de cette problématique.

L'étude de l'état de l'art indique que les méthodes basées sur l'apprentissage supervisé sont actuellement les plus performantes. Ces méthodes sont soit basées sur des patches soit sur les images de taille réelle.

Dans [10], les auteurs proposent une méthode basée sur des réseaux de neurones à convolution. Ils commencent par classer chaque pixel de l'image en fonction d'un voisinage fixé (*i.e.* un patch) centré en ce pixel. Autrement dit, pour un patch de taille  $m \times m$  le réseau produit un label pour le pixel central. Ensuite, le réseau est modifié pour produire une carte de segmentation de taille  $s \times s$  ( $s < m$ ) à partir d'un patch  $m \times m$  en entrée.

Les méthodes décrites dans [9, 11] ont proposé de produire la segmentation complète d'un patch en entrée. Dans [9],




FIGURE 1 – Architecture du réseau utilisé. Les chiffres en-dessous de chaque couche représentent le nombre de filtres de cette dernière.

la méthode est basée sur l'apprentissage de dictionnaire parcimonieux et discriminant. Elle consiste à séparer les patches de la base d'apprentissage en deux classes puis à apprendre un dictionnaire par classe. Un dictionnaire est appris sur les patches contenant un vaisseau sanguin et un autre sur les patches du fond. Pour un patch de test, on lui attribue la classe du dictionnaire qui le reconstruit le mieux. Si le patch contient un vaisseau, un seuillage est effectué pour produire la segmentation complète du patch. Dans le cas contraire, un patch rempli de zéros est retourné. Dans [11], un réseau de neurones à convolution est utilisé. Pour un patch en entrée, leur réseau produit la segmentation associée.

L'utilisation des patches permet d'extraire un nombre conséquents d'exemples d'apprentissage pour apprendre les réseaux. Par contre, ces modèles nécessitent une étape supplémentaire d'agrégation pour reconstruire la segmentation complète d'une image. Cette procédure peut constituer un frein pour une application temps réelle des modèles.

Il est aussi possible d'apprendre les réseaux avec des images entières sans passer par une étape d'extraction de patches. Auquel cas, la taille réduite des bases d'images rendra le problème d'apprentissage délicat. Pour palier ce problème, la base d'apprentissage est généralement augmentée à l'aide de transformations diverses, puis les poids du réseaux sont initialisés de manière appropriée.

Dans le cadre de la segmentation de vaisseaux sanguins, Mo et al. [12] ont proposé une architecture à convolution pour segmenter les images entières. Outre, l'augmentation de la base d'apprentissage, les poids de leur réseau sont initialisé avec ceux du réseau VGG[14] appris sur la base d'ImageNet. La réutilisation des poids du VGG impose une architecture similaire à ce dernier.

Dans ce papier, nous étudions l'efficacité d'une autre méthode d'initialisation qui permet de rendre le choix de l'architecture libre. Le réseau de neurones à convolution (RNC) proposé est appris en deux étapes. La première utilise des patches extraits des images de la base d'apprentissage. Le RNC est par la suite affiné sur les images de taille réelle (voir Figure 2). Une étude expérimentale compare les résultats de chaque étape avec ceux de l'état de l'art.

Le plan de notre article est le suivant : nous commençons

par présenter les RNC et l'architecture proposée dans la section 2. La section 3 présente l'étude expérimentale partant de la création des bases d'apprentissage aux résultats numériques. Enfin, la section 4 présente le bilan et les perspectives.

## 2 Modèle profond

Les réseaux de neurones (artificiels) sont généralement constitués de plusieurs couches différentes ayant chacune une motivation. Les couches complètement connectées et celles à convolution apprennent des attributs importants permettant de caractériser la base d'apprentissage. Ces derniers peuvent être discriminants (*e.g.* dans les tâches de classification) ou génératifs (*e.g.* dans les modèles génératifs). De l'autre côté les couches d'agrégation, de normalisation ou de non-linéarité injectent dans le réseau des notions d'invariance et de généralisation [13].


La concaténation de ces couches permet d'extraire des caractéristiques de meilleure qualité et de plus en plus abstraites [15]. Les premières couches du réseau capturent les variations brusques et les zones régulières de l'entrée. Quant aux couches avancées, elles se focalisent sur l'information sémantique et structurelle de l'image.

Dans ce qui suit, nous présentons l'architecture et la fonction de coût du réseau de neurones à convolution utilisé dans cet article.


### 2.1 Architecture du modèle profond

Le réseau de neurones à convolution utilisé, de type auto-encodeur, est illustré sur la figure 1. La phase d'encodage (les onze premières couches sur la figure 1) extrait des attributs riches et abstraits qui caractérisent la structure sous-jacente de la base d'apprentissage. Ces attributs sont utilisés dans la phase de décodage (couches 12 à 20) pour produire une segmentation.

Le réseau est constitué de couches de convolutions et de duplications ("upscaling"). Nous appliquons deux convolutions avec des pas de 2 pour effectuer la réduction de dimension. Ensuite, l'augmentation de dimension est faite pour retrouver la taille initiale de l'entrée avec deux duplications de pas 2. Toutes les convolutions sont suivies d'un ReLU pour introduire de la non-linéarité. La dernière



(a) Phase 1 : Le réseau est appris sur des patches extraits des images d'apprentissage.



(b) Phase 2 : Les poids appris de la phase précédente sont utilisés pour initialiser l'apprentissage sur les images de taille réelle.

FIGURE 2 – Les deux phases d'apprentissage du réseau.

convolution est suivie d'un Sigmoid pour produire une sortie bornée.

## 2.2 Fonction de coût

Soient  $\mathbf{y}$  la vérité-terrain d'un exemple d'apprentissage et  $\tilde{\mathbf{y}}$  la segmentation produite par le réseau.

Nous utilisons la fonction de coût suivante

$$\text{loss}(\mathbf{y}, \tilde{\mathbf{y}}) = CE(\mathbf{y}, \tilde{\mathbf{y}}) + \alpha \|\mathbf{y} - \tilde{\mathbf{y}}\|_1, \quad (1)$$

avec

$$CE(\mathbf{y}, \tilde{\mathbf{y}}) = - \sum_i \mathbf{y}[i] \log(\tilde{\mathbf{y}}[i]) + (1 - \mathbf{y}[i]) \log(1 - \tilde{\mathbf{y}}[i]),$$

où  $CE$  est l'entropie croisée (*cross-entropy*) et  $\alpha$  contrôle l'importance des deux termes. L'entropie croisée est une fonction très utilisée pour apprendre des réseaux [10, 11, 12]. Elle est basée sur un calcul de distance entre deux distributions de probabilité. La norme  $\ell_1$  de l'équation (1) ajoute plus d'information structurelle dans la fonction. L'intérêt de cette fonction réside dans la combinaison de deux types d'information pour éviter au mieux le sur-apprentissage du réseau.

## 3 Études expérimentales

Dans cette section, le modèle présenté ci-dessus est appliqué sur une tâche de segmentation de vaisseaux sanguins à partir d'images de rétines. Il est comparé, à l'échelle des patches et celle des images, aux autres méthodes de l'état de l'art sur des bases d'images connues. Nous commençons par introduire les bases d'images et leur composition. Ensuite, les détails expérimentaux sont présentés, *i.e.* la création de la base d'apprentissage, les prétraitements, etc..

### 3.1 Comment segmenter ?

Dans le cas de notre réseau, l'apprentissage peut être réalisé soit sur des patches, soit sur les images entières. Pour

une entrée (patch ou une image entière), le réseau produit une carte de segmentation complète en classifiant chaque pixel de l'entrée. Si l'on travaille sur des patches, pour une image en entrée, on extrait avec un certain pas des patches qui sont segmentés par le réseau, puis une étape d'agrégation permet de retrouver la segmentation de l'image d'origine (voir Figure 2). Dans ce papier, les deux approches sont comparées, mais il est important de noter que l'apprentissage sur les images est réalisée en apprenant le réseau d'abord sur les patches puis en l'affinant ("fine-tuning") sur les images entières. Cela permet d'utiliser une plus grande base d'apprentissage (car composée de patches), tout en conservant une étape de segmentation rapide (une seule passe par image à segmenter). La section 3.3 présente la procédure de création d'une base d'apprentissage du réseau.


### 3.2 Base d'images

Ici, nous présentons les bases d'images de rétines utilisées dans nos expériences. Elles sont toutes accessibles publiquement et couvrent une variété de cas, tels que les changements de courbure élevés, les micro-vaisseaux, les croisements / bifurcations et les artefacts de fond.


**DRIVE** La base DRIVE<sup>1</sup> (Digital Retinal Images for Vessel Extraction) [16] contient 40 images RGB de taille  $585 \times 564 \times 3$ . Une image masque délimitant le champ de vision ("field of view" (FoV)) est fournie pour chaque image de la base. La base est divisée en deux ensembles de 20 images chacun : l'ensemble d'apprentissage et celui de test.

**STARE** La base STARE<sup>2</sup> (STructured Analysis of the REtina) [17] contient 20 images couleur de taille  $605 \times 700 \times 3$ . La base n'est pas séparée en test et apprentissage

1. <http://www.isi.uu.nl/Research/Databases/DRIVE/>  
2. <http://www.ces.clemson.edu/ahoover/stare/>



(a) Image de DRIVE.



(b) Image de STARE.

FIGURE 3 – Exemples de résultats qualitatifs avec le réseau. De gauche à droite : la segmentation sur les images entières, la segmentation sur les patches, la vérité-terrain, l'image RGB originale.

et les images masques ne sont pas données. Mais, si besoin, ces dernières peuvent être calculées à l'aide de traitements simples.

### 3.3 Apprentissage du réseau

Sur la base DRIVE, les patches sont extraits des images d'apprentissage. Sur STARE, une validation croisée "leave-one-out" est utilisée. Sur toutes les bases, on applique préalablement trois opérations sur les images : 1) conversion en niveau de gris, 2) correction gamma (avec gamma égal à 1.7), et 3) algorithme CLAHE [24].

**Apprentissage sur les patches** Des patches de taille  $32 \times 32$  avec un pas de 8 sont extraits. En outre, pour augmenter la quantité de patches contenant des vaisseaux sanguins, nous avons aléatoirement extrait 12000 patches centrés sur des pixels de vaisseaux. Enfin, pour augmenter la base d'apprentissage, chaque patch est retourné horizontalement, verticalement et incliné de 90 degrés. La technique "Xavier" [25] est appliquée pour l'initialisation des poids.

**Apprentissage sur les images** Dans cette procédure, les poids appris sur les patches sont utilisés pour initialiser le réseau. Les entrées du réseaux deviennent les images entières. Pour augmenter le nombre d'images dans l'apprentissage, chaque image est retourné horizontalement et verticalement. Si besoin, on concatène une matrice nulle à l'image pour assurer une sortie de même taille. Autrement dit, si l'image en entrée est de taille  $(584 \times 565)$ , la concaténation va produire une taille  $(584 \times 568)$ , facilitant ainsi la division par 4 des dimensions dans le réseau.

**Implémentation** La librairie "Keras" a été utilisée pour implémenter le modèle. L'apprentissage sur les patches est

effectué avec un batch de taille 128. Sur les images, nous utilisons un batch de taille 1. Dans les deux cas, l'entraînement est fait avec l'algorithme "adadelta" [23].

### 3.4 Résultats

On dénote par  $VP$ ,  $VN$ ,  $FN$ , et  $FP$  respectivement le nombre de vrais positifs, vrais négatifs, faux négatifs, et faux positifs. Nous utilisons la sensibilité  $Sens = \frac{VP}{VP+FN}$ , la spécificité  $Spec = \frac{VN}{VN+FP}$  et l'"accuracy"  $Acc = \frac{VP+VN}{VP+FN+VN+FP}$  pour quantifier la performance du modèle.

La sortie du réseau n'étant pas binaire, on calcule l'aire sous la courbe ROC (AUC) comme métrique supplémentaire. La  $Sens$ , la  $Spec$  et l' $Acc$  sont calculées avec un seuil de 0.5. Ainsi, l'AUC exhibe plus la robustesse du modèle face à divers seuils.

Le tableau 1 présente les résultats numériques obtenus et ceux de l'état de l'art. "Réseau-patches" correspond aux résultats obtenus lorsque le réseau est appris uniquement sur les patches et "Réseau-images" aux résultats obtenus lorsque le réseau est affiné sur les images entières.

Des résultats qualitatifs sont illustrés sur la figure 3. Concernant le passage des patches à l'apprentissage des images entières, on remarque que les résultats produits par le réseau affiné sur les images contiennent moins de faux positifs.

### 3.5 Discussion

L'une des grandes discussions en segmentation de vaisseaux sanguins réside dans la comparaison des méthodes. En effet, les résultats sont souvent calculés sur différents FoV, notamment sur la base STARE qui n'est pas fournie

TABLE 1 – Comparaison des résultats numériques

Méthodes	DRIVE				STARE			
	AUC	Spec	Sens	Acc	AUC	Spec	Sens	Acc
Réseau-patchs	98.15	98.13	79.21	95.70	98.70	98.40	80.11	96.54
	-	-	-	-	99.04	98.81	80.11	97.41
Réseau-images	98.01	98.63	74.20	95.49	98.63	98.18	82.18	96.56
	-	-	-	-	99.00	98.68	82.18	97.44
Abbasi-Sureshjani et al. [20]	95.25	97.94	74.03	94.85	-	-	-	-
Birgui S. et al. [21] (JDCL)**	-	96.32	80.60	94.93	-	95.78	77.24	94.45
Dasgupta et al. [11]*	97.44	98.01	76.91	95.33	-	-	-	-
Javidi et al. [9]**	-	97.02	72.01	94.50	-	96.53	77.80	95.17
Liskowski et al. [10]*	97.90	98.07	78.11	95.35	99.28	98.62	85.54	97.29
Orlando et al.[18]	-	96.84	78.97	-	-	97.38	76.80	-
Mo et al. [12]*	97.82	97.80	77.79	95.21	98.85	98.44	81.47	96.74
Vega et al.[8]*	-	96.00	74.44	94.12	-	96.71	70.19	94.83
Zhang et al. [19]	96.36	97.25	77.43	94.76	97.48	97.58	77.91	95.54
Zhou et al. [22]	-	96.74	80.78	94.69	-	97.61	80.65	95.85

\*apprentissage profond | \*\*apprentissage de dictionnaire

avec les masques. Nous ajoutons sur le tableau 1 (lignes grises) les résultats numériques sur STARE calculés sur toutes les images sans utilisation de masques.

Les résultats numériques montrent que notre réseaux produit des résultats état de l'art sur DRIVE qu'il soit appris sur les patchs ou affiné sur les images. Sur STARE, les résultats demeurent compétitifs par rapport à l'état de l'art.

Concernant le passage des patchs à l'apprentissage des images entières, on remarque une légère diminution des métriques. D'une part le réseau est encouragé à être précis sur des fenêtres restreints (*i.e.* les patchs). D'autre part, l'apprentissage sur les images de taille réelle considère des fenêtres élargies. Dans les deux cas, on minimise une erreur moyenne qui dans le cas des fenêtres élargies peut négliger certains détails très fins. Cela peut expliquer la légère diminution des performances lorsque l'on passe à l'échelle des images.

## 4 Bilan et perspectives

Dans ce papier, nous avons étudié l'efficacité des réseaux à convolution – appris sur des patchs et sur des images de taille réelle – sur une tâche de segmentation de vaisseaux sanguins à partir d'images de rétines. Notre procédure d'apprentissage permet d'extraire un grand nombre de patchs pour bien initialiser le réseau. Cette initialisation permet d'apprendre assez rapidement le réseau sur les images entières. Avec cette procédure d'apprentissage, n'importe quel type de réseau peut être appris sur des bases d'images relativement petite. Ainsi, il n'y a plus de restriction imposant au modèle une architecture de type VGG [14].

Les travaux futurs s'orienteront vers l'implémentation de meilleurs extracteurs d'attributs pour la classification (mo-

dèles de réseaux résiduels, de réseaux larges, etc.). L'application des méthodes proposées à d'autres modalités d'images médicales est également envisagée.

## Références

- [1] Yau, J. W. et al. (2012). Global Prevalence and Major Risk Factors of Diabetic Retinopathy. *Diabetes Care*, 35(3) :556–564.
- [2] Tham, Y.-C., Li, X., Wong, T. Y., Quigley, H. A., Aung, T., and Cheng, C.-Y. (2014). Global Prevalence of Glaucoma and Projections of Glaucoma Burden through 2040 : A Systematic Review and Meta-Analysis. *Ophthalmology*, 121(11) :2081–2090.
- [3] Klein, B. E. K. (2007). Overview of Epidemiologic Studies of Diabetic Retinopathy. *Ophthalmic Epidemiology*, 14(4) :179–183.
- [4] Viswanath, K. and McGavin, D. D. M. (2003). Diabetic retinopathy : clinical findings and management. *Community eye health*, 16(46) :21–24.
- [5] Fraz, M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A., Owen, C., Barman, S. : Blood vessel segmentation methodologies in retinal images - A survey. *Computer Methods and Programs in Biomedicine*, 108(1), 407–433 (2012).
- [6] Srinidhi, C. L., Aparna, P., Rajan, J. (2017). Recent Advancements in Retinal Vessel Segmentation. *Journal of Medical Systems*, 4(41), 70 :1–70 :22.
- [7] Mookiah, M.R.K., Acharya, U.R., Chua, C.K., Lim, C.M., Ng, E.Y.K., Laude, A. : Computer-aided diagnosis of diabetic retinopathy : A review. *Comp. in Bio. and Med.*, 43(12), 2136–2155 (2013).

- [8] Vega, R., Sánchez-Ante, G., Falcón-Morales, L., Sossa, H., Guevara, E. : Retinal vessel extraction using Lattice Neural Networks with dendritic processing. *Comp. in Bio. and Med.* 58, 20–30 (2015).
- [9] Javidi, M., Pourreza, H.R., Harati, A. : Vessel segmentation and microaneurysm detection using discriminative dictionary learning and sparse representation. *Computer Methods and Programs in Biomedicine* 139, 93–108 (2017).
- [10] Liskowski, P., Krawiec, K. (2016). Segmenting Retinal Blood Vessels With Deep Neural Networks. *IEEE Trans. Med. Imaging* 35 (11), 2369–2380.
- [11] Dasgupta, A., Singh, S. (2017). A fully convolutional neural network based structured prediction approach towards the retinal vessel segmentation. In : *IEEE International Symposium on Biomedical Imaging (ISBI)*, 248–251.
- [12] Mo, J. and Zhang, L. (2017). Multi-level deep supervised networks for retinal vessel segmentation. *Int. J. Computer Assisted Radiology and Surgery*, 12(12) :2181–2193.
- [13] Goodfellow, I., Bengio, Y., Courville, A. C. (2016). *Deep Learning*. MIT Press. ISBN : 978-0-262-03561-3..
- [14] Simonyan, K., Zisserman, A. (2014). “Very Deep Convolutional Networks for Large-Scale Image Recognition,” *CoRR*, vol. abs/1409.1556.
- [15] Zeiler M.D., Fergus R. (2014) Visualizing and Understanding Convolutional Networks. In : Fleet D., Pajdla T., Schiele B., Tuytelaars T. (eds) *Computer Vision – ECCV 2014*. *ECCV 2014. Lecture Notes in Computer Science*, vol 8689. Springer, Cham
- [16] Staal, J., Abrmoff, M.D., Niemeijer, M., Viergever, M.A., Ginneken, B.V. (2004). Ridge-based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging*, 501–509.
- [17] Hoover, A., Kouznetsova, V., Goldbaum, M. (2000). Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. *IEEE Transactions on Medical Imaging* 19, 203–210.
- [18] Orlando, J.I., Prokofyeva, E., Blaschko, M.B. (2017). A Discriminatively Trained Fully Connected Conditional Random Field Model for Blood Vessel Segmentation in Fundus Images. *IEEE Trans. Biomed. Engineering* 64(1), 16–27.
- [19] Zhang, J., Dashtbozorg, B., Bekkers, E. J., Pluim, J. P. W., Duits, R., and ter Haar Romeny, B. M. (2016). Robust Retinal Vessel Segmentation via Locally Adaptive Derivative Frames in Orientation Scores. *IEEE Trans. Med. Imaging*, 35(12) :2631–2644.
- [20] Abbasi-Sureshjani, S., Smit-Ockeloen, I., Zhang, J., and ter Haar Romeny, B. M. (2015). Biologically-Inspired Supervised Vasculature Segmentation in SLO Retinal Fundus Images. In Kamel, M. and Campilho, A. J. C., editors, *ICIAR*, volume 9164 of *Lecture Notes in Computer Science*, pages 325–334.
- [21] Birgui Sekou T., Hidane M., Olivier J., Cardot H. Segmentation of Retinal Blood Vessels Using Dictionary Learning Techniques. In : Cardoso M. et al. (eds) *Fetal, Infant and Ophthalmic Medical Image Analysis. FIFI 2017, OMIA 2017. Lecture Notes in Computer Science*, vol 10554. (2017).
- [22] Zhou, L., Yu, Q., Xu, X., Gu, Y. and Yang, J. (2017). Improving dense conditional random field for retinal vessel segmentation by discriminative feature learning and thin-vessel enhancement.. *Computer Methods and Programs in Biomedicine*, 148, 13-25.
- [23] Matthew D. Zeiler, “ADADELTA : An Adaptive Learning Rate Method,” *CoRR*, vol. abs/1212.5701, 2012.
- [24] K. Zuiderveld (1994). Contrast Limited Adaptive Histogram Equalization. In : P. Heckbert : *Graphics Gems IV*, Academic Press.
- [25] X. Glorot and Y. Bengio (2010). Understanding the difficulty of training deep feedforward neural networks. In *International conference on artificial intelligence and statistics*, pp. 249–256.