

“Sentetik Büyük Veri” İnşasında Kullanılan Desen Yayma Yaklaşımlarının İncelenmesi

Investigation of Pattern Spreading Approaches Used In Construction of "Synthetic Large Data"

Gaffari ÇELİK¹, Muhammed Fatih TALU²

¹Ağrı İbrahim Çeçen Üniversitesi, Ağrı, Türkiye (gcelik@agri.edu.tr)

²İnönü Üniversitesi, Malatya, Türkiye (fatihthalu@gmail.com)

Gönderim Tarihi:07.04.2018

Kabul Tarihi: Eylül 2018

Yayın Tarihi: Eylül 2018

Özetçe — Derin öğrenme yaklaşımlarının performansı, eğitim aşamasında kullanılan veri kümesinin büyüklüğü ile doğru orantılıdır. Bu nedenle günümüzde imge sınıflandırma, bölütleme veya nesne yakalama gibi problemlerin çözümü için büyük veri kümeleri inşa edilmektedir. Örneğin Alexnet veritabanı 1.2M imge ve 1K kategoriye; Imagenet, 15M imge ve 22K kategoriye; Yahoo Flickr, 100M imge ve 2K kategoriye sahiptir. Bu veri kümeleriyle eğitilen derin ağların doğruluk oranı oldukça yüksektir. Ancak imgeleri kategorilere atama işleminin manuel yapılması, hiç şüphesiz derin öğrenme yaklaşımlarının en büyük dezavantajıdır. İmgeleri kategorize etme (etiketleme), oldukça zahmetli ve hata eğilimi yüksek bir işlemdir. Bu zorluğu ve hata ihtimalini kaldırılabilmesi için gerçek imgeler yerine, sentetik imgeleri içeren veri kümelerinin kullanımı önerilmektedir. Sentetik imge üretimi, şekil ve desen üretimi aşamalarını içermektedir. Bir nesnenin sentetik olarak üretilebilmesi şekil ve desen tanımlayıcı modellerin inşasıyla mümkündür.

Bu çalışma, desen tanımlayıcı yöntemleri (Parça, Piksel, Piramit) kapsamaktadır. Bu yöntemler, gerçek bir imgeden alınan küçük bir desen bilgisinden yola çıkarak deseni yayma ve yüksek boyutlu imge üretmeyi amaçlamaktadır. Doğruluk, zaman ve gürültü duyarlılığı kıstaslarıyla yapılan kıyaslama sonucunda parça tabanlı yöntemin en elverişli desen yayma yöntemi olduğu kanaatine varılmıştır.

Anahtar kelimeler: *Desen yayma, piksel tabanlı, parça tabanlı, piramit tabanlı, sentetik görüntü*

Abstract — The performance of deep learning approaches is directly proportional to the size of the data set used in the training phase. For this reason, large data sets are currently being built to solve problems such as image classification, segmentation or object capture. For example Alexnet database 1.2M image and 1K categorie; Imagenet, 15M image and 22K categorie; Yahoo Flickr has 100M image and 2K categorization. However, manual assignment of imagery to categories is undoubtedly the greatest disadvantage of deep learning approaches. Categorizing images (labeling) is a very troublesome and error-prone process. In order to remove the possibility of this difficulty and error, it is suggested to use data sets containing synthetic images instead of real images. Synthetic image production includes phases of pattern and pattern production. It is possible to synthetically produce an object by constructing shape and pattern descriptive models.

This study covers pattern descriptive methods (Patch, Pixel, Pyramid). These methods are aimed at generating a high-dimensional image by spreading the pattern out of a small pattern information obtained from a real image. As a result of comparison with accuracy, time and noise sensitivity criteria, the pach-based method is considered to be the most suitable pattern spreading method.

Keywords: *Pattern spread, pixel-based, patch-based, pyramid-based, synthetic image*

1.Giriş

DerinEvrışimli Sinir Ağları (Deep Convolutional Neural Networks, DCNN) yaklaşımları, bilgisayarlı görü alanındaki birçok problemin (imge sınıflandırma, nesne tespiti, hareket algılama) çözümünde klasik yöntemlerden

daha baskın, daha başarılı bir yöntem olarak karşımıza çıkmaktadır. DCNN, yüksek tahmin doğruluğu ve paralel işleme uygun mimarisiyle, alanı domine eden etkili bir çözüm yöntemi konumuna gelmiştir. Ancak bu yöntemin kullanımında belirli zorlukların olduğu görülmektedir. Bunlar;

1. Büyük eğitim kümesine ihtiyaç duyulması[1],[2]
2. Eğitim aşamasında GPU tabanlı yüksek performanslı bilgisayarlara ihtiyaç duyulması

Şüphesiz büyük eğitim kümelerini inşa etmek oldukça zorlu bir süreçtir. Örneğin tüberküloz hastalığının varlığını gösteren “basil” yapılarının medikal imgelerde tespitini yapacak DCNN ağını eğitebilmek için, basil olan ve olmayan bölgelerin uzman hekimler yardımıyla belirlenmesi gerekmektedir. Binlerce imgedeki basil yapılarının ImageJ gibi araçlar yardımıyla dikdörtgen çerçeve içerisine alınması ve basil yapılarının belirlenmesi, zaman alıcı ve hata yapma eğilimi yüksek bir işlemdir.

Literatürde imge sınıflandırma problemini çözebilecek DCNN ağına eğitimi için Alexnet, Imagenet ve Flickr gibi büyük veri tabanları inşa edilmiştir. Örneğin Flickr veritabanında yaklaşık 100 milyon imge, 2 milyon kategori altına yerleştirilmiştir. Kategorizasyon işlemi uzmanlar tarafından manuel yapılmıştır. Bu veri tabanlarıyla eğitilen derin ağların sınıflandırma doğruluğu, klasik sinir ağlarından yüksek çıkmaktadır. Ayrıca eğitilmiş derin ağ, farklı bir amaç için hazırlanmış eğitim kümesiyle birlikte kullanılabilir. Bu yöntem literatürde “transfer learning” olarak isimlendirilmektedir.

Nesne tespiti probleminin çözümü için Pascal VOC 2012 (~11K imge) ve MS COCO (~123K imge) veri tabanları inşa edilmiştir. Bu veri tabanlarının sınıflandırma için kullanılan veri tabanlarından oldukça küçük olmasının nedeni, nesnelerin dikdörtgen çerçeve içerisine alınma zorluğudur. Hata yapma eğilimi yüksek olan bu işlem, aşırı zaman almakta ve oldukça emek gerektirmektedir.

Eğitim kümesinin inşa edilmesinde yaşanan bu zorlukları önleyebilmek ve istenilen sınıflandırma veya nesne tespiti işlemlerini gerçekleştirebilmek için sentetik imgelerin kullanılmasını önermekteyiz. Gerçeğinden neredeyse ayırt edilemeyecek düzeyde benzerliğe sahip bu imgeleri üretebilmek için, imgede yer alan her bir nesnenin modellenmesi gerekmektedir. Modelleme aşaması, geometrik şeklinin elde edilmesi ve desen bilgisinin şekil üzerine yayılması olarak iki aşamayı içermektedir. Nesnenin üç boyutlu geometrik yapısının çıkarılması konusu bu makalenin kapsamı dışındadır.

Bu çalışmada, “Geometrik olarak modellenmiş ancak desensiz bir nesne üzerine gerçek bir imgedeki deseni nasıl aktarabiliriz, nasıl yayabiliriz?” sorusuna yanıt verebilecek çözüm yöntemleri (parça, piksel, piramit) incelenmiş ve bu yöntemler doğruluk ve zaman kıstaslarına göre kıyaslanmıştır.

2. Desen Yayma Yöntemleri

Medikal alanda desen özellikleri, bir görüntünün içeriğini belirlemek için çok önemlidir[3]. İmgelerde desen bilgisi, hücrenin kanserli olup olmadığı hakkında bilgi verir. Endüstriyel alanda bir tekstil makinesinde üretilen kumaş imgesindeki desen bilgisi, üretilen kumaşın hatalı olup olmadığı ile ilgili bilgi verir.


Desen yayma yöntemleri bahsedilen alanlarla birlikte bilgisayar oyunlarında, bilgisayar destekli tasarımda, yüzey gerçekçiliğini artırmak, daha gerçekçi bir imge elde etmek için yaygın bir şekilde kullanılmaktadır[4]. Bu yöntemler, referans imgedeki desen bilgisini bozmadan genişletmeyi amaçlamaktadır.

2.1. Piksel Tabanlı

Bu yöntem giriş imgedeki küçük bir parçayı, çıkış imgeye aktarmakla başlar. Aktarılan parçaya bitişik boş pikselleri doldurmak için, boş piksel merkezli küçük parçalara giriş imgesinde en çok benzeyen parçayı arar. Denklem (1)’de, giriş (f) ve çıkış (g) imge parçaları arasındaki fark değeri (kareler farkı toplamı) hesaplanır. Fark değeri minimum olan piksel kopyalanır. Şekil 1a’da görsel olarak ifade edilen kopyalama işlemi, çıktı imgesindeki tüm pikseller dolana kadar devam eder[5],[6],[7].

$$SSD(i, j) = \sum_{i=0}^M \sum_{j=0}^N [f(i, j) - g(i + u, j + v)]^2 \quad (1)$$


Denklemdaki M ve N , parçanın satır ve sütun değerini, u ve v ise yatay ve dikey kayma değişkenlerini ifade eder[8].



Şekil 1. Desen yayma yöntemleri (a) Piksel tabanlı (b) Parça tabanlı[5]

2.2. Parça Tabanlı


Piksel yerine parça kopyalanması (bk. Şekil1b), yöntemin hızlanmasına ve doğruluğun artmasına neden olmaktadır[5]. Ancak kopyalama sonunda, sınırbölgelerinde örtüşmezlikler görülmektedir (bk. Şekil2).



Şekil 2. Parça tabanlı desen yayma yönteminin aşamaları[9]

Uygun bir örtüşme için giriş ve çıkış imge parçaları üzerinde genişliği w_E olan sınır bölgeleri ($E_{çıkış}$, E_{B_k}) arasındaki ortalama fark değeri hesaplanır (Denklem (2))[9],[10]. Minimum fark değerine sahip olan bölgede Denklem 4'e göre örtüşme gerçekleşir[11].

$$d(E_{B_1}, E_{B_2}) = \frac{1}{n} \sum_{i=1}^n (E_{B_1} - E_{B_2})^2 \quad (2)$$



Şekil 3. Örtüşen iki bölge arasındaki hata yüzeyi ve minimum maliyet yolu[11]

Şekil 3'te örtüşen sonucunda elde edilen imge gösterilmektedir. B1 ve B2 imgeleri sırasıyla B_1^{ov} ve B_2^{ov} örtüşen bölgeleriyle dikey kenarları boyunca çakışan iki blok için, hata yüzeyi $e = (B_1^{ov} - B_2^{ov})^2$ şeklinde hesaplanır[12]. Dikey yönde örtüşen bölgelerin örtüşmesi için Denklem 4'de belirtilen minimum hata sınır kesme (MEBC) formülü kullanılır.


$$E_{ij} = e_{ij} + \min[E_{i-1, j-1}, E_{i-1}, E_{i-1, j+1}] \quad (3)$$

Burada E_{ij} , i . ve j . pikseldeki biriken minimum hatayı verir. Denklem (3)'de belirtilen formül yatay ve dikey yönler için kullanılır[11].

2.3. Piramit Tabanlı

Piramit tabanlı yöntem, girdi olarak iki imge almaktadır: Giriş imgesi ve gürültü imgesi (genellikle beyaz gürültü). Bu yöntem, gürültü imgesini giriş imgesine benzetmeye çalışır. Benzetme işlemi piramitleştirme ve histogram eşleştirme aşamalarını içerir.

Piramitleme aşamasında, imge çözünürlüğü kademeli olarak azaltılır (downsampling) ve artırılır (upsampling). Üretilen imgeler üst üste dizildiğinde piramit yapısı oluştuğu için bu ismi almıştır. Çözünürlük azaltma işlemi kabalaştırma, artırma işlemi keskinleştirme olarak ifade edilebilir. Piramitleştirme işlemi giriş ve gürültü imgelerinin her ikisine birden uygulanır ve aynı seviyede olan imgelerin histogramları karşılaştırılır. Histogram farkı minimum olması için gürültü imgesi iteratif bir şekilde güncellenir[13],[14]. Şekil 4'te piramit tabanlı desen yayma yönteminin örnek bir imge üzerindeki sonucu gösterilmektedir.



Şekil 4. Piramit tabanlı desen yarma örneği (a) Giriş (b) Gürültü (c) Çıkış [14].

3. Uygulama

Bu bölümde piksel, parça ve piramit tabanlı desen yarma yöntemlerinin farklı boyutlarda ve yapılarıdaki performansları karşılaştırılmıştır. Testlerde [256x256] boyutlarına sahip imgeler kullanılmıştır. Bu imgeler üzerinden [146x146] bir parça alınarak yöntemlere girdi olarak verilmiştir. Yöntemlerin gürültü duyarlılığını analiz etmek için Gaussian gürültüsü ve bulanıklaştırması kullanılmıştır. Yarma sonucu üretilen imge ile girdi imgesinin benzerliği için yapısal benzerlik (SSIM [15]) ve ortalama karesel hata (MSE) değerleri elde edilmiştir.

SSIM değerinin hesaplanması için Denklem (4)'teki katsayı hesaplanır.

$$SSIM(x, y) = [I(x, y)]^\alpha \cdot [C(x, y)]^\beta \cdot [S(x, y)]^\gamma \quad (4)$$

$$I(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \quad (5)$$

$$C(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \quad (6)$$

$$S(x, y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3} \quad (7)$$

X ve Y imgeleri için, μ_x, μ_y renk ortalamaları, σ_x, σ_y renk standart sapmaları ve σ_{xy} kovaryansı ifade etmektedir. Sıfıra bölme hatasından kaçınmak için c_1, c_2, c_3 küçük katsayılar kullanılmıştır. α, β, γ katsayıları ise her terimi ağırlıklandırmak için kullanılır.

Yapılan ilk uygulamada yöntemlerin (parça, piksel, piramit) desen yarma doğruluğu araştırılmaktadır. Bunun için Şekil 5'in ilk sütununda gösterilen imge parçaları, yöntemlere girdi olarak verilmiştir. Şekil 5'in diğer sütunlarında, sırasıyla parça, piksel ve piramit yöntemlerinden elde edilen sonuçlar gösterilmektedir. Sonuçlar incelendiğinde, parça tabanlı yöntemin en makul desen yaydığı görülmüştür. Tablo 1'de desen yarma işlemi esnasında harcanan süre, yapısal benzerlik değerleri ve karesel hata değerleri gösterilmektedir. Değerler incelendiğinde parça tabanlı yöntemin oldukça hızlı çalıştığı görülmektedir. Parça tabanlı yöntemin en doğru sonuçları en makul sürede üretebilmesi yöntemin kullanılabilirliğini arttırmaktadır. Tablo 1'de verilen yapısal benzerlik (SSIM) ve hata değerleri (MSE) incelendiğinde, piramit tabanlı yöntemin en hatalı, piksel ve parça tabanlı yöntemlerin ise kabul edilebilir seviyede hata değerleri ürettiği görülmektedir. Ayrıca piksel ve parça tabanlı yöntemlerin sonuçlarının oldukça benzer olduğu görülmüştür. Yapılan bu ilk deneysel çalışma sonucunda, doğruluk ve zaman bakımından diğer iki yönteme kıyasen parça tabanlı yöntemin tercih edilebilir olduğu görülmüştür.

Tablo 1. Parça, piksel ve piramit desen yayma yöntemlerinin harcanan zaman, yapısal benzerlik ve karesel hata sonuçları

	İmge1	İmge2	İmge3	İmge4	İmge5
	Harcanan Zaman(sn)				
<i>Parça</i>	13.82	13.87	16.67	13.15	13.83
<i>Piksel</i>	3942.39	4242.63	3695.23	4310.94	3864.32
<i>Piramit</i>	64.45	69.10	81.21	93.60	64.30
	Yapısal Benzerlik (SSIM)				
<i>Parça</i>	0.40	0.35	0.55	0.11	0.68
<i>Piksel</i>	0.36	0.29	0.51	0.17	0.72
<i>Piramit</i>	0.22	0.35	0.46	0.11	0.74
	Ortalama Karesel Hata (MSE)				
<i>Parça</i>	17.98	17.70	16.71	18.37	16.80
<i>Piksel</i>	17.99	17.14	16.90	18.47	16.52
<i>Piramit</i>	18.07	18.08	17.51	19.52	16.86

Diğer bir uygulamada, giriş imgelerine Gaussian gürültüsü eklenerek yöntemlerin (parça, piksel, piramit) desen yayma doğruluğu incelenmektedir. Bunun için Şekil 6'nın ilk sütununda gösterilen Gaussian gürültüsü eklenmiş imge parçalarını, diğer sütunlarında, belirtilen yöntemlerden elde edilen sonuçlar gösterilmektedir. Şekil 6'nın ilk sütunu yöntemlere girdi olarak verilmiştir. Tablo 2'de desen yayma işlemi esnasında harcanan süre, yapısal benzerlik değerleri ve karesel hata değerleri göstermektedir. Değerler incelendiğinde parça tabanlı yöntemin oldukça hızlı çalıştığı görülmektedir. Tablo 2'de verilen yapısal benzerlik (SSIM) ve hata değerleri (MSE) incelendiğinde, piramit tabanlı yöntemin en hatalı değerleri, parça ve piksel tabanlı yöntemin benzerlik oranları yüksek değerler ürettiği görülmektedir. Gürültü eklenmiş imgelerle yapılan çalışma sonucunda, benzerlik ve zaman bakımından diğer iki yönteme kıyasen parça tabanlı yöntemin daha iyi sonuçlar verdiği görülmüştür.

Tablo 2. Gaussian gürültüsü eklenmiş imgelerde parça, piksel ve piramit desen yayma yöntemlerinin harcanan zaman, yapısal benzerlik ve karesel hata sonuçları


	İmge1	İmge2	İmge3	İmge4	İmge5
	Harcanan Zaman(sn)				
<i>Parça</i>	28.36	28.22	28.60	28.83	28.85
<i>Piksel</i>	4255.94	4302.41	4702.85	4860.18	4353.22
<i>Piramit</i>	85.18	80.20	138.195	88.893	112.60
	Yapısal Benzerlik (SSIM)				
<i>Parça</i>	0.18	0.20	0.27	0.14	0.56
<i>Piksel</i>	0.17	0.23	0.30	0.12	0.57
<i>Piramit</i>	0.13	0.22	0.32	0.10	0.63
	Ortalama Karesel Hata (MSE)				
<i>Parça</i>	18.19	18.13	17.24	18.51	17.08
<i>Piksel</i>	18.12	17.88	17.19	18.50	16.97
<i>Piramit</i>	18.40	18.41	17.80	19.52	17.29

İmge
Parçaları

Parça Tabanlı

Piksel Tabanlı

Piramit Tabanlı




Şekil 5.Parça, piksel ve piramit desen yarma yöntemlerinin görsel yarma sonuçları

İmge
Parçaları

Parça Tabanlı

Piksel Tabanlı

Piramit Tabanlı



Şekil 6. Gaussian gürültü eklenmiş imgerlerde parça, piksel ve piramit desen yayma yöntemlerinin görsel yayma sonuçları

Yaptığımız son uygulamada, giriş imgelerine Gaussian yumuşatması uygulanarak yöntemlerin desen yayma doğruluğu araştırılmıştır. Bunun için Şekil 7'nin ilk sütununda gösterilen Gaussian bulanıklaştırılması eklenmiş imgeleri, diğer sütunlarında, belirtilen yöntemlerden elde edilen sonuçlar gösterilmektedir. Şekil 7'nin ilk sütunu yöntemlere girdi olarak verilmiştir. Tablo 3'de desen yayma işlemi esnasında harcanan süre, yapısal benzerlik değerleri ve karesel hata değerleri gösterilmektedir. Değerler incelendiğinde parça tabanlı yöntemin oldukça hızlı çalıştığı görülmektedir. Ancak Tablo 3'de verilen yapısal benzerlik (SSIM) ve hata değerleri (MSE) incelendiğinde, piksel tabanlı yöntemin benzerliği yüksek ve hata oranı düşük imgeler ürettiği görülmektedir. Bulanıklaştırma eklenmiş imgelerle yapılan çalışma sonucunda, benzerlik ve hata açısından diğer iki yönteme kıyasen piksel tabanlı yöntemin daha iyi sonuçlar verdiği gözlemlenmiştir.

Tablo 3. Gaussian bulanıklaştırması eklenmiş imgelerde parça, piksel ve piramit desen yayma yöntemlerinin harcanan zaman, yapısal benzerlik ve karesel hata sonuçları

	İmge1	İmge2	İmge3	İmge4	İmge5
	Harcanan Zaman(sn)				
<i>Parça</i>	29.05	28.84	28.15	28.79	28.83
<i>Piksel</i>	6311.32	6253.31	6212.64	6223.47	6269.42
<i>Piramit</i>	97.27	91.92	117.01	110.00	125.87
	Yapısal Benzerlik (SSIM)				
<i>Parça</i>	0.60	0.52	0.77	0.38	0.91
<i>Piksel</i>	0.64	0.64	0.80	0.38	0.94
<i>Piramit</i>	0.36	0.57	0.77	0.27	0.92
	Ortalama Karesel Hata (MSE)				
<i>Parça</i>	17.54	17.32	16.17	17.68	15.79
<i>Piksel</i>	17.17	14.71	15.68	17.68	14.91
<i>Piramit</i>	17.50	17.22	16.32	18.76	15.43

4. Sonuçlar


Bu çalışmada, yapay imge üretiminde kullanılan desen yayma yöntemleri incelenmiştir. Parça, piksel ve piramit tabanlı olmak üzere üç farklı yöntemin uygulamaları gerçekleştirilmiştir. Gerçek bir desen görüntüsünden alınan küçük bir parçadan yola çıkarak bütün desen görüntüsünü inşa etmeyi amaçlayan bu yöntemlerin zaman, doğruluk ve yapısal benzerlik kıstasları kullanılarak farklı imgeler üzerinde karşılaştırmaları yapılmıştır. Normal, gürültülü ve bulanık görüntüler kullanılarak yapılan karşılaştırmalar neticesinde, bulanık görüntüler hariç, normal ve gürültülü görüntülerde, parça tabanlı yöntemin en doğru seçim olduğu görülmüştür.

İmge
Parçaları

Parça Tabanlı

Piksel Tabanlı

Piramit Tabanlı



Şekil 7. Gaussian bulanıklaştırması eklenmiş imgelere parça, piksel ve piramit desen yayma yöntemlerinin görsel yayma sonuçları

Kaynakça

- [1] Pu Y, Yuan X, Stevens A, Li C, Carin L. “A Deep Generative Deconvolutional Image Model”. Appearing in Proceedings of the 19th International Conference on Artificial Intelligence and Statistics, Cadiz, Spain, 7-11 May 2016.
- [2] Zeiler M D, Fergus R. Visualizing and Understanding Convolutional Networks. Editors: Fleet D, Pajdla T, Schiele B, Tuytelaars T. Computer Vision – ECCV 2014, 818–833, Springer, Berlin, Germany 2014.
- [3] Ergen B, Baykara M. “Texture based feature extraction methods for content based medical image retrieval systems” *Bio-Medical Materials and Engineering*. 24(2014):3055-3062, 2014.
- [4] Celaya-Padilla J M, Galvan T C E , Delgado C J R , Galvan-Tejada I, Sandoval E I. “Multi-seed texture synthesis to fast image patching” *Procedia Engineering*. 35, 210–216, 2012.
- [5] Wei L-Y, Lefebvre S, Kwatra V, Turk G. “State of the Art in Example-based Texture Synthesis”. Inria Headquarters and research centres, Rocquencourt , France, State Art Report, 93–117, 2009.
- [6] Efros A A, Leung T K., “Texture synthesis by non-parametric sampling,” *Proc. Seventh IEEE Int. Conf. on Comput. Vis. Corfu, Greece, 20-27 September 1999*.
- [7] Shah R. “Texture Synthesis”.
http://rajvishah.weebly.com/uploads/6/3/0/9/6309814/texture_synthesis_final_report.pdf Erişim 12.10.2017
- [8] Hisham M B, Yaakob S N, Raof R A A, Nazren A B A, Wafi N M. “Template Matching using Sum of Squared Difference and Normalized Cross Correlation”. 2015 IEEE Student Conference on Research Development (SCORED), Kuala Lumpur, Malaysia, 13-14 Dec. 2015.
- [9] Liang L I N, Liu C E, Xu Y, Guo B. “Real-Time Texture Synthesis by Patch-Based Sampling”. *ACM Transactions on Graphics*, 20(3), 127–150, 2001.
- [10] Malm P, Brun A, Bengtsson E. “Simulation of bright-field microscopy images depicting pap-smear specimen”. *Cytometry. Part A*, 87(3), 212–226, 2015.
- [11] Vinod Kumar R S, Arivazhagan S. “Adaptive Patch Based Texture Synthesis Using Wavelet”. 2011 International Conference on Signal Processing, Communication, Computing and Networking Technologies, Thuckafay, India, 21-22 July 2011.
- [12] Efros A A, Freeman W T. “Image quilting for texture synthesis and transfer”. *Proc. 28th Annu. Conf. Comput. Graph. Interact. Tech. - SIGGRAPH '01*, Los Angeles, CA, USA, 12-17 August 2001.
- [13] Heeger D J, Bergen J R. “Pyramid-based texture analysis/synthesis”. *Proceedings Book of International Conference on Image Processing*, Washington, DC, USA, 23-26 Oct. 1995.
- [14] De Ville D V, Guerquin-Kern M, Unser M. “Pyramid-based texture synthesis using local orientation and multidimensional histogram matching”. *SPIE Optical Engineering & Applications*, San Diego, California, USA, 4 September 2009.
- [15] Wang Z, Bovik A C, Sheikh H R, Simoncelli E P. “Image quality assessment: From error visibility to structural similarity”. *IEEE Transactions on Image Processing*, 13(4), 600–612, 2004.