

Tarımsal Özniteliklerin Analizi

Analysis of Agricultural Features

Hulya Yalcin

Görsel Zeka Laboratuvarı, İstanbul Teknik Üniversitesi

hulyayalcin@itu.edu.tr

Özetçe — Tarım alanında, tarımsal bitkilerin sınıflandırılması, otomasyonun artırılması ve böylelikle mahsul veriminin iyileştirilebilmesi için önemli bir problem teşkil etmektedir. Bu çalışma, doku, renk, HOG (gradyanların histogramı) ve GIST (global görüntü tanımlayıcısı) dahil olmak üzere farklı öznitelik tanımlayıcıları ve bütün bu özniteliklerin bir kombinasyonunu kullanarak bitkisel ürün sınıflandırmasına odaklanmaktadır. Bu araştırmada, hem temel sınıflandırıcılar hem de topluluk sınıflandırıcıları dahil olmak üzere çeşitli makine öğrenme algoritmaları uygulanmakta ve sınıflandırma sonuçlarının performansı çoğuluk oylaması ile analiz edilmektedir. Baz sınıflandırıcılar olarak Naive Bayes (NB), Destek Vektör Makinesi (SVM), k En Yakın Komşu (KNN) ve Çok Katmanlı Algılayıcı (MLP) kullanılmaktadır. Topluluk sınıflandırıcıları olarak Rastgele Orman (RF), Torbalama (Bagging) ve Adaboost yöntemleri kullanılmaktadır. Deneyel sonuçlar, sınıflandırma doğruluğunu, doku, renk, HOG ve GIST özelliklerinin birleşimindeki topluluk sınıflandırıcıları ve çoğuluk oylaması ile arttığını göstermektedir.

Anahtar Kelimeler — Hassas tarım, tarımsal ürün sınıflandırma, yapay görme.

Abstract — In agriculture field, classification of agricultural plants is a major problem due to need for improving the crop yield. This research work focuses on the classification of crops by applying machine vision and knowledge-based techniques with image processing by using different feature descriptors including texture, color, HOG (Histogram of oriented gradients) and GIST (Global image descriptor). A combination of all these features was used in the classification of crops. In this research, several machine learning algorithms including both base classifiers and ensemble classifiers were applied and the performances of classification results were evaluated by majority voting. Naive Bayes (NB), Support Vector Machine (SVM), K-nearest-neighbor (KNN) and Multi-Layer Perceptron (MLP) were used as Base classifiers. Ensemble classifiers include Random Forest (RF), Bagging and Adaboost were utilized. The experimental results showed that the classification accuracy is improved by majority voting with ensemble classifiers in the combination of texture, color, HOG and GIST features.

Keywords — precision agriculture, crop classification, computer vision.

I. GİRİŞ

Bitki sınıflandırması, tarımsal kaynakların optimal yönetimi için önemli araçlardan biri haline gelmiştir [1].

Bitki türlerinin sınıflandırması için yapay görme ve makina öğrenmesi algoritmaları uygulanırken birçok zorluk yaşanmaktadır [2]. Son yıllarda, bitki türlerinin tanınması/bölütlenmesi, alanlardaki su seviyesinin tespiti, tarlalardaki yabancı otların tespiti gibi problemlere çözüm olabilecek yaklaşımın geliştirilmesinde önemli bir rol oynamaktadır. Bu araştırmalar tohum ekim aşamasından ekin toplama aşamasına kadar tarımsal üretimin tam otomasyonunun birçok aşamasını desteklemeyi amaçlamaktadır. Tam otomasyon aşamasına henüz zaman olmasına rağmen, bitkilerin tanınması, yabancı otların tespiti, bitki hastalıklarının tespiti ve su seviyelerinin belirlenmesinde önemli gelişmeler katedilmiştir. Hatalı tespitler tarımsal üretmeye çok zarar vereceğinden, geliştirilen algoritmaların doğruluk oranının her zaman çok yüksek olması ve hata payının çok az olması beklenmektedir.

Makine öğrenme algoritmaları, temel sınıflandırıcılar ve topluluk sınıflandırıcıları tasarlama için uygulanmaktadır [3][4][5]. Topluluk öğrenme sınıflandırıcıları, birden fazla temel sınıflandırma modelini birleştirerek makine öğrenme sonuçlarını iyileştirmeye yardımcı olur.

Bu çalışmada, bitki sınıflandırılması için doku, renk, HOG ve GIST özellikleri gibi farklı özniteliklerin kombinasyonu incelenmiştir. Bitki sınıflandırma, on kat çapraz doğrulama test stratejisi kullanılarak temel ve topluluk sınıflandırıcılarla farklı öznitelik kombinasyonları için test edilmiştir. Farklı tarım alanlarından bitkileri sınıflandırmaya yönelik performansları iyileştirmek için hem temel hem de topluluk sınıflandırıcılarına çoğuluk oylaması uygulanmıştır.

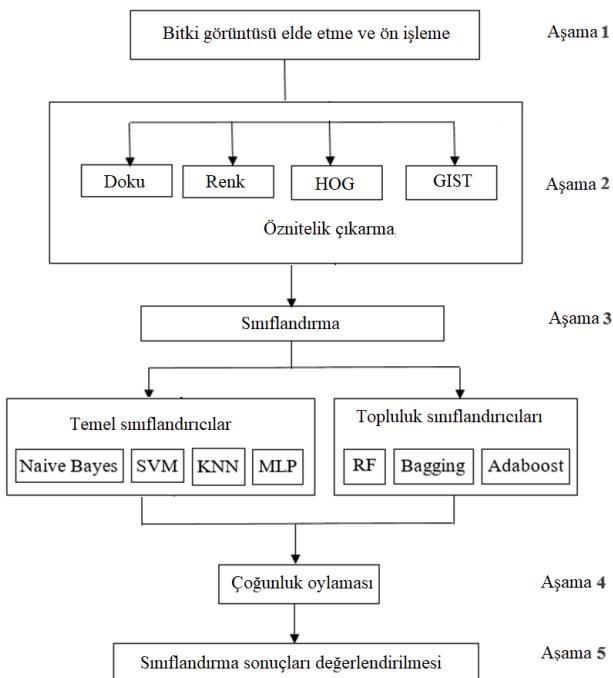
II. ÖNERİLEN YÖNTEM

Farklı tarla bitkilerinin tanımlanması ve sınıflandırılması için yapay görme teknikleri uygulanmıştır. Tarla bitkileri sınıflandırmalarının tam akış diyagramı Şekil 1'de gösterilmektedir. Bitki görüntüsü elde etme ve ön işleme, öznitelik çıkarma, sınıflandırma (temel ve topluluk sınıflandırıcıları), çoğuluk oylama ve sınıflandırma sonuçları değerlendirilmesini içeren beş aşama bulunmaktadır. Doku, renk, HOG ve GIST öznitelikleri paralel bir sırayla çıkarılmış ve hem temel hem de topluluk sınıflandırıcılarını içeren makine öğrenme algoritmaları, farklı özniteliklerin bir kombinasyonu için ayrı ayrı uygulanmıştır. Sınıflandırma sonuçlarının doğruluğunu

artırmak için en son aşamada çoğuluk oylaması stratejisi uygulanmıştır.

Görüntü işleme ile bitki sınıflandırması yapabilmek için, bitki görüntü verileri indirgenmiş öznitelik grubuna dönüştürülür ve öznitelik çıkarımı ile boyut indirgeme gerçekleştirilir. Öznitelikler, bitki görüntülerinin rengi ve dokusu hakkında göreceli bilgiler içerir. Bu çalışmada, bitki görüntülerinden doku, renk, HOG ve GIST gibi öznitelikler çıkarılmış ve sınıflandırma performansını artıran öznitelik kombinasyonları ile özellik vektörleri oluşturulmuştur. Öznitelik çıkarma yöntemlerinin ayrıntıları aşağıda verilmiştir.

Doku, bitki sınıflandırması için önemli bir faktördür. Doku çıkarımı için daha önce yerel ikili desen (LBP) [6], gri-seviye eş oluşma matrisi (GLCM) [7] ve Gabor filtreleri gibi çeşitli öznitelik çıkarım yöntemleri kullanılmıştır. Bu çalışmada, doku öznitelik çıkarımı için GLCM uygulanmaktadır. Her görüntünün GLCM verisinden kontrast, korelasyon, enerji, homojenlik ve entropi dahil olmak üzere beş adet ikinci dereceden istatistiksel öznitelik çıkarılmıştır. Ek olarak varyans, bükümle (skewness) ve kurtosis olmak üzere üç adet birinci derece histogram tabanlı öznitelik çıkarılmıştır.



Şekil 1 Bitki sınıflandırmasının akış diyagramı.

Bitki görüntüsünün dönüşünden veya çevrilmesinden etkilenmedikleri ve doku özniteliklerine kıyasla daha fazla stabilite sağladıkları için renk öznitelikleri, bitki sınıflandırma için önemli görsel özniteliklerdir. Bitki görüntülerinin, kırmızı, yeşil ve mavi renk kanallarının histogramlarından renk öznitelikleri oluşturulmaktadır.

HOG öznitelik çıkarımı, gradyan hesaplama, histogram üretimi ve blok normalizasyonu olmak üzere üç aşamada gerçekleştirilir [8]. Bitki görüntüsü önce 64×128 piksel olarak yeniden boyutlandırılır. Daha sonra, $105 (7 \times 15 = 105)$ blok içeren% 50 çakışan bloklarla 16×16 piksele bölünür. Her blokta 8×8 piksel büyülüğünde 2×2 hücre bulunur. Her blok için gradyan oryantasyonları ve gradyan büyülükleri belirlenir. Azaltılmış oryantasyonlar 9 açısal bölgeme normalize edilir ve oryantasyon histogramı her blok için hesaplanır. Daha sonra tüm histogram girişi normalleştirilir ve 3780 öznitelik (blok başına toplam blok \times hücre sayısı \times histogram başına 9 hücre = $105 \times 4 \times 9$) oluşturulur.

GIST tanımlayıcısı, ilk olarak herhangi bir bölütleme uygulamadan, düşük seviyeli özniteliklere dayalı tanıma için kullanılmıştır. Pürüzlülük, açıklık, sağlamlık ve genişleme gibi algısal boyut kümelerinden oluşan tanımlayıcı, görüntünün baskın uzamsal yapısını tanımlar [9]. GIST tanımlayıcıları, farklı ölçeklendirme, kırpmacı ve sıkıştırma durumlarında daha yüksek doğruluk sağlar. GIST öznitelikleri, bitki görüntüsünün 4 ölçeklemeye 32 Gaborfiltresi evrişitirilmesi ile 32 öznitelik haritası hesaplanır. Her özellik haritası 16 bölgeye (4×4 'luk hazne) ayrılmıştır ve her bölge için ortalama öznitelik değerleri belirlenir. Son olarak, tüm 32 öznitelik haritasının 16 ortalama değeri birleştirilir ve $512 (16 \times 32 = 512)$ büyülüğünde GIST özniteligi elde edilir.

Sınıflandırıcı performansını artırmak için HOG ve GIST özniteliklerinin boyutları PCA kullanılarak azaltılmıştır. PCA, en önemli varyasyonları korurken, birbirine ilişkili çok sayıda değişken içeren veri kümelerini boyutunu azaltmak için etkili bir araçtır [10]. Sınıflandırma için, en yaygın kullanılan makine öğrenme algoritmaları olan Naive Bayes, SVM, Karar Ağacıları, Rastgele Orman, Yapay Sinir Ağları ve En Yakın Komşu kullanılmıştır [11]. Bitki görüntülerden elde edilen doku, renk, HOG ve GIST özniteliklerinden bir öznitelik vektörü oluşturulur ve bitki sınıflarını tanımlamak için sınıflandırıcılar beslenir. Çalışmamızda, hem temel hem de topluluk sınıflandırıcıları uygulanmıştır. Kullanılan temel sınıflandırıcılar Naive Bayes, SVM, KNN ve MLP'dir. Rastgele orman, Torbalama ve Adaboost algoritmaları, topluluk sınıflandırıcıları olarak kullanılmıştır. Topluluk sınıflandırıcıları, tek bir modele kıyasla sınıflandırma doğruluğunu geliştirmek için birkaç temel sınıflandırıcıyı birleştirir.

III. DENEYSEL DEĞERLENDİRME

Deneysel, üzerine pekçok sensör yerleştirilen tarımsal akıllı istasyonlara monte edilmiş kameralardan toplanan bitki görüntülerini üzerinde yürütülmüştür. Dünya genelinde ulusal tarım izleme ağ sistemleri kuran pek çok ülke gibi, Türkiye'de de Tarımsal İzleme ve Bilgi Sistemleri (TARBIL) projesi aracılığıyla bir tarımsal izleme ve bilgi sistemi kurulmuştur. Her türlü sensörle donatılmış bu istasyonlar aracılığıyla toplanan veriler, çevrimiçi bir depolama sunucusunda ve hızlı fiber ile ağ altyapısında biriktirilmektedir. Toplanan görüntüler, bir tarım alanının belirli alanlarının yakın plan çekimlerinden oluşmaktadır. Her yarı saatte bir bitki görüntülerini almaktadır. Bu

bildiride, Şekil 2’te görüldüğü gibi buğday, arpa, mercimek, pamuk, biber, mısır bitkileri kullanılmıştır. Şekilde görülebileceği gibi, değişen aydınlatma koşullarının istenmeyen etkileri gibi, tarım bitkilerinin büyümeye aşamalarında birçok mevsimsel değişiklik ortaya çıkmaktadır ve bu durum bitki görüntülerini sınıflandırmayı zorlaştırmaktadır.

TARBIL veri kümesindeki altı bitki sınıfını kullanılmıştır. Her bitki türü için yaklaşık 400 örnek vardır. Bunlardan 280’i eğitim amaçlı ve 120’si test amaçlı kullanılmıştır. Her büyümeye aşamasında yaklaşık 30 örnek görüntü bulunmaktadır. Eğitim verilerini artırmak için, her görüntü daha da büyük yamalara bölünmekte ve her yama için öznitelikler çıkarılmaktadır. Görüntülerin orijinal boyutları 2288 x 1712 pikseldir. Eğitim verilerinin artırılması için orijinal görüntülerden 227 x 227 boyutlu yamalar oluşturulmuştur. Deneyler, Matlab 2016a ve Windows 7 Pro 64-bit işletim sistemi ortamında, Intel Xeon E5-1607, 16GB RAM, Nvidia Quadro K600 donanım özellikleri olan bir bilgisayarda gerçekleştirilmiştir. Performans ölçütleri olarak, hassasiyet, çağrıma, F1-ölçüsü ve doğruluk kullanılmıştır.



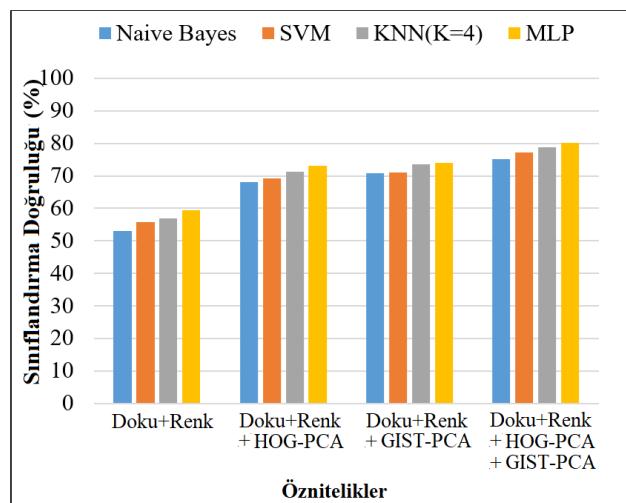
Şekil 2 Buğday, arpa, mercimek, pamuk, biber, mısır (sırasıyla satır 1 - satır 6) bitkilerinden görüntüler.

Yöntemi test etmek için bir k-kat çapraz doğrulama kullanılmış, yüksek bir tahminsel doğruluk elde etmek için ise $k = 10$ seçilmiştir. Bitki veri kümesi, k alt grubundan birinin test seti olarak kullanıldığı ve diğer $k-1$ alt gruplarının eğitim seti olarak kullanıldığı k alt grubuna ayrılmaktadır. Bu durum, test için her bir katlama kullanılıncaya kadar tekrar edilir. Sınıflandırıcının doğruluğu, tüm k çapraz onaylama durumlarında elde edilen doğrulukların ortalaması alınarak tahmin edilir.

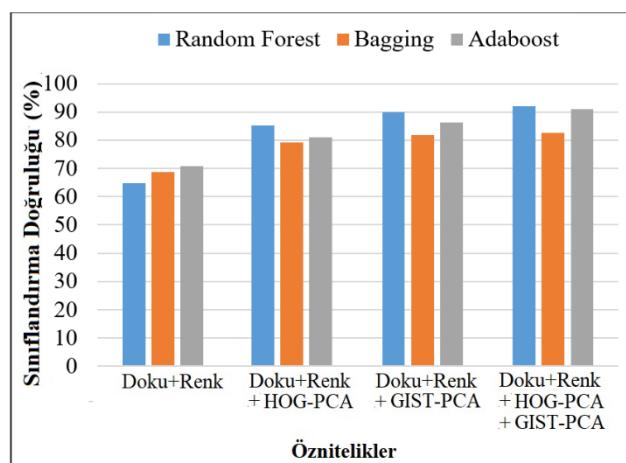
Önerilen bitki sınıflandırma sistemi ilk önce temel sınıflandırıcılar uygulanarak test edilmiş, doku, renk, HOG-PCA ve GIST-PCA kombinasyonları için Naive Bayes, SVM, KNN ve MLP sınıflandırıcıları ile elde edilen doğruluk oranları Şekil 3’de gösterilmektedir. En iyi

sonucun doku, renk, HOG-PCA, GIST-PCA kombinasyonuna MLP sınıflandırıcı uygulanarak elde edildiği görülmektedir.

Sınıflandırma doğruluğunu artırmak için, rastgele orman, Torbalama ve Adaboost yaklaşımı gibi üç topluluk sınıflandırıcıları, farklı öznitelik kombinasyonları için 10 kat çapraz doğrulama kullanılarak karşılaştırılmıştır. Rastgele orman yaklaşımında, ağaç sayısı 100 olarak seçilmiştir. Hızlı karar ağacı öğrencisi (REPTree) ve J48 karar ağacı, sırasıyla Torbalama ve AdaBoost’ın temel öğrenme algoritması olarak kullanılmıştır. Şekil 4’te gösterilen sonuçlar incelendiğinde, rastgele orman sınıflandırıcısının farklı özellik kombinasyonları için diğer iki topluluk sınıflandırıcısından daha iyi performans gösterdiği görülmektedir. Ayrıca, rastgele orman sınıflandırıcısı çok sayıda özniteligi girdi olarak alabilmekte ve daha az işlem süresi gerektirmektedir.



Şekil 3 Temel sınıflandırıcılar ile elde edilen sonuçlar.



Şekil 4 Topluluk sınıflandırıcıları ile elde edilen sonuçlar.

Bitki veri kümesi için, doku, renk, HOG-PCA ve GIST-PCA öznitelik kombinasyonlarının sonuçları hem temel

(Naive Bayes, SVM, KNN ve MLP) sınıflandırıcılarının füzyonu ve hem de topluluk sınıflandırıcılarının füzyonuna (Rastgele Orman, Torbalama ve Adaboost) çoğunluk oylaması uygulanmıştır. Çoğunluk kategorisini (sınıfı) öngören çoğunluk oylamasına ilişkin sınıflandırma sonuçları Tablo 1'de gösterilmektedir.

TABLO 1. ÇOĞUNLUK OYLAMASI İLE SINIFLNDIRMA DOĞRULUKLARI.

Öznitelik Kombinasyonu	Çoğunluk Oylaması	
	Temel Sınıflandırıcılar (Naive Bayes, SVM, KNN ve MLP füzyonu)	Topluluk Sınıflandırıcıları (Rastgele orman, Torbala ve Adaboost füzyonu)
Doku + Renk	70.1905	72.7976
Doku + Renk + HOG-PCA	85.5238	93.3929
Doku + Renk + GIST-PCA	87.4524	94.6786
Doku + Renk + HOG-PCA + GIST-PCA	90.0238	96.4881

Tablo 1'den, çoğunluk oylama sonuçlarının, rastgele orman, Torbalama ve Adaboost topluluk sınıflandırıcılarının birleştirilmesiyle uygulandığında daha yüksek sınıflandırma doğruluğu sağladığı görülmektedir. Ayrıca, çoğunluk oylamasının sonuçları, doku, renk, HOG-PCA ve GIST-PCA öznitelik kombinasyonunun birleşmesi ile daha iyi sonuç verdiği görülmektedir.

TABLO 2. ÇOĞUNLUK OYLAMASI İLE SINIFLNDIRMA METRIKLERI.

Sınıflandırıcı Metrikleri	Temel Sınıflandırıcılar Füzyonu			Topluluk Sınıflandırıcıları Füzyonu		
	Hassasiyet	Çağırma	F-ölcüsü	Hassasiyet	Çağırma	F-ölcüsü
Bitki Veriseti	0.953	0.970	0.962	0.994	0.975	0.984

Tablo 2'den, çoğunluk oylama sonuçlarının, rastgele orman, Torbalama ve Adaboost topluluk sınıflandırıcılarının birleştirilmesiyle uygulandığında göreceli olarak daha iyi sınıflandırma ölçütleri sağladığı görülmektedir.

IV. SONUÇLAR

Bu bildiride, tarla bitkilerini makine öğrenme algoritmaları kullanılarak sınıflandırmak için bir yaklaşım geliştirilmiştir. Tüm özniteliklerin farklı kombinasyonları arasında doku, renk, HOG ve GIST özniteliklerli temel ve topluluk sınıflandırıcıları kullanılarak analiz edilmiştir. Sınıflandırma doğruluğu, temel ve topluluk sınıflandırıcılarına çoğunluk oylaması uygulanarak geliştirilmiştir. Deneysel sonuçlar, topluluk sınıflandırıcılarına çoğunluk oylaması uygulanmasının önceki yaklaşımlardan daha iyi performans gösterdiğini doğrulamıştır. Çalışmanın sonraki aşamalarında, bitkileri

tanimlamak için daha fazla sayıda bitki sınıfı ve daha fazla eğitim örneği kullanılması planlanmaktadır. Ayrıca, bir makine öğrenme modellerinin performansı, çok sınıflı bitki sınıflandırma problemleri için hiper-parametre optimizasyonu ile geliştirilebilir.

TEŞEKKÜR

Bu çalışma ile ilgili veriler İstanbul Teknik Üniversitesi TARBIL (Tarım-Bilişim Araştırmaları) Merkezi tarafından sağlanmıştır. Bu çalışma, İstanbul Teknik Üniversitesi Bilimsel Araştırma Fonu (39412 no'lu proje), İTÜ TARBIL Araştırma Fonu (proje # 2012A020130) ve Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) ARDEB 3001 programı kapsamında (proje # 118E057) desteklenmektedir.

KAYNAKÇA

- [1] D. Schimmelpfennig et al., "Farm profits and adoption of precision agriculture," United States Department of Agriculture, Economic Research Service, Tech. Rep., 2016.
- [2] P. Cosmin, "Adoption of artificial intelligence in agriculture," Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca. Agriculture, 68(1), 2011.
- [3] Dardas, N.H. and Georganas, N.D., 2011. Real-time hand gesture detection and recognition using bag-of-features and support vector machine techniques. IEEE Transactions on Instrumentation and measurement, 60(11), 3592-3607.
- [4] Shao, Y. and Lunetta, R.S., 2012. Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. ISPRS Journal of Photogrammetry and Remote Sensing, 70, 78-87.
- [5] Gudigar, A., Chokkadi, S. and Raghavendra, U., 2016. A review on automatic detection and recognition of traffic sign. Multimedia Tools and Applications, 75(1), 333-364.
- [6] H. Yalcin, "Phenology Monitoring Of Agricultural Plants Using Texture Analysis," Fourth International Conference on Agro-Geoinformatics, Istanbul, 2015. (doi: 10.1109/Agro-Geoinformatics.2015.7248114)
- [7] Lee, H.H. and Hong, K.S., 2017. Automatic recognition of flower species in the natural environment. Image and Vision Computing, 61, 98-114.
- [8] Li, Y. and Su, G., 2015, November. Simplified histograms of oriented gradient features extraction algorithm for the hardware implementation. In Computers, Communications, and Systems (ICCCS), Int. Conference on (192-195). IEEE.
- [9] Douze, M., Jégou, H., Sandhawalia, H., and Schmid, C., 2009. Evaluation of gist descriptors for web-scale image search. In Proceedings of the ACM International Conference on Image and Video Retrieval (p. 19). ACM.
- [10] Martineau, M., Conte, D., Raveaux, R., Arnault, L., Munier, D. and Venturini, G., 2017. A survey on image-based insect classification. Pattern Recognition, 65, 273-284.
- [11] Lo, S.L., Chiong, R. and Cornforth, D., 2015. Using support vector machine ensembles for target audience classification on Twitter. PloS one, 10(4), p. 855.