

Hiperspektral Görüntülerde Sınıflandırma Hızının İyileştirilmesi

Accelerating Classification Time in Hyperspectral Images

Kemal Gürkan Toker, Seniha Esen Yüksel
Elektrik ve Elektronik Mühendisliği Bölümü
Hacettepe Üniversitesi
Ankara, Türkiye
{kgtoker,eyuksel}@ee.hacettepe.edu.tr

Özetçe —En yakın K komşu (EYKK) algoritması öznitelik uzayındaki en yakın eğitim örneklerine dayanarak nesneleri sınıflandıran, basit ama en çok kullanılan örtütü tamama yöntemlerinden birisidir. Az sayıda veriyle çalışıldığında basit ve dayanıklı bir yöntemdir. Fakat veri kümesi büyüdüğünde ve boyut arttığında yavaş çalışmaktadır. Hiperspektral görüntülemede, genellikle uçaktan olmak üzere kilometrelere alandan çok sayıda ve çok boyutlu veri alınmaktadır. Bu yüzden hiperspektral görüntülemede de EYKK gibi yöntemler yavaş çalışmaktadır. Bu problemlerle başa çıkmak ve hızı artırmak için bu çalışmada yaklaşık olarak en yakın komşuyu bulma işlemi yapan yerel duyarlı kiyim yöntemi önerilmektedir. Yapılan deneyler yerel duyarlı kiyim yönteminin sınıflandırma başarısını çok fazla etkilemeden sınıflandırma süresini önemli ölçüde hızlandırdığını göstermiştir.

Anahtar Kelimeler—*yerel duyarlı kiyim, en yakın k komşu yöntemi, hiperspektral görüntüleme*.

Abstract—K-nearest neighbour (K-NN) is a supervised classification technique that is widely used in many fields of study to classify unknown queries based on some known information about the dataset. K-NN is known to be robust and simple to implement when dealing with data of small size. However its performance is slow when data is large and has high dimensions. Hyperspectral images, often collected from high altitudes, cover very large areas and consist of a large number of pixels, each having hundreds of spectral dimensions. We focus on one of the most popular algorithms for performing approximate search for large datasets based on the concept of locality-sensitive hashing (LSH) for Hyperspectral Image Processing, that allows us to quickly find similar entries in large databases. Our experiments show that LSH accelerates the classification time significantly without effecting the classification rates.

Keywords—*locality Sensitive Hashing, hyperspectral imaging, k nearest neighbour method.*

I. GİRİŞ

Hiperspektral görüntüleme, elektromanyetik spektrumdan gelen bilgiyi toplamakta ve işlemekte kullanmaktadır. Hiperspektral görüntülemenin amacı nesneleri bulma, tanıma,

sınıflandırma için görüntü içerisindeki her bir piksele ait spektral bilgi elde etmektir [1] [2]. Tarım, madencilik, şehir bölge planlama gibi pek çok askeri ve sivil uygulama alanlarında kullanılmaktadır.

Geleneksel kameralar sadece RGB renk filtrelerini kullanarak insan gözünü taklit etmektedir. Bu yüzden sahne spektrinasına ait birçok detayı kaybetmektedir. Hiperspektral görüntüleme ise her bir piksel örneği için onlarca ya da yüzlerce farklı spektrumda ölçüm almaktadır. Hiperspektral görüntüler üç boyutlu veriküpü (hiperküp) olarak gösterilebilir. İki boyut uzamsal, 3. boyut ise spektral değişimi ifade etmektedir. Başka bir deyişle her bir piksel spektral bilgiye sahiptir [3].

Hiperspektral görüntüleme ile elde edilen detaylar sayesinde sahneye ait içsel özellikler açığa çıkartılabilmektedir ve sahnedeki her bir nesne elektromanyetik spektrumda kendine has imzaya sahip olmaktadır. Bunlara spektral imza denilmektedir. Bu imzalar materyallerin tanınmasına imkan sağlamaktadır ve sınıflandırma, hedef tespiti gibi bir çok konuda fayda sağlamaktadır [4]. Hiperspektral görüntüleme ile elde edilen bu fazla bilgiler; getirdiği faydalardan yanı sıra, hesaplama maliyeti, zamanı gibi bir çok önemli zorluğu da beraberinde getirmektedir.

Bu çalışmada, EYKK yöntemi ile ilgilenilmektedir. EYKK algoritması birçok alanda kullanılan eğitimsiz bir sınıflandırma yöntemidir. Az sayıda veri ile uğraşırken çalışması basit bir yöntemdir ve dayanıklıdır. Fakat büyük veri kümelerinde hesaplama maliyetleri ve süreleri artmaktadır. Hiperspektral görüntüleme de yüzlerce banttaki örneklerle ilgilenmektedir. Bu yüzden hiperspektral görüntülemede de EYKK gibi yöntemler yavaş çalışmaktadır. Bu çalışmada, EYKK yöntemine ait bu probleme başa çıkmak, sınıflandırma hızını artırmak için yaklaşık olarak en yakın komşu bulma işlemi yapan yerel duyarlı kiyim yöntemi kullanılmaktadır. Bu yöntem büyük veri kümelerinde benzer girdilerin kısa sürede bulunmasına olanak sağlamaktadır [5].

Yerel duyarlı kiyim yönteminin çalışma prensibi oldukça basittir. Yerel duyarlı kiyimdaki kilit fikir farklı kiyim tabloları kullanarak yakın olan test verilerinin tablolarda aynı hücrelere yerleştirilmesi olasılığı yüksek olacak şekilde tablolara yerleştirilmesidir. Böylece soru verisi geldiğinde onu da

aynı kiyim fonksiyonlarından geçirip sadece yerleştiği tablo hücresindeki verilerle karşılaştırılması üzerinedir.

Yerel duyarlı kiyim tekniği literatürde birçok alanda kullanılmaktadır. Büyük veri kümesine sahip, büyük boyutlu problemlerde; görüntülerdeki nesnelerin tanınması, hiper-spektral görüntülerin sınıflandırılması, web dökümanlarının sınıflandırılması ve kümelenmesi, benzer görüntülerin bulunması, benzer videoların bulunması, benzer twitlerin bulunması gibi birçok konuda günümüzde geniş uygulama alanları bulunmaktadır [6] [7] [8] [9] [10].

II. YÖNTEM

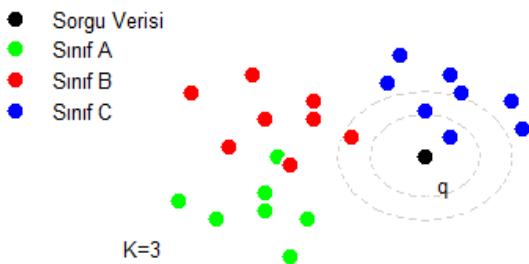
Bu çalışmada, EYKK yöntemi ile ilgilenilmektedir. EYKK yöntemi kısaca öznitelik uzayında birbirine yakın öğeleri bulmakla ilgilenmektedir. Düşük boyutlu verilerle uğraşırken çalışması basit bir yöntemdir ve dayanıklıdır. Fakat büyük veri kümelerinde ya da yüksek boyutlu problemlerle ilgilenirken hesaplama maliyetleri ve süreleri artmaktadır. Benzer öğeleri kısa sürede bulmak için Indyk and Motwani tarafından yaklaşık olarak en yakın komşuyu bulmaya yönelik yerel duyarlı kiyim yöntemi (locality sensitive hashing) geliştirilmiştir [11] [12].

Yerel duyarlı kiyim yöntemi sorgu verisine benzer ögenin bulunması bakımından önemli bir tekniktir. Hesapsal zamanı önemli ölçüde azaltmaktadır. En yakın komşuyu bulma problemi için hızlı ve yaklaşık bir sonuç sağlamaktadır.

A. En Yakın K-Komşu Yöntemi(EYKK)

En Yakın K-Komşu (EYKK) algoritması öznitelik uzayındaki en yakın eğitim örneklerine dayanarak nesneleri sınıflandırır, en basit örtütü tanıma yöntemlerinden birisidir. Temel fikir; yeni gelen veri setini sınıflandırmak için her bir veri, eğitim kümesindeki bütün verilerle tek tek işleme alınmaktadır, ve aralarındaki uzaklıkları karşılaştırarak en yakın k tane komşu veriyi bulmaktadır. Bu k tane en yakın komşu arasından çoğunuğun ait olduğu sınıf test edilen verinin sınıfı olarak atanmaktadır [13].

Şekil 1'de 3 farklı sınıf için bir EYKK sınıflandırma örneği gösterilmektedir. Sorgu verisi q ile gösterilmektedir. q verisi en yakın 3 komşusuna göre sınıflandırılmaktadır. En yakın komşularından ikisi sınıf C'ye, bir tanesi ise sınıf B'ye aittir. Böylece sorgu verisi üç en yakın komşusuna göre sınıf C olarak atanmaktadır [14].



Şekil 1: En yakın K komşu algoritması ile sınıflandırma. Sorgu verisi q en yakın k komşu arasından çoğunuğun ait olduğu sınıfı atamır.

EYKK algoritmasında; k değerinin ve uzaklık metriği seçimi performansı etkilemektedir. Öklit, Korelasyon, Şehir mesafe uzaklığı gibi bir çok uzaklık metriği bulunmaktadır. Bu çalışmada Şehir mesafe uzaklığı metriği kullanılmıştır.

B. Yerel Duyarlı Kiyim

Yerel duyarlı kiyim yöntemi büyük veri tabanlarında benzer girdileri hızlı bir şekilde bulabilmek için geliştirilmiştir. Bu yaklaşım rastgelelenmiş algoritmalar sınıfına girmektedir. Bu algoritmalar tam sonucu bulma güvencesi vermez, fakat bunun yerine büyük olasılıkla doğru ya da yakın sonucu bulma güvencesi verir [11] [12].

Birçok problem benzer öğeleri bulma problemini içermektedir. Bu problemler genelde bazı metrik uzaylarında en yakın komşuyu bulma problemi ile çözülebilir. Bu kolay bir problemdir, fakat veritabanı çok büyündüğünde veya nesneler karmaşık olduğunda işleme zamanı, öğelerin sayısı ve karmaşıklığı ile doğru orantılı olarak artmaktadır. Yerel duyarlı kiyim büyük veri tabanlı ve çok boyutlu öğeler için sorgu öğesine benzer öğelerin bulunması için önemli bir yöntemdir. Bu aramalarda hesapsal zamanı önemli ölçüde düşürmektedir.

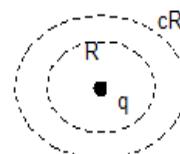
Şekil 2'de gösterildiği gibi, p eğitim kümesinden bir veri, q ise test verisi içerisinde bir sorgu verisi olsun; yerel duyarlı kiyim algoritmasının temel amacı, birbirine yakın verilerin ($\| p, q \| < R$) aynı hücreye düşme olasılığını (P_1) artırmak, uzak olanların ($\| p, q \| \geq cR$) aynı hücreye düşme olasılığını (P_2) azaltmaktadır. Bu hücreler oluşturulduktan sonra sorgulanan veri kiyim fonksiyonlarından geçirilip sadece ait olduğu hücrelerdeki veriler üzerinden en yakın komşular bulunur. Burada belirlenmesi gereken parametreler; tablo sayısı ve her bir tabloyu oluşturmak için kullanılan kiyim fonksiyon sayısıdır. Kiyim fonksiyon sayısı m , tablo sayısı L , kiyim fonksiyonları h , kiyim fonksiyonlar seti g ile gösterilmektedir.

H (kiyim fonksiyonları) ailesi (R, cR, P_1, P_2) aşağıdaki koşulu sağladığında yerel duyarlı denir.

$$\| p, q \| < R \Rightarrow Pr_H[h(q) = h(p)] \geq P_1 \quad (1)$$

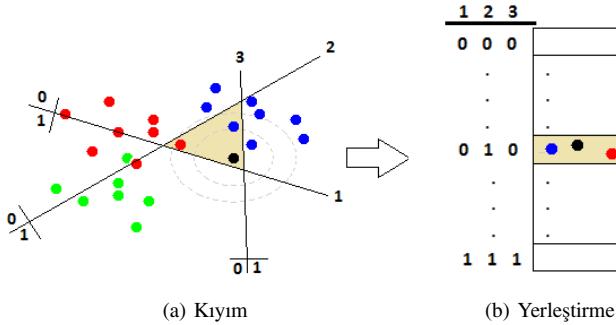
$$\| p, q \| \geq cR \Rightarrow Pr_H[h(q) = h(p)] \leq P_2$$

Yerel duyarlı kiyim ailesinin kullanılması için, $P_1 \gg P_2$ koşulunu sağlamalıdır. Böylece kiyim yaparak en yakın komşular bulunabilir.



Şekil 2: Sorgu verisi ve yerel duyarlı kiyim. Birbirine yakın verilerin ($\| p, q \| < R$) kiyim sırasında aynı hücreye düşme olasılığının (P_1) yüksek, uzak olanların ($\| p, q \| \geq cR$) aynı hücreye düşme olasılığının (P_2) ise düşük olması hedeflenmektedir.

Bu çalışmada yerel duyarlı kıymı̄m yöntemi hiperspektral görüntüye şu şekilde uygulanmaktadır: eğitim verisine ait her bir piksel için kıymı̄m fonksiyonları kullanılarak m-boyutlu boolean vektörler oluşturmaktadır. Şekil 3a'da gösterilen doğrular kıymı̄m fonksiyonlarıdır. Şekil 3b'de görüldüğü gibi kıymı̄m fonksiyonlarına göre aynı boolean değere sahip olan pikseller tablonun aynı hücresına yerleştirilmektedir. Bu işlem L defa uygulanarak L tane ayrı tablo oluşturulmaktadır. Böylece her bir piksel L tane tablodaki hücrelere yerleştirilmektedir. Bu şekilde tüm eğitim verileri yerleştirilmektedir. Daha sonra test verileri de aynı kıymı̄m fonksiyonlarından geçirilir ve ilgili tablo hücrelerine yerleştirilir. Bu hücrelerde bulunan pikseller sorgu sonuçlarıdır ve test pikselleri için EYKK yöntemi sadece bu hücreler içerisindeki eğitim piksellerine uygulanır.



Şekil 3: Yerel Duyarlı Kıymı̄m Algoritması. $L = 1$ için rastgele 3 kıymı̄m fonksiyonu kullanılarak 3-boyutlu boolean vektörler oluşturuyor. Kıymı̄m fonksiyonlarına göre aynı boolean değere sahip olan veriler tablonun aynı hücresına yerleştirilmektedir. Sorgu verisi q da aynı kıymı̄m fonksiyonlarından geçirilmektedir ve en yakın komşuyu bulmak için sadece yerleştirildiği hücrelerdeki veriler ele alınmaktadır.

Özetle algoritma aşağıdaki gibidir;

Önīleme:

- L tane fonksiyon kümesi g_j , $j = 1, \dots, L$, her bir g , m tane fonksiyondan $g_j = (h_{1,j}, h_{2,j}, \dots, h_{m,j})$ olmaktadır ve h 'lar rastgele H ailesinden seçilmektedir.
- L tane hash tablosu oluşturulur, her $j=1, \dots, L$ için j . kıymı̄m tablosu g_j fonksiyonu kullanılarak indekslenen verileri içerir.

Sorgu verisi q için sorgu algoritması her $j=1, 2, \dots, L$ için,

- J . hash tablosundaki $g_j(q)$ indeksinde yer alan veriler alınır.
- Alınan her veri için q verisi ile arasındaki uzaklık hesaplanır ve en yakın komşular bulunur.

III. DENEYSEL SONUÇLAR

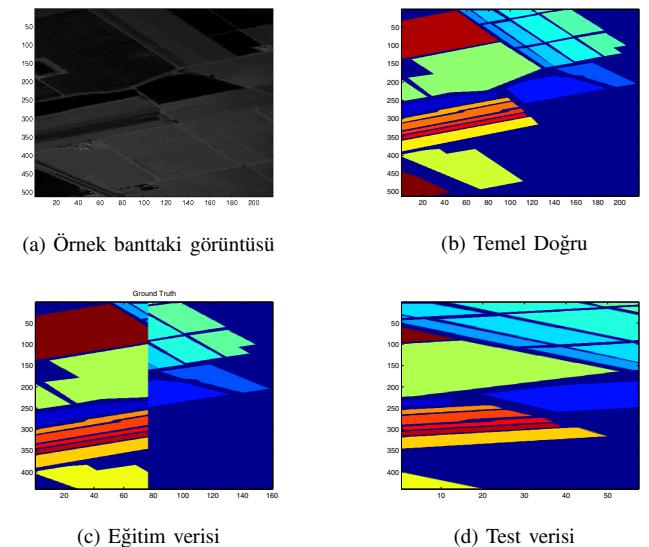
Çalışmada Şekil 4'te görülen Salinas verisi kullanılmıştır. Kullanılan veri Salinas Vadisi, Kaliforniya üzerinden AVIRIS sensörü kullanılarak alınmıştır. 224 banttan oluşmaktadır, su bantları atıldıktan sonra geriye 204 bant kalmıştır. Görüntü radyans verisi olarak 512×21 örnekten oluşmaktadır, yüksek

uzamsal çözünürlüğe sahiptir (Piksel başına 3.7 metre). Bu veride sebze, bağ, toprak alanları olmak üzere tablo I'da görüldüğü gibi 16 sınıf bulunmaktadır [15].

Sınıflar	Toplam Örnek Sayısı	Eğitim Örnek Sayısı	Test Örnek Sayısı
1	2009	1831	178
2	3726	1973	1753
3	1976	1976	0
4	1394	377	1017
5	2678	796	1882
6	3959	2207	1752
7	3579	3466	113
8	11271	7312	3959
9	6203	3359	441
10	3278	2100	1178
11	1068	841	227
12	1927	1393	534
13	916	596	320
14	1070	712	358
15	7268	7030	238

Tablo I: Kullanılan sınıflara ait yer doğrusu ve örnek sayıları. Görüntü eğitim verileri sınıflandırma için yeterli olacak ve sonuçlar görsel olarak gözlemlenecek şekilde ikiye ayrılmıştır. Salinas verisindeki 16. sınıf, eğitim ve test verilerinin dengeyi olmasını sağlamak amacıyla görüntünden kırılmıştır ve sınıflandırmaya dahil edilmemiştir.

Deneysel gerçekleştirildirmeden önce gürültüyü azaltmak ve performansı artırmak için veriye 3D anizotropik difüzyon uygulanmıştır [16]. Veri Şekil 4 ve Tablo II görüldüğü gibi iki gruba ayrılmış, bir kısmı eğitim bir kısmı da test verisi olarak kullanılmıştır.



Şekil 4: Kullanılan salinas verisi. Görüntü üçe bölünüp ortadaki test verisi, diğerleri eğitim verisi olarak kullanılmıştır [15].

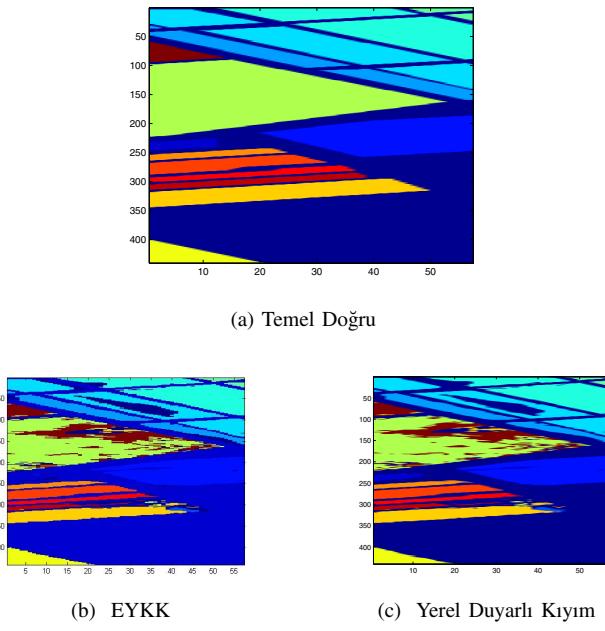
Bir önceki kısımda anlatıldığı gibi yerel duyarlı kiyimındaki temel fikir farklı kiyim tabloları kullanarak yakın olan verilerin aynı tablolara yerleştirilmesidir. Bu çalışmada, birkaç farklı m ve L değerleri için gözlemler yapılmıştır [17].

EYKK yöntemi görüntü üzerinde farklı K değerleri için uygulanmıştır. Hesapsal yük ve sınıflandırma başarımı göze alınarak K değeri 7 olarak seçimiştir ve l_1 uzaklık metriği kullanılmıştır. K=7 için yöntemlere ait sınıflandırma performansı ve sınıflandırma zamanı Tablo II'de gösterilmektedir. Yerel duyarlı kiyim yöntemi ile her bir parametre ile 10'ar sonuç elde edilmiş ve ortalama değerler bulunmuştur.

Yöntem	Sınıflandırma Başarımı	Sınıflandırma Zamanı
EYKK	% 80.57	2108.69 saniye
YDK ($m = 1000, L = 1$)	$\% 74.30 \pm 3.17$	71.98 ± 5.46 saniye
YDK ($m = 100, L = 1$)	$\% 80.23 \pm 0.56$	228.74 ± 44.37 saniye
YDK ($m = 100, L = 20$)	$\% 80.52 \pm 0.003$	932.10 ± 122.90 saniye

Tablo II: EYKK ve farklı parametreler için YDK ortalama sınıflandırma başarımları ve ortalama sınıflandırma zamanları

Sonuçlar test verileri üzerinden elde edilmiştir. Sonuçlara bakıldığında yerel duyarlı kiyim yöntemi ile veriye bağlı olarak 2 parametre ayarlanarak sınıflandırma hızı ve/veya başarımı artırılabilir. Uygun parametre değerleri seçildiğinde sınıflandırma başarısı çok fazla etkilenmeden sınıflandırma süresinin önemli ölçüde hızlandığı görülmektedir. EYKK yöntemi ve yerel duyarlı kiyim yöntemine ($m = 100, L = 20$) ait sınıflandırma başarımları Şekil 5'te gösterilmektedir. Her iki yöntemin de benzer sonuçlar verdiği görülmektedir.



Şekil 5: Yöntemlerin Sınıflandırma Başaramları

IV. SONUÇLAR

EYKK algoritması; basit, önemli ve etkili bir yöntem olmasına rağmen hiperspektral görüntüler çok büyük veri kümeleri olmalarından dolayı bu algoritma için yüksek hesap yükü getirmektedir. Yerel duyarlı kiyim yöntemi bu yükü azaltmaktadır. Yerel duyarlı kiyim yönteminin yüksek başarımlı değerleri verdiği ve hızlı sınıflandırma zamanı sağladığı görülmektedir. Yerel duyarlı kiyim tekniği, en yakın k komşu yönteminin büyük verilerdeki yavaşlığını üstesinden gelmekte ve sınıflandırma performansını çok fazla etkilemeden sınıflandırmayı hızlandırmaktadır.

KAYNAKÇA

- [1] C.I. Chang. *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. Number 1. c. in Hyperspectral Imaging: Techniques for Spectral Detection and Classification. Springer US, 2003.
- [2] H. Grahn and P. Geladi. *Techniques and Applications of Hyperspectral Image Analysis*. Wiley, 2007.
- [3] Li Ma, M.M. Crawford, and Jinwen Tian. Local manifold learning-based k-nearest-neighbor for hyperspectral image classification. *Geoscience and Remote Sensing, IEEE Transactions on*, 48(11), Nov 2010.
- [4] Guolan Lu and Baowei Fei. Medical hyperspectral imaging: a review. *Journal of biomedical optics*, 19(1):010901–010901, 2014.
- [5] Malcolm Slaney and Michael Casey. Locality-sensitive hashing for finding nearest neighbors [lecture notes]. *Signal Processing Magazine, IEEE*, 25(2):128–131, 2008.
- [6] Christian Hachenberg and Thomas Gottron. Locality sensitive hashing for scalable structural classification and clustering of web documents. In *Proceedings of the 22Nd ACM International Conference on Conference on Information & Knowledge Management, CIKM '13*, pages 359–368, New York, NY, USA, 2013. ACM.
- [7] R. Buaba, M. Gebril, A. Homaifar, E. Kihm, and M. Zhizhin. Locality sensitive hashing for satellite images using texture feature vectors. In *Aerospace Conference, 2010 IEEE*, pages 1–10, March 2010.
- [8] Zixiang Kang, Wei Tsang Ooi, and Qibin Sun. Hierarchical, non-uniform locality sensitive hashing and its application to video identification. In *Multimedia and Expo, 2004. ICME '04. 2004 IEEE International Conference on*, volume 1, pages 743–746 Vol.1, 2004.
- [9] M.S. Lin Yan. *Region-Based Geometric Active Contour for Classification Using Hyperspectral Remote Sensing Images*. PhD thesis, The Ohio State University, 2011.
- [10] Narayanan Sundaram, Aizana Turmukhametova, Nadathur Satish, Todd Mostak, Piotr Indyk, Samuel Madden, and Pradeep Dubey. Streaming similarity search over one billion tweets using parallel locality-sensitive hashing. *Proc. VLDB Endow.*, 6(14):1930–1941, September 2013.
- [11] Alexandr Andoni and Piotr Indyk. Near-optimal hashing algorithms for approximate nearest neighbor in high dimensions. *Commun. ACM*, 51(1):117–122, January 2008.
- [12] Alexandr Andoni. Efficient algorithms for substring near neighbor problem. In *in ACM-SIAM Symposium on Discrete Algorithms (SODA)*, 2006, pages 1203–1212, 2006.
- [13] M. Farhoodi and A. Yari. Applying machine learning algorithms for automatic persian text classification. In *Advanced Information Management and Service (IMS), 2010 6th International Conference on*, pages 318–323, Nov 2010.
- [14] Supardi Nadiatun Zawiyah, Mohd Yusoff, Prof Madya Dr Mashor, Harun Nor Hazlyna, Bakri Fatimatul Anis, and Hassan Rosline. Classification of blasts in acute leukemia blood samples using k-nearest neighbour. 2012.
- [15] Hyperspectral remote sensing scenes. http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes. [Online; 21-December-2014].
- [16] P. Perona and J. Malik. Scale-space and edge detection using anisotropic diffusion. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(7):629–639, Jul 1990.
- [17] Locality sensitive hashing. <http://ttic.uchicago.edu/~gregory/download.html>. [Online; 14-February-2014].