

# Siber Zorbalık Tespiti İçin yapay Sinir Ağı Tabanlı Sınıflandırıcıların Performans Analizi

## Performance Analysis of Artificial Neural Network Based Classifiers for Cyberbullying Detection

Eren Çürük  
Dept. of Electrical-Electronics Engineering  
Mersin University  
Mersin, Turkey  
erencuruk@gmail.com

Çiğdem Acı  
Dept. of Computer Engineering  
Mersin University  
Mersin, Turkey  
caci@mersin.edu.tr

Esra Saraç Eşsiz  
Dept. of Computer Engineering  
Adana Science and Technology University  
Adana, Turkey  
esarac@adanabtu.edu.tr

**Öz**—Bu çalışmada gelişen internet ve sosyal platformlarla beraber hayatımıza girmiş olan siber zorbalığın Yapay Sinir Ağı (YSA) tabanlı sınıflandırıcılarla tespitine yönelik analizler gerçekleştirilmiştir. Literatürde siber zorbalık tespitinde kullanılan genel sınıflandırıcılardan farklı olarak YSA tabanlı Destek Vektör Makinaları (DVM), Stokastik Dereceli Azalma (SGD), Radyal Temelli Fonksiyon (RBF) Ağları ve Lojistik Regresyon (LR) sınıflandırıcılar test edilmiştir. Yapılan çalışmada bahsedilen sınıflandırıcıların performansları Formspring.me ve Myspace ortamlarından elde edilen yorumlarla test edilmiştir. Sınıflandırıcıların genel performansları ölçülmek istendiği için nitelik çıkarımında N-gram model kullanılmış ve N=1 olarak seçilmiş, ayrıca etkisiz kelimeler niteliklerden ayıklanmıştır. Yapılan performans analizlerinde bütün sınıflandırıcılar için performans ölçütü F-ölçütü olarak alınmış ve genel olarak 0,90'nın üzerinde performanslar alınmıştır. Sınıflandırıcıların doğruluk ve süre performansları göz önüne alındığında siber zorbalık tespiti için en uygun sınıflandırıcının SGD sınıflandırıcısı olduğu gözlenmiştir.

**Anahtar Sözcükler**—Siber Zorbalık, Sınıflandırma, Metin Madenciliği, DVM, RBF, SGD, Lojistik Regresyon Sosyal Medya

**Abstract**— In this study, analyzes were performed to detection of cyberbullying by Artificial Neural Network (ANN) based classifiers. In contrast to the general classifiers used in the detection of cyberbullying in the literature, ANN basis classifiers as Support Vector Machines (SVM), Stochastic Gradient Descent (SGD), Radial Basis Function (RBF) and Logistic Regression (LR) classifiers have been tested. The performances of the classifiers mentioned in the study were tested with comments from Formspring.me and Myspace media. N-gram model was used for the qualitative derivation and N = 1 was chosen because we wanted to measure the overall performance of the classifiers, also stop-words have been removed from features. In these studies, the F-measure value was taken over than 0.90. Given the accuracy and time performance of the classifiers, it has been observed that the most appropriate classifier for cyberbullying detection is the SGD classifier.

**Keywords**—Cyberbullying, Classification, Text Mining, DVM, RBF, SGD, Logistic Regression, Social Media

### I. GİRİŞ

Siber zorbalık, internet, e-posta, kısa mesaj, blog, sosyal medya mesajı gibi birçok elektronik yöntemi kullanarak savunmasız kişilere karşı saldırgan bir tavırla kasıtlı olarak gerçekleştirilen eylemler olarak tanımlanabilir [1][2]. Siber zorbalık eylemlerinin gerçekleştirilmesinde, siber uzayda kimliğin gizlenebiliyor olması, siber zorbalığın anahtarı olarak ifade edilebilir ve gerçek hayatta herhangi bir zorbalığı gerçekleştirilemeyecek olan bireylerin birer siber zorbaya dönüşebilmesini sağlayabilmektedir [3]. İnternet kullanımının ve çevrimiçi topluluklara erişim kolaylığının artmasıyla birlikte siber zorbalık gibi siber suç oranları da artış göstermektedir. ABD'de siber zorbalık oranlarının giderek artmasıyla birlikte siber zorbalık sosyal bir tehdit olarak tanımlanmıştır [4].

Her geçen gün siber zorbalığın olumsuz etkileri artarak devam etmektedir. Geleneksel zorbalığın aksine, siber zorbalık da kullanılan teknikler ve formlar hızla değişebilmekte, tespit edilmesi de daha zor olmaktadır. Örneğin, anonim bir şekilde çevrimiçi olan insanlar hakkında söylentiler yaymak kolaydır ve yakalanma riski düşüktür [5]. Amerikan Çocuk ve Ergen Psikiyatrisi Akademisi'ne göre, mağdurlar genellikle psikolojik sıkıntı çekmektedir[6]. Siber zorbalık araştırmaları, gençlerin ana kurbanlar olduğunu göstermektedir. Bu nedenle, ergenleri korumak için siber zorbalığı tespit etmek gerekmektedir. British Columbia Üniversitesinde yapılan bir araştırmaya göre, siber zorbalık geleneksel zorbalığa göre daha büyük bir sorun olduğu görülmüştür. Yapılan çalışmada 733 ergenin %25-30'unun siber zorbalığa maruz kalırken, sadece %12'sinin geleneksel zorbalığa maruz kaldığı yapılan anketlerle elde edilmiştir [7]. Yapılan başka bir çalışmada siber zorbalığa uğrayan ergenlerin benlik saygısının olumsuz yönde etkilendiği sonucuna ulaşılmıştır [8]. Bu yönde yapılan çalışmalar incelendiğinde özellikle çocuk ve ergen yaş grubundaki bireylerin siber zorbalığı hem daha sık uğradığını hem de uğradıkları siber zorbalık karşısında olumsuz etkilendiği görülmektedir. Bu sebeple siber zorbalığın otomatik olarak

algılanmasına ergen ve çocukların sağlık sorunları için bir önem kazanmaktadır.

Siber zorbalık tespiti üzerine yapılan çalışmalar incelendiğinde J48 karar ağacı, Naive Bayes (NB), Destek Vektör Makinaları (DVM), ve k en yakın komşu (K-NN) sınıflandırıcıları gibi sınıflandırıcılar kullanılmıştır [9][10][11][12]. Ancak, çevrimiçi algılamaya çok az dikkat edilmiştir. [13][14][15][16]'daki çalışmalar, siber zorbalığı otomatik olarak algılamak için iyi bilinen metin madenciliği tekniklerini uygulayan başlıca örneklerdir. Siber zorbalığı otomatik olarak tespit etme, ön işleme, nitelik çıkarma, nitelik seçimi ve sınıflandırma gibi metin madenciliği yöntemlerini içerir. Bu çalışmada siber zorbalığın otomatik tespitinin geliştirilmesine yardımcı olmak amacıyla Yapay Sinir Ağı (YSA) tabanlı sınıflandırıcıların performansları ölçülmüştür. Yapılan çalışmalarda YSA tabanlı Radyal Temelli Fonksiyon (RBF), Stokastik Dereceli Azalma (SGD), Lojistik Regresyon (LR), DVM gibi sınıflandırıcıların performans ölçütü ve işlem süreleri karşılaştırılarak, siber zorbalığın otomatik olarak tespit edilmesine yönelik çalışmalara fayda sağlanması amaçlanmaktadır.

Bu çalışmanın ilerleyen bölümleri aşağıdaki şekilde düzenlenmiştir: ikinci bölümde konuyla ilgili yapılmış çalışmalarını kısa birer özeti sunulmuştur. Üçüncü kısımda, kullanılan veri kümesi ve uygulanan yöntemler anlatılmıştır. Dördüncü bölümde ise deneysel sonuçlar ve tartışma olarak çalışmamız tamamlanmıştır.

## II. YAPILMIŞ ÇALIŞMALAR

Son yıllarda siber zorbalık analizleri için, metin madenciliği yöntemleri kullanılarak mesaj ve sohbet içeriklerinin sınıflandırılmasıyla birtakım çalışmalar gerçekleştirilmektedir. Bu alanda yapılan bir çalışmada siber zorbalık tespiti için sınıflandırma yöntemi olarak DVM ve NB sınıflandırıcılarının performansları karşılaştırılmıştır. Yapılan çalışmada DVM ortalama %97,11 doğruluğa sahip olurken NB sınıflandırıcısı için %92,81 ortalama doğruluk oranı ölçülmüştür. Çalışmanın diğer adımlarında K-NN ve J48 karar ağacı yöntemlerinin performansları da ölçülmüş ve en iyi değerler YSA tabanlı olan DVM ile yapılan sınıflandırmalar sonucunda elde edilmiştir [17].

Siber zorbalık tespiti ve metin madenciliğinde sınıflandırma yöntemlerinin yanında farklı etiketle ve ağırlıklandırma yöntemleri de kullanılmaktadır. Yapılan bir çalışmada N-gram kullanarak etiketleme ve TF-IDF kullanarak ağırlıklandırma işlemleri gerçekleştirilmiştir [18]. Bu alanda yapılan ve Yapay Zeka Algoritmalarından Karınca Koloni Algoritması ile nitelik alt kümelerinin seçilmesine yönelik bir tez çalışmasında Formspring.me, Youtube, MySpace ve Twitter veri kümeleri üzerinde Karınca Koloni Algoritması ve Chi-2 algoritması birleştirilerek yapılan nitelik seçimi yönteminde sınıflandırma performansının arttığı gözlemlenmiştir. Yapılan bu tez çalışması yapay zeka algoritmalarının IG ve Chi-2 gibi genel nitelik seçimi yöntemlerinden daha iyi sonuçlar verdiğini göstermiştir [10]. Bir başka çalışmada ise denetimli bir makine öğrenme yaklaşımı uygulanmış, Youtube yorumları toplanmış, el ile etiketlenmiş ve cinsellik, fiziksel görünüş, zeka ve algılama olmak üzere üç farklı konu üzerine ikili ve çok sınıflı

sınıflamalar uygulanmıştır. Yapılan test sonuçlarında ikili sınıflandırmalarda %80,2 doğruluk elde edilirken çok sınıflı testlerde %66,7 doğruluk elde edilmiştir [19].

Yukarıda bahsedilen çalışmaların tamamı siber zorbalık tespitinde metin madenciliği yöntemlerini kullanarak gerçekleştirilmiş analizlerdir. Siber zorbalık tespiti bir metin madenciliği problemi olarak görülse de haber metinleri gibi diğer metinlerden daha farklı özelliklere sahip olabilir bu yüzden yazarın yaşı ve cinsiyeti gibi diğer ek sorunsal özelliklerin kullanılması gerekebilir. Bu nedenle siber zorbalık tespitinde ilk olarak standart metin madenciliği yöntemlerinin başarısı test edilmeli daha sonra gerekirse algılamının iyileştirilmesi amacıyla yeni yöntemlerin araştırılması gerekmektedir. Literatürde yapılan çalışmalar incelendiğinde genellikle J48 karar ağacı, NB K-NN ve DVM gibi sınıflandırıcıların performansları ölçülmüştür. YSA tabanlı RBF, LR, SGD gibi sınıflandırıcıların siber zorbalık tespiti üzerine performans analizlerinin yapıldığı bir çalışma yaptığımız literatür taramalarında bulunamamıştır. Bu nedenle YSA tabanlı bu sınıflandırıcıların performans analizleri ve süre karşılaştırmaları bu çalışmada gerçekleştirilmiştir.

## III. MATERYAL VE YÖNTEM

Bu çalışmada Formspring.me ve Myspace sosyal medya platformlarından elde edilmiş veri kümelerinin siber zorbalık sınıflandırması YSA tabanlı DVM, LR, RBF ve SGD sınıflandırıcıları ile gerçekleştirilmiş ve performansları karşılaştırılmıştır. Veri kümeleri içerisinde yer alan mesajlar siber zorbalık içerme bakımından pozitif ve negatif olarak etiketlenmiştir. TABLO I'de her bir verisi kümesi için siber zorbalık içeren ve içermeyen mesaj sayıları gösterilmiştir. Deneysel çalışmalar sırasında veri kümesinde yer alan pozitif ve negatif mesajların dengelenmesi amacıyla pozitif örnekler dengeli bir veri kümesi oluşacak şekilde çoğaltılmıştır. Veri kümesi içerisindeki mesajların %75'i eğitim verisi %25'i ise test verisi olarak ayrılmıştır.

TABLO I. VERİ KÜMESİ POZİTİF/NEGATİF MESAJ DAĞILIMI

Veri Kümesi	Pozitif Mesajlar	Negatif Mesajlar
Formspring.me	892	12266
Myspace.com	357	1396

### A. Veri Kümeleri

Formspring.me veri kümesi içerisinde toplamda 50 farklı kullanıcıdan toplanmış 13158 adet yorumdan meydana gelmektedir. Veri kümesi içerisindeki mesajların 892 tanesi siber zorbalık içerme bakımından pozitif, 12266 mesaj ise negatif olarak etiketlenmiştir. ŞEKİL I'de veri kümesi içerisinde yer alan her bir yorum için içerik bilgileri gösterilmektedir.

Myspace veri kümesi ise farklı Myspace grup sohbetlerinden toplanmış ve her bir grup sohbet kendi içerisinde 10'arlı guruplara ayrılmıştır. Örneğin bir grup sohbeti 100 adet yorum içermekte ise ilk grup 1-10 arası mesajları ikinci grup 2-11 arası mesajları içermekte ve bu

şekilde devam eden gruplandırmalarla son mesaj gurubu 91-100 arası mesajları içererek gruplandırma tamamlanmaktadır. Etiketleme işlemi ise her 10'lu grup için bir kere yapılmakta ve o 10 mesaj içerisinde siber zorbalık bulunduran mesaj olup olmadığı etiketlenmektedir. Veri kümesi içerisinde bu şekilde 10'arlı gruplara ayrılmış 357'si pozitif 1396'sı negatif olarak etiketlenmiş 1753 mesaj grubu bulunmaktadır.

```

<FORMSPRINGID>
  <BIO>Gema Loves Preston. :D</BIO>
  <DATE>20100731</DATE>
  <LOCATION>Jackson Michigan</LOCATION>
  <USERID>aguitarplayer94</USERID>
  <POST>
    <TEXT>Q: what is your favorite song? :D A: I
    like too many songs to have a favorite</TEXT>
    <ASKER></ASKER>
    <LABELDATA>
      <ANSWER>No</ANSWER>
    <CYBERBULLYWORD>n/a</CYBERBULLYWORD>
    <SEVERITY>0</SEVERITY>
    <OTHER></OTHER>
    <WORKTIME>13</WORKTIME>
  <WORKERID>A8PXREHJMZJPZ</WORKERID>
  <LABELDATA>
    .....
  </POST>
</FORMSPRINGID>

```

ŞEKİL I. Örnek Formspring.me Veri Kümesi Yorumu

## B. Sınıflandırıcılar

Bu çalışmada siber zorbalık tespiti için WEKA veri madenciliği aracının YSA tabanlı sınıflandırıcılarından DVM, SGD, LR ve RBF sınıflandırıcıları kullanılmıştır.

DVM sınıflandırma problemleri için kullanılan bir eğitimli öğrenme yöntemidir. DVM eğitim kümesi her biri olumlu ya da olumsuz olarak etiketlenmiş örneklerden oluşmaktadır. Algoritma eğitim kümesini kullanarak bir model meydana getirmektedir. Bu model, olasılıksız bir ikili doğrusal sınıflandırıcı oluşturmak için kullanılır [20].

SGD Sınıflandırıcılarda, SGD ile düzenli doğrusal modeller uygulanır. SGD, seyrek ve yüksek boyutlu verilerde iyi performans gösterdiğinden karşılaştırma sınıflandırıcısı olarak sıklıkla seçilmektedir. SGD, tüm eğitim verilerini dikkate alan Dereceli Azalma (GD) modelinden farklı olarak ağırlık değiştirirken sadece 1 rastgele noktayı dikkate alır. SGD modeli büyük veri kümeleri ile uğraşırken GD modelinden çok daha hızlıdır [21].

RBF sinir ağı, öğrenme için denetimli ve denetimsiz bileşenlerin her ikisine de sahiptir. Girdi, gizli ve çıktı olmak üzere üç katmanlı nöronlardan oluşur. Gizli katman nöronları, giriş veri alanındaki merkez dizileri temsil eder. Bu merkezlerin her biri, genelde Gauss aktivasyon işlevine sahiptir. Aktivasyon, sunulan girdi vektörü ile merkez arasındaki mesafeye bağlıdır. Vektör merkezden ne kadar uzaklaşırsa aktivasyon da o kadar düşük olur. Merkezlerin üretimi ve genişlikleri, denetimsiz k-aracı kümeleme algoritması kullanılarak yapılır. Bu algoritma tarafından oluşturulan merkezler ve genişlikler daha sonra kümeleme

yapıldıktan sonra değiştirilmeden kalan gizli katmanın ağırlıklarını ve bias değerlerini oluşturur. Çıktı katmanı (lineer olmayan aktivasyonlara sahiptir), geri yayılımla eğitilir [22].

LR, girdi olarak çalışan ve ağırlık değeriyle giriş değerini çarpan birçok makine öğrenme yönteminden biridir. Farklı olası sınıflar arasında ayırım yapmak için en faydalı olan özellikleri öğrenen bir sınıflandırıcıdır [23].

Sınıflandırma performansı Denklem 1'de verilen F-ölçüsü değeri ile ölçülür.

$$F_{ölçütü} = \frac{2 \times \text{hassasiyet} \times \text{doğruluk}}{\text{hassasiyet} + \text{doğruluk}} \quad (1)$$

Doğruluk, sınıflandırma algoritmasının kesinliğidir ve pozitif sınıfa ait olarak doğru şekilde etiketlenmiş örneklerin sayısının, pozitif olarak etiketlenmiş toplam örnek sayısına oranıdır. Hassasiyet, sınıflandırma algoritmasının bütünlüğüdür ve gerçek pozitiflerin sayısının, aslında pozitif sınıfa ait olan elementlerin toplam sayısına oranıdır. Veri kümemiz dengeli olduğu için, her iki sınıf için de F-ölçüm değerlerini hesaplıyoruz (yani, siber zorbalık varken ve siber zorbalık olmadan), bu iki F-ölçüm değerinin ortalamasını alıyoruz.

## C. Önişleme Ve Nitelik Çıkarımı

Veri kümesi içerisinde yer alan mesajlara sınıflandırma yöntemleri uygulamak için ilk olarak önişleme ve nitelik çıkarı adımları uygulanması gerekmektedir. Şekil 1'de gösterilmiş olan örnek yorum içerisindeki <TEXT> etiketinde yer alan mesajlara dizgilerine ayırma yöntemi uygulanmaktadır. Önişleme adımında ayrılan dizgiler içerisinde yer alan etkisiz kelimeler (stop-words) ayıklanmaktadır. Bu adımları gerçekleştirilerek sınıflandırma performansının artırılması amaçlanmaktadır. Önişleme ve nitelik çıkarımı adımında gerçekleştirilen işlemlerden sonra her bir veri kümesi için hesaplanan nitelik sayıları TABLO II'de gösterilmiştir.

TABLO II. VERİ KÜMELERİNİN NİTELİK SAYILARI

Veri Kümesi	Nitelik Sayısı
Formspring.me	1653
Myspace.com	11572

Nitelik çıkarımı adımı tamamlandıktan sonra her bir niteliğin veri kümesi içerisindeki ağırlıklarının hesaplanması için terim frekansı (tf) ve ters belge frekansı (idf) kullanılarak Denklem 2'de verilen TF-IDF ağırlıklandırma yöntemi kullanılmıştır.

$$tf\_idf_{t,d} = tf_{t,d} \times idf_{t,d} \quad (2)$$

TF-IDF ağırlıklandırma yöntemi kullanılarak elde edilen nitelik ağırlıkları ve veri kümesi içerisinde yer alan <ANSWER> etiketinde belirtilen siber zorbalık barındırma durumu bilgileri ile birlikte bir arff dosyası halinde kaydedilmektedir. Bu dosyada yer alan nitelik ağırlıkları ve sınıf türü

sınıflandırılmada kullanılmak üzere WEKA veri madenciliği aracına aktarılmaktadır.

#### IV. SONUÇLAR VE TARTIŞMA

Bu çalışmada metin sınıflandırmada kullanılan temel yöntemler Formspring.me ve Myspace ortamlarından elde edilmiş veriler üzerine siber zorbalık tespiti gerçekleştirilmek üzere uygulanmıştır. Bu kapsamda Formspring.me ve Myspace platformlarından elde edilmiş veri kümeleri üzerinde DVM, SGD, RBF ve LR sınıflandırıcıları test edilerek performans ve süre analizleri gerçekleştirilmiştir. Literatürde siber zorbalık tespiti için kullanılan temel sınıflandırmalarda elde edilen sonuçlar YSA tabanlı sınıflandırıcılarda da elde edilmiştir. TABLO III ve TABLO IV’de gösterilen sonuçlar doğrultusunda YSA tabanlı sınıflandırıcıların siber zorbalık tespiti probleminde uygulanabileceği sonucuna ulaşılabilmektedir. Ancak hem doğruluk hem de süre performanslarının artırılması amacıyla yeni yöntemlerin uygulanması gerektiği de açıktır.

TABLO III. SINIFLANDIRMA PERFORMANSI

Veri Kümesi	DVM	SGD	RBF	LR
Formspring.me	0.937	0.951	0.865	0.902
Myspace.com	0.983	0.982	0.984	0.982

TABLO III’de gösterildiği gibi uygulanan temel yöntemlerle herhangi bir nitelik seçimi adımı gerçekleştirilmeksizin yapılan testlerde sınıflandırıcıların doğruluk performansları genel olarak 0,90’nın üzerinde elde edilmiştir. Bu sonuçlar önışleme ve nitelik çıkarımı adımlarında uygulanacak yeni yöntemlerle birlikte daha da arttırılabileceği tahmin edilmektedir. TABLO IV’de saniye cinsinden gösterilen sınıflandırıcıların işlem süreleri dikkate alındığında SGD ve RBF sınıflandırıcılarının süre performanslarının DVM ve LR sınıflandırıcılara göre daha iyi olduğu görülmektedir. Sınıflandırıcıların doğruluk ve süre performansları doğrultusunda SGD sınıflandırıcısının siber zorbalık tespiti için en uygun YSA tabanlı sınıflandırıcı olduğu sonucuna ulaşılmaktadır.

TABLO IV. SINIFLANDIRICILARIN SÜRE ANALIZI

Sınıflandırıcı	Formspring.me			Myspace		
	Eğitim Süresi	Test Süresi	Toplam	Eğitim Süresi	Test Süresi	Toplam
DVM	2293,34	0,56	2293,9	63,29	0,35	63,64
SGD	33,43	0,31	33,74	37,23	0,2	37,43
RBF	28,15	1,72	29,87	19,96	1,34	21,3
LR	848,17	0,37	848,54	240,53	0,23	240,76

Yapılan bu çalışma gelecekte yapılacak siber zorbalık tespiti çalışmalarına fayda sağlayacağı düşünülmekte ve devam edecek çalışmalarda sınıflandırıcıların doğruluk ve süre performanslarının artırılması amacıyla önışleme adımı farklı yöntemlerin kullanılması planlanmaktadır. YSA tabanlı sınıflandırıcıların genel olarak siber zorbalık tespiti performanslarının iyi olduğu görülmektedir bununla birlikte nitelik çıkarımı adımıdan sonra uygulanacak Relieff, SVM Attribute Eval, Chi 2 testi gibi nitelik seçimi yöntemleri ile nitelik sayısının düşürülmesi ve Çok Katmanlı Yapay Sinir Ağı modelleri gibi yeni sınıflandırma yöntemleri ile performansların arttırılacağı düşünülmektedir.

#### KAYNAKLAR

- [1] J. Snakenborg, R. Van Acker, and R. A. Gable, “Cyberbullying: Prevention and Intervention to Protect Our Children and Youth,” *Prev. Sch. Fail. Altern. Educ. Child. Youth*, vol. 55, no. 2, pp. 88–95, Jan. 2011.
- [2] P. K. Smith, J. Mahdavi, M. Carvalho, S. Fisher, S. Russell, and N. Tippett, “Cyberbullying: its nature and impact in secondary school pupils,” *J. Child Psychol. Psychiatry*, vol. 49, no. 4, pp. 376–385, Apr. 2008.
- [3] S. Poland, “Cyberbullying Continues to Challenge Educators,” 2010, [Online], Available: [www.districtadministration.com/article/cyberbullyingcontinues-challenge-educators](http://www.districtadministration.com/article/cyberbullyingcontinues-challenge-educators).
- [4] S. A. Ozel, E. Sarac, S. Akdemir, and H. Aksu, “Detection of cyberbullying on social media messages in Turkish,” in *2017 International Conference on Computer Science and Engineering (UBMK)*, 2017, pp. 366–370.
- [5] M. A. Campbell, “Cyber Bullying: An Old Problem in a New Guise?,” *Aust. J. Guid. Couns.*, vol. 15, no. 1, pp. 68–76, Jul. 2005.
- [6] The American Academy of Child Adolescent Psychiatry, “Facts for families.”
- [7] H. A. J. Shapka, “Cyberbullying and bullying are not the same: UBC research,” [Online] <http://news.ubc.ca/2012/04/13/cyberbullying-and-bullying-are-notthe-same-ubc-research/>.
- [8] Y. Özdemir, “Cyber victimization and adolescent self-esteem: The role of communication with parents,” *Asian J. Soc. Psychol.*, vol. 17, no. 4, pp. 255–263, Dec. 2014.
- [9] H. Sanchez, “Twitter Bullying Detection,” *UCSC ISM245 Data Min. course Rep.*, 2011.
- [10] E. S. Eşsiz, “Selecting Optimum Feature Subsets With Nature Inspired Algorithms for Cyberbully Detection,” Çukurova University, 2016.
- [11] K. Dinakar, K. Dinakar, R. Reichart, and H. Lieberman, “Modeling the Detection of Textual Cyberbullying.”
- [12] M. Dadvar, F. M. G. de Jong, R. J. F. Ordelman, and R. B. Trieschnigg, “Improved cyberbullying detection using gender information.” Ghent University, 23-Feb-2012.
- [13] A. Kontostathis and A. Kontostathis, “ChatCoder: Toward the Tracking and Categorization of Internet Predators,” in *Proc. Text Mining Workshop 2009 Held In Conjunction With The Ninth Siam*

- International Conference On Data Mining (SDM 2009). Sparks, NV. May 2009.*, 2009.
- [14] M. Dadvar and F. M. G. de Jong, "Improved Cyberbullying Detection Through Personal Profiles." Université de Bourgogne Observatoire International de la Violence Scolaire, 2012.
- [15] V. Nahar, S. Unankard, X. Li, and C. Pang, "Sentiment Analysis for Effective Detection of Cyber Bullying," 2012, pp. 767–774.
- [16] K. Reynolds, A. Kontostathis, and L. Edwards, "Using Machine Learning to Detect Cyberbullying," in *2011 10th International Conference on Machine Learning and Applications and Workshops*, 2011, pp. 241–244.
- [17] L. A. H. Noviantho, S. M. Isa, "Cyberbullying Classification using Text Mining," in *1st International Conference on Informatics and Computational Sciences (ICICoS)*, 2017.
- [18] L. E. Dawei Yin, Zhenzhen Xue, Liangjie Hong, Brian D. Davison, April Kontostathis, "Detection of Harassment on Web 2.0," in *In Proceedings of the Content Analysis in the WEB 2.0 (CAW2.0) Workshop at WWW2009*, 2009.
- [19] H. L. Karthik Dinakar, Roi Reichart, "Modeling the Detection of Textual Cyberbullying | Request PDF," in , *Social Mobile Web Workshop at International Conference on Weblog and Social Media*, 2011.
- [20] E. Saraç and S. A. Özel, "Effects of Feature Extraction and Classification Methods on Cyberbully Detection," *Süleyman Demirel Üniversitesi Fen Bilim. Enstitüsü Derg.*, vol. 21, no. 1, p. 190, Dec. 2016.
- [21] A. B. Prasetijo, R. R. Isnanto, D. Eridani, Y. A. A. Soetrisno, M. Arfan, and A. Sofwan, "Hoax detection system on Indonesian news sites based on text classification using SVM and SGD," in *2017 4th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE)*, 2017, pp. 45–49.
- [22] R. A. Finan, A. T. Sapeluk, and R. I. Damper, "Comparison of multilayer and radial basis function neural networks for text-dependent speaker recognition," in *Proceedings of International Conference on Neural Networks (ICNN'96)*, vol. 4, pp. 1992–1997.
- [23] S. T. Indra, L. Wikarsa, and R. Turang, "Using logistic regression method to classify tweets into the selected topics," in *2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS)*, 2016, pp. 385–390.