

## Makine Öğrenmesi Yöntemleri ile Somatizasyon ve Duygusal Öz Farkındalık Üzerinden Şiddetin Tahmini

### Violence Prediction on Somatization and Emotional Self Awareness with Machine Learning Methods

Burcu Türk\*, Hasan Halit Tali

**Öz:** **Amaç:** Bu çalışma somatizasyon ve duygusal öz farkındalık kavramları üzerinden makine öğrenmesi yöntemlerinden biri olan gözetimli öğrenmenin sınıflandırma algoritmaları ile bireylerin şiddet mağduriyetlerinin tahmin edilmesi amacıyla yapılmıştır.

**Gereç ve Yöntem:** Çalışma 149 (%27) erkek ve 403 (%73) kadın olmak üzere toplam 552 katılımcıdan oluşmaktadır. Araştırmada veri toplama araçları olarak Kişisel Bilgi Formu, Somatizasyon Ölçeği ve A Duygusal Öz Farkındalık Ölçeği-10 (A-DÖFÖ-10) kullanılmıştır. Makine öğrenmesinde sıkça kullanılan sınıflandırma algoritmalarından K-En Yakın Komşu, Destek Vektör Makineleri, Naive Bayes ve Lojistik Regresyon kullanılmış; ilgili sınıflayıcıların performans karşılaştırması model başarımları ölçütlerine göre yapılmıştır.

**Bulgular:** Doğruluk ve f1-skoru değerleri göz önüne alındığında en iyi sınıflama performansı 0.74 doğruluk ve 0.82 f1-skoru değeri ile Lojistik Regresyondan elde edilmiştir.

**Sonuç:** Bu doğrultuda somatizasyon ve duygusal öz farkındalık kavramları üzerinden makine öğrenmesi yöntemleri ile bireylerin şiddet mağduriyetlerinin belirli bir doğruluk oranında tahmin edilebildiğini söylemek mümkündür.

**Anahtar Kelimeler:** Şiddet, Somatizasyon, Duygusal Öz Farkındalık, Makine Öğrenmesi

**Abstract:** **Objective:** This study aims to predict the violent victimization of individuals using the classification of algorithms of supervised learning, one of the methods of machine learning through somatization and emotional self-awareness concepts.

**Materials and Methods:** This study consisted of 552 participants, 149 (27%) male and 403 (73%) women. Personal Information Form, Somatization Scale and An Emotional Self Awareness Scale-10 (A-DÖFÖ-10) were used as data collection tools in this study. K-Nearest Neighbor, Support Vector Machines, Naive Bayes and Logistics Regression, one of the classification algorithms frequently used in machine learning, were applied.

**Results:** The performance comparison of the relevant classifiers was made according to the model performance criteria. Given accuracy and f1-score values, the best classification performance was derived from Logistics Regression with 0.74 accuracy and 0.82 f1-score value.

**Conclusions:** Accordingly, it is possible to say that the methods of machine learning through somatization and emotional self-awareness concepts can be used to estimate the victimization of violence of individuals at a certain rate of accuracy.

**Keywords:** Violence, Somatization, Emotional Self-Awareness, Machine Learning

DOI: 10.17986/blm.1385

Burcu Türk: Dr. Öğr. Üyesi, Haliç Üniversitesi, Psikoloji Bölümü, İstanbul.  
Eposta: burcuturk@halic.edu.tr  
ORCID ID: <https://orcid.org/0000-0003-3290-5886>

Hasan Halit Tali: Dr. Öğr. Üyesi, Haliç Üniversitesi, Matematik Bölümü, İstanbul.  
Eposta: hasantali@halic.edu.tr  
ORCID ID: <https://orcid.org/0000-0002-1704-3694>

#### Bildirimler

\* Sorumlu Yazar

#### Çıkar Çatışması

Yazarlar bu makale ile ilgili herhangi bir çıkar çatışması bildirmemişlerdir.

#### Finansal Destek

Yazarlar bu makale ile ilgili herhangi bir mali destek kullanımı bildirmemişlerdir.

#### Etik Beyan

Çalışma için Haliç Üniversitesi Etik Kurulundan 31.01.2020 tarih ve 8 sayılı izin alınmış olup Helsinki Bildirgesi kriterleri göz önünde bulundurulmuştur.

Geliş: 21.02.2020

Düzeltilme: 04.06.2020

Kabul: 11.06.2020

p-ISSN: 1300-865X

e-ISSN: 2149-4533

[www.adlitipbulteni.com](http://www.adlitipbulteni.com)

## 1. Giriş ve Amaç

İnsanlık tarihi kadar eski bir olgu olan şiddetin önemi günümüzde de bireyler ve toplumlar açısından devam etmektedir. Türk Dil Kurumu'nun şiddeti, "Bir hareketin, bir gücün derecesi, yeğinlik, sertlik", "hız", "bir hareketten doğan güç" ve "kaba güç" olarak tanımladığı görülürken etimolojik olarak bakıldığında Arapça şidda(t) kelimesinden geldiği ve sertlik, katılık, zorluk anlamlarını taşıdığı görülmektedir (1,2).

Dünya Sağlık Örgütü şiddeti; gücün ya da kuvvetin; kişinin kendisine, başka bir kişiye, bir gruba ya da topluluğa karşı kullanılarak fiziksel zarara veya fiziksel zararla sonuçlanma ihtimalini arttırmasına, psikolojik zarara veya ölüme sebebiyet vermesi olarak tanımlanmaktadır (3,4). Literatürde farklı şiddet türlerinin olduğu görülmektedir. Dünya Sağlık Örgütü şiddeti, kendine yönelik şiddet, kişilerarası şiddet ve kolektif şiddet olmak üzere üç kategoriye ayırmıştır. Kendine yönelik şiddet; kendine zarar verme ve intihar davranışını içerirken, kişilerarası şiddet, aile ve eş/flört şiddeti ile grup şiddeti şeklinde, kolektif şiddet ise sosyal, ekonomik ve siyasi olarak görülmektedir (5,6).

Ayrıca şiddet eylemlerinin ortaya çıkışında fiziksel şiddet, cinsel şiddet, psikolojik/duygusal şiddet ve ihmal/yoksun bırakılma olarak sınıflandırılması söz konusudur (4). Fiziksel şiddet, başkasının vücut bütünlüğüne zarar veren, ona acı çektiren her türlü saldırı olarak nitelendirilmekte; tokat, yumruk, tekme atmak, itmek, ısırarak, kolunu bükme, boğazını sıkma, kesici ya da delici bir alet ile yaralamak, işkence yapmak, ateşle ya da kaynar suyla yakmak gibi yöntemleri içermektedir (7). Cinsel içerikli tüm saldırgan davranışlar, "cinsel şiddet" başlığında değerlendirilir (8). Fiziksel güç, tehdit ve sindirme ile cinsel ilişkiye zorlama, aşağılayıcı cinsel eylemlerde bulunma, cinsel yolla bulaşan hastalıklara karşı korumak için önlemler alma hakkını elinden alma gibi davranışları içermektedir (9). Psikolojik/duygusal şiddet, sözlü aşağılama, takip etme, kontrol etme, kişinin başkalarıyla iletişimini sınırlandırma ve tehdit gibi tekrarlanan ya da birden fazla biçim olarak tanımlanmıştır (10). İhmal ise, kişinin, yiyecek, giyecek, ısınma gibi temel gereksinimlerinden mahrum edilmesi olarak tanımlanabilmektedir (11). Bu sınıflandırmaya ek olarak ayrıca ekonomik şiddetten de söz etmek gerekir. Ekonomik şiddet, bilerek kişinin para veya kaynaklarını çalmak, bir ortağın ekonomik refahına zarar vermek, mali durumu kontrol etmek, para için yalvarmak, temel ihtiyaçlarını satın almamak ve iş performansını sabote etmek gibi davranışları içerebilmektedir (12).

Kişilerarası şiddetin fiziksel ve ruhsal açıdan pek çok olumsuz etkisi söz konusudur. Fiziksel açıdan önemsiz

yaralanmalardan beyin hasarlarına hatta ölüme kadar değişebilen sonuçları olmaktadır. Ruhsal açıdan bireyin özgüveninde azalma, depresyon, anksiyete bozukluğu, travma sonrası stres bozukluğu, uyku bozuklukları, yeme bozuklukları, alkol ve madde kötüye kullanımı, kendini yaralama ve intihar davranışları, dikkat problemleri, öğrenme güçlükleri görülebilmesi söz konusudur (13, 3). Somatizasyon da kişiler arası şiddetin bir ruhsal sonucu olarak karşımıza çıkmaktadır.

Somatizasyon, ruhsal sıkıntıların ve psikososyal stresin duygusal ve bilişsel olmasından ziyade bedensel belirtilerle ifade edilmesi olarak tanımlanabilmektedir (14). Somatizasyonun ortaya çıkışını açıklamak için bir takım teoriler öne sürülmüştür. Bunlardan birine göre, olumsuz çocukluk deneyimlerinin somatizasyon davranışı gelişimine katkıda bulunmasıdır (15). Aile üyelerinde bedensel hastalık ya da hastalık davranışının bulunması ve bireyin bedensel yakınmalar yoluyla çevreden ilgi ve sevgi toplamaya ilişkin deneyimleri ve ikincil kazançların varlığı da somatizasyonu destekleyen etkenlerdir. Özellikle çocukluk çağı travmatik yaşantıları nedeniyle bireylerin duygusal yaşantılarını söze dökme yeteneğinin kısıtlanması dolayısıyla sözelleştirilemeyen duyguların bedensel belirtiler yoluyla ifade edilmesi söz konusudur (14). Bu noktada duygusal öz farkındalık kavramına değinmek gerekmektedir. Duygusal öz farkındalık; dikkati duygular üzerine odaklayabilmeyi, duygusal yaşantılar üzerine düşünebilmeyi, duygular hakkında genel değerlendirmeler yapabilmeyi gerektirmektedir. Duyguları tanıma ve anlamlandırma becerilerinden yoksun olan bireylerin, duygularını doğru bir şekilde değerlendiremedikleri için duyguları yönetmede ve olumsuz duygularla baş etmede güçlük yaşamaları söz konusudur (16).

Son yıllarda Psikoloji, Psikiyatri ve Adli Bilimler alanları da dahil olmak üzere pek çok alandaki araştırmada yapay zekanın evrelerinden biri olan makine öğrenmesi yöntemlerinin kullanıldığı görülmüştür. Makine öğrenmesi yöntemleri kullanılarak yapılmış çalışmalara bakıldığında Oh, Yun, Hwang & Chae (2017) 573 katılımcı üzerinden intiharı tahmin etmişlerdir. Çalışmanın sonuçlarına göre kullanılan modelin genel doğruluk oranı 1 aylık süre içinde % 93.7, 1 yılda % 90.8 ve yaşam boyu intihar girişimlerinde % 87.4 olarak tespit edilmiştir (17). Chekroud ve ark.nın (2016) çalışmalarında, depresyonun tedavisine yönelik kullandıkları modellerden birinde tahmin oranı % 59.6, diğer modelde % 59.7 olarak bulunmuştur (18). Yöntem ve Adem'in (2019) çalışmalarında ise Destek Vektör Makineleri (DVM) modelindeki polinomsal dağılım bulguları incelendiğinde otomatik düşüncelerin aleksitimi düzeyini büyük oranda tahminleyebildiği görülmekte olup, bu bulgu aleksitiminin bilişsel

davranışçı terapiler kapsamında ele alınmasının sağaltım açısından yararlı olacağını göstermektedir (19)

Makine öğrenmesi, bilgisayarların örnek veri ya da geçmiş deneyimi kullanarak başarımlarını arttıracak biçimde programlanması şeklinde tanımlanmaktadır (20). Makine öğrenmesine dayalı yöntemler, veri birimleri arasındaki etkileşimi hesaba katmakta, aynı zamanda istatistiksel çıkarımlarda da bulunarak sınıflandırma, teşhis ve koruyucu önlemlerin alınmasında kullanılmaktadır. (21,22). Bu çalışmada kullanılan ve makine öğrenmesine dayalı yöntemlerden biri olan gözetimli öğrenme, bir özelliği tahmin etmek için kullanılır. Tahmin edilmek istenen özellik bir kategori veya sayısal bir değer olabilir. Bunun için daha önceden gözlemlenmiş ve sonucu bilinen bir veri seti kullanılarak bilinen farklı özellikler ile hedef değer arasında bir ilişki bulunmaya çalışılır (23).

Bu çalışmanın amacı da somatizasyon ve duygusal öz farkındalık kavramları üzerinden makine öğrenmesi yöntemlerinden biri olan gözetimli öğrenmenin sınıflandırma algoritmaları ile bireylerin şiddet mağduriyetlerinin tahmin edilmesidir. Bu bağlamda birinci basamak sağlık kuruluşlarına başvurularda bedensel yakınmalar ve kişilerin duygusal öz farkındalıklarına ilişkin yanıtları daha kolay alabilmenin mümkün olması ile şiddet mağduriyetlerinin fark edilmesi, tespit edilmesi, adli mercilere bildirim yapılması ve tedavi sürecine başlanması noktasında süreçlerin hızlanması için yol gösterici niteliğinde olacağı düşünülmektedir. Ayrıca gelecekteki çalışmalar için de bir kaynak oluşturulması amacını da taşımaktadır.

## 2. Gereç ve Yöntem

Çalışmanın evrenini, 2018 yılı TÜİK verilerine göre 18-30 yaş arası genç yetişkin olan 12.823.598 kişi oluşturmaktadır (24). Evrenden basit tesadüfi örnekleme yöntemi ile örneklem belirlendiğinde % 95 güven aralığı, % 5 düzeyinde hata payıyla en az 385 katılımcının analiz yapmak için yeterli olacağı bulunmuş olup, araştırma için 552 kişiye ulaşılmıştır.

Araştırmada veri toplama araçları olarak Kişisel Bilgi Formu, Somatizasyon Ölçeği ve A Duygusal Öz Farkındalık Ölçeği-10 (A-DÖFÖ-10) kullanılmıştır.

*Kişisel Bilgi Formu:* Katılımcıların demografik özelliklerini belirlemek için araştırmacılar tarafından hazırlanmış olup; cinsiyet, yaş, medeni durum, eğitim durumu gibi bazı değişkenlere dair soruları içermektedir.

*Somatizasyon Ölçeği:* Somatizasyon Ölçeği, Minnestota Çok Yönlü Kişilik Envanteri (MMPI)'nin somatizasyon bozukluğu ile ilgili olan maddelerinden alınarak Dülgerler (2000) tarafından geçerlik, güvenilirlik çalışması yapılmış ve toplamda 33 maddeden oluşmaktadır.

Somatizasyon ölçeğinin, iç tutarlık güvenilirlik katsayısı (Kuder Richardson-20) 0.83, test retest güvenilirlik kat sayısı 0.996, testi yarılama tekniği (Split-Half) ile 1. yarı alpha değeri 0.8810, 2. yarı alpha değeri 0.8439, SCL-90-R ölçeği ile olan benzer ölçek korelasyonu (Pearson Momentler Çarpımı korelasyon katsayısı) 0.80 olarak bulunmuştur (25). Ölçekteki her maddenin “doğru” ya da “yanlış” olmak üzere iki seçeneği vardır. Ölçeğin puanlaması yapılırken, 1-4-5-6-7-10-11-19-20-21-22-23-26-27- 32-33 numaralı ifadeler “doğru” yanıtı verildiğinde 1 puan, “yanlış” yanıtı verildiğinde 0 puan, 2-3-8-9-12-13-14-15-16-17-28-24-25-28-29-30-31 numaralı ifadeler “yanlış” yanıtı verildiğinde 1 puan, “doğru” yanıtı verildiğinde ise 0 puan verilir. Toplam puan doğru ve yanlış cevaplardan alınan puanlar toplanarak elde edilir. Ölçekten alınan puanlar 0-33 arasında değişmektedir. Toplam puanın artması somatizasyon belirtilerinin yüksek olduğuna işaret eder. Bu veriler doğrultusunda somatizasyon ölçeği geçerli ve güvenilir bir ölçek olarak saptanmıştır (25).

*A Duygusal Öz Farkındalık Ölçeği-10 (A-DÖFÖ-10):*

10 maddeden oluşan ölçek için yapılan güvenilirlik ve madde analizi sonuçlarına göre içtutarlılık güvenilirlik katsayısı hem kadın grubunda hem erkek grubunda hem de tüm grupta 0,85 olarak hesaplanmıştır. Ölçek 5’li Likert tipinde olup puan aralığı 10-50 arasında değişmektedir ve alınan yüksek puan duyguları okuma, fark etme becerisinin yüksek oluşunu göstermektedir. (16).

Bu çalışmada makine öğrenmesi yöntemlerinden gözetimli öğrenme yöntemi kullanılmıştır. Girdi değerleri kullanılarak gözetimli öğrenme yönteminin sınıflandırma algoritmaları ile bireylerin şiddet mağduriyetleri tahmin edilmiştir. Ayrıca karmaşıklık matrisi (confusion matrix) kullanılarak doğruluk (accuracy), kesinlik (precision) ve hassaslık (recall) oranları hesaplanarak çıkarımlar yapılmıştır. Makine öğrenmesi için kullanılmış olan programlama dili Python olup kodları yazmak için kullanılan ortam Anaconda içindeki Spyder olarak belirlenmiştir.

Bu çalışmada kullanılan sınıflandırma algoritmalar şu şekildedir:

### i. K-En Yakın Komşu(KNN)

K-En Yakın Komşu kuralı parametrik olmayan sınıflandırıcılardan biridir. K-En Yakın Komşu algoritmasında yeni bir örneğin sınıfı, örneğin belirlenen bir k değerine göre, mevcut örneklem içindeki örneklere olan uzaklığı hesaplanarak tespit edilir. Algoritma şu şekilde ifade edilir:

İlk olarak sınıfı belirlenmek istenen örneğin, eğitim örnekleminde yer alan örneklere uzaklığı hesaplanır. Daha sonra hesaplanan uzaklıklar sıralanır, içlerinden en

küçük k tanesi seçilir. Son olarak yeni örneğin sınıfının tespiti için oylama yapılır.

$X = x_1, x_2, x_3, \dots, x_n$  örnek uzayı olmak üzere, keyfi bir  $x_i \in X$  örneği için  $a_r(x_i)$ ,  $x_i$ 'nin  $r$ . niteliğinin değerini gösterir.

$$d(x_i, x_j) = \sqrt{\sum_{i=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (1)$$

fonksiyonu bu çalışmada bu algoritma için uzaklık fonksiyonu (Öklid uzaklığı) olarak kullanılmıştır. Ayrıca oylama olarak da bu çalışmada en çok tekrar eden sınıfın, yeni örneğin aranan sınıfı olduğu Çoğunluk Oylaması kullanılmıştır (K=19 seçilmiştir.) (26).

## ii. Naive Bayes

Naive Bayes algoritması, her niteliğin sonuca etkisinin koşullu olasılığının hesaplanmasına dayanan istatistiksel bir yöntemdir. Bu algoritma şu şekilde ifade edilir:

$$X = \begin{bmatrix} \vec{x}_1 \\ \vec{x}_2 \\ \vdots \\ \vec{x}_m \end{bmatrix} \quad m \text{ adet örnekten oluşan örnek uzayı}$$

$$\begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \in R^{m \times n} \quad n \text{ adet nitelik ve } m \text{ adet veriden}$$

oluşan gözlem matrisi,  $C_1, C_2, \dots, C_k$  örnek uzaydaki sınıf değerleri ve  $\vec{x} \in X$  ise örnek uzayından alınan ve sınıfı bilinmeyen veri örneği olmak üzere;

$$P(c_j | \vec{x}) = \frac{P(\vec{x} | c_j) \cdot P(c_j)}{P(\vec{x})}, \quad j = 0, 1, 2, \dots, k \quad (2)$$

$$P(\vec{x} | c_j) = \prod_{i=1}^n P(x_{ai} | c_j), \quad i = 0, 1, 2, \dots, n, \quad j = 0, 1, 2, \dots, k \quad (3)$$

şeklindedir. Sınıfı bilinmeyen örneğin sınıfı

$$\operatorname{argmax}_{c_j} \{P(x_{ai} | c_j) \cdot P(c_j)\} \quad (4)$$

denklemleri ile bulunur. Bu çalışmada Gaussian Yöntemi kullanılmıştır.

Bunun için  $\mu_{c_j}$  ortalama,  $\sigma_{c_j}$  standart sapma olmak üzere,

$$P(x_i | y_i) = \frac{1}{\sigma_{c_j} \sqrt{2\pi}} \cdot e^{-\frac{1}{2} \left( \frac{x_i - \mu_{c_j}}{\sigma_{c_j}} \right)^2} \quad (5)$$

olarak ele alınmıştır.

## iii. Lojistik Regresyon

Regresyon Analizi iki ya da daha fazla değişken arasındaki ilişkileri ölçmek için kullanılmakta, tanımlayıcı ve çıkarımsal istatistik sağlamaktadır. Lojistik Regresyon Analizinde temel amaç; bağımlı ve bağımsız değişkenler arasındaki ilişkiyi, en az değişken ile en iyi uyuma sahip olacak şekilde tanımlayabilen, kabul edilebilir bir modeli kurabilmektir.

Bu çalışmada bağımlı değişkenin iki kategorili olma durumu olan ikili lojistik regresyon kullanılmıştır. Lojistik Regresyon Modeli şu şekilde ifade edilir:

$x_{ik}$  lar tasar matrisinin elemanları,  $y_i$  ler her bir popülasyonda gözlenen başarıları gösteren elemanlar,  $N$  popülasyonların toplam sayısı,  $M$  toplam gözlem sayısı,  $n_i$  ler  $i$ . popülasyondaki gözlem sayısı ve  $\beta$  parametre vektörü olmak üzere log olabirlik fonksiyonu

$$l(\beta) = \sum_{i=1}^N y_i \cdot \left( \sum_{k=0}^K x_{ik} \cdot \beta_k \right) - n_i \cdot \ln \left( 1 + e^{\sum_{k=0}^K x_{ik} \cdot \beta_k} \right) \quad (6)$$

şeklindedir.

Bu fonksiyonun her  $\beta$  için birinci dereceden türevi sıfıra eşitlenerek  $\beta_k$  lar çözülür.

$$\frac{\partial l(\beta)}{\partial \beta_k} = \sum_{i=1}^N y_i x_{ik} - n_i \pi_i x_{ik} = 0 \quad (7)$$

## iv. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri kenar payını ölçüt olarak kullanılır. Model parametreleri öğrenme örneklerinin bir alt kümesinin etkilerinin ağırlıklı toplamı olarak yazılır ve bu etkiler uygulamaya özgü bir benzerlik çekirdeğince tanımlanır.

Lojistik Regresyon Modeli şu şekilde ifade edilir:

$X = \{x^t, r^t\}$  örnekleminde  $x^t \in C_1$  ise  $r^t = +1$  ve  $x^t \in C_2$  ise  $r^t = -1$  olsun.  $w$  ve  $w_0$  parametreleri

$$r^t (w^T x^t + w_0) \geq +1 \quad (8)$$

koşullarını sağlasın. Lineer olarak ayrılma durumunda, iki sınıflı bu veriler ayırıcı bir düzlem ile ayrılabilir. Burada amaç sınıflama hatasını en küçük yapacak üstün düzlemi seçmektir. Bunun için iyi  $w$  ve  $w_0$  değerleri belirlenmelidir.

$$\min \frac{1}{2} \|w\|^2 \quad (9)$$

probleminin kısıtı altındaki çözümü en iyi  $w$  ve  $w_0$  değerlerini verir. (20).

Bu çalışmada bu algoritmada lineer çekirdek fonksiyonu kullanılmıştır.



### Model Başarısı

Bu çalışmada sınıflandırma algoritmalarının başarılarını ölçmek için karmaşıklık matrisi (Confusion Matrix) kullanılmıştır. Karmaşıklık matrisine ait tanım ve formüller şu şekildedir:

Karmaşıklık matrisi kabaca; bir ekseninde tahmin değerlerinin diğer ekseninde gerçek değerlerin olduğu bir matristir.

Karmaşıklık matrisi Doğru Pozitif, Doğru Negatif, Yanlış Pozitif ve Yanlış Negatif ifadelerinden oluşmaktadır.

Gerçekte sınıfı pozitif olan örneği model de pozitif olarak sınıflandırırsa bu durum doğru pozitif, yanlış olarak sınıflandırırsa yanlış negatif olarak isimlendirilir.

Gerçekte sınıfı negatif olan örneği model de negatif olarak sınıflandırırsa bu durum doğru negatif, pozitif olarak sınıflandırırsa yanlış pozitif olarak isimlendirilir.

**Tablo 1. Karmaşıklık matrisi**

	Tahmin	Tahmin
Gerçek $C_1$	Doğru Pozitif (DP) $C_1$	Yanlış Negatif (YN) $C_1$
Gerçek $C_2$	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Doğruluk (Accuracy): Doğru sınıflandırılmış örneklerin sayısının toplam örnek sayısına oranıdır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (10)$$

Kesinlik (Precision): Modelin pozitif grupta sınıflandırdığı gözlemlerdeki isabet oranıdır.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (11)$$

Duyarlılık (Recall): Modelin gerçekte pozitif grupta olan gözlemlerdeki isabet oranıdır.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (12)$$

f1-skoru: Kesinlik ve duyarlılığın harmonik ortalamasının hesaplanması ile bulunan f1-skoru değeri de model performans göstergesi olarak kullanılmaktadır (23).

$$f1 - \text{skoru} = 2 \cdot \frac{\text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (13)$$

### Etik Beyan

Çalışma için Haliç Üniversitesi Etik Kurulundan 31.01.2020 tarih ve 8 sayılı izin alınmış olup Helsinki

Bildirgesi'ne kriterleri göz önünde bulundurulmuştur. Katılımcılara ölçekler uygulanmadan önce araştırma hakkında bilgi verilmiş ve araştırmaya katılma konusunda gönüllük esası olduğu belirtilmiştir.

### 3. Bulgular

Araştırma grubu 149 (%27) erkek ve 403 (%73) kadın olmak üzere toplam 552 katılımcıdan oluşmaktadır. Katılımcıların yaşları 18 ile 30 arasında değişmektedir ( $\bar{x}$ = 20.69, SD=2.68). Erkek katılımcıların yaş ortalaması 21.87±2.90, kadın katılımcıların yaş ortalaması ise 20.25±2.46 dır.

Kadın katılımcıların 309'unun (%77), erkek katılımcıların da 82'sinin (%55) şiddetin herhangi bir türüne maruz kaldığı tespit edilmiştir.

#### I. Veri Seti

Bu çalışma 552 veriden oluşmaktadır. Bu verilerin her biri Kişisel Bilgi Formu, Somatizasyon ve Duygusal Öz Farkındalık Ölçeklerinin sorularının cevaplarından oluşan 52 adet özelliğe sahiptir. Makine Öğrenmesi Algoritmalarının kullanılacağı temizlenmiş veri seti girdileri (552,52) boyutunda çıktıkları ise bireylerin şiddet mağduriyetlerinden oluşan (552,1) boyutunda veri çerçeveleridir (Dataframe).

**Tablo 2. Modellerden elde edilen karmaşıklık matrisleri**

	P N	Tahmin		
		P	N	
KNN	Gerçek	P	113	16
		N	44	10
DVM	Gerçek	P	106	23
		N	30	24
NAİVE BAYES	Gerçek	P	83	46
		N	21	33
Lojistik Regr.	Gerçek	P	109	20
		N	27	27

#### II. Değerlendirme

Bu çalışmada kullanılan veri seti 552 veriden oluşmaktadır. Bu veri setinin %33'lük kısmı (183 veri) test, %67'lik kısmı (369 veri) eğitim kümesi olarak ayrılmıştır. Daha sonra eğitim ve test kümesindeki girdi verileri

standardize edilmiştir. Standardize edilen eğitim verileri ile KNN, Naive Bayes, DVM ve Lojistik Regresyon modelleri oluşturulmuştur. P değeri şiddete uğramış kişilerin sayısını, N değeri ise şiddete uğramamış kişilerin sayısını göstermek üzere test verileri üzerinden her bir model için karmaşıklık matrisleri elde edilmiştir.

Karmaşıklık matrislerindeki veriler ile her bir model için doğruluk, kesinlik, duyarlılık ve f1-skoru değerleri elde edilmiştir. Doğruluk ve f1-skoru değerleri göz önüne alındığında en iyi sınıflama performansı 0.74 doğruluk ve 0.82 f1-skoru değeri ile Lojistik Regresyondan elde edilmiştir.

**Tablo 3. Model başarı değerleri**

Yöntem	Doğruluk	Kesinlik	Duyarlılık	f1-skoru
KNN	0.67	0.72	0.88	0.79
DVM	0.71	0.78	0.82	0.80
Naive Bayes	0.63	0.80	0.64	0.63
Lojistik Regr.	0.74	0.80	0.84	0.82

#### 4. Tartışma ve Sonuç

Bu araştırmada somatizasyon ve duygusal öz farkındalık kavramları üzerinden makine öğrenmesi yöntemlerinden biri olan gözetimli öğrenmenin sınıflandırma algoritmaları ile bireylerin şiddet mağduriyetlerinin tahmin edilmesi çalışması yapılmıştır. Makine öğrenmesinde sıkça kullanılan sınıflandırma algoritmalarından K-En Yakın Komşu, Destek Vektör Makineleri, Naive Bayes ve Lojistik Regresyon kullanılmış; ilgili sınıflayıcıların performans karşılaştırması model başarı ölçütlerine göre yapılmıştır. Bu başarı ölçütleri incelendiğinde en yüksek değerler Lojistik Regresyondan elde edilmiştir.

Yapılan bir meta-analiz çalışmasında (Singh, Grann & Fazel, 2011) şiddet riski ölçüldüğünde %70 ile %74 arasında ortalama bir doğruluk oranı çıkmaktadır (27). Blair, Blattman ve Hartman (2015), araştırmalarında 2008 risk faktörlerini kullanarak yapmış oldukları modellerinin 2012 yılında gerçekleşen şiddetin %88'ini tahmin ettiği sonucuna ulaştılar (28) Menger, Scheepers ve Spruit (2018) ise şiddet riskini değerlendirmek için ulaştıkları % 78'lik doğruluk oranının umut verici olduğunu nitelendirdiler (29). Bu çalışmada ise şiddetin tahmini açısından %74'lük bir doğruluk oranının çıktığı görülmektedir.

Araştırmanın bulguları doğrultusunda literatürle de uyumlu olarak şiddetin bir ruhsal sonucu olan somatizasyon ile duyguları tanıma ve anlamlandırma becerilerinden yoksun olup olmamanın yani duygusal öz farkındalık kavramı üzerinden makine öğrenmesi yöntemlerinden

biri olan gözetimli öğrenmenin sınıflandırma algoritmaları ile bireylerin şiddet mağduriyetlerinin belirli bir doğruluk oranında tahmin edilebildiğini söylemek mümkündür. Her ne kadar literatürde duygusal öz farkındalık ve somatizasyon kavramları üzerinden şiddetin tahminine yönelik bir çalışmaya rastlanmadıysa da benzer amaçlı çalışmalarla doğruluk oranının paralel çıkması söz konusudur. Bu bağlamda sağlık kuruluşlarına başvurularda bedensel yakınmalar ve kişilerin duygusal öz farkındalıklarına ilişkin yanıtları daha kolay alabilmenin olanaklı olması ile bireylerin şiddet mağduriyetleri fark edilebilir. Fark edilme noktasında kişilerin yaşadıkları şiddete ilişkin daha ayrıntılı görüşme yapılması, tanı konulması ve tedavi sürecine bir an önce başlanması gerçekleştirilebilir. Ayrıca adli mercilere bildirim yapılması gerekliliği söz konusu ise hukuki sürecin başlaması hızlanabilir. Bunun yanı sıra şiddet mağduriyeti açısından risk taşıyan kişilerin de tespit edilmesi ve önüne geçilebilmesi de söz konusu olacaktır. Bu açıdan araştırma önleme stratejilerinin önemine odaklanmaktadır.

Gerek dünyada gerekse ülkemizde yaşanan şiddet olaylarının sıklığı ile bireylerin şiddet mağduru olduğunda bunu açıklayabilmesi ve/veya bildirim yapmasında engel teşkil eden unsurların olması göz önüne alındığında bunun fark edilmesi ve gerekli müdahalelerin yapılması önem arz etmektedir. Şiddetin önüne geçilebilmesi; bilinçli olunması, ihtiyaçların tespit edilmesi, gerekli prosedürlerin uygulanması ile mümkündür.

Bu araştırmada şiddetin sadece duygusal öz farkındalık ve somatizasyon boyutları üzerinden değerlendirilmesi söz konusudur. Gelecekte konuyla ilgili olarak şiddetin diğer gözlemlenebilir sonuçları üzerinden de araştırmalar yapılmasının katkı sağlayacağı düşünülmektedir. Ayrıca veri ve örneklem sayısının artırılmasının doğruluk oranı tahminini yükseltebileceği düşünülmektedir.

Mevcut çalışma, bireylerin şiddet mağduriyetlerini ortaya koyma, hem ileride yapılacak çalışmalara hem de şiddeti önleme çalışmalarına katkı sağlama ve yol gösterici nitelikte olma amacı taşımaktadır. Ancak çalışmaya katılan bireylerin %73'ünün kadın, %27'sinin erkek olması cinsiyetler arasında karşılaştırma imkanını zorlaştırmıştır. Konuyla ilgili yapılacak gelecek araştırmalarda kadın ve erkek katılımcıların birbirine yakın sayıda olması yerinde olacaktır. Ayrıca yaş grupları açısından farklı yaş gruplarının da dahil edilmesinin uygun olacağı varsayılmaktadır. Bunun yanı sıra bu araştırmanın sadece şiddetin herhangi bir türüne maruz kalıp kalmaması kısmına odaklanmış olduğu, farklı şiddet türlerine ilişkin çalışmalar yapılmasının da fayda sağlayacağı düşünülmektedir.

Sonuç olarak yaşanan teknolojik gelişmelerle birlikte makine öğrenmesinin yaşamımıza dahil olmasının

Psikoloji, Psikiyatri ve Adli Bilimler alanları da dahil olmak üzere pek çok alanda sağlayacağı katkıları göz ardı etmemek gerekmektedir.

## Kaynaklar

1. Türk Dil Kurumu. Şiddet. <http://sozluk.gov.tr/> erişim tarihi: 13.12.2019.
2. <https://www.nisanyansozluk.com/?k=%C5%9Fiddet>. erişim tarihi: 13.12.2019.
3. Güleç H, Topaloğlu M, Ünsal D, Altıntaş M.(2012) Bir kısır döngü olarak şiddet. Psikiyatride Güncel Yaklaşımlar, 4 (1):112-137. <https://doi.org/10.5455/cap.20120408>
4. World Health Organization (2002). World report on violence and health. Geneva: WHO. World Health Organization
5. Mil, H.İ. ve Şanlı, S. (2015). Sporda Şiddet ve Medya Et-kisi: Bir Maçın Analizi. Elektronik Sosyal Bilimler Dergisi, 14 (55):231-247. <https://doi.org/10.17755/esosder.54183>
6. Karşlı, N. (2016). Psiko-sosyal Açıdan Şiddet ve Çözüm Yolları. Dinbilimleri Akademik Araştırma Dergisi. 16 (3):63-89
7. Özgentürk, İ. , Karğın , V. ve Baltacı , H (2012). Aile İçi Şiddet ve Şiddetin Nesilden Nesile İletilmesi. Polis Bilimleri Dergisi Cilt:14(4):55-77.
8. Kayı, Z., Yavuz, M. F., & Arıcan, N. (2000). Kadın Üniversite Gençliği ve Mezunlarına Yönelik Cinsel Saldırı Mağdur Araştırması. Adli Tıp Bülteni, 5(3): 157-163. <https://doi.org/10.17986/blm.200053421>.
9. Krantz, G.& Garcia-Moreno, C. (2005). Violence against women. J Epidemiol Community Health. 59 (10): 818-821. 10.1136/jech.2004.022756. <https://doi.org/10.1136/jech.2004.022756>
10. Leithner, K., Assem-Hilger, E., Naderer, A., Umek, W., Springer-Kremser, M. (2009). Physical, sexual, and psychological violence in a gynaecologicalpsychosomatic outpatient sample: prevalence and implications for mental health. Eur J Obstet Gynec Reprod Biol; 144: 168–72. <https://doi.org/10.1016/j.ejogrb.2009.03.003>
11. Akdemir, P. , Görgülü, A., Çınar, Y . (2008). Yaşlı İstismarı ve İhmali. Hacettepe Üniversitesi Hemşirelik Fakültesi Dergisi , 15 (1): 68-75. <https://dergipark.org.tr/pub/hunhemsire/issue/7845/103307>
12. Davis, M. (2018) The Intersection of Intimate Partner Violence Perpetration, Intervention and Faith. Arts & Sciences Electronic Theses and Dissertations. 1524. [https://open-scholarship.wustl.edu/art\\_sci\\_etds/1524](https://open-scholarship.wustl.edu/art_sci_etds/1524)
13. Okan İbiloğlu, A. (2012) Aile İçi Şiddet. Psikiyatride Güncel Yaklaşımlar-Current Approaches in Psychiatry;4(2):204-222. <https://doi.org/10.5455/cap.20120413>
14. Kesebir S (2004) Depresyon ve Somatizasyon. Klinik Psikiyatri, Ek 1:14-9.
15. Stuart, S. & Noyes, R. Jr.(1999) Attachment and interpersonal communication in somatization. Psychosomatics;40:34-43. [https://doi.org/10.1016/S0033-3182\(99\)71269-7](https://doi.org/10.1016/S0033-3182(99)71269-7).
16. Tatar, A., Özdemir, H., Çelikbaş, B., & Özmen H. E. (2018). A Duygusal Öz Farkındalık Ölçeği'nin Geliştirilmesi ve Klinik Olmayan Örnekleme Duygusal Öz Farkındalığın Kaygı ve Depresyondaki Rolünün İncelenmesi. Social, Mentality and Researcher Thinkers Journal, 4(13): 793-806. <https://doi.org/10.31576/smryj.125>
17. Oh, J., Yun, K., Hwang, J-H. and Chae, J-H. (2017) Classification of Suicide Attempts through a Machine Learning Algorithm Based on Multiple Systemic Psychiatric Scales. Front. Psychiatry 8:192. <https://doi.org/10.3389/fpsy.2017.00192>
18. Chekroud, A.M., Zotti, R.J., Shehzad, Z., Gueorguieva, R., Johnson, M.K., Trivedi,M.H., Cannon, T.D., Krystal, J.H. & Corlett, P.R. (2016) Cross-trial prediction of treatment outcome in depression: a machine learning approach. Lancet Psychiatry 3, 243–250. [https://doi.org/10.1016/S2215-0366\(15\)00542-8](https://doi.org/10.1016/S2215-0366(15)00542-8)
19. Yöntem, M. ve Adem, K. (2019). Otomatik Düşüncelere Makine Öğrenme Yöntemlerinin Uygulanması ile Aleksitimi Düzeyinin Tahmini. Psikiyatride Güncel Yaklaşımlar , 11 ( ) , 64-78 . <https://doi.org/10.18863/pgy.554788>
20. Alpaydın, E. (2018). Yapay Öğrenme (4.Baskı). Boğaziçi Üniversitesi Yayınevi.
21. Uyulan, Ç., Tekin Ergüzel, T. ve Tarhan, N. (2019) Elektroensefalografi Tabanlı Sinyallerin Analizinde Derin Öğrenme Algoritmalarının Kullanılması. The Journal of Neurobehavioral Sciences: 6(2): 108-124. <https://doi.org/10.5455/JNBS.1553607558>
22. Yılmaz Akşehirli, Ö., Ankaralı H, Aydın D, Saraçlı Ö. (2013) Tıbbi Tahminde Alternatif Bir Yaklaşım: Destek Vektör Makineleri. Türkiye Klinikleri Biyoistatistik Dergisi;5(1):19-28.
23. Arslan, İ. (2019). Python ile Veri Bilimi(1. Baskı). Pusula 20 Teknoloji ve Yayıncılık.
24. TÜİK (2018) Türkiye İstatistik Kurumu İstatistikleri. <https://tuik.gov.tr/>. erişim tarihi: 17.02.2020.
25. Dülgerler, Ş. (2000). İlköğretim okulu öğretmenlerinde somatizasyon ölçeğinin geçerlik ve güvenilirliği. Ege Üniversitesi Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, İzmir.
26. Balaban, M. E., Kartal E., (2015). Veri Madenciliği ve Makine Öğrenmesi (1.Baskı). İstanbul:Çağlayan Kitabevi.
27. Singh, J.P., Grann, M. & Fazel, S. (2011) A comparative study of violence risk assessment tools: a systematic review and metaregression analysis of 68 studies involving 25,980 participants. Clin. Psychol. Rev., 31 (3): 499-513. <https://doi.org/10.1016/j.cpr.2010.11.009>
28. Blair, R., Blattman, C. & Hartman, A. (2015) Predicting Local Violence. American Journal of Political Science. 1-81. <https://doi.org/10.2139/ssrn.2497153>
29. Menger, V., Scheepers, F., Spruit, M. (2018) Comparing Deep Learning and Classical Machine Learning Approaches for Predicting Inpatient Violence Incidents from Clinical Text. Appl. Sci., 8 (6), 981. <https://doi.org/10.3390/app8060981>