

ARAŞTIRMA RESEARCH

Otomatik Düşüncelere Makine Öğrenme Yöntemlerinin Uygulanması ile Aleksitimi Düzeyinin Tahmini

Prediction of the Level of Alexithymia through Machine Learning Methods Applied to Automatic Thoughts

Mustafa Kemal Yöntem¹, Kemal Adem²

Öz

Bu araştırmada bilişsel davranışçı terapi kavramlarından otomatik düşüncelerin aleksitimi ile ilişkisi incelenmiştir. Bu amaçla otomatik düşünceler ölçeğini oluşturan etkili özellikleri tespit etmek için FisherScore analizi uygulanmıştır. Ayrıca veri kümesinin Yapay Sinir Ağı (YSA) ve Destek Vektör Makinesi (DVM) makine öğrenmesi yöntemlerine giriş olarak verilmesiyle aleksitimi düzeyi tahmin edilmiş ve bu sayede önceliğin hangi otomatik düşüncelere vermesi gerektiği konusunda bir yol haritası sunulması amaçlanmıştır. Araştırma Türkiye'nin 10 farklı ilinden 386 (%54) erkek 328 (%46) kadın olmak üzere 714 katılımcı ile gerçekleştirilmiştir. Katılımcılara kişisel bilgiler formu, Otomatik Düşünceler Ölçeği ve Toronto Aleksitimi ölçeği uygulanmıştır. Otomatik düşünceler ölçeğinden elde edilen veri kümesine Fisher Score yöntemi ile öznelik seçim işlemi uygulanarak 5 adet öznelik içeren veri kümesi elde edilmiştir. Bu veri kümesine DVM yönteminin uygulanması sonucunda 4.01 RMSE hatası ile aleksitimi seviyesi tahmin edilmiştir. Sonuçlar otomatik düşünceler ölçeğindeki özneliklerin aleksitimi düzeyi ile ilişkili olduğunu göstermektedir.

Ahtar sözcükler: Aleksitimi, otomatik düşünce, makine öğrenmesi.

Abstract

This study aims to investigate the relationship among alexithymia levels and automatic thoughts from cognitive behavioral therapy concepts. For this aim, Fisher Score analysis was applied to determine the most effective attributes of the automatic thoughts scale. In addition, the level of alexithymia was predicted by the introduction of the data set into the machine learning methods of the Artificial Neural Network (ANN) and Support Vector Machine (SVM). It is aimed to develop a roadmap of what automatic thoughts should be given priorities in studies. The research, from 10 different provinces of Turkey, was performed with a total of 714 participants, of which 386 (54%) male and 328 (46%) female. Personal information form, Automatic Thoughts Scale and Toronto Alexithymia scale were applied to the participants. The data set obtained from the scale of automatic thoughts was applied to the feature selection by using the Fisher Score method and a data set containing 5 attributes was obtained. As a result of the implementation of the SVM method to this data set, the alexithymia level was predicted with 4.01 RMSE error. The results show that the features of the automatic thoughts are related to the alexithymia level.

Keywords: Alexithymia, automatic thoughts, machine learning.

¹ Nevşehir Hacı Bektaş Veli Üniversitesi Eğitim Fakültesi, Rehberlik ve Psikolojik Danışmanlık Anabilim Dalı, Nevşehir,

² Aksaray Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Yönetim Bilişim Sistemleri Bölümü, Aksaray

✉ Mustafa Kemal Yöntem, Nevşehir Hacı Bektaş Veli Üniv. Eğitim Fakültesi, Rehberlik ve Psikolojik Danışmanlık Anabilim Dalı, Nevşehir, Turkey
muskemtem@hotmail.com

ALEKSİTİMİ kısaca duygusal körlük şeklinde tanımlanabilir (Grabe ve ark. 2004). Aleksitimik özellik gösteren kişinin duygularını anlama ve düzenleme konusunda zorluk yaşadığı belirtilmektedir (Nemiah ve ark. 1970, Motan ve ark. 2007). Aleksitimi üzerine yapılan araştırmalar incelendiğinde genel olarak aleksitiminin çeşitli psikiyatrik bozukluklarla ilişkisinin incelendiği görülecektir (Honkalampi ve ark. 2000, Berthoz ve ark. 2007, Declercq ve ark. 2010, Coriale ve ark. 2012, Coolidge ve ark. 2013). Bununla birlikte aleksitiminin açıklanmasında çeşitli kuramsal bakış açıları bulunmakla beraber (Stephanos 1975, Wolff 1977, Levant 1992) bilişsel davranışçı terapiler alan uzmanları tarafından en çok tercih edilen modeller arasında yer almaktadır.

Bilişsel bakış açısına göre duygusal bozuklukların temelinde bilişlerin önemli bir etken olduğu ileri sürülmektedir (Stoudemire 1991). Bilişsel terapinin kurucu olan Beck (1979), psikolojik problemlerin sağaltımında bilişlerin önceliğini vurgulamaktadır. Başka bir ifade ile duygular ve davranışların oluşumuna bilişler öncülük etmektedir. Bu konuda Lazarus (1982), duyguyu bireyin çevre ile etkileşiminde yaptığı bilişsel değerlendirmelerin bir sonucu olarak tanımlamış ve duyguların altında bilişsel değerlendirmelerin yattığını savunmuştur. Martin ve Phil (1986), Lazarus' un bu görüşünü temel alarak aleksitimi açıklamışlar ve aleksitimik bireylerin bilişsel gelişimlerini tamamlamadıklarını ileri sürmüşlerdir. Onlara göre aleksitimik bireyler ilkel bilişsel şemaları kullanmaktadırlar. Martin ve Phil ayrıca bilişsel çarpıtmalar ve varsayımların duyguların öncülü olmasından ötürü aleksitimie de neden olacağını ileri sürmektedir.

Bilişsel iletişimin en gözlenebilir yapısı ise otomatik düşüncelerdir. Otomatik düşünceler, bireylerin zihinlerine istemsiz, plansız bir şekilde gelir. Otomatik düşünceler çevreye ve duruma, genellikle duygusal tepkiler biçiminde bir tepki olarak ortaya çıkar (Greenberger ve ark. 2015). Otomatik düşünceler kendiliğinden ortaya çıkar ve genellikle bireyler onları fark edemez. Tanımlanabilir duygular otomatik düşünceler sonucunda ortaya çıkar. Bu duygular otomatik düşüncelerin içeriğine paraleldir (Türkçapar 2007). Aaron Beck (2000) otomatik düşünceleri kendiliğinden oluşan ve hızla ortaya çıkan düşünceler olduğunu ifade etmektedir ve otomatik düşünceler olumsuz duyguları güçlendirir (Şahin 2017). Otomatik düşünceler aniden ortaya çıkar ve kontrol edilemez. Çok hızlı bir şekilde ortaya çıktıklarından, bir rasyonellik filtresinden geçmeden doğru olarak kabul edilirler. Otomatik düşünceler bireye göre mantıklı ve inandırıcıdır (Beck 2001). Erken çocukluk döneminde meydana gelen olaylar, temel düşünce ve inançların oluşumuna katkıda bulunur. Erken dönemde ortaya çıkan bu temel düşünce ve inançlar, bireylerin kendi algılarını ve dünya görüşlerini şekillendirir. Bu temel düşünce ve inançlar belirli bir yaşam olayında ortaya çıkar ve otomatik düşünceleri ortaya çıkarır. Otomatik düşünceler, belirli bir olayla ilgili verilerin işlenmesi sırasında meydana gelen bilişsel hatalar ve çarpıtmaların bir sonucu olarak ortaya çıkar (Schniering ve ark. 2002). Özet olarak, otomatik düşünceler, bilişsel şemaların kökenindeki yansımalarına sahip, aniden ortaya çıkan düşünceler olarak tanımlanabilir, bunlar şemalardan daha kolay keşfedilebilir. Bu nedenle bilişsel davranışçı terapi (BDT) prosedüründe ilk olarak danışanların otomatik düşünceleri ortaya koyularak bilişsel şemalara ulaşılmaya çalışılmaktadır. Başka bir deyişle, vaka formülasyonunda önce otomatik düşünceler göz önünde bulundurulur. BDT'nin aleksitimi düzeyi üzerine etkisi üzerine farklı klinik örneklemelerde gerçekleştirilen araştırmalara göre BDT temelli tedavilerin aleksitimi düzeylerine olumlu etkileri olduğu görülecektir (Bach ve ark. 1995, Rosenblum ve ark. 2005, Ruffer ve ark. 2008, Spek ve ark. 2008). Bu araştırma kapsamında BDT'nin

önemli bir ögesi olan otomatik düşüncelerin hangilerinin aleksitimiyi yordadığı ortaya konulmaya çalışılmıştır. Bu sayede BDT temelli tedavilerde alan çalışanlarının hangi otomatik düşünceler üzerinde durması gerektiği konusunda bir yol haritası oluşturulmaya çalışılmıştır.

İstatistiklerde çok sayıda farklı tahmin yöntemi ve analizleri olmasına rağmen, makine öğrenmesi olarak bilinen yöntem daha önce bilinmeyen ve potansiyel olarak yararlı bilgileri ortaya çıkarmak için kullanılır. Psikoloji alanındaki birçok çalışmada sınıflandırma, kestirim ve kümeleme gibi çok sayıda makine öğrenmesi yönteminin kullanıldığı görülmüştür (Baba-Garcia ve ark. 2006, Song 2010, Qinghua 2016).

Makine öğrenme yöntemlerini kullanarak, Baca-Garcia ve arkadaşları (2006), acil serviste kontrol altına alınan 509 intihar girişimcisinde psikiyatristlerin hastaneye yatma kararlarını tahmin etmiştir. Çalışmanın sonuçlarına göre, hastalar ileri seçme yöntemini kullanarak %99 başarı oranı ile doğru bir şekilde sınıflandırılmıştır. Nguyen ve arkadaşları (2010) uzun süreli uyku apne sendromunun tedavisinde uykusuzluk semptomlarının sonuçlarını değerlendirmek için makine öğrenmesi yöntemlerini kullanmıştır. Karar ağaçları kullanılarak tedaviye verilen olumsuz tepkilerin uzun vadeli ayarlama çalışmaları ile ilgili olmadığını göstermiştir. Song (2010), üniversite öğrencilerinin psikolojik değerlendirme verilerini araştırmak için kNN, Bayes ve Destek Vektör Makinesi (DVM) makine öğrenme yöntemini kullanmıştır. İkili sınıflandırma modeli için en iyi sonuca, %79.1'lik bir başarı oranına sahip DVM kullanılarak ulaşılmıştır. Qinghua (2016), öğrencilerin psikolojik veri yönetim sistemindeki operasyonel verimliliğini artırmak için geri yayımlı yapay sinir ağını temel alan makine öğrenmesi teknolojisini uygulamıştır. Çalışma, özellikle psikolojik krizleri önlemeyi amaçlamıştır. Rosenthal ve diğ. (2007), mesleki rehabilitasyon hizmeti alan psikiyatrik bozukluğu olan kişilerin mesleki rehabilitasyon sürecinde mesleki sonuçları etkileyen faktörleri incelemek için makine öğrenmesi yöntemlerini kullanmıştır. CHAID algoritması sayesinde işe yerleştirme hizmeti alan kişiler için profesyonel sonuçlar üzerinde olumlu bir etkiye sahip olduğu gösterilmiştir. Bae ve diğ. (2010), şizofreni hastaları üzerinde anlamlı etkisi olan değişkenleri sosyal işlevsellik açısından incelemek için karar ağacı algoritmalarını kullanmıştır. Görüldüğü gibi, makine öğrenmesi yöntemleri psikoloji alanında kullanılmaktadır.

Bu çalışmanın amacı BDT kavramlarından aleksitimi düzeyleri ile otomatik düşünceler arasındaki ilişkiyi incelemektir. Bu amaçla, otomatik düşünce ölçeğinin en etkin özniteliklerini belirlemek için Fisher Score analizi uygulanmıştır. Ek olarak, aleksitimi seviyesi Yapay Sinir Ağı (YSA) ve DVM makine öğrenmesi yöntemleri ile tahmin edilmiştir. Böylece gelecekteki çalışmalar için bir kaynak oluşturulması amaçlanmıştır.

Yöntem

Örneklem

Araştırma grubu 386 (54%) erkek ve 328 (46%) kadın olmak üzere toplam 714 katılımcıdan oluşmaktadır. Katılımcıların yaşları 16 ile 40 arasında değişmektedir (\bar{x} =21.84, SD =3.68). Katılımcıların, 129'ü üniversite mezunu (18.07%), 495'i üniversite öğrencisi (69.32%) ve 90'ı lise mezunudur (12.60%). Katılımcılar Türkiye'in 7 bölgesinde bulunan 10 farklı ilden seçilmiştir. Bu iller İstanbul (n=94), Ankara (n=106), Diyarbakır (n=38), Malatya (n=47), İzmir (n=64), Antalya (n=24), Adana (n=51), Tokat (n=130),

Nevşehir (n=141), Erzincan (n=19) illeridir. Araştırma kapsamında uygun örnekleme yöntemi kullanılmıştır ve katılımcılar klinik olmayan örneklem seçilmiştir. Katılımcılara ölçekler uygulanmadan önce araştırma hakkında bilgi verilmiş ve araştırmaya katılma konusunda gönüllük esası olduğu belirtilmiştir. Daha sonra yüz yüze veri toplanan katılımcılardan aydınlatılmış onam formu (n=495) alınmıştır. Google Drive yolu ile toplanan verilerde (n=219) ise öncelikle araştırma konusunu açıklayan bir metin verilmiş ve her katılımcıdan araştırmaya katılım için onam alınmıştır.

Veri Toplama Araçları

Araştırma verilerinin toplanması amacı ile Kişisel bilgiler formu, Toronto Aleksitimi Ölçeği ve Otomatik düşünceler ölçekleri kullanılmıştır. Araştırma kapsamında bu ölçeklerin seçilmiş olma nedeni alanyazında konu ile ilgili araştırmalarda bu ölçeklerin yaygın olarak kullanılması ve ölçeğin psikometrik özelliklerinin yapılan araştırmalarda yeterli düzeyde olmasıdır (Şahin ve ark. 1992, Motan ve ark. 2007, Güleç ve ark. 2009, Güleç ve ark. 2010, Oktay ve ark. 2014, Arcan ve ark. 2016, Karahan ve ark. 2016).

Kişisel Bilgiler Formu

Araştırmacılar tarafından geliştirilen formda, cinsiyet, yaş, eğitim düzeyi, yaşanılan şehir gibi bilgiler toplanmıştır.

Toronto Aleksitimi Ölçeği

Beşli likert tipi ölçek Bagby ve arkadaşları tarafından geliştirilmiş ve Türkçe adaptasyonu Güleç ve diğerleri tarafından yapılmıştır (Bagby et al. 1994, Güleç et al. 2009). Ölçekten alınabilecek maksimum puan 100 minimum puan 20'dir. Ölçeğin Türkçe versiyonunun Cronbach's alphası .78 olarak bulunmuştur (Güleç et al. 2009). Bu araştırmada ise Cronbach's alpha değerinin .72 olduğu görülmüştür.

Otomatik Düşünceler Ölçeği

Hollan and Kendall (1980) tarafından geliştirilen ölçek beşli likert tipindedir. Ölçekten alınabilecek en düşük puan 30 en yüksek puan 150'dir. Ölçeğin Türkçe versiyonunun ise Cronbach's alpha değeri .93'tür (Şahin et al. 1992). Bu araştırmada ise ölçeğin tamamına ilişkin Cronbach's alpha değeri .96 bulunmuştur. Ayrıca alt ölçeklere ilişkin Cronbach's alpha değerleri ise .66 ile .91 arasında değişmektedir.

İstatistiksel Analiz

Veri analizi için, Fisher score öznitelik seçme yöntemi ile yapay sinir ağı (YSA) ve destek vektör makinesi (DVM) tahminleme yöntemleri kullanılmıştır. Deneysel analizler Matlab R2017b ve Weka platformlarında gerçekleştirildi. Üç yöntem de son yıllarda tıp ve psikoloji çalışmalarında kullanılan yöntemlerdendir (Bilge 2007, Ghazavi ve ark. 2008, Yavuz ve ark. 2011). Araştırmada öznitelik seçme için Fisher Score yönteminin, tahminleme için de YSA ve DVM yöntemlerinin kullanılmasının amacı yüksek başarı oranları ve zaman performanslarının düşük olmasıdır (Öztürk 2008, Ayhan ve ark. 2014). Fisher Score, ANN ve SVM yöntemleri hakkında kısa bilgiler aşağıda verilmektedir.

Fisher Skor Yöntemi

Öznitelik seçme yöntemi veri madenciliğinde bir ön işleme adımı olarak sıklıkla kullanılmaktadır. Öznitelik seçim işlemi zaman karmaşıklığı ve gürültülü özniteliklerin atılmasında önemli faydalar sağlamaktadır (Cai ve ark. 2009). Öznitelik seçme işlemleri


için kullanılan yöntemlerden biri istatistiksel bilgiye dayalı olan filtreleme yöntemleridir. Bu yöntemlerde istatistiksel ölçütlere dayalı fonksiyonlar ile öznitelik seçimi işlemi gerçekleştirilmektedir. Filtreleme yöntemlerinin çalışma şekli veri kümesini oluşturan her bir öznitelik için istatistiksel amaç fonksiyonlarını kullanarak skor değerleri hesaplamak ve bu değerlere göre özniteliklerin etkisini sıralayabilmektir (Hsu ve ark. 2011). Çalışmada en çok kullanılan filtreleme yöntemlerinden olan Fisher skor yöntemi kullanılmıştır. Bu yöntem, her bir sınıf için özniteliklere ait en yaygın istatistiksel ölçütlerden olan ortalama ve standart sapma değerlerini kullanarak Eşitlik 1'deki gibi bir ilişki skoru hesaplar (Ferreira ve ark. 2012).

$$FS(x_i) = \frac{|\mu_i^+ - \mu_i^-|}{\sigma_i^+ - \sigma_i^-} \quad (1)$$

Eşitlik 1'de bulunan + ve - sembolleri iki farklı sınıfı ifade etmektedir. μ_i her bir sınıfın aritmetik ortalamasını, σ_i ise her bir sınıfın standart sapma değerine karşılık gelmektedir. Fisher skor yöntemi ile öznitelik seçme işlemi, özniteliklerin hesaplanan skor değerlerine göre büyükten küçüğü sıralanması ile üst sıradan başlanarak istenilen sayıda öznitelik seçilmesi şeklinde yapılmaktadır (Saeys ve ark. 2007).

Yapay Sinir Ağı

Nedenleri ve sonuçları bilinen örnekleri yorumlayarak karşılaşılan yeni örnekler hakkında sonuç üreten tahminleme yöntemlerinden biri Yapay Sinir Ağı (YSA)'dır (Haykin 1999). Bu çalışmada, yapay sinir ağı modeli olarak Çok Katmanlı Algılayıcı Sinir Ağı (ÇKASA) modeli kullanılmıştır (Öztürk 2008). Bu model giriş, gizli ve çıkış olmak üzere 3 katmandan oluşmaktadır. Gizli katman içerisinde aktivasyon fonksiyonu içeren nöronlar bulunmaktadır. Şekil 1'de ÇKASA'da kullanılan örnek bir nöron verilmektedir.



Şekil 1. Çok Katmanlı Algılayıcı Sinir Ağında kullanılan örnek bir nöron

Şekil 1'de görüldüğü gibi, verinin her boyutu ($i_1, i_2, i_3, \dots, i_n$) ayrı bir ağırlıkla ($w_1, w_2, w_3, \dots, w_n$) çarpılmakta ve girişler nöron içerisinde iki işlem biriminden geçerek elde edilen değer çıkışa (y) verilmektedir. İlk işlem birimi gelen her veriyi ağırlıklar ile çarpıp sonuçları toplayan doğrusal birimdir. Daha sonra, bu sonucu aktivasyon fonksiyonunu içeren ikinci birime gönderir. Aktivasyon fonksiyonundan geçen değer çıkış katmanına verilir. Gizli katmanda kullanılan denklemler Eşitlik 2 ve 3'te verilmektedir.

$$n = \sum_k i_k w_k \quad (2)$$

$$y_{out} = g(n) \quad (3)$$

Eşitlik 3'teki g ifadesi aktivasyon fonksiyonlarını göstermektedir. Çalışmalarda genellikle hiperbolik tanjant, sigmoid ve birim basamak fonksiyonları kullanılmaktadır (Demuth ve ark. 2000). Karşılaşılan probleme göre aktivasyon fonksiyonlarının birbirlerine karşı üstünlükleri mevcuttur.

ÇKASA'da nöronların arasındaki bağlantıların ağırlıklarını ayarlayarak ağırlık çıkışını optimize eden geriye yayımlı eğitim algoritması çeşitleri kullanılmaktadır (Hagan ve ark. 1994). Bu sayede, ağırlık çıkışında bulunan değerden (y') gerçek değer (y) farkı alınır ve hesaplanan değere göre tüm bağlantıların ağırlıkları güncellenir. Güncelleme aşamasında genellikle eğim azaltma yöntemi kullanılmaktadır (Kaastra ve ark. 1996). Bu işlemler gerçekleştirilirken kullanılan denklemler Eşitlik 4, 5 ve 6'da verilmektedir.

$$e = y' - y \quad (4)$$


$$\varepsilon = \frac{1}{2} e^2 \quad (5)$$

$$\Delta w = -\eta \frac{\partial \varepsilon}{\partial w} \quad (6)$$

Eşitlik 4'te ağırlık hesapladığı değerin gerçek değere göre ne kadar saptığını gösteren e değeri hesaplanmaktadır. Eşitlik 5, nöronun ani hata enerjisini (ε) hesaplamaktadır. Eşitlik 6'da ise hesaplanan hata enerjisinin ilgili nörona gelen tüm bağlantı ağırlıklarına mevcut ağırlıkların (w) tersi oranında dağıtılması yardımıyla her ağırlığın güncellenme miktarı (Δw) hesaplanmaktadır (Kaastra ve ark. 1996, Nabiyevev 2003). Yapılan işlemler veri kümesindeki her bir örnek için ayrı ayrı hesaplanarak çözümlerin ortalaması hesaplanmaktadır.

Destek Vektör Makinesi (DVM)

Destek vektör makinesi (DVM) istatistiksel öğrenme teorisine dayalı bir sınıflandırıcıdır (Vapnik ve ark. 2000). DVM'nin çalışma amacı, iki sınıfı birbirinden ayırabilen en uygun karar fonksiyonunun tahmin edilmesi işlemidir (Hearst ve ark. 1998, Vapnik ve ark. 2000). Bu karar fonksiyonunun bulunmasıyla Şekil 2'de görüldüğü gibi eğitim veri kümesini ayırabilecek en uygun hiper düzlem tespit edilmektedir.



Şekil 2. Uygun hiper düzlem ve destek vektörleri (Vapnik ve ark. 2000)

Doğrusal olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde DVM'deki destek vektörlerinin denklemleri Eşitlik 7'de verilmektedir.

$$\mathbf{w}\mathbf{x} + \mathbf{b} = +1 \text{ için } y = +1 \text{ sınıfı} \quad (7)$$

$$\mathbf{w}\mathbf{x} + \mathbf{b} = -1 \text{ için } y = -1 \text{ sınıfı}$$

Burada y sınıf etiketlerini, w ağırlık vektörünü ve b ise yaklaşım değerini göstermektedir. Optimum düzlem aralığını arttırmak için Eşitlik 8'de görüldüğü gibi w değerinin minimum değerde tutulması gerekmektedir (Hastie ve ark. 2009).

$$m = \frac{2}{\sqrt{ww}} f_{min}(w) = \frac{ww}{2} \quad (8)$$

Eşitlik 8'e bağlı olarak,

$$y_i(\mathbf{w}\mathbf{x}_i + \mathbf{b}) - 1 \geq 0 \quad (9)$$

elde edilir. Eşitlik 9, Lagrange denklemleriyle çözülerek Eşitlik 10 elde edilmektedir.

$$L(\mathbf{w}, \mathbf{b}, \mathbf{a}) = \frac{w^2}{2} - \sum_{i=1}^k a_i y_i (\mathbf{w}\mathbf{x}_i + \mathbf{b}) + \sum_{i=1}^k a_i \quad (10)$$

İki sınıflı bir problem için destek vektör makinesinin vereceği karar fonksiyonu Eşitlik 11'da verilmektedir (Osuna ve ark. 1997).

$$f(\mathbf{x}) = \text{sign}(\sum_{i=1}^k a_i y_i (\mathbf{x}_i) + \mathbf{b}) \quad (11)$$

Eşitlik 10'da bulunan a_i ve y_i parametreleri, marjin genişliğini ayarlayan düzenleme parametreleridir. Parametre değerleri ne kadar küçük olursa, geniş marjin aralığına neden olan kısıtlamaları göz ardı etmek o kadar kolay olmaktadır. Değerler büyükse, küçük marjin aralığına neden olan kısıtlamaları göz ardı etmek zorlaşmaktadır (Pardo ve ark. 2005). Bu nedenle, deneysel çalışmalar sonucunda, sınıflandırmayı en iyi hale getirmek için parametreleri ayarlamak çok önemlidir. DVM'nin en önemli avantajı, tahmin problemini karesel optimizasyon problemine dönüştürerek eğitim aşamasındaki işlem sayısını azaltması ve sonucu bu aşamadaki diğer algoritmalarından daha hızlı bulmasıdır (Nitze ve ark. 2012). Ayrıca, optimizasyona dayalı olduğu için büyük veri setlerinde tahmin doğruluğu ve hesaplama karmaşıklığı açısından diğer yöntemlerden daha iyi performans gösterir (Vapnik ve ark. 2000).

Geleneksel istatistiksel analizler bağımsız ve bağımlı değişkenler arasında doğrusal bir ilişki olduğunu varsaymaktadır. Bu durum önemli bir hatadır. Geçmiş araştırmalar, ilişkilerin genellikle doğrusal olmadığını göstermektedir (Garver 2002). Yapay Sinir Ağlarının en önemli avantajı, önceki deneyimlerinden öğrenebilmeleri, veri kümeleri aracılığıyla bilinmeyen ilişkileri akıllıca tanımlayabilmeleri ve ağırlık katsayısı gibi parametrelerinin çözümüne adapte olabilmeleridir. Ayrıca, doğrusal olmayan fonksiyonlar da çözüme gitmektedir. Bu nedenle, karmaşık istatistiksel yöntemler bu problemleri daha doğru çözebilmektedir. Doğrusal olmayan davranışlar hissedilir, algılanır ve bilinir. Ancak bu problem ve davranışları matematiksel olarak çözmek zordur (Güneri 2001, Elmas 2003). Destek Vektör Makineleri'nin temel avantajı, sınıflandırma problemini karesel optimizasyon problemine dönüştürmesidir. Böylece, problem çözme

sürecinin eğitim aşamasında işlem sayısı azalmakta ve diğer algoritmalarından daha hızlı bir çözüm ortaya çıkmaktadır (Osowski ve ark. 2004). Ayrıca, optimizasyon tabanlı olduğu için sınıflandırma performansı, hesaplama karmaşıklığı ve kullanılabilirliği diğer yöntemlerden daha başarılıdır (Nitze ve ark. 2012). Sınıflandırma için kullanılan her iki yaklaşımda da, sonuçların değerlendirilmesinde çapraz değerlendirme kullanılarak aşırı öğrenme önlenmektedir. Ayrıca, YSA yönteminde aktivasyon fonksiyonlarındaki katsayıları belirleyerek ve SVM yönteminde sınır aralığını ayarlayan hiper düzlem parametrelerini belirleyerek aşırı öğrenmenin önlenmesi düşünülmektedir (Kim 2003).

Her iki tahminleme yönteminde de kullanılan değerlendirme kriteri olan Ortalama karesel hata karekökü (OKHK), bir veri kümesinin hatalarının kareleri toplamı veri sayısına bölünür ve bu değer karekökü alınarak bulunur (Willmott ve ark. 2005). Eşitlik 12'de verilen x gerçek değer, x' tahmin edilen değer ve n ise veri sayıdır.

$$OKHK = \sqrt{\frac{\sum_{i=1}^n (x-x')^2}{n}} \quad (12)$$

Eşitlik 12 ile verilen hesaplamada hataların kareleri alındığı için veri kümesi içindeki büyük hataların ortalama üzerindeki etkisi daha büyük olmakta ve bu sayede büyük hataların tüm ölçüm üzerindeki etkisi belirlenebilmektedir (Chai ve ark. 2014). Tahmin problemlerinin değerlendirme kriteri olarak kullanılan OKHK değerinin genellikle %10'un altında olması beklenmektedir (Lee 2014).

Bulgular

Bu çalışmada, Otomatik Düşünceler Ölçeğini oluşturan kişinin kendi kendine yönelik duygu ve düşünceleri (Kkyd), şaşkınlık/kaçma fantezileri (Saskinkac), kişisel uyumsuzluk ve değişme istekleri (Uyumsuz), yalnızlık/izolasyon (Yalnızizo) ve ümitsizlik özneliklerinin (bağımsız değişkenlerinin) giriş olarak verilmesiyle aleksitimi düzeyinin (bağımlı değişken) tahmin edilmesi için ÇKASA ve DVM makine öğrenmesi yöntemleri kullanılmıştır. Ayrıca tahminleme işlemi otomatik düşünce alanlarını oluşturan en etkili özneliklerin çıkarımı için veri kümesine korelasyon matrisi ve Fisher score analizi uygulanmıştır. Bu sonuçlar Tablo 1 ve Tablo 2'de gösterilmektedir.

Tablo 1. Öznelikler ile aleksitimi sonucu arasındaki korelasyon matrisi

| Değişken | Kkyd | Saskinkac | Uyumsuz | Yalnızizo | Ümitsizlik | Aleksit | M | SD |
|------------|------|-----------|---------|-----------|------------|---------|-------|------|
| Kkyd | 1 | | | | | | 19.04 | 8.39 |
| Saskinkac | .82 | 1 | | | | | 14.07 | 6.24 |
| Uyumsuz | .76 | .81 | 1 | | | | 7.68 | 2.85 |
| Yalnızizo | .77 | .76 | .82 | 1 | | | 9.22 | 3.87 |
| Ümitsizlik | .8 | .8 | .72 | .74 | 1 | | 7.83 | 3.98 |
| Aleksitimi | .59 | .58 | .52 | .61 | .56 | 1 | 50.23 | 10.7 |

Kkyd: kişinin kendi kendine yönelik duygu ve düşünceleri; Saskinkac: şaşkınlık/kaçma fantezileri; Aleksit: Aleksitimi; Uyumsuz: kişisel uyumsuzluk ve değişme istekleri; Yalnızizo: yalnızlık/izolasyon.

Tablo 2'de gerçekleştirilen Fisher Score analizinde görüldüğü gibi aleksitimi düzeyini etkileyen öznelikler Tablo 1'de verilen korelasyon matrisiyle doğru orantılı bir şekilde değişmektedir. Gerçekleştirilen deneysel çalışmalar sonucunda, skorlamaya 0.75'ten düşük bağımsız değişkenlerin sınıflandırmaya eklenmesinin başarı oranını düşürmesi nedeniyle 5 öznelik (bağımsız değişken) seçilip sınıflandırma gerçekleştirildi.

rilmiştir. Bu iki tabloya göre aleksitimi düzeyini etkileyen en anlamlı özneliliğin yalnızlık/izolasyon olduğu görülmektedir. Diğer öznelilikler ise sırasıyla kişinin kendi kendine yönelik duygu ve düşünceleri, şaşkınlık/kaçma fantezileri, ümitsizlik ve kişisel uyumsuzluk ile değişme istekleri'dir.

Tablo 2. Öznelilik seçimi için veri kümesine Fisher Skor yönteminin uygulanması

| Öznelilik adı | Fisher Score |
|---------------|--------------|
| Yalnızlık | 0.92 |
| Kkyd | 0.87 |
| Saskinkac | 0.85 |
| Ümitsizlik | 0.81 |
| Uyumsuz | 0.77 |

Kkyd: kişinin kendi kendine yönelik duygu ve düşünceleri, Saskinkac: şaşkınlık/kaçma fantezileri, Uyumsuz: kişisel uyumsuzluk ve değişme istekleri, Yalnızlık: yalnızlık/izolasyon

ÇKASA modelinde kullanılan gizli katmanda 10 nöron, nöronlar içerisindeki aktivasyon için hiperbolik tanjant fonksiyonu ve eğitim için de geri yayılım algoritması kullanılmıştır. DVM modelinde ise çekirdek fonksiyonu olarak polinomsal ve gauss fonksiyonları kullanılarak karşılaştırmalar yapılmıştır (Soman et al. 2011).


Bu çalışmada, aleksitiminin tahmini için hazırlanan veri kümesine ÇKASA ve DVM modellerinin tarafsız olarak testine imkân veren rasgele seçimli 10 katlı çapraz geçerlik yöntemi uygulanmıştır. Makine öğrenme modellerini eğitmek için kullandığımız veri kümesine eğitim verisi denir. Eğitim sonucu oluşturulan nihai modelin objektif bir değerlendirmesini yapmak için tahsis edilen veri kümesinin kalan kısmına ise test verisi adı verilir. Test işlemi, modelin değerlendirilmesi için altın bir oran sağlar. Veri kümesi genellikle %70 eğitim ve %30 test olarak ayrılmıştır (Kohavi 1995). Bu yöntemde eldeki veri kümesi eğitim ve test olmak üzere 2 kümeye dağıtılmaktadır. Çalışmada verilerin dağılımı genellikle bu çalışmalarda kullanılan orana göre yani %70 (497) veri madenciliği yöntemlerinin eğitimi ve %30 (217) modelin testi olmak üzere yapılmıştır (Hastie ve ark. 2009). Deneysel analizler 714 denek ve 5 öznelilik ile gerçekleştirilmiştir. Literatür incelendiğinde, çalışmada kullanılan 714 kişilik örneklem büyüklüğünün, iki makine öğrenmesi yönteminin değerlendirilmesi için yeterli olduğu düşünülmektedir (Öztemel 2003, Steinwart ve ark. 2008). Sonuçları objektif olarak değerlendirmek için, dağılım oranlarını aynı tutup yerlerini değiştirerek verinin 10 farklı eğitim aşamasına tabi tutulmasıyla deneyler yapıldı. Analizler 10 kez tekrarlandı ve sonuçların çapraz geçerlilik yönteminde pozitif olarak etkilenmemesi için 10 farklı sonucun ortalaması alındı. Ek olarak, her analizde, eğitim ve test veri kümesi objektif değerlendirme için rastgele bir şekilde dağıtılmıştır. Bu deneylerden elde edilen Ortalama karesel hata karekökü (OKHK) değerleri Tablo 3'te verilmiştir.

Tablo 3. Aleksitimi için kullanılan modeller ve OKHK değerleri

| Model | OKHK |
|------------------|------|
| ÇKASA | 5.04 |
| DVM (Polinomsal) | 4.01 |
| DVM (Gauss) | 4.26 |

Tablo 3'te Aleksitimi düzeyinin tahmini için kullanılan 3 yöntem içerisinde en başarılı modelin 4.01 OKHK değeri ile polinomsal çekirdek fonksiyonu kullanan DVM

modeli olduğu görülmektedir. OKHK değerinin sıfıra yaklaşması önerdiğimiz modelin başarısını göstermektedir. Test veri kümesinden alınan en başarılı modelin tahmin ettiği sonuçlar ile aleksitimi düzeyi sonuçları Şekil 3'te gösterilmektedir.



Şekil 3. Aleksitimi tahmini ve gerçek sonuçların grafiksel gösterimi

Şekil 3'te görüldüğü gibi, 5 öznitelikten oluşan otomatik düşünceler ölçeğine DVM yönteminin uygulanması ile yapılan Aleksitimi tahmin sonuçlarının gerçek değerleri 4.01 OKHK değeri ile tahmin edilmiştir.

Regresyon Analizi

Regresyon analizi gerçekleştirilmeden önce ilgili varsayımlar incelenmiştir. Bu amaçla değişkenler arasındaki ilişkiye bakılmıştır. Yapılan inceleme sonucunda yalnızlık/izolasyon ve kişisel uyumsuzluk ve değişme istekleri alt boyutu; benlik kavramı ve şaşkınlık/kaçma fantazileri; kişisel uyumsuzluk ve değişme istekleri ve şaşkınlık/kaçma fantazileri arasında .80 ve üzeri ilişki bulunmuştur (Table 1). Ayrıca, variance inflation factor (VIF) değerleri bu değişkenlerde 5'ten fazla çıkmıştır. Bu durum çoklu bağlantı sorunu olduğunu göstermektedir (Kline 2016). Bu nedenle regresyon analizine çoklu bağlantı sorunu olan değişkenlerle aleksitimi ile yüksek ilişkide olan değişkenler dahil edilmiştir. Otomatik düşüncelerin aleksitimi düzeyini yordayıcılığı ile ilgili regresyon analizi sonuçları Tablo 4'te görüldüğü gibidir.

Tablo 4. Regresyon analizi sonuçları

| | β | t | R^2 | ΔR^2 | F |
|------------|---------|--------|-------|--------------|---------|
| | | | .65 | .42 | 52.53** |
| Yalnızizo | .37 | 4.20** | | | |
| Kkyd | .21 | 2.22* | | | |
| Ümitsizlik | .12 | 1.29 | | | |

* $p < .05$, ** $p < .01$, $n = 714$; Yalnızizo: yalnızlık/izolasyon. Kkyd: kişinin kendi kendine yönelik duygu ve düşünceleri.

Tablo 4'te görüldüğü gibi, Yalnızizo ve Kkyd değişkenleri aleksitimiye anlamlı şekilde yordamaktadır ($p < .01$). Ayrıca otomatik düşünceler toplam varyansın %42'sini açıklamaktadır ($R^2 = .42$). Yalnızizo değişkeni ise modele en fazla katkı sağlayan değiş-

kendir ($\beta = .37$, $t=4.20$, $p<.01$). Bu sonuçlar Fisher's score analizine benzer bulgular ortaya koymaktadır.

Tartışma

Otomatik düşünceler ölçeğine göre toplanan veri kümesi üzerinde yapılan aleksitimi düzeyinin tahmin edilmesiyle ilgili deneysel çalışmalar sonucunda en başarılı tahmin modelinin 4.01 OKHK değeri ile polinomsal çekirdek fonksiyonu kullanan DVM modeli olduğu görülmüştür. Çalışmada kullanılan DVM modelinde polinom, gauss çekirdek fonksiyonları ve MLPNN modelinde ise step, sigmoid, hiperbolik tanjant ve eşik değer aktivasyon fonksiyonları bulunmaktadır. Yapılan analizler sonucunda, veri kümesinin polinomsal dağılıma uygun olduğunu göstermektedir. DVM modelindeki polinomsal dağılım bulguları incelendiğinde otomatik düşüncelerin aleksitimi düzeyini büyük oranda tahminleyebildiği görülmektedir. Bu bulgu aleksitiminin bilişsel davranışçı terapiler kapsamında ele alınmasının sağaltım açısından yararlı olacağını göstermektedir. İlgili alanyazın incelendiğinde elde edilen bu bulgunun desteklediği görülecektir (Sifneos ve ark. 1977, Krystal 1982, Lesser 1985, Taylor ve ark. 1992). Krystal (1982) psikanatik tedavilerin duygu düzenleme ve tanımlama gibi yetersizliklerden çok davranış problemlerinin kökenleri üzerine yoğunlaştığını bu nedenle aleksitimi sağaltımında yeterli olmayacağını ifade etmektedir. Bu öngörü deneysel araştırmalar ile de desteklenmiştir (Lesse 1985, Yu ve ark. 2013).

Bununla birlikte birçok araştırmacı aleksitiminin kökeninde bireylerin bilişsel gelişim sürecini tamamlamamış olmasının yattığını ve bu nedenle aleksitimik bireylerin duygularını ayırtıramayarak duygularını somatik belirtilerle ortaya koyduklarını ifade etmektedir (Lazarus 1982, Martin ve ark.1986). Bu durum aleksitimik bireylerin ilkel bilişsel şemalar kullandıkları şeklinde yorumlanmaktadır. Bununla birlikte bilişsel davranışçı terapi kapsamında geliştirilen müdahale programlarının aleksitimi düzeyini azalttığını raporlayan çalışmalara da rastlamak mümkündür (Taylor ve ark. 1992, Bach ve ark. 1995, Rosemblum ve ark. 2005, Spek ve ark. 2008, Rufer ve ark. 2010). Görüldüğü üzere bu araştırmanın temel bulgusu olan otomatik düşüncelerin aleksitimi düzeylerini yordaması alanyazınla uyumludur. Araştırmanın bu bulgusu ve ilgili alan yazın göstermektedir ki aleksitimi sağaltımında bilişsel- davranışçı terapiler önemli bir yere sahiptir.

Çalışmada kullanılan Fisher Score yöntemine göre aleksitimi düzeyini en çok tahminleyen otomatik düşünce alanı ise yalnızlık ve izolasyondur. Bu bulgu beklenen bir bulgudur. Çünkü duyguları ifade etmeme kişiler arası ilişkileri ve iletişimi olumsuz şekilde etkilemektedir (Spitzer ve ark. 2005, Vanheule ve ark. 2007). Örneğin Koçak (2016), yaptığı araştırmanın nitel boyutunda katılımcıların aleksitimik duygular konusundaki ifadelerini ortaya koymuştur. Bu ifadelerin özellikle yalnızlık ve izolasyon ile ilişkili ifadeler olduklarını ifade etmiştir. Koçak aynı araştırmada aleksitimi düzeyinin azalmasının yalnızlık düzeyini de azalttığı raporlamıştır. Arcan ve Yüce (2016) ve Craparo (2011) ise internet bağımlısı olan bireylerin yalnızlık ve aleksitimi düzeylerinin yüksek olduğunu raporlamışlar ve aleksitimi düzeyi yüksek bireylerin interneti bir çeşit izolasyon aracı olarak kullandıkları yorumunu yapmışlardır. Besharat (2010) ise aleksitimik bireylerin problemler ile kaçınan bir tarzda baş ettiklerini ifade etmektedir. Başka bir ifade ile aleksitimik bireyler kendilerini izole etmeyi tercih etmektedirler.

Ogrodniczuk, Sochting, Piper ve Joyce (2012) benzer şekilde grup terapisi ile aleksitimi düzeyini azaltarak kişiler arası ilişkileri geliştirdiklerini belirtmektedirler.

Tüm bu bulgular ve alan yazın bir arada düşünüldüğünde aleksitimik bireylerle çalışırken bilişsel davranışçı terapi kapsamında çalışmaların yürütülmesinin faydalı olacağı yorumu yapılabilir. Ayrıca aleksitimik bireylerin özellikle yalnızlık ve izolasyon temelinde problemler yaşadıklarından dolayı duygu ifade etme becerilerinin yanında kişiler arası ilişkiler konusunda da psiko eğitim programlarından yararlanmaları faydalı olabilir. Alan çalışanları aleksitimi ile çalışırken yalnızlık ve izolasyon düşüncelerine odaklanabilirler. Ayrıca alanyazında aleksitimi tedavisinde destekleyici ve eğitici yaklaşımların öne çıkması gerektiği belirtilmiştir (Sifneos ve ark. 1977, Krystal 1982, Taylor ve ark. 1992, Ruffer ve ark. 2010). Dolayısıyla, aleksitimik bireylerle çalışırken yalnızlık ve izolasyonla başa çıkmak psiko eğitim programları için uygulanabilir. Tasarlanacak psiko eğitim programlarında bilişsel davranışçı terapi temel alınabilir.

Bu araştırmada aleksitimi bilişsel davranışçı terapi kavramlarından otomatik düşünceler temelinde incelenmiştir. İleride yapılacak araştırmalarda bilişsel terapinin farklı kavramlarının da aleksitimi düzeyi ile ilişkisi incelenebilir. Ayrıca bu araştırma ilişkisel bir modelde gerçekleştirilmiştir. İleride yapılacak araştırmalarda araştırma bulguları deneysel ve/veya boyamsal desenler kullanılarak kontrol edilebilir. Bu sayede değişkenler arasında daha sağlıklı neden sonuç ilişkileri kurulabilir.

Son olarak bu araştırmada kullanılan öznelik seçme için Fisher Score yönteminin, tahminleme için de YSA ve DVM makine öğrenme yöntemlerinin ilişkisel tarama çalışmalarında kullanılabilir yöntemler olduğu görülmektedir. Bu yöntemlerin öznelik seçme ve tahminleme konusunda güçlü yöntemler olduğu bilinmektedir. Bu nedenle ileride gerçekleştirilecek olan benzer çalışmalarda bu yöntemlerin daha yaygın kullanılması önerilmektedir..

Kaynaklar

- Arcan K, Yüce ÇB (2016) İnternet bağımlılığı ve ilişkili psiko-sosyal değişkenler: aleksitimi açısından bir değerlendirme. *Türk Psikoloji Dergisi*, 31(77):46-56.
- Ayhan S, Erdoğan Ş (2014) Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9:175-198.
- Bagby RM, Parker JDA, Taylor GJ (1994) The twenty-item Toronto Alexithymia Scale-I Item selection and cross validation of the factor structure. *J Psychosom Res*, 38:23-32
- Beck AT (1979) *Cognitive Therapy and the Emotional Disorders*. New York, Penguin.
- Baca-García E et al. (2006) Using data mining to explore complex clinical decisions: a study of hospitalization after a suicide attempt. *J Clin Psychiatry*, 67:1124-1132.
- Bae SM, Lee SH, Park YM, Hyun MH, Yoon H (2010) Predictive factors of social functioning in patients with schizophrenia: exploration for the best combination of variables using data mining. *Psychiatry Invest*, 7:93-101.
- Bellanger M (2000). *Digital Processing of Signal: Theory and Practice*. New York, Wiley.
- Berthoz S, Perdureau F, Godart N, Corcos M, Haviland M (2007) Observer and self-related alexithymia in eating disorder patients: Levels and correspondance among three measures. *J Psychosom Res*, 62:341-347.
- Besharat MA (2010) Relationship of alexithymia with coping styles and interpersonal problems. *Procedia Soc Behav Sci*, 5:614-618.
- Bilge U (2007) Tıpta yapay zeka ve uzman sistemler. 2007 Türkiye Bilişim Derneği Kongresi, Antalya, Türkiye.
- Cai R, Hao Z, Yang X, Wen W (2009) An efficient gene selection algorithm based on mutual information. *Neurocomputing*, 72:991-999.
- Chai T, Draxler RR (2014). Root mean square error (rmse) or mean absolute error (MAE). *Geoscientific Model Development*, 7:1247-1250.
- Coolidge FL, Estey AJ, Segal DL, Marle PD (2013) Are alexithymia and schizoid personality disorder synonymous diagnoses? *Compr Psychiatry*, 54:141-148.
- Coriale G, Bilotta E, Leone L, Cosimi F, Porrari R, De Rosa F (2012) Avoidance coping strategies, alexithymia and alcohol abuse: A mediation analysis. *Addict Behav*, 37:1224-1229.
- Coyne JC, Gotlib IH (1983) The role of cognition in depression: A critical appraisal. *Psychol Bull*, 94:472-505.
- Declercq F, Vanheule S, Deheegher J (2010) Alexithymia and posttraumatic stress: Subscales and symptom clusters. *J Clin Psychol*, 66:1076-1089.
- Demuth H, Beale M (2000) *Neural Network Toolbox for use with Matlab*. Natick, USA; Math Works Inc.
- Elmas Ç (2003) *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*. Ankara, Seçkin Yayınları.
- Ferreira AJ, Figueiredo MAT (2012) Efficient feature selection filters for high dimensional data. *Pattern Recognit Lett*, 33:1794-1804.
- Garver MS (2002) Using data mining for customer satisfaction research. *Journal of Marketing Research*, 14:8-12.
- Ghazav SN, Liao TW (2008) Medical data mining by fuzzy modeling with selected features. *Artif Intell Med*, 43:195-206.
- Grabe HJ, Spitzer C, Freyberger HJ (2004) Alexithymia and personality in relation to dimensions of psychopathology. *Am J Psychiatry*, 161:1299-1301.
- Güleç H, Köse S, Güleç YM, Çitak S, Evren C, Borckardt J, Sayar K (2009). Reliability and factorial validity of the Turkish version of the 20-Item Toronto Alexithymia Scale (TAS-20). *Bull Clin Psychopharmacol*, 19:214-220.
- Güneri N, Apaydin A (2004) Öğrenci başarılarının sınıflandırılmasında lojistik regresyon analizi ve sinir ağları yaklaşımı. *Ticaret ve Turizm Eğitim Fakültesi Dergisi*, 1:170-188.
- Hagan MT, Menhaj MB (1994) Training feedforward networks with the Marquardt algorithm. *IEEE Trans Neural Netw*, 5:989-993.
- Hastie T, Tibshirani R, Friedman J (2009). *Unsupervised learning*. In *The Elements of Statistical Learning*. New York, Springer.
- Haykin S (1999). *Neural Networks: A Comprehensive Foundation*. New Jersey, Prentice Hall.
- Hearst MA, Dumais ST, Osuna E, Platt J, Scholkopf B (1998). Support vector machines. *IEEE Intell Syst*, 13:18-28.
- Hollon S, Kendal P (1980) Cognitive self-statement in depression: Clinical validation of an automatic thoughts questionaire. *Cognit Ther Res*, 4:383-395.
- Honkalampi K, Hintikka J, Tanskanen A, Lehtonen J, Viinamaki H (2000) Depression is strongly associated with alexithymia in the general population. *J Psychosom Res*, 48:99-104
- Hsu H, Hsieh C, Lu M (2011) Hybrid feature selection by combining filters and wrappers. *Expert Syst Appl*, 38:8144-8150.
- Kaastra I, Boyd M (1996) Designing a neural network for forecasting financial and econometric time series. *Neurocomputing*, 10:215-236.

- Kim KJ (2003) Financial time series forecasting using support vector machines. *Neurocomputing*, 55:307-319.
- Koçak R (2016) Duygusal ifade eğitim programının üniversite öğrencilerinin aleksitimi ve yalnızlık düzeylerine etkisi. *Türk Psikolojik Danışmanlık Rehberlik Dergisi*, 3(23):29-45
- Kohavi R (1995) A study of cross-validation and bootstrap for accuracy estimation and model selection. *IJCAI'95 Proceedings of the 14th international joint conference on Artificial intelligence*, Volume 2:1137-1143.
- Krystal HJ (1982) Alexithymia and effectiveness of psychoanalytic treatment. *Int J Psychoanal Psychother*, 9:353-378.
- Lazarus RS (1982) Thoughts on the relation between emotion and cognition. *Am Psychol*, 37:1019-1024.
- Lee PH (2014) Is a cutoff of 10% appropriate for the change-in-estimate criterion of confounder identification? *J Epidemiol*, 24:161-167.
- Lesser LM (1985) Current concepts of psychiatry, alexithymia. *N Engl J Med*, 312:690-694.
- Levant FR (1992) Toward the construction of masculinity. *J Fam Psychol*, 5: 379-402.
- Martin JB, Pihl RO (1986) Influence of alexithymic characteristics on physiological and subjective stress responses in normal individuals. *Psychother Psychosom*, 45: 66-77.
- Nabiyev VV (2003). *Yapay Zeka*. Ankara, Seçkin Yayıncılık.
- Nitze I, Schulthes U, Asche H (2012) Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. *Proceedings of the 4th GEOBIA (7-9 May 2012, Rio de Janeiro)*, p.7-9, Rio de Janeiro, Brazil.
- Nguyen X, Chaskalovis J, Rakotonanahary D, Fleury B (2010) Insomnia symptoms and CPAP compliance in OSAS patients: A descriptive study using data mining methods. *Sleep Med*, 11:777-784.
- Ogrodniczuk JS, Sochting I, Piper WE, Joyce AS (2012) A naturalistic study of alexithymia among psychiatric out patient treated in an integrated group therapy program. *Psychol Psychother*, 85:278-291.
- Oswski S, Siwekand K, Markiewicz T (2004) MLP and SVM Networks – a Comparative Study. *Proceedings of the 6th Nordic Signal Processing Symposium –NORSIG*.
- Osuna EE, Freund R, Girosi F (1997) Support vector machines: training and applications, Massachusetts Institute of Technology and Artificial Intelligence Laboratory. Massachusetts. 1602:144.
- Öztemel E (2003) *Yapay Sinir Ağları*. İstanbul, Papatya Yayıncılık.
- Öztürk A (2008) *Doppler işaretlerinin kaotik ölçütlerle sınıflandırılması (Doktora tezi)*. Konya, Selçuk Üniversitesi.
- Pardo M, Sberveglieri G (2005) Classification of electronic nose data with support vector machines. *Sens Actuators B Chem*, 107:730-737.
- Rosenthal DA, Dalton JA, Gervy R (2007) Analyzing vocational outcomes of individuals with psychiatric disabilities who received state vocational rehabilitation services: A data mining approach. *Int J Soc Psychiatry*, 53:357-368.
- Saeyns Y, Inza I, Larrañaga P, (2007) A review of feature selection techniques in bioinformatics. *Bioinformatics*, 23:2507-2517.
- Soman KP, Loganathan R, Ajay V (2011) *Machine Learning with SVM and Other Kernel Methods*. New Delhi, PHI Learning.
- Song Q (2010) The comparison and analysis of classification methods for psychological assessment data. *Information Science and Engineering (ICISE)*, 2nd International Conference on. IEEE. 4133-4135.
- Sifneos PE, Apfel SR, Frankel FH, (1977) The phenomenon of alexithymia. *Psychother Psychosom*, 28:47-57.
- Spitzer C, Siebel-Jürges U, Barnow S, Grabe HJ, Freyberger HJ, (2005) Alexithymia and interpersonal problems. *Psychother Psychosom*, 74:240-246.
- Steinwart I, Christmann A (2008) *Support Vector Machines*. New York, Springer.
- Stephanos S (1975) A concept of analytical treatment for patients with psychosomatic disorders. *Psychoter Psychosom*, 26:178-187.
- Stoudemire A (1991) Somatothymia: parts I and II. *Psychosomatics*, 32:365-381.
- Şahin NH, Şahin N, (1992) Reliability and validity of the Turkish version of the Automatic Thoughts Questionnaire. *J Clin Psychol*, 48: 334-340.
- Taylor GJ, Parker JDA, Bagby RM, Acklin MV (1992) Is alexithymia and somatic complaints psychiatric out patients. *J Psychosom Res*, 36:417-424.
- Türkçapar MH, (2009) *Bilişsel Terapi: Temel İlkeler ve Uygulamalar*. Ankara, Hekimler Yayın Birliği.
- Qinghua J (2016) Data mining and management system design and application for college student mental health. 2016 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS): 410-413.
- Vanheule S, Desmet M, Meganck R, Bogaerts S (2007) Alexithymia and interpersonal problems. *J Clin Psychol*, 63:109-117.
- Vapnik V, Chapelle O (2000) Bounds on error expectation for support vector machines. *Neural Comput*, 12:2013-2036.
- Willmott CJ, Matsuura C, (2005) Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Climate Research*, 30:79-82.

- Wolff HH, (1977) The contribution of interview situation to the restriction of fantasy life and emotional expression in psychosomatic patients. *Psychother Psychosom* 28: 58- 67.
- Yavuz Ö, Tecim V (2011) Cbs tabanlı suç önleme çalışmalarında yapay sinir ağları kullanılarak mekansal karar sistemi oluşturulması. Suç Önleme Sempozyumu (7 - 8 October Bursa), 2011, p.295-309, Bursa, Türkiye.

Yazarların Katkıları: Tüm yazarlar, her bir yazanın çalışmaya önemli bir bilimsel katkı sağladığını ve makalenin hazırlanmasında veya gözden geçirilmesinde yardımcı olduğunu kabul etmişlerdir.

Etik Onay: Tüm katılımcılardan yazılı aydınlatılmış onam alınmıştır.

Danışman Değerlendirmesi: Dış bağımsız

Çıkar Çatışması: Yazarlar çıkar çatışması bildirmemiştir.

Finansal Destek: Yazarlar bu çalışma için finansal destek almadıklarını beyan etmişlerdir.

Authors Contributions: All authors attest that each author has made an important scientific contribution to the study and has assisted with the drafting or revising of the manuscript.

Ethical Approval: Written informed consent was obtained from all participants.

Peer-review: Externally peer-reviewed.

Conflict of Interest: No conflict of interest was declared by the authors.

Financial Disclosure: The authors declared that this study has received no financial support.
