

**Bağımlılık Yapıcı Madde Kullanımı Riskinin Makine Öğrenmesi Yöntemleriyle Tahmini**

Prediction of Substance Abuse Usage Risk by Using Machine Learning Methods

Murad Naghiyev¹ , İclal Çetin Taş² , Yücel Tekin³ 

Geliş Tarihi (Received): 25.04.2023

Kabul Tarihi (Accepted): 10.08.2023

Yayın Tarihi (Published): 28.08.2023

Abstract: With the rapid development of technology, data-driven studies are increasingly being carried out in various fields. Machine learning algorithms are commonly used in these studies, and their use for early diagnosis and detection in the medical field is becoming more widespread. Machine learning techniques help in the early diagnosis of diseases, treatment planning, and making more effective and accurate decisions in disease management in the medical field. This leads to increased knowledge about patients' health conditions, thereby improving the quality and efficiency of healthcare services. The aim of this study is to predict which other addictive substances individuals who use addictive substances may use in the future using machine learning methods. KNN (k-nearest neighbor), Gaussian SVM (support vector machine), and decision tree methods were used in the application on the dataset of addictive substance use, and the results obtained were examined. The highest success rate was obtained with the Gaussian SVM method, which was 90.60%.

Keywords: Substance Addiction, Machine Learning, Prediction, KNN, SVM, Decision Tree

&

Öz: Teknolojinin hızlı gelişimiyle birlikte, farklı alanlarda veri odaklı çalışmalar giderek artmaktadır. Bu çalışmalarda, makine öğrenme algoritmaları sıklıkla kullanılmakta ve özellikle tıp alanında erken tanı ve teşhis amaçlı kullanımı giderek yaygınlaşmaktadır. Makine öğrenme teknikleri, tıp alanında hastalıkların erken teşhis edilmesi, tedavi planlaması ve hastalık yönetiminde daha etkili ve doğru kararlar alınmasına yardımcı olmaktadır. Bu sayede hastaların sağlık durumları hakkında daha fazla bilgiye sahip olunarak, sağlık hizmetlerinin kalitesi ve verimliliği artırılmaktadır. Bu çalışmanın amacı, bağımlılık yapıcı madde kullanan kişilerin ileride başka hangi bağımlılık yapan maddeleri kullanma risklerinin olabileceğini makine öğrenmesi yöntemleri ile tahminlemektir. Bağımlılık yapıcı madde kullanımına ilişkin veri setinde yapılan uygulamada KNN (k-nearest neighbour), Gaussian SVM (support vector machine), karar ağacı (DT-decision tree) yöntemleri kullanılmış olup elde edilen sonuçlar incelendiğinde en yüksek başarı %90,60 ile Gaussian SVM yönteminden elde edilmiştir.

Anahtar Kelimeler: Madde Bağımlılığı, Makine Öğrenmesi, Tahmin, KNN, SVM, Karar Ağacı

Atf/Cite as: Naghiyev M, Taş İC, Tekin Y. Bağımlılık Yapıcı Madde Kullanımı Riskinin Makine Öğrenmesi Yöntemleriyle Tahmini. Abant Sağlık Bilimleri ve Teknolojileri Dergisi, 2023;3(2):1-13.

İntihal-Plagiarism/Etik-Ethic: Bu makale, en az iki hakem tarafından incelenmiş ve intihal içermediği, araştırma ve yayın etiğine uyulduğu teyit edilmiştir. / This article has been reviewed by at least two referees and it has been confirmed that it is plagiarism-free and complies with research and publication ethics. <https://dergipark.org.tr/tr/pub/sabited/policy>

Telif Hakkı/Copyright © Published by Bolu Abant İzzet Baysal University, Since 2021 – Bolu

¹Murad Naghiyev, Ostim Teknik Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği, Ankara, Türkiye, murad90m@gmail.com, <https://orcid.org/0000-0001-8885-0314>

²İclal Çetin Taş, Ostim Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, Ankara, Türkiye, iclal.cetintas@ostimteknik.edu.tr, <https://orcid.org/0000-0002-1101-9773> (Sorumlu yazar / Corresponding Author)

³Yücel Tekin, Ostim Teknik Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği, Ankara, Türkiye, yucel.tekin@ostimteknik.edu.tr, <https://orcid.org/0000-0002-4565-5401>

Giriş

Antik zamanlardan beri insanlar kimyasal madde kullanmışlardır. Kullanılan bu kimyasal maddelerin Sümerlerin milattan önce 5000 yıllarında opium kullandıkları, Çinlilerin ise yine milattan önce 3500 yıllarında esrar kullandıkları kayıtlara geçmiştir (1). İlaç kullanımının tarihçesi incelendiğinde her medeniyetin madde kullanımına farklı bir bakış açısı getirdiği görülür. Eski insanlar bazı maddelerin rahatlatıcı, bazılarının dikkat artırıcı, bazılarının ise tahrik edici etkisi olduğunu fark etmişlerdir (2). Kimyasal maddeler kişi tarafından kötüye kullanılıyor ve bu maddeler kişide kötü etkilere sebep oluyorsa kişinin ilaç kullanım bozukluğuna sahip olması muhtemeldir. Bireyin amacı dışında, dozlamasına dikkat etmeden kullandığı ilaç niteliğinde olan ya da olmayan kimyasallar başta kişinin beyin aktivitelerini olumsuz etkilemesi, kişide bağımlılık meydana gelmesi, ilacın etki toleransının yükselmesi, ilgili madde alınmadığında yoksunluk hissi oluşturması gibi etkilere sahiptir (3). Bu sebepler, beyindeki fonksiyonların kişinin madde kullanımı sonucu değişmesine sebep olan davranışları gösteren bireyler ise madde bağımlısı olarak adlandırılır. Bu bağımlılık yapıcı maddeler kişide beş duyu organının algıladığı uyarıları farklı algılatmaya sebep olabilir (4). Bu durum kişilerde en alt seviyede davranış bozukluğu olmak üzere şiddet eğilimi, psikolojik problemleri beraberinde getirmektedir. Bir maddenin uyuşturucu madde niteliğinin olup olmadığına karar vermek için bazı kriterler bulunmaktadır. Bunları o maddenin uyarıcı, keyif verici, gerçek dışı öğeleri hayal ettiren, tahrik ve sarhoş edici olup olmadığına, kıstasına bu sebeplerden herhangi birisi sebebiyle insan irade ve muhakemesini ortadan kaldırıp kaldırmadığına da bakılarak karar verilmektedir (5).

Madde bağımlılıkları sadece kişiyi fiziksel sağlığında değil, kişinin sosyo-ekonomik durumuna da kötü etkisi bulunmaktadır (6). Opioidler, ağrı kesici olarak kullanılan (ancak aynı zamanda yasadışı uyuşturucu olarak da tüketilen), beynin opioid reseptörleriyle etkileşime girerek ağrıyı azaltan ve mutluluk, rahatlama ve uyusukluk hissi gibi yan etkilere neden olan ilaçlardır. Opioidler, genellikle morfin, kodein, hidrocodone, oksikodon, fentanil ve metadon gibi maddeler içerir ve doğal olarak afyon gibi bitki kaynaklı bileşiklerden veya sentetik olarak kimyasallardan üretilir. Ancak, uzun süreli ve yanlış kullanımları bağımlılık, aşırı doz ve ölüme neden olabilen ciddi sağlık sorunlarına yol açabilir (7). Türkiye Uyuşturucu ve Uyuşturucu Bağımlılığı İzleme Merkezi (UBİM) maddenin kötüye kullanımı konusunda projeksiyon yapmışlardır. Bunun sonucunda da madde bağımlılığının yakın gelecekte Türkiye'nin en önemli sorunlarından biri olacağını öngörmüşlerdir (8). Yine UBİM'in 2022 yılında yayınlanan raporuna göre Uyuşturucu ile mücadele alanında yapılan kamu harcamaları son yıllarda artış göstermiştir. 2019 yılında 1.441.955.782TL olan harcamalar, 2020 yılında %26'lık bir artışla 1.840.513.297TL'ye yükselmiştir. 2021 yılında ise bu rakam %27'lik bir artışla 2.340.421.544TL'ye ulaşmıştır (9). Bu veriler, uyuşturucu ile mücadele konusunun Türkiye'deki önemini ve kamu bütçesinden bu alana ayrılan kaynakların artmasının gerekliliğini ortaya koymaktadır. Tüm psikotik bağlantılı ölümler arasında madde kötüye kullanımından ölümler en yaygın ikinci sebeptir. Bu maddelerden en çok can alanı ise dünyada 1 milyar tüketicisi ile sigara ve tütündür (10). Bunun haricinde son yıllarda yaygın kullanımı olan bağımlılık yapıcı ilaçların sentetik kanabinoidler (özellikle tetrahidrokannabinol (THC) ve kannabidiol (CBD) gibi bileşikler) ve bunların türevleri olduğu tespit edilmiştir (11).

Teknolojinin gelişmesi ve makine öğrenmesindeki gelişmeler, veri toplama ve işleme tekniklerinde yeniliklere imkân sağlamıştır (12). Erken tanı ve teşhisin yapılmasında da tahmin kaynaklı sınıflandırma metotları tıpta kullanılmaktadır (13). Daha önce psikiyatride hastalıkların tanınmasını sağlayan pek çok bulgu keşfedilmiş ve model oluşturulmuştur. Bu oluşturulan modeller gerçek verilerden türetilmiş olup sınıflandırma yapılmasında da kullanılmaktadır (14). Birçok tıbbi analizde yapay sinir ağlarının kullanılması ile erken teşhis yapılabilmektedir (15).

Uyuşturucu madde kullanımı her geçen gün artmaktadır. İlaç kullanımı ise aşırı miktarlara ulaştığında bireyde bağımlılığa dönüşme riskine sahiptir. Maddelerin bu şekilde kötüye kullanımını tedavi etmek amaçlı atılan adımlar kapsayıcı fakat fazlasıyla genel yöntemler olmaktadır (16). Birçok hatalıkta olduğu gibi madde bağımlılığının tedavisinde kişiye yönelik özel bir tedavi planı uygulanmasının daha etkili olacağı düşünülmektedir. Bu sebeple, madde kullanan bireylerin kişilik özelliklerinin tedavi planlarını düzenlemekte kullanılabilecek bir faktör olup olmadığı tartışılmaktadır (17). Kişilerin madde kullanımına yatkın olup olmadıklarının önceden tespit edilmesi, bu maddeleri kullanmalarının önceden önlenmesi

konusunda kolaylık sağlar. Eğer spesifik risk faktörleri belirlenebilirse kısa zamanda kötüye madde kullanımını azaltabilecek stratejilerin geliştirilebileceği keşfedilmiştir (18).

Tıbbi açıdan 2008 yılında BMC Psychiatry'nin yayınladığı veriler ve analizler incelendiğinde farklı kişilik özelliklerine sahip insanların bağımlılık yapıcı maddeler kullandığı belirtilmiştir (19). Kişiliğin insan davranışlarına yansıdığı düşünüldüğünde, tedavi kişiselleştirmesi için örneğin Ferwerda ve Schedl ortak bir psikolojik model kullanılmışlardır (20). Uyuşturucu kullanmaya başlama yaşı da araştırmacıları tedaviyi kişiselleştirmenin daha etkili olacağı konusunda birleştirmiştir (21). Kontrolsüz madde kullanımı ve bağımlılık gibi problemlerin çözümünde günümüze kadar kullanılan metotlar fazlasıyla genel yaklaşımlarla sorunu ele alıp kişi bazında değişikliklere gitmemektedir (22). Fakat efektif bir tedavi ve tanının yapılabilmesi için kişi bazında probleme yaklaşılmalıdır. Çünkü her madde bağımlısı bireyin madde kullanımı hikayesi, metabolizması vs. farklı olup tedaviye göstereceği yanıt farklıdır (23). Kişisel tedavilerin süreci atlatmakta da daha iyi sonuçlar verdiğini gösteren birçok çalışma bulunmaktadır. Son 5 yıl içerisinde yapılan birçok araştırma, kişisel terapilerin grup terapilerine göre daha etkili sonuçlar verdiğini göstermektedir. Kişisel terapiler, bireylerin kendi ihtiyaçlarına özgü çözümler geliştirmelerine, öz farkındalıklarını artırmalarına ve kendilerini daha iyi anlamalarına yardımcı olur. Bu tür terapiler, ayrıca gizlilik, mahremiyet ve güvenlik açısından da grup terapilerine göre daha avantajlıdır. Bu nedenle, son yıllarda kişisel terapilerin popülaritesi artmıştır (24). Madde kullanımının sadece kişide bağımlılık riski taşıması değil, kişinin sirkadyen ritmini bozması durumu da vardır (25). Sirkadyen ritminin üç farklı tipi olduğunu bulunmaktadır (26). Bunlar kişilerin optimal uyku derinliklerinin günün hangi zamanına denk geldiğini ifade eden açıklayıcıdır (27). Madde kullanımı gözlenen kişilerde uyku kalitesinin düşüklüğü, REM uykusuna girmekte zorluk ve uzun vadede de sirkadyen ritminin bozulduğu keşfedilmiştir (27). Sigara kullanımının sirkadyen ritme en negatif maddelerden biri olduğu da belirtilmiştir (29).

Belirli bazı maddelerin kişiler arasında kullanılıp kullanılmadığı, ne sıklıkla kullanıldığı ve en son ne zaman maddeyi kullandıkları gibi verilerden yola çıkarak madde bağımlılarının ileride hangi maddeleri kullanma risklerinin olup olmadığının belirlenmesinin tedavi sürecine katkı sağlayacağı ya da yeni oluşabilecek bağımlılık durumları konusunda önlem alınabilmesi hususunda yardımcı olabileceği düşünülmektedir. Bu yaklaşımın önemli bir katkı sağladığı ve literatürdeki boşluğu doldurduğu açıktır. Çünkü bu çalışmada, bağımlılık yapıcı madde tüketimi riskini değerlendirmek için daha gerçekçi bir model önerilmektedir. Bu model, birden fazla madde arasındaki ilişkileri dikkate alarak, daha kapsamlı bir analiz sunmaktadır.

Çalışmamızın ana amacı, makine öğrenmesi tekniklerini kullanarak, belirli bir maddenin diğer üç maddeyle olan ilişkisini tahmin etmektir. Bu şekilde, bağımlılık yapıcı madde tüketimi riskini daha doğru bir şekilde değerlendirmek mümkün olacaktır. Çalışmamızın sonuçları, bağımlılık yapıcı maddelerin birlikte kullanımının risk faktörlerini daha iyi anlamamızı sağlayacak ve önleyici tedbirlerin geliştirilmesine katkıda bulunabilecektir. Bu sebeple bu duruma dair bir sınıflandırma problemi oluşturulmuştur. Bu çalışmada, bir gruptaki bağımlılık yapıcı maddelerinin bir kısmını kullandıktan sonra gruptaki diğer maddeleri kullanma potansiyelleri tahmin edilmeye çalışılmaktadır. Bu yöntemler bireylerin tedavilerinde bireysel yol haritaları belirlenerek bağımlılık sürecinin daha kısa sürelerde sonlanmasına katkıda bulunulması amaçlanmaktadır. Bir sonraki bölümde literatürde bu alanda yapılan çalışmaların analizi yapılmıştır. 3. Bölümde ise veri seti ve kullanılan yöntemlere değinilmiştir. 4. Bölümde deneysel prosedürlerin detayları açıklanmış ve sonuçları paylaşılmıştır. Son bölümde ise çalışmanın analizi üzerinde tartışma bölümünün detayları aktarılmıştır.

Literatür özeti

Çalışmadan önce, makine öğrenme yöntemleri ile ilgili olarak yapılmış önceki çalışmaları incelenmiş olup, detayları ile aktarılacaktır. Bu çalışmada, sınıflandırma ve tahmin için kullanılan makine öğrenme yöntemleri hakkında bilgi verilmektedir. Bu bölümde, yapılan araştırmaların özeti sunulmaktadır.

Aynı veri seti kullanılarak Fehrman ve ark. tarafından 2015 yılında farklı kişilik modellerinde uyuşturucu tüketim riskinin tahmin edilmesi amacıyla yapılan çalışmada Decision Tree (DT), Random Forest (RF), KNN, Lineer Discriminant Analysis (LDA), Logistic Regression (LR) and Naive Bayes (NB) algoritmalarını

uygulanmıştır. Elde edilen sonuçlarda duyarlılık ve özgünlüğün %75'in üzerinde olmasıyla en iyi sonuçlar esrar, crack, ecstasy, LSD ve uçucu madde kötüye kullanımı (VSA) için elde edilmiştir (30).

Nath ve ark. ise 2017 yılında uçucu madde kötüye kullanımının tahmini için bir makine öğrenme yaklaşımı olarak yapay sinir ağlarını (YSA) önermişlerdir. Bir kişinin VSA kullanıp kullanmadığını tahmin etmek için ANN-D (Artificial Neural Networks for Diagnostics) ve kullanım zamanını tahmin etmek için ANN-C (Artificial Neural Networks for Control) olmak üzere iki YSA modülü tasarlanmıştır. Kullanılan girdi özellikleri yaş, cinsiyet, ülke, etnik köken, eğitim, nevroitiklik, deneyime açıklık, dışadönüklük, uyumluluk, vicdanlılık, dürtüsellik, sansasyon arayışı vb.'dir. ANN-D modülüne, uçucu madde kötüye kullanımının (VSA) olup olmadığını tahmin etmek için girdi özellikleri verilir. ANN-C modülü gün, hafta, ay, yıl, onluktan önceki vb. zaman açısından VSA kullanımını tahmin eder. ANN-D modülünün doğruluğu %81 ve ANN-C modülü %71,9 olarak bulunmuştur (31).

Dumortiera ve arkadaşları tarafından yapılan çalışmada makine öğrenmesi yaklaşımlarını kullanarak eroin bağımlılığını (HD) ve amfetamin bağımlılığını (AD) sınıflandıran çok değişkenli maddeye özgü kriterleri belirlemek hedeflenmiştir. Söz konusu çalışmada 1990 - 1995 yılları arasında Pittsburgh Üniversitesi'nden toplanan veriler ile oluşturulmuş veri seti kullanılmıştır. Veri setini oluşturan 39 amfetamin mono-bağımlısı, 44 eroin mono-bağımlısı, 58 çoklu madde bağımlısı ve 81 madde bağımlısı olmayan bireylere ait verilerden oluşmaktadır. Toplamda 222 katılımcı bulunmaktadır. Bu çalışmada kullanılan makine öğrenmesi metodlarından NB, DT, Discriminant Analysis (DA) kullanılmıştır. DT yöntemi ile %86'ya varan bir doğruluk oranıyla NB ve DA yöntemlerinden daha iyi performans gösterdiği gözlemlenmiştir (32).

Hariran ve arkadaşları 2016 yılında Portekiz'de ortaokul öğrencilerinin alkol bağımlılıklarının tahminin etmek amacıyla bir çalışma gerçekleştirilmiştir. Bu çalışmada Portekiz'in Alentjo bölgesindeki 2 devlet okulundan elde edilen veriler ile oluşturulmuş bir veri seti kullanılmıştır. Söz konusu çalışmada, veri setinin anlaşılması ve tahmin edilebilmesi için RF ve SVM algoritmaları kullanılmıştır. SVM'nin doğruluk oranı yaklaşık %96,6 ve RF'nin doğruluk oranı ise %98,5 ile daha da yüksek olduğu tespit edilmiştir (33).

Materyal & Metot

Bu çalışmada kullandığımız veri seti UCI Machine Learning Repository'den (37) alınmıştır. Çalışmamızda, makine öğrenmesi algoritmalarını kullanarak gerçekleştirilen testlerin sonuçlarını Matlab 2022 ile analizler yapılarak elde edilmiştir. Çalışma kapsamındaki analizlerin yapıldığı bilgisayar işlemci 11th Gen Intel(R) Core(TM) i5-1135G7 @ 2.40GHz, 8 GB RAM, Windows 11 Home 64 bit işletim sistemine sahiptir. Çalışmada uygulanan adımlar sırasıyla Şekil 1'de gösterilmiştir.



Şekil 1. Çalışmada izlenen adımlar.

Veri Toplama ve Ön İşleme

Çalışmada kullandığımız veri setinin oluşturulmasında 1885 adet katılımcının madde kullanımlarıyla ilgili sorulara cevap vermeleri istenmiştir. Her katılımcı için 10 adet cevap alınmıştır. Tüm öznelikler kategorik ve ölçeklendirilmiş olup gerçek değerlidir. Tablo 2'de gösterilen öznelikler araştırmada kullanılan maddelerdir.

Tablo 1. Son 10 yıl içinde yapılmış olan çalışmaların özeti.

Yazarlar	Yıl	Yöntem	Sonuç/Bulgu
1 Fehrman ve ark. (30)	2015	DT RF KNN LDA LR NB	Duyarlılık ve özgülüğün %75'in üzerinde olmasıyla en iyi sonuçlar esrar, crack, ecstasy, LSD ve uçucu madde kötüye kullanımı (VSA) için elde edilmiştir.
2 Dumoriter ve ark. (32)	2016	NB DT DA	Decision Tree yöntemi, %86'ya varan bir doğruluk oranıyla diğer algoritmalarından daha iyi performans göstermiştir.
3 Hariharan ve ark. (33)	2016	RF SVM	%96,60 %98,50
4 Nath ve ark. (31)	2017	ANN-D ANN-C	ANN-D modülünün doğruluğu %81 ve ANN-C modülü %71,9 olarak bulunmuştur.
5 Xiaoyu ve ark. (36)	2017	SVM	Grid-search yöntemiyle öznitelik seçimi gerçekleştirilmiş ve makine öğrenmesi teknikleri kullanılarak dinlenme durumu FMRI verileri kullanılarak nörolojik veya nöropsikiyatrik hastalık durumlarını tahmin etmek için uygulanmıştır. SVM algoritmasını kullanarak %75,5 oranında doğruluk elde edilmiştir.
6 Jing ve ark. (35)	2019	LR MB SVM DNN RF	Bu çalışmada, RF modelinin madde kullanım bozukluğunu 30 yaşına kadar tahmin etmede en etkili algoritma olduğunu ortaya koymuştur.
7 Kharabsheh ve ark. (34)	2019	SVM NB K-Star IBk	Çalışmada, SVM ve NB algoritmalarının diğer sınıflandırıcılardan daha iyi sınıflandırma performansı sunmasını göstermektedir.

Tablo 2. Öznitelikler ve açıklamaları.

Öznitelikler	Açıklamaları	Öznitelikler	Açıklamaları
1. Alcohol	Alkol	6. Caff	Kafein
2. Benzos	Benzodiazepin	7. Ecstasy	Ekstazi
3. Cannabis	Marihuana	8. Ketamine	Ketamin
4. Heroin	Eroin	9. Meth	Metamfetamin
5. Amphet	Amfetamin	10. LSD	LSD

Kullanıcılardan her bir madde için cevaplardan birini seçmeleri istenmiştir cevap detayları Tablo 3'te verilmektedir.

Veri toplama kısmında Tablo 3'te de gösterildiği gibi kullanıcıların ilgili maddeyi en son ne zaman kullandıkları sorusunun 7 cevabı bulunmaktadır. Bu her bir cevap CL0'dan CL6'ya kadar 1'den 7'ye kadar sayılarla temsil edilmiştir. Böylece sayısallaştırma yapılarak numerik olmayan özneliklerin numerik hale getirilmesi sağlanmıştır. Bu sayede veriler regresyona veya sınıflandırmaya uygun hale getirilmiştir.

Tablo 3. Ankette verilen cevap açıklamaları.

Cevap	Cevap Açıklaması
CL0	Madde hiç kullanılmadı
CL1	Madde 10 yıldan önce kullanıldı
CL2	Madde son on yıl içerisinde kullanıldı
CL3	Madde geçen bir yıl içerisinde kullanıldı
CL4	Madde geçen bir ay içerisinde kullanıldı
CL5	Madde geçen bir hafta içerisinde kullanıldı
CL6	Madde geçen bir gün içerisinde kullanıldı

Veri setinde bulunan, gürültülü verilerin eliminasyonu yapılmıştır. Eksik veri bulunmadığından tamamlama işlemi yapılmamıştır. 9 adet gürültülü veri tespit edilmiş ve veri setine ilgili satırlarda işlem yapılmıştır.

Veri seti üzerinde normalizasyon çalışması yapılmıştır. Tüm verileri (0,1) aralığına dönüştürülmüştür. Bu işlemle, makine öğrenmesi metotlarının daha doğru sonuçlar vermesine katkıda bulunulması amaçlanmıştır. Normalizasyon işlemi için kullanılan formül Denklem 1'dir.

$$X_{nor} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Bu çalışmada, KNN, Gaussian SVM ve DT olmak üzere 3 farklı metot kullanılmıştır.

KNN sınıflandırma yöntemi, makine öğrenmesinde sık kullanılan ve oldukça popüler olan bir yöntemdir. Bu yöntem, veri setindeki noktaların komşularına dayanarak sınıflandırma yapmaktadır. KNN yöntemi, veri seti üzerinde önceden eğitilmemiş ve sınıflandırma işlemi sırasında her veri noktası için komşularının sınıfını hesaplar. Bu sayede, eğitim verilerinin ayrıntılı incelemelerine gerek kalmadan, yeni verilerin sınıflandırmasını yapabilir.

KNN yöntemi, sınıflandırma problemlerinde ve benzerlik ölçümlerinde kullanılmaktadır. Bu yöntemde, veri noktaları arasındaki mesafeler ölçülerek, en yakın k komşusu belirlenir ve bu komşuların sınıfları yeni veriye atanır. KNN, çok boyutlu veri setlerinde de etkili bir şekilde kullanılabilir. Ancak, KNN yöntemi hesaplama yoğunluğu yüksek olduğundan, büyük veri setleri için uygun olmayabilir.

KNN yöntemi, sınıflandırma yanı sıra regresyon analizinde de kullanılabilir. Bu yöntemde, bir veri noktasının tahmin edilmesi, çevresindeki en yakın k noktanın ortalama değerinin alınması ile hesaplanır. Bu sayede, KNN yöntemi çok çeşitli uygulamalarda kullanılabilir ve özellikle sınıflandırma problemlerinde oldukça etkilidir (38,39).

K-En Yakın Komşu (KNN) algoritmasında Euclidean uzaklık formülü, yeni veri noktasının sınıflandırılması için kullanılan temel bir matematiksel ifadedir. Öklid uzaklık, iki nokta arasındaki doğrusal mesafeyi hesaplamak için kullanılır ve şu şekilde ifade edilir:

$$D(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (2)$$

Burada, D(x,y) Öklid uzaklığını gösterir, (x₁, x₂, ..., x_n) ve (y₁, y₂, ..., y_n) iki veri noktasının koordinatlarını temsil eder.

Gaussian SVM, makine öğrenmesinde yaygın olarak kullanılan bir sınıflandırma yöntemidir. Bu yöntem, veri setini iki sınıf arasında ayırtmak için kullanılan bir hiperdüzlem oluşturur. Bu hiperdüzlem, veri setindeki noktaların Gaussian dağılımını kullanarak hesaplanır.

SVM yöntemi, veri setindeki sınıfların lineer olarak ayırtılamadığı durumlarda daha çok farklı çekirdek fonksiyonları ile tercih edilen bir yöntemdir. SVM lineer fonksiyonlarla da çözümlenebilir. SVM yöntemi, özellikle düşük boyutlu veri setleri için oldukça etkilidir. Ancak, çok boyutlu veri setleri için kullanıldığında, hesaplama yoğunluğu yüksek olduğundan işlemci gücü gerektirir.

Gaussian SVM yöntemi, sınıflandırma yanı sıra regresyon analizinde de kullanılabilen bir yöntemdir. Bu yöntemde, regresyon analizindeki hiperdüzlemler yerine, çevrelerindeki en yakın noktaların etkisi kullanılır. Bu sayede, SVM yöntemi çok çeşitli uygulamalarda kullanılabilir ve özellikle non-lineer sınıflandırma problemlerinde oldukça etkilidir.

Gaussian SVM yöntemi, birçok alanda kullanılmaktadır. Örneğin, biyomedikal araştırmalarda kanser hücrelerinin sınıflandırılması ve görüntü işleme alanında nesne tanıma gibi uygulamalarında etkilidir (39, 40).

Destek Vektör Makineleri (SVM) algoritmasında, genellikle doğrusal olmayan verileri sınıflandırmak için çekirdek fonksiyonu kullanılır. SVM'nin temel matematiksel ifadesi, doğrusal çekirdek işlevi için şu şekildedir:

$$f(x) = \text{sign} \left(\sum (a_i * y_i * K(x_i, x) + b) \right) \quad (3)$$

Burada, $f(x)$ yeni veri noktasının sınıfını belirten fonksiyondur. a_i , destek vektörlerinin katsayılarıdır ve y_i , bu destek vektörlerinin etiketleridir. $K(x_i, x)$ çekirdek işlevidir ve x_i ve x , sırasıyla, destek vektörlerinin ve yeni veri noktasının özellik vektörleridir. b , SVM'nin karar sınırını ve marjini ayarlayan bias terimidir.

DT, Karar Ağaçları yöntemi olarak bilinen bir sınıflandırma veya regresyon metodudur. Bu metod, veri setinden elde edilen bilgileri kullanarak sınıflandırma yapmak için hiyerarşik bir yapı oluşturur. Bu yapı, veri setinde bulunan özellikleri kullanarak sınıflandırma yapar ve her seviyede bir karar noktası oluşur. Karar ağaçları, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılır ve genellikle yüksek doğruluk oranlarına sahiptir. Ayrıca, karar ağaçları insan tarafından anlaşılması kolay olduğu için, sınıflandırma veya regresyon problemlerinin açıklanması için kullanışlıdır. Karar ağaçları ayrıca, sınıflandırma veya regresyon işlemini gerçekleştirmek için hızlı ve etkili bir yöntem olarak bilinir (38, 41).

DT, bir veri kümesini sınıflandırmak veya regresyon yapmak için ağaç yapısını oluştururken ana faktör olan ayrıştırma kriteri dikkate alınmıştır. Gini's çeşitlilik indeksi, verilerin homojenliğini veya saflığını ölçmek için kullanılan bir ayrıştırma kriteridir ve ağacın düğümlerini bölmek için temel olarak kullanılır.

Ayrıştırma kriteri Gini's çeşitlilik indeksi için formül şu şekildedir:

$$Gint(t) = 1 - \sum (p(i|t)^2) \quad (4)$$

Burada, t düğümü için Gini katsayısı hesaplanır. $p(i|t)$, düğüm t içinde sınıf i 'nin görülme olasılığını temsil eder. Düğümlerin Gini katsayısı ne kadar düşük olursa, o düğümdeki veriler o kadar homojen veya saftır.

Bu üç metod, makine öğrenimine yönelik popüler ve etkili yöntemlerdir ve veri setinde sınıflandırma problemleri çözmek için kullanılabilirler.

Tablo 4. Model parametreleri.

KNN	SVM	DT
Number of neighbours: 10 Mesafe hesaplama yöntemi: Öklid	Kernel fonksiyonu: Gauss Kernel scale: 4.9	Maximum ayrıştırma sayısı: 20 Ayrıştırma kriteri: Gini's çeşitlilik indeksi

Bulgular

Makine öğrenimi yöntemlerini kullanarak, bağımlılık yapıcı maddeler kullanan kişilerin LSD, METH ve CANNABİS bağımlılık yapıcı maddesini kullanma riskini tahmin edilmiştir.

Deneylerdeki bağımlılık yapıcı maddelerin birbirleri arasında olan ilişkilerine kısaca değinilecektir. Alkol, amfetaminler ve benzos arasında etkileşimler ve yan etkiler gözlemlenebilir. Örneğin, alkol ve amfetaminlerin birlikte kullanımı, kişinin uyarılma hissini artırabilir ve davranışlara yol açabilir. Benzos ise merkezi sinir sistemi üzerinde sakinleştirici sahip bir ilaç grubudur. Benzos ile alkol bir arada kullanıldığında, sinir sistemi üzerindeki depresif etkiler artar ve solunum problemlerine olabilir (43).

Tablo 5. Deney detayları.

Deney adı	Etken Madde Kombinasyonu
Deney1	Alcohol Amphet Benzos
Deney2	Caff Cannabis Ecstasy
Deney3	Heroin Ketamine Meth
Deney4	Heroin Ketamine Lsd
Deney5	Caff Meth Ecstasy

Kahve, kenevir ve ecstasy her biri bağımlılık yapıcı etkilere sahip olabilir. Uzun süreli ve kötüye kullanım durumunda, bu maddeler bağımlılık gelişimine katkıda bulunabilir. Bağımlılık, bir maddenin sürekli kullanılmasına ve vücutta tolerans ve bağımlılık gelişimine bağlı olarak ortaya çıkabilir. Her madde bağımlılık potansiyeli farklılık gösterebilir ve bireyler arasında değişkenlik gösterebilir (43).

Heroin, Ketamin ve Metamfetamin farklı etkiler sergileyen maddelerdir. Heroin, güçlü bir opiyattır ve merkezi sinir sistemi üzerinde depresif etkiler yaratır. Ketamin, anestezi bir madde olarak kullanılır ve halüsinojenik etkileri vardır. Metamfetamin, uyarıcı bir maddedir ve uyarılma, artan enerji ve odaklanma hissi yaratır. Bu maddeler bir arada kullanıldığında, etkileşimleri ve yan etkileri artabilir (43).

Kafein, Metamfetamin ve Ecstasy farklı etkiler sergileyen maddelerdir. Kafein merkezi sinir sistemini uyarır ve uyanıklık hissi verir. Metamfetamin, uyarıcı bir maddedir ve enerji, artan odaklanma ve uyarılma hissi yaratır. Ecstasy ise uyarıcı ve halüsinojenik bir maddedir ve enerji, sevgi ve algı değişiklikleri yaratır. Bu maddeler bir arada kullanıldığında, etkileşimleri ve yan etkileri artabilir (13).

Maddeler arasındaki ilişkileri içeren deneysel kombinasyonlar belirlenirken bahsedilen etkileşimler göz önünde bulundurulmuştur. Deney detayları Tablo 5'te verilmiştir. Elde edilen sonuçlar sırasıyla Tablo 6, Tablo 7 ve Tablo 8'de gösterilmiştir. Bu sonuçlar, makine öğrenme yöntemlerinin bağımlılık yapıcı maddeler kullanma riskini ölçmek için etkili bir yöntem olabileceğini göstermektedir. Bu sonuçlar, sağlık hizmetleri ve bağımlılıkla mücadele konusunda önemli bilgiler sağlayabilir.

Tablo 6. LSD için alınan sonuçlar.

Algoritma	Knn (%)	Gaussian Svm (%)	Decision Tree (%)
Deney1	76.60	77.60	77.00
Deney2	69.00	74.00	76.60
Deney3	77.60	75.60	75.80

Tablo 7. METH için alınan sonuçlar.

Algoritma	Knn (%)	Gaussian Svm (%)	Decision Tree (%)
Deney1	89.60	90.20	89.20
Deney2	90.00	90.00	89.60
Deney4	90.60	90.60	90.40

Tablo 8. CANNABIS için alınan sonuçlar.

Algoritma	Knn (%)	Gaussian Svm (%)	Decision Tree (%)
Deney1	40.20	43.80	45.40
Deney5	45.60	45.80	45.20
Deney4	41.00	41.60	42.20

Çalışmada etken maddesi aynı olmayan, farklı etken maddeleri arasında ilişki gözlemlenmiştir. Bunun sonunda Deney1 Deney2 ve Deney3 kapsamındaki bağımlı bir bireyin cannabis etken maddesi için eğiliminin tetikleyici nitelikte olmadığı elde edilen sonuçlara göre Deney1 Deney2 ve Deney4'te ki bağımlılık sahibi bireylerin Meth yöneliminin olduğu ve Deney1 Deney2 ve Deney3'te ki etken maddeleri bağımlılığı olan bireylerin Lsd kullanımı için daha yönelimli olduğu tespit edilmiştir. Bağımlılık yapıcı madde tüketimi riskinin daha kapsamlı bir şekilde incelendiğini ve birden fazla madde arasındaki ilişkilerin önemli olduğunu görülmektedir. Sonuçlar incelendiğinde tedavi sürecinde ilgiliye ön görüş sağlayabilecek bu yaklaşımın sürece katkı sağlayabileceği aşikardır.

Tartışma

Literatürde benzer veri setleri ile daha önce yapılan çalışmalarda bağımlılık yapıcı madde tüketimi tahminlenmesi (44), bağımlılık yapıcı maddelerin kullanımı sonucu psikolojik değişimler (45) ve fiziksel riskler (46), ekonomik boyutu (47) gibi çok farklı alanlar üzerinde olduğu görülmektedir. Bağımlılık yapıcı maddelerin diğer etken maddelerle olan etkileşimine dair çalışmalar bulunmamaktadır. Bu çalışma kapsamında makine öğrenmesi yöntemlerinin yalnızca bir risk faktörü olarak bağımlılık yapıcı maddeler kullanımını değerlendirilmesi yapılmıştır. Ancak farklı risk faktörlerinin de bulunduğu ve bu faktörlerinin de dikkate alınması gerektiği göz ardı edilmemelidir. Örneğin, bağımlılığı tetikleyici neden olabilen kişinin sosyo-ekonomik durumu, psikolojik sağlığı ve çevresel faktörler. Bu faktörlerin değerlendirilmesiyle daha kapsamlı ve doğru sonuçlar elde edilebilir. Bu nedenle, makine öğrenmesi yöntemlerinin bağımlılık yapıcı maddeler kullanma riskini ölçmede tavsiye niteliğinde geri bildirim vermektedirler. Bağımlılık yapıcı maddeler kullanma riskinin doğru bir şekilde ölçülmesi için, diğer risk faktörlerinin de kesinlikle değerlendirilmesi ve hem fiziksel hem psikolojik değerlendirmeyi yapabilecek uzmanlar tarafından analizlerin yapılması gerekmektedir. Bu sayede, sağlık hizmetleri ve bağımlılıkla mücadele konusunda daha etkili önlemler alınabilir. Ayrıca bu veri setleri oluşturulurken ki toplanan anketlere katılan bireylerin cevaplarında manipülasyon olmadığı ön görülmektedir. Madde bağımlılığı toplum tarafından da hoş karşılanmayan bir davranış olması sebebiyle bireylerin doğruları yansıtmayan cevaplar verebilecekleri ihtimalde bulunmaktadır.

Sonuçlar ve Öneriler

Sonuç olarak, makine öğrenmesi yöntemlerinin bağımlılık yapıcı maddeler kullanma riskini ölçmek için etkili bir yöntem olabileceği konusunda kanıtlar vardır. Ancak, bu yöntemlerin tek başına kullanılması tavsiye edilmez ve daha fazla araştırma yapılması gerekmektedir. Bu araştırmalar, makine öğrenmesi yöntemlerinin bağımlılık yapıcı maddeler kullanma riskini ölçmede ne kadar güvenilir olduğunu, hangi

yöntemlerin en etkili olduğunu ve hangi durumlarda kullanılmasının en uygun olduğunu belirleyebilir. Bu bilgiler sayesinde, makine öğrenmesi yöntemlerinin bağımlılık yapıcı maddeler kullanma riskini ölçmede daha etkili bir şekilde kullanılması mümkün olabilir. Ancak yöntemler dışında maddeler arasındaki benzerlikler veya ayrışmalarında etkili olduğu cannabis etken maddesi deneylerinden elde edilen sonuçlar incelendiğinde ortaya çıkmaktadır. İleriki çalışmalar uygulanacak farklı yöntemler dışında ilgili maddelerin kimyasal nitelik ve özellikleri incelenerek deneysel prosedürler oluşturulabileceği ve özellik çıkarımı yapılabileceği düşünülmektedir.

Etik Beyan: Bu çalışmanın hazırlanma sürecinde bilimsel ve etik ilkelere uyulmuş ve yararlanılan tüm çalışmaların kaynakçada belirtilmiştir. Bu makale, iTenticate yazılımınca taranmıştır. İntihal oranı %2 olarak tespit edilmiştir.

Yazar Katkıları: Çalışma konsepti/tasarımı - İÇT; Veri toplama - MN; Veri analizi - MN; Makalenin yazımı - MN, İÇT; İçeriğin eleştirel incelemesi - İÇT, YT; Son onay ve sorumluluk - MN, İÇT, YT; Malzeme ve teknik destek - İÇT, YT; Süpervizyon - İÇT, YT.

Akran Değerlendirmesi: Dış bağımsız.

Çıkar Çatışması: Yazarlar, çıkar çatışması bulunmadığını beyan etmişlerdir.

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

Teşekkür: Yok.

Diğer Beyanlar: Yok.

Kaynaklar

1. Open.lib.umn.edu. n.d. Drug Use in History. Retrieved from: <https://open.lib.umn.edu/socialproblems/chapter/7-1-drug-use-in-history/>.
2. Wilson B. The effect of drugs on male sexual function and fertility. *The Nurse Practitioner*. 1991;16(9):12-24.
3. NIDA. Drug Misuse and Addiction. Retrieved from <https://nida.nih.gov/publications/drugs-brains-behavior-science-addiction/drug-misuse-addiction> 2020, July 13.
4. Shaffer H. Understanding the means and objects of addiction: Technology, the internet, and gambling. *Journal of Gambling Studies*. 1996;12(4):461-9.
5. Gökler R, Koçak R. Uyuşturucu ve madde bağımlılığı. *Sosyal Bilimler Araştırmaları Dergisi*. 2008;3(1):89-104.
6. Schuckit M. Treatment of opioid-use disorders. *New England Journal of Medicine*. 2016;375(4):357-68.
7. Kumari D, Kilam S, Nath P, et al. Prediction of alcohol abused individuals using artificial neural network. *Int. J. Inf. Technol*. 2018;10:233-7.
8. Prat G, Adan A. Influence of circadian typology on drug consumption, hazardous alcohol use, and hangover symptoms. *Chronobiology International*. 2011;28(3):248-57.
9. Türkiye Cumhuriyeti İçişleri Bakanlığı Narkotik Suçlarla Mücadele Daire Başkanlığı. 2022. Türkiye Uyuşturucu Raporu 2022. Erişim adresi: (<https://www.narkotik.pol.tr/kurumlar/narkotik.pol.tr/TUB%C4%B0M/Ulusal%20Yay%C4%B1nlar/Turkiye-Uyusturucu-Raporu-2022.pdf>) 2022.
10. Crane R. The most addictive drug, the most deadly substance: smoking cessation tactics for the busy clinician. *Primary Care: Clinics in Office Practice*. 2007;34(1):117-135.
11. Rech M, Donahey E, Cappiello D, Greenhalgh E. New Drugs of Abuse. *Pharmacotherapy: The Journal of Human Pharmacology and Drug Therapy*. 2014;35(2):189-197.
12. Roh Y, Heo G, Whang E. A survey on data collection for machine learning: a big data-ai integration perspective. *IEEE Transactions on Knowledge and Data Engineering*. 2019;33(4):1328-47.
13. Zhang ZM, Tan JX, Wang F, et al. Early diagnosis of hepatocellular carcinoma using machine learning method. *Frontiers in Bioengineering and Biotechnology*. 2020;8:254.
14. Salvatore C, Cerasa A, Battista P, Gilardi M, Quattrone A, Castiglioni I. Magnetic resonance imaging biomarkers for the early diagnosis of Alzheimer's disease: a machine learning approach. *Frontiers in Neuroscience*. 2015; 9:307.
15. So A, Hooshyar D, Park KW, Lim HS. Early diagnosis of dementia from clinical data by machine learning techniques. *Applied Sciences*. 2017;7(7):651.
16. Ashton C and Kamali F. Personality, lifestyles, alcohol and drug consumption in a sample of British medical students. *Medical education*. 1995, 29(3), pp.187-192.
17. Fehrman E, Muhammad AK, Mirkes EM, Egan V, Gorban AN. The five-factor model of personality and evaluation of drug consumption risk. In *Data science*. Springer, Cham. 2017, 231-242.
18. Ferwerda B, Tkalcic M. Exploring the prediction of personality traits from drug consumption profiles. In *Adjunct Publication of the 28th ACM Conference on User Modeling, Adaptation and Personalization*. 2020, 2-5.
19. Skóra MN, Pattij T, Beroun A, Kogias G, Mielenz D, de Vries T, et al. Personality driven alcohol and drug abuse: New mechanisms revealed. *Neurosci Biobehav Rev*. 2020;116:64-73.

20. Franken, IH, Stam, CJ, Hendriks, VM, & van den Brink, W. (2004). Electroencephalographic power and coherence analyses suggest altered brain function in abstinent male heroin-dependent patients. *Neuropsychobiology*, 49(2), 105–110. <https://doi.org/10.1159/000076419>
21. Fumiahru T, Neil SC, Benjamin HN. Electroencephalogram characteristics of autonomic arousals during sleep in healthy men. *Clin. Neurophysiol.* 2006;117:2490–2623.
22. Subaşı A, Erçelbi E. Classification of EEG signals using neural network and logistic regression. *Computer Methods and Programs in Biomedicine.* 2005;78:77-90.
23. Uzbay T. Madde Kötüye Kullanımı ve Bağımlılığı. *Psikofarmakoloji.* Yüksel N. (Ed.), Çizgi Tıp Kitabevi, Ankara, 2003, Yenilenmiş 2. Baskı, s. 485-520.
24. Swift JK, Callahan JL, Vollmer BM. Preferences. *Journal of Clinical Psychology.* 2018;74(7):1009-18.
25. Kantarsic M. *Data Mining: Concepts, Models, Methods, and Algorithms.* John Wiley & Sons Publishing, 2003.
26. Köknel Ö. *Bağımlılık Alkol ve Madde Bağımlılığı.* (1. Baskı). İstanbul: Altın Kitap. 1998.
27. Mansour A, Khacaturian H. Anatomy of CNS opioid receptors. *Trend Neurosci.* 1988;11(7):308–14.
28. Macellan T, Lewis C. Drug dependence, a chronic medical illness: Implications for treatment, insurance, and outcomes evaluation. *JAMA.* 2000; 284(13):1689–95.
29. Panksepp B, Lavhis GP. Rodent empathy and affective neuroscience. *Neurosci Biobehav Rev.* 2011;35(9):1854–85.
30. Fehrman, E, Muhammad, AK, Mirkes, EM, Egan, V, Gorban, A.N. (2017). The Five Factor Model of Personality and Evaluation of Drug Consumption Risk. In: Palumbo, F., Montanari, A., Vichi, M. (eds) *Data Science . Studies in Classification, Data Analysis, and Knowledge Organization.* Springer, Cham. https://doi.org/10.1007/978-3-319-55723-6_18.
31. Nath P, Kilam S, Swetapadma A. A machine learning approach to predict volatile substance abuse for drug risk analysis. 2017 Third International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN), Kolkata. 2017, 255-258.
32. Dumortier A, Beckjord E, Shiffman S, Sejdić E. Classifying smoking urges via machine learning. *Comput Methods Programs Biomed.* 2016;137:203-13.
33. Hariharan B, Krithivasan R, Deborah A. Prediction of secondary school students' alcohol addiction using random forest. *International Journal of Computer Applications.* 2016;149(6):21-5.
34. Kharabsheh M, Meqdadi O, Alabed M, Veeranki S, Abbadi A, Alzyoud S. A machine learning approach for predicting nicotine dependence. *International Journal of Advanced Computer Science and Applications.* 2019;10(3):179-84.
35. Yuan Y, Huang J, Yan K. Virtual reality therapy and machine learning techniques in drug addiction treatment. 2019 10th International Conference on Information Technology in Medicine and Education (ITME). doi:10.1109/itme.2019.00062 .2019.
36. Ding X, Yang Y, Stein EA, Ross TJ. Combining Multiple Resting-State fMRI features during classification: Optimized frameworks and their application to nicotine addiction. *Front Hum Neurosci.* 2017;11:362.
37. Fehrman, Elaine, Egan, Vincent, and Mirkes, Evgeny. (2016). Drug consumption (quantified). UCI Machine Learning Repository. <https://doi.org/10.24432/C5TC7S>
38. Hastie T, Tibshirani R, Friedman J. *The elements of statistical learning: data mining, inference, and prediction.* Springer Science & Business Media. 2009.

39. Fix, E., & Hodges, JL. (1989). Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties. *International Statistical Review / Revue Internationale de Statistique*, 57(3), 238–247. <https://doi.org/10.2307/1403797>
40. Cristianini, N, Ricci, E. (2008). Support Vector Machines. In: Kao, MY. (eds) *Encyclopedia of Algorithms*. Springer, Boston, MA. https://doi.org/10.1007/978-0-387-30162-4_415
41. Bell, DE, Raiffa, H, & Tversky, A. (1988). Descriptive, normative, and prescriptive interactions in decision making. In D. E. Bell, H. Raiffa, & A. Tversky (Eds.), *Decision making: Descriptive, normative, and prescriptive interactions* (pp. 9–30). Cambridge University Press. <https://doi.org/10.1017/CBO9780511598951.003>
42. Bishop, CM, & Nasrabadi, NM. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
43. NIDA. 2023, May 30. Preface. Retrieved from <https://nida.nih.gov/research-topics/addiction-science/drugs-brain-behavior-science-of-addiction> on 2023, July 18
44. Ghousi, R, Mehrani, S, & Momeni, M. (2012). Application of Data Mining Techniques in Drug Consumption Forecasting to Help Pharmaceutical Industry Production Planning.
45. Motamedi E, Barile F and Tkalčić M. (2022). Prediction of Eudaimonic and Hedonic Orientation of Movie Watchers. *Applied Sciences*. 10.3390/app12199500. 12:19. (9500).
46. Dede, Ş, Kayabaşı, H, Karagöz, F, Aker Karagöz, Y, & Savaş, A. (2017). Uyuşturucu Madde Kullanımına Bağlı Akut Böbrek Hasarı: Olgu Serisi [Acute Kidney Injury due to Drug Abuse: A Case Series]. *Gaziosmanpaşa Taksim Training and Research Hospital*. DOI: 10.5152/jarem.2017.988
47. Bickel, WK, Yi, R, Mueller, ET, Jones, BA, & Christensen, DR. (2010). The Behavioral Economics of Drug Dependence: Towards the Consilience of Economics and Behavioral Neuroscience. In D. Self & J. Staley Gottschalk (Eds.), *Behavioral Neuroscience of Drug Addiction. Current Topics in Behavioral Neurosciences*, Vol. 3, s. 3-24. Springer. https://doi.org/10.1007/7854_2009_22