

Toplumsal Analizlerde Makine Öğrenmesi

Ömer Faruk Seymen¹

Özet

Makine öğrenimi (ML), büyük veri kümelerinin analizi yoluyla sosyal davranışın anlaşılmasını ve tahmin edilmesini geliştirmek için önemli bir fırsat sunar. Bu teknoloji, geleneksel araştırma metodolojilerini geride bırakır ve sağlık eşitsizlikleri, ekonomik eğilimler, oy verme davranışı ve yanlış bilginin tespiti dahil olmak üzere çeşitli sosyal zorluklara yenilikçi çözümler sunar. Sosyal medya, anketler, kamu veritabanları ve sensörler gibi çeşitli kaynaklardan gelen verileri kullanarak ML, sosyal eğilimlerin belirlenmesini, duygu analizini ve kamu ihtiyaçlarının öngörülmesini kolaylaştırır. Özellikle sosyal medya eğilimleri ve tüketici geri bildirimlerini yansıtan veriler üreterek sosyal analizde önemli bir rol oynar. Makine öğrenimi, sosyal davranış ve ortaya çıkan eğilimler hakkında daha derin içgörüler elde etmek için bir dizi veri kaynağı kullanır. Ayrıca, Nesnelerin İnterneti (IoT) gibi teknolojiler, gerçek zamanlı veri içgörülerini sunarak pazarlama ve ürün geliştirme süreçlerini destekler. Ancak, bu teknolojinin uygulanmasıyla ilişkili etik endişeleri ele almak zorunludur. Algoritmaların opaklığı ve dijital izlemeyle ilgili uygulamalar bireysel özgürlükler için risk oluşturabilir. Bununla birlikte, sosyal medya platformlarının manipülasyon aracı olarak kullanılma potansiyeli önemli etik soruları gündeme getiriyor. Makine öğreniminin sosyal sonuçlarına dikkatli bir değerlendirme ve titiz bir analizle yaklaşmak önemlidir.

1. GİRİŞ

İçinde bulunduğumuz çağda veri, toplumsal davranışları anlamak, öngörmek ve bunlar üzerinde etkili olmak için benzersiz fırsatlar sunan son derece değerli bir kaynak olarak kabul edilmektedir (Kim & Adler, 2015). Sosyal alandaki tüm değişimleri ve gelişmeleri içeren büyük miktarlarda veriyi analiz edebilme kapasitesi sosyal dünyayı yeniden anlamlandırmamızı

1 Dr. Öğretim Üyesi, Sayısal Yöntemler Bölümü, Sakarya Üniversitesi, ofseymen@sakarya.edu.tr
ORCID ID: 0000-0003-2224-5546

sağlamaktadır (Gruber, 2008). Yapay zekanın (YZ) bir alt kümesi olan makine öğrenimi (ML), bu yeniden anlamlandırma dönüşümünde çok önemli bir yere sahiptir. Makine öğrenimi, bilgisayarların verileri analiz etmesini ve bunlardan öğrenmesini sağlayarak araştırmacılara, politika yapıcılara ve kuruluşlara daha önce hayal bile edilemeyen içgörüler elde etme kapasitesi sunmaktadır (Mitchell, 2007).

Makine öğreniminin sosyal analize uygulanması, karmaşık toplumsal zorlukların ele alınması için yeni yollar sağlayarak makine öğreniminin sosyal analize uygulanması, toplumsal huzursuzlukların öngörülmesi, sağlık alanındaki eşitsizliklerin anlaşılması, oy verme davranışının analizi ve tüketici davranışındaki eğilimlerin belirlenmesi de dahil olmak üzere toplumun karmaşık dinamiklerini çözmek için yenilikçi araçlar sunduğu belirtilmektedir (Wu, 2024). Sosyal araştırma alanında geleneksel metodolojilerin kullanılması genellikle kısıtlı veri setlerinin kullanılmasını veya sabit modellerin uygulanmasını gerektirir. Bununla birlikte, makine öğreniminin ortaya çıkışı, kapsamlı veri kümelerini barındırabilen, sürekli girdilerden içgörü elde edebilen ve sürekli iyileştirmeye tabi tutulan daha esnek ve uyarlanabilir tekniklerin uygulanmasını kolaylaştırmıştır. Bu dinamik yaklaşım, değişimin sürekli olduğu ve toplumu etkileyen faktörlerin genellikle birbirine bağlı ve çok boyutlu olduğu sosyal bilimlerde onu özellikle değerli kılmaktadır.

Sosyal analizde makine öğreniminin kapsamı çok geniştir. Gelecek tahminine dayalı modeller oluşturmak, sosyal olguları etkileyen bileşenlerdeki gizli korelasyonları belirlemek ve karar verme süreçlerine rehberlik etmek amacıyla siyaset bilimi, ekonomi, pazarlama, psikoloji, sosyoloji ve halk sağlığı dahil olmak üzere çeşitli sosyal bilim alanlarında kullanılmaktadır (Christin, 2020). Örneğin, makine öğrenimi algoritmaları şu anda bulaşıcı hastalıkların yayılmasını tahmin etmek, yanlış bilgileri tespit etmek için sosyal medyada paylaşılan düşüncelerin kalıplarını veya kapsamını analiz etmek, ekonomik eğilimleri tahmin etmek ve hatta tüketici seçimlerini etkileyen psikolojik ve sosyal faktörleri anlamak için kullanılmaktadır. İster yapılandırılmış (örneğin nüfus sayımı verileri) ister yapılandırılmamış (örneğin sosyal medya paylaşımları) olsun, verilerin artan kullanılabilirliği, makine öğrenimini ham verileri eyleme geçirilebilir bilgiye dönüştürmek için vazgeçilmez bir araç haline getirmiştir.

Ancak makine öğreniminin sosyal analizde kullanılması önemli soruları ve zorlukları da beraberinde getirmektedir. Veri koruma sorunlarını, algoritmik önyargı potansiyelini ve otomatik karar vermenin etik sonuçlarını tam olarak dikkate almak önemlidir. Bir makine öğrenimi modelinin etkinliği, modelin

eğitildiği verilerin kalitesine ve uygulanmasını yöneten etik çerçeveye göre belirlenir. Bu nedenle, makine öğrenimini sosyal araştırmalara entegre etme konusunda, potansiyeli konusunda heyecan ve sınırlamalarına dair gerçekçi bir anlayışla dengeli bir yaklaşım benimsemek önemlidir.

Bu bölümde makine öğreniminin sosyal analiz alanına nasıl uygulandığını hem sunduğu fırsatları hem de ortaya çıkardığı zorlukları göz önünde bulundurarak inceliyoruz. Ancak belirli uygulamaları değerlendirmeden önce makine öğreniminin temel ilkelerini anlamak önemlidir. Bu temellerle, toplumsal sorunları çözmek için makine öğrenimi kullanılabilir ve dünyanın karmaşık dinamiklerine nasıl yeni bakış açıları kazandırabileceği daha iyi anlaşılabilir.

Bu sebeple veriyi anlama dönüştürmede en büyük yardımcı olan makine öğrenmesi konusu büyük önem arz etmektedir.

2. MAKİNE ÖĞRENMESİ NEDİR?

Makine öğrenimi, bilgisayarların verileri analiz etmesini ve bunlardan öğrenmesini sağlayan, araştırmacıların ve işletmelerin daha önce anlaşılmamış içgörüler elde etmesine yardımcı olan yapay zekanın bir parçasıdır (Mitchell, 1997). Bir makine öğrenimi büyük ve karmaşık girdi verileri kullanılarak tahminleme, yorumlama, çıkarımlar sağlama gibi çeşitli görevleri yerine getiren algoritmik bir bilgisayar tekniğidir (Qiu vd., 2016). Algoritmalar, deneyimlerinden sürekli olarak öğrenme ve yeni veriler ortaya çıktıkça bunlara uyum sağlama konusunda olağanüstü bir kapasiteye sahiptir.

İnsan öğrenmesini taklit eden makine öğrenmesi daha hızlı öğrenir, bilgi saklama potansiyeli daha fazladır ve öğrenme sonuçlarını objektif olarak sunarak daha anlaşılır kılabilir (Wang vd., 2009). Bu sebeple, yapay zeka alanındaki ilerlemeler makine öğrenmesi alanını da aynı oranda ilerletecek, makinelerin daha insansı bilişsel kapasiteye ve zekaya ulaşmasını beraberinde getirecektir. Bu da makine öğrenmesinin toplum üzerindeki uygulamalarını ve etkilerini arttıracaktır.

Makine öğrenmesi temelde dört temel öğrenme tarzında değerlendirilir. Bu başlıkları kısaca açıklayalım

- Denetimli öğrenme
- Denetimsiz öğrenme
- Yarı denetimli öğrenme
- Pekiştirmeli öğrenme

2.1. Denetimli Öğrenme

Makine öğrenimindeki en önemli metodoloji olan gözetimli öğrenme, adını sınıflandırma problemlerinde eğitim örnekleri için sınıf etiketleri sağlayarak öğrenme sistemine rehberlik eden bir “gözetmen” kavramından almaktadır (Cunningham vd., 2008). Denetimli öğrenmede, özellik kümelerini ve bunlara karşılık gelen etiketleri içeren bir veri kümesi içerir. Denetimli öğrenmede birinci amaç, veri setindeki bağımlı – bağımsız değişken ayırımına dayanarak bağımlı değişkenin etiketini doğru bir şekilde tahmin edebilen bir tahminci geliştirmektir. Öğrenme algoritması, bağımsız özelliklerini gerçek bağımlı değişken ile birlikte işler, tahmin edilen ve gerçek çıktılar arasındaki tutarsızlıkları en aza indirerek parametrelerini iyileştirmeyi amaçlar. Ortaya çıkan hatalar için sınıflandırıcı modellerinde ayarlamalar yapılır (Nasteski, 2017). Özellikle toplumsal analizlerin sınıflandırma problemlerinde sıklıkla kullanılmaktadır.

2.2. Denetimsiz Öğrenme

Veri setinde sınıf etiketlerinin olmadığı durumlarda verilerin kendi bünyesindeki durumlarına göre önceden belirlenmiş bir sayıda veya tamamen serbest bırakılarak kümelenmesi veya bölümlere ayrılması gerektiğinde denetimsiz öğrenme kullanılmaktadır (Greene vd., 2008). Çünkü burada amaç veri setindeki verilerin birbirinden küme veya bölümler ile ayrıştırılması ve daha sonra kullanılmak üzere yeni bir etiket verilmesi için hazırlık yapılmasıdır. Denetimsiz öğrenme basitçe girdileri alınır ve bunun dışında başka bir geri bildirim veya tanımlayıcı bilgi almadığı göz önüne alındığında algoritma karar verme, gelecekteki girdileri tahmin etme, girdileri başka bir algoritmaya veya makineye verimli bir şekilde iletme gibi girdi temsilleri oluşturmak olduğu fikrine dayalı olan denetimsiz öğrenme verilerdeki örüntüleri bulmak amacıyla kullanılır (Ghahramani, 2003).

2.3. Yarı Denetimli Öğrenme

Yarı denetimli öğrenme, etiketli ve etiketsiz verilerin bir karışımının sağlandığı denetimli ve denetimsiz öğrenme arasında yer alır ve son araştırmalarda önemli bir rol oynar. Denetimsiz öğrenmede tamamen etiketsiz verilere dayanarak tahmin yapmak her zaman beklenen sonuçları vermeyebilir. Araştırmacının karşılaşacağı en büyük sorun verinin özneliliklerine bağımlılığından dolayı kümeleme yapılsa bile doğru çıkarım sağlanamayabilinir (Reddy vd., 2018). Bu nedenle etiketsiz verilerin rolü, potansiyel çıkarım kuralları alanını kısıtlamaktır, bu sebeple doğru bir öğrenme algoritmasının çalışabilmesi için az sayıda etiketli verinin olması beklenir (Zhou & Belkin, 2014).

2.4. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, dinamik bir çevre ile deneme-yanılma etkileşimleri yoluyla davranış öğrenmesi gereken bir algoritmanın karşılaştığı problemdir (Barto, 1997). Basitçe söylemek gerekirse algoritmanın ulaşması gereken bir hedefe deneme-yanılma yoluyla etkileşime girerek bu hedefe nasıl ulaşacağını öğrendiği bir yöntemdir (Harmon ve Harmon, 1996).

Makine öğrenmesine ait tanımlar ve öğrenme tarzlarını kısaca açıkladıktan sonra öğrenmesinin toplumsal analizlerde makine öğrenmesinin kullanıldığı problemleri incelenmelidir.

3. TOPLUMSAL ANALİZLERDE MAKİNE ÖĞRENMESİ KULLANIMI

Makine öğrenmesi algoritmaları ve yöntemleri, akademide, üretim, pazarlama, hesaplamalar gibi birçok alanda sıklıkla kullanılmaktadır. İşletmelerin üretim süreçlerini, ürünlerinin geliştirilmesini anlamak için gerek kendi elde ettiği gerekse çeşitli kanallarla elde ettiği verilerden anlamlı çıkarımlar yapmaya çalışmaktadırlar. Daha önceden işletme ile müşteri arasındaki veri elde etme kanalları sayısı az iken şimdi mobil telefon, internet araçları ve sosyal medya kullanımının artması ile doğrudan müşteriye ulaşabilme ve geri bildirim alabilme imkanı doğmuştur (Wieneke & Lehrer, 2016). Çağımızda müşteriler pazarlamada çok önemli bir güce kavuşmuşlar ve satın almayı tercih ettikleri firmaların da bu sese kulak vermelerini istemektedirler (Greenberg, 2010). Gücünün farkında olan müşterilere karşılık işletmelerin rekabette var olabilmek için müşterilerine kişiselleştirme ile ulaşmalı, onlarla etkileşimli ve işbirliğine dayalı bir müşteri ilişkileri yönetimi kurmaları beklenmektedir (Setia vd., 2013). Aynı şekilde işletmelerde olduğu gibi siyasal ve kamusal kurumların da benzer yöntemi kullanmaları beklenmektedir (Driss vd., 2019).

Toplum analizleri söz konusu olduğunda yukarıda verilen örneklerdeki gibi temel makine öğrenmesi uygulama alanları karşımıza çıkmaktadır. Sosyal medya analizleri, metin madenciliği, duygu analizi, kamu veya özelden elde edilen veriler, anketler, sensör veya mobil verileri de toplumsal analizlerde kullanılmaktadır. Özellikle son zamanlarda politik ve siyasi olayların merkezinde yer alan makine öğrenmesi ve yapay zeka kavramlarının etkileri de incelenecektir (Yurtay, vd. 2018).

Sırasıyla bu konuların içeriklerinde makine öğrenmesi kullanım alanları bahsedilecektir.

3.1. Sosyal Medya

Günümüzde sosyal medya denildiğinde akla öncelikle sosyal ağ uygulamaları gelse de aslında sosyal medya, kullanıcıların kısmen ya da tamamen açık profiller oluşturabildiği, bağlantıda oldukları kişilerin listelerini hazırlayıp sergileyebildiği, içerik paylaşabildiği ve diğer kullanıcıların profilleri ile bağlantılarını inceleyebildiği dijital platformlardır (Boyd ve Ellison, 2007). Bu tanımdan yola çıkarak sosyal medyada *katılımcılar*, katılımcıların serbestçe hareket edebildiği *açıklık*, iki yönlü ya da monolog olarak görüş bildirmeye dayalı *konuşma*, paylaşım özgürlüğünün getirdiği *topluluklar* ve kullanıcıların birbirleriyle paylaşım yapmalarını sağlayan *bağlantılılık* gibi özellikler bulunmaktadır (Solmaz vd., 2013). Sosyal medya kullanımı göz önüne alındığında özellikle gençlerin yoğun bir şekilde kullandığı ve Amerika'da gerçekleştirilen bir rapora göre zamanla günde sosyal medyada geçirilen zaman oldukça artmıştır (Gottfried, 2024). Gençlerin sosyal ve duygusal gelişimini desteklediği, iletişim becerilerini güçlendirdiği ve duygusal refahlarını artırdığı da düşünülen sosyal medya, bireyleri bir araya getirmenin yanı sıra işletmelerin hedef kitleleriyle etkili iletişim kurmasını da sağlamaktadır (Elda Tartari, 2015; Katırcı & Bulut, 2024; Kuem vd., 2017).

Sosyal medya bilginin yayılmasında son 10 yılda oldukça baş aktör olmuştur. Her ne kadar bilginin yayılması temel hakikat ve doğruluk ilkelerine bağlı kalması beklense de sosyal medya bilginin yayılması sürecinin yapısını, boyutlarını ve karmaşıklığını yeniden şekillendirmiştir (Olan vd., 2024; Orso vd., 2020). Özellikle sosyal medyanın politik bilgi ve haberlerin geniş çaplı yayılmasındaki payının yüksekliği dikkat çekicidir. Sosyal medyanın en büyük zararlarından birisi olarak da yayılan yanlış bilgilerin varlığıdır. Yanlış bilginin güvenilirliği, kalitesi ve doğruluğuna ilişkin sorular gündeme gelse de etkisinin gücünden dolayı engelleyici çalışmalar yetersiz kalmaktadır (Olan vd., 2024). Sosyal medya sahip olduğu bilgi sebebiyle en büyük veri kaynaklarından biridir. Özellikle her ülkede politik seçimler, referandumlar öncesinde insanların politik düşüncelerini yansıttıkları bir ortam olduğundan anket, mülakat gibi görüşmelerden elde edilen bilgilere nazaran daha güvenilir olmaktadır (Hansson ve Page, 2023). Yalan veya da doğru haberin doğrudan muhatabı olan insanlar kendi düşünme ve karar verme sürecinden geçirerek bu bilgilere olan inanma veya inanmama kararlarını vermede özellikle Brexit referandumunda Facebook'un rolündeki gibi yanıltılmışlardır (Bossetta vd., 2023).

Sosyal medyada birçok uygulamada kullanıcıların paylaştığı verilerin yanı sıra bu uygulamaları kullandıkları kendi cihazlarında da erişim izni verdikleri birçok öge bulunmaktadır. Kullanıcıların telefon rehberi, mesajları, galerisi,

konum, mikrofon, kişisel takvim ve hatta kamera kullanımına kadar izin verdikleri düşünüldüğünde sosyal medya uygulamalarının sahip olabileceği verinin büyüklüğü korkutucu boyutlara ulaşmaktadır (Tahaei vd., 2023).

Sosyal medya aynı zamanda işletmelerin de sıkıca takip etmesi gereken bir konudur. Sosyal medya kullanımının artması ile işletmeler müşterileri ile sosyal medya üzerinden daha hızlı ve daha doğru bilgiyi içeren bir iletişim kurabilirler. Böylelikle reklam kampanyalarından, yanlış bilginin dağılımını engellemeye kadar birçok konuda doğrudan iletişim kurabilirler (Khanom, 2023).

Sosyal medyadan elde edilen bilgilerden çıkarım yapılabilmesi için makine öğrenmesi yoğun bir şekilde kullanılmaktadır. Özellikle sosyal medyadan elde edilen veriler gelecek satış tahminleri, ürün ve marka konumlandırılması, zaman serileri, birliktelik analizleri, sınıflandırma veya müşteri portföyü çıkarımları için makine öğrenmesi kullanılmaktadır (Tahir ve Khan, 2023).

Sosyal medya işletmelere gerçek zamanlı pazarlama kapsamında, reklam mesajlarının müşterilere özellikle aracılığıyla hızlı ve anlık bir şekilde sunulmasını ve mesajların içeriğinin müşterinin özel ihtiyaçlarına göre kişiselleştirilerek bu faaliyetlerin etkinliğinin izlenmesini sağlayan yöntemlerden biridir (Yılmaz, 2018).

Toplum üzerinden etkisi sürekli güçlenen ve yeni bir pazarlama kanalı olan sosyal medya müşterilere ilişkin kapsamlı demografik bilgilere sahip olduğundan pazarlamacıların iletişimlerini doğru hedeflemelerini ve hedef kitlesi tercihleriyle uyumlu hale getirmelerini sağlayan bir araç olmuştur (Say, 2015).

Pazarlama bilgileri, tanıtım faaliyetleri, halkla ilişkiler, ürün ve müşteri yönetimi ve pazarlama iletişimi gibi unsurlardan oluşan pazarlama stratejilerinin giderek daha önemli bir rol üstlendiği fakat bu durumun müşterilerin internete olan ilgisinin artması ve sosyal medyada paylaşılan bilgilerin firmaların kendi yaydıkları bilgilerden daha güvenilir olduğunun kabul edilmesiyle kanıtlanmaktadır (Alves vd., 2016).

Sosyal medyada makine öğrenmesinin en sık kullanıldığı alan duygu analizidir. Duygu analizi, belirli metin, ses ve makine tabanlı veriler aracılığıyla aktarılan duygusal durumları ve tutumları tanımlamayı amaçlayan bir metinsel analiz biçimidir (Kotan, 2022). Sosyal medya uygulamalarında kişilerin paylaşımlarının elde edilmesiyle başlayan duygu analizi sürecinde kişilerin belirli konulara yönelik görüşlerini olumlu, olumsuz veya tarafsız olarak üç temel duygu üzerinden değerlendirme söz konusudur. En sık kullanılan kelime grupları, duygunun şiddeti gibi bilgilerin edinildiği duygu

analizinde sadece metin değil aynı zamanda farklı veriler de kullanılmaktadır. Özellikle müşteri ile firma arasındaki iletişim kanallarından biri olan çağrı merkezlerinde toplanan görüşme kayıtları da makine öğrenmesi yardımıyla çıkarım yapılmak için kullanılmaktadır (Yurtay vd., 2024).

Buradan duygu analizinin politika, iş sektörü, spor vb. her alanda kullanılabilen bir makine öğrenmesi tekniği olduğu çıkarımı yapılması oldukça doğaldır. Duygu analizinde doküman içinde tarama, cümle içinde tarama ve özellikler üzerinden tarama şeklinde üç ayrı kısımda değerlendirilir (Cebeci, 2020; Kotan, 2022).

Bu, müşterilerin işletmeden memnuniyetinin güvence altına alınmasını kolaylaştırır ve memnun olmayan müşterilerin deneyimlerinin düzeltilmesi için potansiyel yolların belirlenmesini sağlar. Ayrıca, iyileştirme fırsatları da tespit edilebilir.

Genel olarak sosyal medya verileri toplumsal analizlerde genellikle şu aşamalarda kullanılmaktadır (Sprout Social, 2023).

1. Trend belirleme, yeni ortaya çıkan trendleri yaygın kabul görmeden önce tespit etme sürecidir. Ortaya çıkan kalıpları belirlemeye yardımcı olabilecek sosyal medya analizlerini yakından izlenir ve şu eğilimler tespit edilebilir:
 - Hangi platformların popülerlik ve çekicilik açısından büyüme veya düşüş yaşadığının anlaşılması
 - Hedef müşteri kitlesi tarafından tartışılan ilgi konularının belirlenmesi (marka söylemleri dahil)
 - Hedef müşteri kitlesinin ilgisini çeken reklam türlerinin analizi
 - Toplum içinde bilinirliği yüksek sosyal medya fenomenlerinin kullanımı
 - Müşteri kitlesinin ilgilendiği popüler içerikler

gibi eğilimler makine öğrenmesi yoluyla tespit edilebilmektedir.

2. Marka duyarlılığı ile müşterilerin bir markaya yönelik duygusal tepkilerinin, tutumlarının ve değerlendirmeleri elde edilir. Duygu analizinin yoğun olarak kullanıldığı bu alanda ifade edilen tüm olumlu, nötr ve olumsuz duygular değerlendirilir. Sosyal medya verileri için mevcut analitik makine öğrenmesi araçları kullanılarak marka duyarlılığı incelenebilir.

3. Markaya veya ürüne karşı müşterilerin algılanan değeri de bir diğer aşamayı ifade eder. Müşteriler bir markanın ürün veya hizmetinin kendi ihtiyaç ve beklentilerine uygun olup olmadığını sosyal medya veya dijital araçlarla

ile ifade eder. Yine burada elde edilen veriler değer analizi kapsamında uygun makine öğrenmesi araçlarıyla toplanabilir ve analiz edilebilir.

Sosyal medya analizinde makine öğrenmesi tekniklerinin en çok ihtiyaç duyduğu veriler performans, demografik, rakip, sosyal medya fenomenleri ve duygu analizidir.

- Performans verilerinde toplum tarafından verilen yanıtlar, paylaşımlar, beğenme ve beğenmeme sayıları, tekrar paylaşımlar, tıklama ve satın alma bilgileri yer almaktadır.
- Demografik verilerde ise yaş, cinsiyet, eğitim, yaşanılan şehir, kullanılan teknolojik aletler gibi kişisel bazda bilgileri içermektedir (Cesare vd., 2017).
- Rakiplere ait verilerde de onların sosyal medya kampanyaları ve paylaşımları, satış hacimleri ve pazardaki müşterilere karşı tutumları ve yanıtları, müşteriye ulaşmak için kullandıkları kanallar gibi veriler kullanılmaktadır (Zhang vd., 2022).
- Sosyal medya fenomenleri de yeni pazarlama kanallarından biridir. Sahip oldukları etki ve ifade güçleri onları rekabette önemli bir aktör haline getirmiştir (Jin vd., 2019).

Doğru analiz edildiği takdirde, sosyal medya analiz raporları kitle için en ilgi çekici içerik hakkında önemli bilgiler sağlayabilir. Bu, daha popüler hale gelen içeriklerin, kitlenin ilgilendiği içerik türlerinin ve gelecekte daha fazla duymak istedikleri konuların belirlenmesine yardımcı olabilir.

Sosyal medya siyaset alanında adaylar ve siyasi konular hakkında birincil bilgi kaynağını temsil ederek kamuoyunun algılarını ve oy verme davranışını etkilemektedir (Rutgers, 2024).

Seçim sürecinde yayılan haberler seçmen davranışını olumlu veya olumsuz yönde etkileme gücüne sahiptir. Sosyal medya akışında adayların seçim yarışındaki göreceli konumlarına odaklanılır. Anket sonuçları, belirli konularda adayların söylemlerinin duygu analizi veya eğilimleri öğrenilebilir. Sosyal medyada kutuplaşmayı öne çıkaran sosyal medyadaki dolaşan bilgi adaylardan ziyade seçmen düşüncelerinin birebir yansımasıdır (Belcastro vd., 2020).

Sosyal medyadan elde edilen veriler haricinde makine öğrenmesi ile gerçekleştirilen başka veri türleri de bulunmaktadır. Anket ve kamu bilgileri, sensör ve mobil verileri de bunlardan sayılır.

a. Anket ve Kamu Verileri

Anket, genellikle sosyal alanlarda kullanılan bir veri toplama yöntemidir (Altunışık vd., 2007). Katılımcılara çeşitli sorular sorarak belirlenmiş amaca yönelik veriler toplanır. Anket verileri genellikle hazır analiz paketleri aracılığıyla değerlendirilir. Makine öğrenmesinin sıklıkla kullanıldığı bu analizde bir ürün, hizmet, reklam, duygu veya siyasetle ilgili bir konu hakkında toplumsal bir analiz yapılabilir. Anket gibi diğer bir veri türü de kamunun sağladığı verilerdir.

Devletin elindeki mevcut kamu verilerinin zenginliği ve politikayla ilgili tahminlere yönelik artan talep, makine öğreniminin kamusal alandaki kullanımını da desteklemektedir. Tıbbi teşhis, ipotek onayları, vergi dolandırıcılığı tespiti ve terörist faaliyet tespiti gibi çeşitli durumlarda karar alma süreçlerinin verimliliği ve hassasiyeti, makine öğrenimi sayesinde halihazırda büyük bir potansiyel göstermiştir (Pi, 2021).

Kamu kurumları sahip oldukları verileri ve makine öğrenmesi kullanarak elde ettikleri çıkarımları şeffaflık ve hesap verebilirlik kapsamında halk ile paylaşarak çağın isteklerine uygun olarak davranmaya başlamışlardır (Ingrams, 2020).

Makine öğrenmesinin sonuçları tahmin etme yeteneği sebebiyle bir diğer avantajdır. Yeni bir politikanın etkilerinin yürürlüğe girene kadar belirsizliği gibi sorunları çözmek için politika yapıcılar politika denemeleri yapmakta ve olası sonuçları makine öğrenmesinin öngörücü gücü ile tahmin etmeye çalışmaktadırlar (Pi, 2021). Örneğin, COVID-19 salgınının ardından Katar'da karantina politikalarının COVID-19 vakalarını nasıl etkileyeceğini tahmin etmek için algoritmik bir yöntem kullanılmış ve bu da sosyal kısıtlama politikalarının oluşturulmasına yardımcı olmuştur (Said vd., 2020)

Her ne kadar kamu verilerinin sonuçlarının açıklanabilirliği ve şeffaflığı dile getirilse de kamu verilerini makine öğrenmesi ile analiz edenler kararın nasıl ortaya çıktığını veya kararın verinin hangi yönlerine dayandığını ayrıntılı olarak açıklayamazlar (Adadi & Berrada, 2018). Bunun sebebi makine öğrenmesi algoritmaları yüksek doğruluğa ulaşmak için girdi değişkenlerini çıktı değişkeni ile örtüşmesi için farklı formlara dönüştürebilirler bu sebeple verinin ilk halin değişebilir. Bu da makine öğrenimi uzmanları, politika yapıcılar ve kamu arasındaki iletişimi zorlaştırır (Letham vd., 2015).

Bu verileri haricinde de sensör ve mobil veriler de toplumsal analizlerde kullanılmak üzere toplanır.

b. Sensör ve Mobil Veriler

Sensör veriler, genellikle yerleştirilmiş sensörler yardımıyla elde edilen verilerdir. Giriş-çıkış tarihleri, sayıları, saatleri, kullanım bilgileri gibi her türlü sensörlerden elde edilen veriler de makine öğrenmesine dâhil edilebilir. Bu veriler örüntü oluşturma, öngörüle bulunma ve hatta alıcı davranışlarını tespit etme amacıyla kullanılabilir. Mobil veriler de mobil cihazlardan elde edilen verileri ifade eder. Sosyal medya kısmında anlatılan uygulamaların ürettiği verileri bu kapsamda değerlendirilebilir. Genel olarak bu tür verilerle pazarlama, üretim, toplumsal görüşler ve istekler gibi birçok alanda bilgi edinilmesi kaçınılmazdır (Grupac & Lăzăroiu, 2022). Özellikle insanların ve nesnelerin her zaman, her yerde, her şeyle ve herkesle, ideal olarak herhangi bir yol/ağ ve herhangi bir hizmeti kullanarak bağlanmasını sağlayan Nesnelerin İnterneti ile sensör ve mobil veriler elde edilebilmektedir (Sundmaecker vd., 2010). Nesnelerin İnterneti, nesnelere değil birbirleriyle bağlantılı olan nesnelere aracılığıyla fiziksel nesnelerin ağlarda birbirine bağlı olduğu, İnternete sürekli erişime sahip olduğu ve verileri bağımsız olarak veya gruplar halinde toplayabildiği, işleyebildiği veya birbirlerine aktarabildiği bir ortam ile verileri toplamak için kullanılır (Bojanowska, 2019).

Örneğin Müşteri İlişkileri Yönetimi (MİY) kapsamında Nesnelerin İnterneti (IoT) kullanılan bir çalışma farz edelim. MİY, IoT ile müşteriler hakkındaki demografik bilgileri, tekrar eden veya yeni davranışlarına ilişkin gerçek zamanlı verileri toplar. IoT veya mobil uygulama üzerinden veri toplanması için, müşteri öncelikle örneğin bir sadakat programı olarak da kullanılabilen uygun programı yüklemeye edilir. Müşteriden konum, bildirim, mesaj, internet hareketlerini izleme gibi çeşitli izinler istenerek veri toplama gerçekleştirilebilir. Daha sonra bu veriler yine makine öğrenmesi amacıyla öncelikle alıcı davranışlarını tespit etme, ürün ve hizmet algısını ölçme, yeni ürün ve hizmet için fikir alma, müşteriye marka konumlandırmasını öğrenme gibi birçok amaca yönelik veri toplanmaktadır (Abiad vd., 2019).

c. Doğal Dil İşleme

Yapay zeka ve dilbilimin bir dalı olan Doğal Dil İşleme (DDİ), bilgisayarların insan dillerinde yazılmış kelimeleri veya ifadeleri anlamasını sağlamaya çalışan bir bilimsel alandır (Chopra vd., 2013). DDİ, genel olarak şu görevleri gerçekleştirmek için kullanılır (Khurana vd., 2023):

- Otomatik özetleme: Bir metin koleksiyonunun anlaşılır bir özetini oluşturur ve tanınan bir kategorideki metinlerin özetlerini veya kapsamlı ayrıntılarını sunar), Ortak referans çözümü: Bir cümlede veya daha büyük bir metin koleksiyonunda aynı nesneye atıfta bulunan tüm kelimeleri belirleme sürecidir.

- **Konu Başlığı Modelleme:** Bir metin koleksiyonunda metinlerin belirli sayıda konu başlıkları altında ayrıştırılması
- **Söylem analizi:** Bir metnin toplumsal bağlamıyla ilişkilendirilmesi
- **Makine çevirisi:** Metnin bir dilden diğerine otomatik çevirisi
- **Morfolojik Segmentasyon:** Kelimeleri anlam taşıyan belirgin morfemlere ayırma süreci
- **İsimlendirilmiş Varlık Tanıma:** İsimlendirilmiş varlıkları tanımlamak ve gruplara ayırmak için bilgi çıkarımı
- **Otomatik metin tanıma:** El yazısı ve basılı metni makine tarafından okunabilir bir biçime dönüştürme
- **Etiketleme:** Her kelimenin hangi konuşma türünü temsil ettiğini ve cümleyi karakterize ettiğini belirten konuşma türü etiketlemesi

İlk başta görüntü kategorizasyonu ve görsel imge analizi alanında kullanılan derin öğrenme yöntemlerinden biri olan evrişimli sinir ağlarının (CNN), DDİ'de cümle sınıflandırması, duygu analizi, metin sınıflandırması, metin özetleme, makine çevirisi ve otomatik cevap ilişkilerinde kullanıldığı birçok çalışma bulunmaktadır (Khurana vd., 2023; Yurtay vd., 2024).

Bir metin koleksiyonunda bulunan konu başlıklarını belirlemek için kullanılan konu başlığı modellemesi, verilerin açık kelime dağarcığını kullanır. Konu başlığı modellemesi, tıpkı faktör analizinin çeşitli anket öğeleri arasındaki temel grupları ortaya çıkarması gibi metinler içinde ve arasında kelimelerin birlikte bulunmasını ölçerek, tartışılan gizli temaları veya konuları ve her temayı veya konuyu oluşturan kelimeleri ortaya çıkarır (Berger & Packard, 2022).

Literatürde DDİ ile ilgili çalışmalara bakıldığında makine öğrenmesi ve derin öğrenme yöntemleri sıklıkla kullanılmaktadır. Derin öğrenmenin diğer makine öğrenmesi yöntemlerine göre öngörü gücünün daha yüksek olduğu, insani davranışlara daha yakın çıkarımlar yaptığı bilinen bir konudur (Berger & Packard, 2022; Rajput, 2020; Sönmez vd., 2023).

DDİ, duygu analizi (Rajput, 2020), sosyal medya analiz (Belcastro vd., 2020), çağrı merkezi analizleri (Yurtay vd., 2024), müşteri analizleri (Olujimi ve Ade-Ibijola, 2023) ve intihar (Arowosegbe & Oyelade, 2023) gibi sosyal dinamikleri anlamak amacıyla kullanılmaktadır.

4. TOPLUMSAL SORUNLAR VE ÇÖZÜMLER İÇİN MAKİNE ÖĞRENMESİ

Makine öğrenimi, toplumsal sorunlar ve çözümler için güçlü bir araç haline gelerek toplum davranışlarını anlamak, tahmin etmek ve etkilemek için daha önce duyulmamış fırsatlar sunmaktadır (Grimmer vd., 2021). Makine öğrenmesi de sosyal medya etkileşimlerindeki eğilimleri belirlemekten hükümet politikalarının farklı demografik gruplar üzerindeki etkisini değerlendirmeye kadar geniş veri kümelerinin analiz edilmesini sağlayarak sosyal dünyaya ilişkin yeni anlamlar çıkarmaya yardım etmektedir. Teknik alanlarda daha yoğun kullanıldığı düşünülen makine öğrenmesi modellerinin sanılanın aksine trafik kazaları, intihar, toplumsal eğilimler, kamu politikalarına yönelik tepkiler, kültürel değişimlere yönelik çalışmalarda uzun zamandır kullanılması olgusal gerçekliktir (Chen vd., 2021). İnsan refahının sürdürülebilirliği için makine öğrenimi tarafından üretilen veri odaklı içgörüler kullanılması makine öğrenmesinin toplumsal analizlerdeki önemini göstermektedir. Örneğin, biyomedikal makine öğrenimi uygulamaları, doktorların kanser ilaçlarını daha iyi hedeflemesine, hastalıkları daha erken ve daha doğru bir şekilde tespit etmesine ve sağlık sektöründe daha iyi hassasiyetle ameliyatlara gerçekleştirmesine yardımcı oluyor. Tarımsal üretkenliği tespit etmede ve geliştirmede de kullanılan makine öğrenmesi daha akıllı, daha verimli ve daha sürdürülebilir şehirler yaratmada destek vermektedir.

Toplum araştırmaları ve analizleri yapan araştırmacıların odaklandığı çalışmalarda çok kaynaklı verilerin kullanılabilirliği ve bilgisayar işleme kapasitesindeki gelişmeler sayesinde, yüksek hassasiyetli tahmin için üç ön koşul olan veri, işleme kapasitesi ve algoritmalar, nicel sosyal bilim araştırmaları tarafından giderek daha fazla karşılanmaktadır. Toplumsal analizlerde büyük sosyal veri kümelerini yorumlama becerisi sürekli gelişmektedir (Hofman vd., 2017).

Toplumsal araştırmalarda veri girişleri çıktıya ve daha yüksek mertebeli terimler ve etkileşimler de dâhil olmak üzere çok sayıda girişe bağlayan karmaşık işlevler makine öğrenmesi tarafından mümkün kılınmıştır (Molina ve Garip, 2019). Örneğin makine öğrenmesi ekonomistler tarafından nedensel çıkarım paradigmasındaki tahmin sorunlarını ve politikayı tahmin etmek gibi çeşitli amaç için kullanılmaktadır.

Yoksulluk ve eşitsizliklerin tahmininde kullanılan makine öğrenmesi, doğru tahminlere en büyük katkıyı yapan faktörlerin tespiti ile yoksulluğu çevreleyen bağlarla ilgili politika çabalarına destek olabilir. Makine öğrenmesi, sosyal yardımların optimizasyonu, yoksulluk haritaları gibi görsel

ve metinsel çıktılar sağlayabilir. Ayrıca, nüfus ve göç ile ilgili sorunların ele alınması, tahminler geliştirilmesi ve artış-azalış trendlerinin ortaya çıkarılması amacıyla da kullanılabilir (Maruejols vd., 2023).

Eğitim alanında kantitatif çalışmalar olsa da makine öğrenmesi ile artık eğitim çatısı altındaki tüm paydaşlar da makine öğrenmesi ile elde edilecek sonuçlarda yer almaktadırlar (Shah vd., 2021).

Toplumsal analizlerde makine öğrenmesinin kullanımı toplumlar için sürekli sadece fayda getiren bir araç olarak sayılmamalıdır. Dijital dünyada bireylerin tüm verilerinin toplanmasına izin verilse de, şeffaf olmayan algoritmik yöntemler, örneğin ilgi sıralamaları, popülerlik ölçümleri ve trend tahminleri, dijital otokrasilerin nüfus düzeyinde davranışsal izleme ve disiplin kontrolü uygulamalarına olanak tanımaktadır (Leslie vd., 2020). Makine öğrenmesinin gelişiminin güçleneceği öngörüldüğünde, bu teknolojinin kişisel ve toplumsal özgürlükler üzerindeki potansiyel tehlikeleri hakkında meşru endişeler ortaya çıkmaktadır. Toplumdaki bireylerin davranış kalıplarının analiz edilerek manipülasyona açık hale getirilmesi, makine öğrenmesi kullanıcılarının etik sorumluluklarını da gündeme getirmektedir (Zuboff, 2015). Ayrıca, gelecek temalı kitaplarda, filmlerde ve fütüristik yazılarda tartışılan bir diğer önemli endişe, hükümetlerin dijital izleme ve otomasyon destekli karar alma süreçlerini eleştirel düşünceden, sorumluluktan ve toplumun kapsayıcı katılımından yoksun bir şekilde uygulamasının, kökleşmiş yoksulluk, eşitsizlik ve ötekileştirme riskini artırabileceği yönündedir (Eubanks, 2018).

Ayrıca yakın zamanda Brexit, Amerika seçimleri, Türkiye’de Gezi Olayları gibi dünyanın her yerindeki toplumsal olaylarda sosyal medya kullanımının etkileri bilinmektedir (Chung vd., 2022; dos Santos Brito ve Adeodato, 2020; Elsafoury, 2019). Özellikle Facebook’un makine öğrenmesi ile yanlış yönlendirme yoluna başvurarak Brexit ve Amerika seçimleri öncesi müdahalesi de söz konusudur (Hall, 2022).

5. SONUÇ

Makine öğrenimi (ML), sosyal analizde büyük miktarda veriyle çalışarak toplumsal davranışları anlama, öngörme ve bu davranışlar üzerinde etkili olma imkanı sunan güçlü bir araçtır. Geleneksel sosyal araştırma yöntemlerinin sınırlamalarını aşan makine öğrenimi, esnek ve sürekli gelişebilen teknikler sayesinde karmaşık toplumsal sorunları çözmek için yenilikçi yaklaşımlar sağlar.

Toplum dinamiklerini analiz etmekte makine öğrenimi, sağlık eşitsizliklerini incelemekten oy verme davranışını ve ekonomik eğilimleri

tahmin etmeye kadar geniş bir uygulama yelpazesine sahiptir. Sosyal medya paylaşımlarını analiz ederek yanlış bilgileri tespit etme veya tüketici tercihlerini şekillendiren psikolojik faktörleri anlamak gibi uygulamalar, makine öğreniminin önemini artırmaktadır. Hem yapılandırılmış hem de yapılandırılmamış veri kaynaklarının artması, makine öğrenimini eyleme geçirilebilir bilgiye dönüştürmekte vazgeçilmez hale getirmiştir.

Bununla birlikte, makine öğreniminin sosyal analizdeki kullanımı, veri koruma, algoritmik önyargılar ve etik sorumluluklar gibi zorlukları da beraberinde getirir. Etkili bir uygulama, yüksek kaliteli veri ve güçlü bir etik çerçeve gerektirir. Bu bağlamda, makine öğreniminin temel ilkelerini anlamak, hem sunduğu fırsatları değerlendirmek hem de karşılaşılabilecek sorunları yönetmek açısından kritik öneme sahiptir.

Makine öğrenimi (ML), bilgisayarların verilerden öğrenmesini sağlayarak çeşitli görevleri yerine getiren ve yapay zekânın bir alt dalı olan bir tekniktir. İnsan öğrenmesini taklit eden ML, dört temel öğrenme tarzına sahiptir: denetimli öğrenme, etiketli verilerle çalışarak sınıflandırma ve tahmin yapar; denetimsiz öğrenme, etiketsiz verilerden örüntüler çıkarır; yarı denetimli öğrenme, etiketli ve etiketsiz verileri birleştirir ve pekiştirmeli öğrenme, deneme-yanılma yöntemiyle karar verme süreçlerini geliştirir. Bu yöntemler, toplumsal analizlerdeki karmaşık sorunları ele almak için güçlü araçlar sunar.

Makine öğrenmesi, üretimden pazarlamaya, kamudan siyasete kadar birçok alanda geniş bir uygulama yelpazesi sunmaktadır. Toplum analizlerinde makine öğrenmesi, sosyal medya, anketler, kamu verileri, sensör ve mobil veriler gibi çeşitli kaynaklardan elde edilen bilgileri anlamlandırmak için kullanılmaktadır. Bu süreç, trendlerin tespiti, marka algısının analizi, duygu analizi, politik eğilimlerin anlaşılması ve halkın ihtiyaçlarının öngörülmesi gibi alanları kapsamaktadır. Sosyal medya, bilgi yayılımında ve toplumun nabzını tutmada önemli bir veri kaynağıdır. Makine öğrenmesi, sosyal medyadan elde edilen verileri duygu analizi, trend tespiti ve müşteri geri bildirimlerini analiz etmede kullanır. Özellikle duygu analizi, metinlerden ya da kullanıcıların diğer verilerinden insanların hislerini olumlu, olumsuz veya tarafsız olarak sınıflandırmada öne çıkar. Bununla birlikte, yanlış bilgi yayılımı ve kişisel veri güvenliği gibi sorunlar da tartışılmaktadır. Anketler, toplumsal eğilimleri ve müşteri görüşlerini anlamak için geleneksel bir yöntemdir. Kamu verileri ise devlet kurumlarının makine öğrenmesi yardımıyla analiz ettiği geniş bir bilgi havuzudur. Bu veriler, politika geliştirme, kamu hizmetlerinin iyileştirilmesi ve tahminsel analizlerde kullanılır. Ancak, makine öğrenmesinin sonuçlarının açıklanabilirliği konusunda zorluklar yaşanabilmektedir. Sensörler ve mobil cihazlardan elde edilen veriler, bireylerin davranışlarını ve toplumsal

eğilimleri anlamada kullanılır. Özellikle Nesnelerin İnterneti (IoT), müşteri davranışlarını gerçek zamanlı takip ederek pazarlama ve ürün geliştirme süreçlerini destekler. Makine öğrenmesinin bir dalı olan DDİ, metin ve konuşma gibi insan diline dair bilgileri anlamak ve işlemek için kullanılır. DDİ, sosyal medya yorumlarının analizi, müşteri geri bildirimlerinin sınıflandırılması ve kullanıcı deneyimlerinin geliştirilmesi gibi çeşitli alanlarda uygulanır.

Makine öğrenmesi, toplumsal analizlerde güçlü bir araç olarak karşımıza çıkmaktadır. Ancak veri güvenliği, etik sorunlar ve algoritmaların açıklanabilirliği gibi konular, bu teknolojinin daha geniş bir kabul görmesi için ele alınması gereken önemli meselelerdir.

Makine öğrenimi, toplumsal sorunları analiz etmek ve çözmek için güçlü bir araçtır. Sosyal medya eğilimlerinden kamu politikalarının etkilerine kadar geniş veri kümelerinin analizi, toplum davranışlarını anlamada ve çözüm üretmede yenilikçi yaklaşımlar sunmaktadır. Trafik kazaları, intihar, yoksulluk, göç ve eğitim gibi birçok alanda uygulanmakta, aynı zamanda sağlık ve tarım gibi sektörlerde verimliliği artırmaya katkı sağlamaktadır. Bu teknoloji, yoksulluk haritaları oluşturarak politika yapıcıları desteklerken, toplumsal eğilimleri daha iyi anlamak için nüfus hareketlerini tahmin edebilir.

Bununla birlikte, makine öğreniminin sınırsız faydalarının yanı sıra, etik ve toplumsal riskler de taşımaktadır. Algoritmik şeffaflık eksikliği, bireysel davranışların manipülasyonu ve dijital izleme uygulamaları, bireylerin özgürlüklerini tehdit edebilir. Özellikle sosyal medya platformlarının seçimler ve toplumsal olaylarda manipülasyon aracı olarak kullanılması bu endişeleri artırmaktadır. Makine öğreniminin etik kullanımına ilişkin tartışmalar, gelecekte toplumsal etkilerinin daha dikkatle ele alınmasını gerekli kılmaktadır.

Kaynakça

- Abiad, M., Kadry, S., Ionescu, S., & Niculescu, A. (2019). Customers' perception of telecommunication services. *EAIMA Business & Management Journal*, 7(2), 51-62.
- Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (XAI). *IEEE access*, 6, 52138-52160.
- Altunışık, R., Coşkun, R., Bayraktaroğlu, S., & Yildirim, E. (2007). Sosyal bilimlerde araştırma yöntemleri. *Sakarya Yayıncılık, Sakarya*, 226, 103-118.
- Alves, H., Fernandes, C., & Raposo, M. (2016). Social media marketing: A literature review and implications. *Psychology & Marketing*, 33(12), 1029-1038.
- Arowosegbe, A., & Oyelade, T. (2023). Application of natural language processing (NLP) in detecting and preventing suicide ideation: A systematic review. *International Journal of Environmental Research and Public Health*, 20(2), 1514.
- Barto, A. G. (1997). Reinforcement learning. İçinde *Neural systems for control* (ss. 7-30). Elsevier.
- Belcastro, L., Cantini, R., Marozzo, F., Talia, D., & Trunfio, P. (2020). Learning political polarization on social media using neural networks. *IEEE access*, 8, 47177-47187.
- Berger, J., & Packard, G. (2022). Using natural language processing to understand people and culture. *American Psychologist*, 77(4), 525.
- Bojanowska, A. (2019). *Customer data collection with Internet of Things*. 252, 03002.
- Bossetta, M., Dutceac Segesten, A., & Bonacci, D. (2023). Reconceptualizing cross-cutting political expression on social media: A case study of Facebook comments during the 2016 Brexit referendum. *Political Communication*, 40(6), 719-741.
- Boyd, D. M., & Ellison, N. B. (2007). Social network sites: Definition, history, and scholarship. *Journal of computer-mediated Communication*, 13(1), 210-230.
- Cebeci, H. (2020). Sosyal medya verileri ile duygu analizi. *Mühendislikte Yapay Zeka Uygulamaları*, 191-212.
- Cesare, N., Grant, C., & Nsoesie, E. O. (2017). Detection of user demographics on social media: A review of methods and recommendations for best practices. *arXiv preprint arXiv:1702.01807*, 1-25.
- Chen, Y., Wu, X., Hu, A., He, G., & Ju, G. (2021). Social prediction: A new research paradigm based on machine learning. *The Journal of Chinese Sociology*, 8, 1-21.

- Chopra, A., Prashar, A., & Sain, C. (2013). Natural language processing. *International journal of technology enhancements and emerging engineering research*, 1(4), 131-134.
- Christin, A. (2020). The ethnographer and the algorithm: Beyond the black box. *Theory and Society*, 49(5), 897-918.
- Chung, W., Dai, D., Elliott, R. J., & Görtz, C. (2022). *Measuring Brexit Uncertainty: A Machine Learning and Textual Analysis Approach*. Centre for Economic Policy Research.
- Cunningham, P., Cord, M., & Delany, S. J. (2008). Supervised learning. İçinde *Machine learning techniques for multimedia: Case studies on organization and retrieval* (ss. 21-49). Springer.
- dos Santos Brito, K., & Adeodato, P. J. L. (2020). *Predicting Brazilian and US elections with machine learning and social media data*. 1-8.
- Driss, O. B., Mellouli, S., & Trabelsi, Z. (2019). From citizens to government policy-makers: Social media data analysis. *Government Information Quarterly*, 36(3), 560-570.
- Elda Tartari. (2015). Benefits And Risks Of Children And Adolescents Using Social Media. *European Scientific Journal, ESJ*, 11(13). <https://eujournal.org/index.php/esj/article/view/5654>
- Elsafoury, F. (2019). *Detecting protest repression incidents from tweets*.
- Eubanks, V. (2018). *Automating inequality: How high-tech tools profile, police, and punish the poor*. St. Martin's Press.
- Ghahramani, Z. (2003). Unsupervised learning. İçinde *Summer school on machine learning* (ss. 72-112). Springer.
- Gottfried, J. (2024). Americans' social media use. *Pew Research Center*, 31.
- Greenberg, P. (2010). The impact of CRM 2.0 on customer insight. *Journal of Business & Industrial Marketing*, 25(6), 410-419.
- Greene, D., Cunningham, P., & Mayer, R. (2008). Unsupervised learning and clustering. *Machine learning techniques for multimedia: Case studies on organization and retrieval*, 51-90.
- Grimmer, J., Roberts, M. E., & Stewart, B. M. (2021). Machine learning for social science: An agnostic approach. *Annual Review of Political Science*, 24(1), 395-419.
- Gruber, T. (2008). Collective knowledge systems: Where the social web meets the semantic web. *Journal of web semantics*, 6(1), 4-13.
- Grupac, M., & Lăzăroiu, G. (2022). Image processing computational algorithms, sensory data mining techniques, and predictive customer analytics in the metaverse economy. *Review of Contemporary Philosophy*, 21, 205-222.

- Hall, N.-A. (2022). Understanding Brexit on Facebook: Developing close-up, qualitative methodologies for social media research. *Sociological Research Online*, 27(3), 707-723.
- Hansson, S., & Page, R. (2023). Legitimation in government social media communication: The case of the Brexit department. *Critical Discourse Studies*, 20(4), 361-378.
- Harmon, M. E., & Harmon, S. S. (1996). Reinforcement learning: A tutorial. *WL/AAFC, WPAFB Ohio, 45433*, 237-285.
- Hofman, J. M., Sharma, A., & Watts, D. J. (2017). Prediction and explanation in social systems. *Science*, 355(6324), 486-488.
- Ingrams, A. (2020). A machine learning approach to open public comments for policymaking. *Information Polity*, 25(4), 433-448.
- Jin, S. V., Muqaddam, A., & Ryu, E. (2019). Instafamous and social media influencer marketing. *Marketing Intelligence & Planning*, 37(5), 567-579.
- Katırcı, E. K., & Bulut, S. (2024). Sosyal Medyanın Çocuk ve Ergenler Üzerindeki Etkileri: Bir Literatür İncelemesi. *İbn Haldun Çalışmaları Dergisi*, 9(2), 125-144.
- Khanom, M. T. (2023). Using social media marketing in the digital era: A necessity or a choice. *International Journal of Research in Business and Social Science (2147-4478)*, 12(3), 88-98.
- Khurana, D., Koli, A., Khatter, K., & Singh, S. (2023). Natural language processing: State of the art, current trends and challenges. *Multimedia tools and applications*, 82(3), 3713-3744.
- Kim, Y., & Adler, M. (2015). Social scientists' data sharing behaviors: Investigating the roles of individual motivations, institutional pressures, and data repositories. *International journal of information management*, 35(4), 408-418.
- Kotan, M. (2022). Duygu Analizi ve Dijital Dönüşüm Üzerine Etkileri. İçinde *Dijital Etkileşimler: Sektörel Yansımaları II* (ss. 59-82). Gazi Kitabevi.
- Kuem, J., Ray, S., Siponen, M., & Kim, S. S. (2017). What leads to prosocial behaviors on social networking services: A tripartite model. *Journal of Management Information Systems*, 34(1), 40-70.
- Leslie, D., Holmes, L., Hitrova, C., & Ott, E. (2020). Ethics review of machine learning in children's social care. *Leslie, D., Holmes, L., Hitrova, C. & Ott, E. (2020). Ethics review of machine learning in children's social care. [Report] London, UK: What Works for Children's Social Care.*
- Letham, B., Rudin, C., McCormick, T. H., & Madigan, D. (2015). *Interpretable classifiers using rules and bayesian analysis: Building a better stroke prediction model.*

- Maruejols, L., Wang, H., Zhao, Q., Bai, Y., & Zhang, L. (2023). Comparison of machine learning predictions of subjective poverty in rural China. *China Agricultural Economic Review*, 15(2), 379-399.
- Mitchell, T. M. (1997). *Machine learning* (C. 1, Sayı 9). McGraw-hill New York.
- Mitchell, T. M. (2007). *Machine learning* (C. 1). McGraw-hill New York.
- Molina, M., & Garip, F. (2019). Machine learning for sociology. *Annual Review of Sociology*, 45(1), 27-45.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b*, 4(51-62), 56.
- Olan, F., Jayawickrama, U., Arakpogun, E. O., Suklan, J., & Liu, S. (2024). Fake news on social media: The impact on society. *Information Systems Frontiers*, 26(2), 443-458.
- Olujimi, P. A., & Ade-Ibijola, A. (2023). NLP techniques for automating responses to customer queries: A systematic review. *Discover Artificial Intelligence*, 3(1), 20.
- Orso, D., Federici, N., Copetti, R., Vetrugno, L., & Bove, T. (2020). Infodemic and the spread of fake news in the COVID-19-era. *European Journal of Emergency Medicine*, 27(5), 327-328.
- Pi, Y. (2021). Machine learning in governments: Benefits, challenges and future directions. *JeDEM-eJournal of eDemocracy and Open Government*, 13(1), 203-219.
- Qiu, J., Wu, Q., Ding, G., Xu, Y., & Feng, S. (2016). A survey of machine learning for big data processing. *EURASIP Journal on Advances in Signal Processing*, 2016, 1-16.
- Rajput, A. (2020). Natural language processing, sentiment analysis, and clinical analytics. İçinde *Innovation in health informatics* (ss. 79-97). Elsevier.
- Reddy, Y., Viswanath, P., & Reddy, B. E. (2018). Semi-supervised learning: A brief review. *Int. J. Eng. Technol*, 7(1.8), 81.
- Said, A. B., Erradi, A., Aly, H., & Mohamed, A. (2020). A deep-learning model for evaluating and predicting the impact of lockdown policies on COVID-19 cases. *arXiv preprint arXiv:2009.05481*.
- Say, S. (2015). Pazarlama aracı olarak sosyal medya kullanımı: Gıda sektöründe Facebook örneği. *İstanbul Aydın Üniversitesi Dergisi*, 7(28), 19-39.
- Setia, P., Setia, P., Venkatesh, V., & Joglekar, S. (2013). Leveraging digital technologies: How information quality leads to localized capabilities and customer service performance. *MIS quarterly*, 565-590.
- Shah, D., Patel, D., Adesara, J., Hingu, P., & Shah, M. (2021). Integrating machine learning and blockchain to develop a system to veto the forgeries and provide efficient results in education sector. *Visual computing for industry, biomedicine, and art*, 4, 1-13.

- Solmaz, B., Tekin, G., Herzem, Z., & Demir, M. (2013). İnternet ve sosyal medya kullanımı üzerine bir uygulama. *Selçuk İletişim*, 7(4), 23-32.
- Sönmez, A. F., Çakar, S., Cerezci, F., Kotan, M., Delibaşoğlu, İ., & Çit, G. (2023). Deep Learning-Based Classification of Dermoscopic Images for Skin Lesions. *Sakarya University Journal of Computer and Information Sciences*, 6(2), 114-122.
- Sundmaeker, H., Guillemin, P., Friess, P., & Woelfflé, S. (2010). Vision and challenges for realising the Internet of Things. *Cluster of European research projects on the internet of things, European Commission*, 3(3), 34-36.
- Tahaci, M., Abu-Salma, R., & Rashid, A. (2023). *Stuck in the permissions with you: Developer & end-user perspectives on app permissions & their privacy ramifications*. 1-24.
- Tahir, F., & Khan, M. (2023). *Big Data: The Fuel for Machine Learning and AI Advancement* (2516-2314). EasyChair.
- Wang, H., Ma, C., & Zhou, L. (2009). *A brief review of machine learning and its application*. 1-4.
- Wieneke, A., & Lehrer, C. (2016). Generating and exploiting customer insights from social media data. *Electronic Markets*, 26, 245-268.
- Wu, Y. (2024). Application of Reinforcement Learning in Analysis and Optimization of Social Behavior of Students in Colleges and Universities. *Journal of Electrical Systems*, 20(10s), 542-548.
- Yılmaz, A. (2018). Yeni bir pazarlama iletişimi yaklaşımı gerçek-zamanlı pazarlama: Otomobil markalarının geleceğe dönüş günü sosyal medya pratikleri. *Erciyes İletişim Dergisi*, 5(4), 423-446.
- Yurtay, N., Yurtay, Y., Gündoğar, E., & Demirci, H. (2018). Müşteri Odaklı Sipariş Yanıtlama Sürecine İlişkin Bir Mobil Karar Destek Sistemi. *AJIT-e: Academic Journal of Information Technology*, 9(34), 25-30. <https://doi.org/10.5824/1309-1581.2018.4.002.x>
- Yurtay, Y., Demirci, H., Tiryaki, H., & Altun, T. (2024). Emotion Recognition on Call Center Voice Data. *Applied Sciences*, 14(20), 9458.
- Zhang, H., Zang, Z., Zhu, H., Uddin, M. I., & Amin, M. A. (2022). Big data-assisted social media analytics for business model for business decision making system competitive analysis. *Information Processing & Management*, 59(1), 102762.
- Zhou, X., & Belkin, M. (2014). Semi-supervised learning. İçinde *Academic press library in signal processing* (C. 1, ss. 1239-1269). Elsevier.
- Zuboff, S. (2015). Big other: Surveillance capitalism and the prospects of an information civilization. *Journal of information technology*, 30(1), 75-89.