

Otizm Belirtilerinin Erken Tespitinde Duygu Durumlarına Yöneltilen Görsel Dikkatin Makine Öğrenmesi Aracılığıyla Değerlendirilmesi

Işık Akin-Bülbül¹

Hacettepe Üniversitesi

İbrahim Kök²

Ankara Üniversitesi

Selda Özdemir³

Hacettepe Üniversitesi

Özet

Otizmli çocuklar doğal sosyal etkileşim durumlarında insan yüzlerine görsel dikkati yönlendirmede ve insan yüzlerinin sergilediği anlamları yorumlamada, sosyal uyum süreci için gerekli bilgileri insan yüzlerinden edinmede sınırlılıklar sergilerler. Bu sınırlılıklardan hareketle bu çalışmada otizmli çocukları tipik gelişen (TG) akranlarından erken yıllarda ayırt etmede makine öğrenme algoritmalarının kullanımı amaçlanmıştır. Bu amaç doğrultusunda mutlu, üzgün ve nötr duyguları yansıtan videolar oluşturulmuştur. Göz izleme cihazı ile 18-36 ay aralığındaki otizmli ve TG'li katılımcıların, ekranda duygu durumlarını yansıtan videoları izlemeleri sırasında sergiledikleri göz hareketleri kayıt altına alınarak her duygu durumu için ayrı bir veri seti oluşturulmuştur. Araştırma kapsamında duygu durum video veri setleri üzerinde filtre ve sarmalama yaklaşımlarına dayalı öznitelik seçim metodları uygulanarak ayırt edici öznitelikler belirlenmiştir. Ardından belirlenen öznitelikler kullanılarak Karar Ağacı, Naive Bayes ve K En Yakın Komşu sınıflandırma algoritmaları uygulanmıştır. Tespit edilen ayırıcı özniteliklere göre uygulanan makine öğrenme algoritmalarından en yüksek başarı oranını K En Yakın Komşu algoritmasıyla nötr duygu durumları veri setinde elde edilmiştir. Çalışma otizmli çocukları TG'li akranlarından ayırt etmede %81.45'lik başarı oranına ulaşmıştır. Çalışmadan elde edilen bulgular gelecekte makine öğrenme algoritmalarına dayalı olarak geliştirilecek yazılımların otizm belirtilerinin klinik değerlendirmesinde kullanılabilirliği konusunda umut verici olarak kaydedilmiştir.

Anahtar kelimeler: Otizm spektrum bozukluğu, göz izleme, duygu durumları, makine öğrenmesi, görsel dikkat, biyo-belirteç

Abstract

Individuals with autism often face challenges in directing visual attention to human faces in natural social situations and in obtaining important social cues from facial gestures and emotional expressions. Given these limitations, our study sought to employ machine learning algorithms to differentiate children with autism from their typically developing (TD) peers. Therefore, videos displaying happy, sad, and neutral emotions were created. An eye-tracking device was used to create separate data sets for each emotional state by recording the eye movements of the participants with autism and TD children, aged 18 to 36 months, as they watched videos reflecting emotional states on the screen. Feature selection methods were used to identify discriminative features from the areas highlighted in the videos. Decision Tree, Naive Bayes and K-Nearest Neighbour classification algorithms were then applied to these features. Among the machine learning algorithms used to discriminate features, the K Nearest Neighbour algorithm showed superior performance on neutral emotion videos. The study achieved an 81.45% success rate in differentiating children with autism from their TD peers. Study findings offer promising insights into the potential use of software, powered by machine learning algorithms, in future clinical assessments of autism symptoms.

Keywords: Autism spectrum disorder, eye tracking, emotions, machine learning, visual attention, biomarker

Yazışma Adresi: Işık Akin-Bülbül¹, Hacettepe Üniversitesi Eğitim Fakültesi, Özel Eğitim Bölümü, E-posta: isikakin@hacettepe.edu.tr, (ORCID: 0000-0001-5964-6082)

İbrahim Kök², Ankara Üniversitesi Mühendislik Fakültesi Yapay Zeka ve Veri Mühendisliği Bölümü, (ORCID: 0000-0001-9787-8079)

Selda Özdemir³, Hacettepe Üniversitesi Eğitim Fakültesi, Özel Eğitim Bölümü, (ORCID: 0000-0001-9205-5946)

Otizm Belirtilerinin Erken Tespitinde Duygu Durumlarına Yöneltilen Görsel Dikkatin Makine Öğrenmesi Aracılığıyla Değerlendirilmesi

Giriş

Sosyal bilişin bir bileşeni olan insan yüzlerinden duygu tanıma, etkili sosyal iletişim ve etkileşim sırasında işlenen temel bir bilişsel süreçtir (Adolphs, 2002; Wang ve ark., 2004). Sosyal bilişin gelişimi tipik gelişim (TG) gösteren çocuklarda ilk gelişim aylarında başlamakta ve bebekler ilk aylardan itibaren diğer görsel uyaranlarla karşılaştırıldığında insanlara ve insan yüzlerine bakmada güçlü bir görsel tercih göstermektedirler. Ayrıca bebekler erken dönemlerden itibaren dikkatlerini yönelttikleri insan yüzlerindeki duygulara ilişkin niteliksel farklılıkları ayırt edebilmektedirler (Begeer, Koot, Rieffe, Terwoigt ve Stegge, 2008; Schultz, 2005). TG'li bebekler yüzün iç özelliklerine odaklandıklarında da gözlere yönelik güçlü bir tercihte bulunmaktadırlar (Klin ve ark., 2002). Bu yönelim TG'li bebeklerin iletişim ortaklarının yüzlerinden dış olaylara (örn., konuşma) ve içsel süreçlere (örn., duygulara) yönelik bilgi almalarını sağlamaktadır (Sterling ve ark., 2008). TG'li bebekler duygulara yönelik bilgiyi insan yüzlerinden almakla kalmamakta, doğumdan sadece saatler sonra yüz ifadelerine uygun tepkiler de verebilmektedir (Meltzoff ve Prinz, 2002). TG'li bebekler henüz 10 haftalıkken duygulara yönelik repertuarını genişleterek kızgın ve mutlu yüz ifadelerine benzer ifadelerle karşılık verebilmekte (Begeer ve ark., 2008), 9 aylık olduklarında iletişim ortaklarının duygusal ifadeleri ile hareketleri arasındaki bağ kurabilmekte (Barna ve Legerstee, 2005), 4 yaşına kadar en temel ve prototipik duyguları doğru bir şekilde sözlü olarak etiketleyebilmektedirler (Widen ve Russell, 2003). Tipik gelişim gösteren çocuklarda bu sürecin öngörülebilir başlangıcı, zamanlaması ve gelişim süreci göz önüne alındığında, yüzden duyguları tanımada gözlemlenen gecikmeler, atipik gelişim ve psikopatoloji oluşumunun anlamlı bir göstergesi olarak değerlendirilebilmektedir. Otizmli çocuklar alanyazında Kanner (1943) tarafından ilk tanımlandıkları günden itibaren göz kontağı kurmada ve yüze dikkat etmede sergiledikleri sınırlılıklarla karakterize edilmektedir. Günümüze gelindiğinde benzer tanılama kriterlerine vurgu yapıldığı da dikkat çekmektedir. Amerikan Psikiyatri Birliğinin Ruhsal Bozukluklarının Tanısal ve İstatistiksel El Kitabı-5 (DSM-5) otizm spektrum bozukluğunu, sosyal etkileşim ve iletişimde güçlüklerin yanı sıra sınırlı, tekrarlayıcı ve stereotipik davranış ve ilgililerle karakterize olan, geniş spektrumlu bir nörogelişimsel bozukluk olarak tanımlanmaktadır. Otizmi tanılamak, gözlemlenen belirtileri iyileştirmek, çaba ve uzun süre gerektiren zorlu bir süreçtir (Crane ve

ark., 2016; Vabalas ve ark., 2020; Zhao ve ark., 2021). Bu nedenle otizmde gözlemlenen erken dönem risklerini ele alan ve otizmin gelişimsel seyrinin değişmesine odaklanan çalışmaların sayısı her geçen gün artmaktadır. Otizme eşlik eden fizyolojik ve klinik özellikler en erken dönemden itibaren davranışsal gözleme dayalı olarak belirlenemese de bazı yaşamsal davranışların otizmi belirlemede yüksek derecede etkili olduğu bilinmektedir (Frazier ve ark., 2018; Schaller ve ark., 2021). Bu nedenle, otizmin ölçülebilir, nesnel biyobelirteçlerini anlamak hem tanı sürecinde karşılaşılan güçlüklerin üstesinden gelmek (Crane ve ark., 2016; Möricke, Buitelaar ve Rommelse 2016; Tebartz van Elst ve ark., 2013; Vabalas ve ark., 2020), hem de tanı süreçlerini daha verimli ve etkili hale getirebilmek için kritik bir çalışma alanı haline gelmiştir (Zhao ve ark., 2021). Öte yandan otizmin tanınmasına ilişkin sorunları iyileştirmek için özellikle küçük çocuklarda daha nesnel, daha kolay ve daha hızlı tarama yöntemlerine de ihtiyaç duyulduğu pek çok araştırmacı tarafından dile getirilmektedir (Bolte ve ark., 2016; Elsabbagh ve Johnson, 2016).

Her geçen gün otizmli çocukların göz hareketleri parametrelerinin otizmde biyobelirteç olarak kullanılabilmesine yönelik bilimsel kanıtlar artmaktadır (Özdemir, Akın-Bülbül, Kök ve Özdemir, 2022). Göz izleme teknolojileri ise otizmi olan çocukların erken tespiti için oldukça yüksek potansiyele sahiptir (Falck-Ytter ve ark., 2013; Öztürk ve ark., 2024; Wan ve ark., 2019). Bu nedenle otizmde gözlemlenen erken dönem risklerini ele alan ve otizmin gelişimsel seyrinin değişmesine odaklanan araştırmaların sıklıkla ele aldığı önemli araştırma konularından birisi otizmli çocukların görsel dikkatte sergiledikleri sınırlılıkların göz izleme teknolojileri ile incelenmesidir. Otizmli bireylerin nereye baktıklarını belirlemek ilk olarak, otizmli çocukları TG'li çocuklardan daha iyi ayırt ederek otizm tanısının doğruluğunu artırma potansiyelindedir. İkinci olarak, belirli algoritmaları TG'li ve otizmli bireylerin göz izleme verileriyle eğiterek, öğrenilen özellikleri görselleştirmek (Le Meur, Nebout, Chereil ve Etchamendy, 2020) ya da sözel dile çevirmek (Öztürk ve ark., 2024) otizmli bireylerin görsel dikkat farklılıklarını ve etkilerini yorumlamıza imkan sağlayacaktır. Nitekim alanyazında otizmli çocukların sosyal bağlamlarda sergiledikleri göz hareketlerinin otizmli çocukları TG'li akranlarından ayırt etmede biyobelirteç olarak kullanılabilmesini destekleyen araştırma bulguları önemli ölçüde artış göstermektedir (Özdemir ve ark., 2022; Wan ve ark., 2019).

Temel bir sınırlılık olarak, sosyal biliş bozulmaları otiz-

min en çok araştırılan yönlerinden biridir. Sosyal bilişin hem süreçlerinde hem de sınır ağları düzeyinden gözlemlenen farklılıkları otizmlili bireylerde sıklıkla bildirilmektedir (Beyer ve Gammeltoft, 2007; Kennedy ve Adolphs, 2012; Özdemir, Akin-Bulbul ve Yıldız, 2024; Palumbo, Burnett ve Jellema, 2015). Alanyazında sosyal durumlarla ilişkili uyaranlara yönlendirilen atipik görsel dikkatin otizmlili ve TG'li bireyler arasında farklılaşmaya katkıda bulunabileceğine ilişkin farklı teoriler geliştirilmiş veya otizmlili bireylerin görsel dikkat özellikleri farklı teorilerle ilişkilendirilmiştir. Önde gelen kuramlar; a) Sosyal Motivasyon Teorisi, b) Zihin Kuramı ve c) Zayıf Merkezi Bütünleme Teorisi olarak sıralanabilir. Sosyal Motivasyon Teorisine göre otizmlili bebeklerin en erken dönemlerden itibaren sosyal uyaranlara ve bilgiye yöneltilen görsel dikkatteki (örneğin doğumdan itibaren insan yüzü görmeyi tercih etme) sınırlılıkların ilerleyen dönemlerde sergilenen sosyal sınırlılıklara neden olabileceği düşünülmektedir (Chevallier, Kohls, Troiani, Brodtkin ve Schultz, 2012). Gelişimin ilk yıllarından itibaren otizmlili bebeklerin sosyal ipuçlarına dikkatlerini yöneltmede sergiledikleri motivasyon problemleri, otizmlili çocukların sosyal ipuçlarını yorumlama ve sosyal ipuçlarına uygun yanıt verme becerilerini etkilemektedir (Özdemir ve ark., 2024). Otizmlili çocuklar zayıf merkezi bütünleme problemleri nedeniyle nesnel bir özelliğine veya bir bölümüne aşırı derecede dikkati odaklandırabilmekte ve nesnenin “gestalt anlamını” anlamada güçlükler sergileyebilmektedirler (Happé ve Frith, 2006; Jolliffe ve Baron-Cohen, 1997). Zayıf merkezi bütünleme otizmdeki temel sınırlılık alanlarını açıklamak için ilk kez Frith tarafından 1989 yılında kuramsallaştırılmıştır (Happé ve Frith, 2006). Zayıf merkezi bütünleme kuramına göre otizmden etkilenmiş bireyler çevreden aldıkları verileri parçalar olarak algıladıkları için, beyinde bir bütün olarak bir araya getirilip anlamlandırılmazlar (Ozonoff ve ark., 1994). Oysaki TG'li çocuklar bu becerilerde geliştikçe algısal süreçlerdeki tutarlılıkları ortaya çıkmakta ve bireyin kendisinin ve diğer insanların zihinsel süreçleri olduğunu bilme ve zihinde gerçekleşen inanış, istek, duygu, düşünce ve bilgileri, davranışları açıklayabilmek ve tahmin edebilmek için kullanma becerisi olan Zihin Kuramı becerilerini de sergileyebilmektedirler (Akin-Bülbul ve Özdemir 2017; Blijd-Hoogewys, Van Geert, Serra ve Minderaa, 2008).). Alanyazında sıklıkla ele alınan bu üç kuramın oldukça heterojen özellikler sergileyen otizmlili bireylerin sergiledikleri sınırlılıkları tek başına açıklaması elbette mümkün değildir. Bununla birlikte söz konusu üç kuramın ele aldığı temel yeterlilik alanları ile görsel dikkat arasındaki ilişki de oldukça dikkat çekicidir. Nitekim en erken gelişim dönemlerinden itibaren görsel dikkatte sergilenen sınırlılıkların aşamalı olarak gözlemlenen gelişimsel

farklılaşma üzerine etkileri, söz konusu araştırma alanında göz izleme teknolojilerinin kullanılabilmesiyle otizmdeki atipik görsel dikkati nesnel olarak inceleyebilmeyi sağlamıştır. Ek olarak erken dönemde sosyal uyaranlara yöneltilen görsel dikkat verileri üzerinde uygulanan algoritmalar, insan gözüyle saptanamayan örüntüleri yakalayabilmekte, hassas analizler yaparak daha güvenilir ve daha hızlı risk değerlendirmesi sağlayabilmektedir (Canavan ve ark., 2017).

Alanyazında çok sayıda araştırma otizmlili çocukların insan yüzlerinde sergilenen mimiklerden ve duygusal ifadelerden sosyal uyum için önemli bilgileri almada sınırlılıklar sergilediklerini göstermiştir (Chawarska ve Volkmar, 2005; McPartland ve ark., 2011; Özdemir, Gürel-Selimoğlu, Töret ve Suna, 2017; Yirmiya, Erel, Shaked ve Solomonica-Levi, 1998). Otizmlili çocuklar insan yüzlerine yöneldiklerinde duyguları anlamada önemli bir bilgi kaynağı olan gözlere ve duygusal ifadelere dikkatlerini yönlendirmede sınırlılık sergilemekte, yüz ifadeleri ile ilgili ipuçlarını birleştirememektedirler (Boucher, Lewis ve Collis, 2000; Yi ve ark., 2013). Göz izleme çalışmaları, özellikle sosyal uyaranlar ve yüze yöneltilen görsel dikkat açısından otizmlili çocuklar ile TG'li çocuklar arasında göz hareketlerinde izlenen örüntü farklılıklarını yaygın olarak rapor etmektedir (Akin-Bülbul ve Özdemir, 2021; Boraston ve Blakemore, 2007; Falck-Ytter ve ark., 2013; Pierce ve ark., 2016). Tüm bulgular arasında en dikkat çekici bulgu ise otizmlili çocukların, TG'li ve diğer yetersizlik gruplarından etkilenmiş akranları ile karşılaştırıldığında gözlere düşük düzeyde ilgi gösterdiklerine ilişkin bulgudur (Akin ve Özdemir, 2021; Bal ve ark., 2010; Corden ve ark., 2008; Dalton ve ark., 2005; Hernandez ark., 2009; Klin ve ark., 2002; Król ve Król, 2019; Pelphrey ve ark., 2002; Yi ve ark., 2013). Benzer şekilde araştırmacılar tarafından rapor edilen bir diğer önemli bulgu ise otizmlili çocukların, yüzen duygu tanıma ile ilgili önemli sınırlılıkları olduğudur (Black ve ark., 2017; Dawson, Meltzoff, Osterling, Rinaldi ve Brown, 1998; Harms ve ark., 2010; Kennedy ve Adolphs, 2012; Uljarevic ve Hamilton, 2013; Whitaker, Simpson ve Roberson, 2017).

Son yıllarda, makine öğrenme algoritmaları kullanılarak ruh sağlığı ve sınır ve davranış bilimlerinde risk belirleme ve tanılamayı amaçlayan çalışmalar yürütülmektedir (Bone ve ark., 2015; Lindsay, 2020). Nitekim yeni doğan nöbet tespiti (Pavel ve ark., 2020), epilepsi (Abbasi ve Goldenholz, 2019), parkinson hastalığı (Mei, Desrosiers ve Frasnelli, 2021) gibi birbirinden oldukça farklılaşan tanılarda makine öğrenme algoritmaları kullanılarak araştırmalar yapıldığı görülmektedir. Makine öğrenme araştırmaları aynı zamanda çocuk ruh sağlığı alanında tanı ve müdahale uygulamalarını iyileştirmek için de önemli bir potansiyele sahiptir. Özellikle oldukça

heterojen özellikler sergileyen otizmlilerle yapılan araştırmalar alanyazına önemli katkılar sunma potansiyelindedir (Bone ve ark., 2015). Nitekim, alanyazında gerçekleştirilen birçok araştırmada otizmlilerle çocukları TG'li çocuklardan ayırt etmek için göz izleme ve makine öğrenme algoritmalarının başarılı bir şekilde uygulandığı görülmektedir (Król ve Król, 2019; Özdemir ve ark., 2022). Erken dönem otizm tanısına sahip çocuklar ve makine öğrenme algoritmaları alanında Özdemir ve arkadaşlarının (2022) çalışması dikkat çekicidir. Araştırmacılar oldukça küçük yaş aralığındaki (18-36 ay) otizmlilerle çocuklar ile gerçekleştirdikleri araştırmada sosyal ve sosyal olmayan uyaranlara görsel dikkati yöneltme ürünlerini incelemiştir. Araştırmacılar otizmlilerle çocukları sınıflamada Karar Ağacı (Decision Tree-DT), Naive Bayes (NB), Rastgele Orman (Random Forest-RF) ve Destek Vektör Makinesi (SVM) algoritmalarını kullanmışlar ve RF ve SVM ile %87,5 başarı oranı elde etmişlerdir. Król ve Król (2019) atipik yüz tarama modellerinin otizmde duygu tanıma ile ilgili gözlenen sorunların nedeni olup olmadığını makine öğrenme algoritmalarını eğiterek araştırmıştır. Araştırmacılar TG'li akranları ile karşılaştırıldığında otizmlilerle çocukların gözlemlere daha az odaklanıp bakışlarını daha çok yüzün alt bölümüne yönlendirdiklerini, bu nedenle duygu tanıma görevlerinde yüzlerden elde edilen bilginin yetersiz olduğunu rapor etmişlerdir. Pelphey (2002) ise yüzün dışındaki alanlara bakmanın artmasıyla birlikte sosyal olarak ilgili alanlara bakmada genel bir azalma olduğunu bildirmiştir. Liu, Li ve Yi (2016) ise bir araştırmada yüz tanıma görevinde otizmlilerle çocukların göz hareketlerini incelemiştir. Araştırmacılar çalışmada yaşları 4-11 arasında değişen otizmlilerle çocukları kronolojik yaşa dayalı olarak TG'li akranlarıyla eşleştirmişlerdir. Araştırmacılar otizmlilerle çocukları kontrol grubundaki çocuklardan ayırt etmede %88.51 sınıflandırma başarı oranı elde ettiklerini rapor etmişlerdir. Başka bir araştırmada Canavan ve ark., (2017) düşük, orta ve yüksek otizm riskleri olan oldukça geniş bir kronolojik yaş aralığındaki (2 ila 60+ yaş aralığındaki) otizmlilerle çocuk ve bireylerin ulusal otizm araştırmaları veri tabanındaki görsel dikkat, bakış bilgilerini kullanarak, bakış özelliklerini demografik özelliklerle analiz etmişlerdir. Araştırmacılar elde ettikleri veriler üzerinde RF, C4.5 karar ağacı ve PART sınıflandırıcıyı kullanarak %96.2 başarı oranına ulaşmıştır.

Kennedy ve Adolphs (2012) da duygulara yönelik duyarlılığı inceledikleri bir araştırmada kontrol grubu ile karşılaştırıldığında otizmlilerle yetişkinlerin duygulara karşı önemli ölçüde daha az duyarlılık sergilediklerini rapor etmişlerdir. Alanyazında yüksek işlevli otizmlilerle çocukların dahi bağlamsal ipuçlarını kullanarak dört temel duyguyu belirlemede TG'li akranlarıyla karşılaştırıldığında belirgin düzeyde zorlandıkları rapor edilmiştir

(Tsang, 2018; Wright ve ark., 2008; Yeung ve Chan, 2020). Duygulara yönelik erken dönem kazanımı olarak nitelendirilebilecek bu becerinin yüksek işlevli otizmlilerle bireyler tarafından dahi sergilenememesi otizmlilerle bireylerin duyguları ve bu duygulara eşlik eden yüz ifadelerini işlemede yaşadıkları zorlukların önemli bir göstergesi olarak yorumlanabilmektedir (Tsang, 2018). Jiang ve arkadaşları (2019) bir araştırmada duygu tanıma görev performansını ile bu görev sırasında yöneltilen görsel dikkati kayıt altına alarak otizmlilerle bireyleri TG'li akranlarından (8-34 yaş aralığındaki) ayırt etmeyi amaçlamışlardır. Araştırmada katılımcıların Dinamik Duygulanım Tanıma Değerlendirmesinde yer alan (öfke, iğrenme, korku, mutluluk, üzüntü ve şaşkınlık) duygularından birini tanıması gerekmiştir. Araştırmacılar otizmlilerle katılımcıların tepki süresi ve göz hareketlerinde farklılıklar gözlemlediklerini, bu farklılıklara dayalı olarak makine öğrenme algoritmalarında %86 sınıflandırma doğruluğu elde ettiklerini rapor etmişlerdir.

Özetle alanyazında gerçekleştirilen araştırmalar incelendiğinde kronolojik yaştan ve otizmden etkilenme düzeyinden bağımsız olarak otizmlilerle çocukların sosyal uyaranlar olan insan yüzlerine ve yüzlerde sergilenen duygusal ifadelerle dikkatlerini yöneltmede sınırlılıklar sergiledikleri görülmektedir. Otizmlilerle çocuklar görsel dikkati yöneltmede sergiledikleri bu sınırlılıklarının yanı sıra sosyal işlevsellikteki bozulmalara katkıda bulunduğu düşünülen yüz ifadelerinden duyguları tanıma da sınırlılıklar sergilemektedirler (Wieckowski, Flynn, Ritchey, Gracian ve White, 2020). Son on yılda otizm gibi nörogelişimsel bozuklukların erken yıllarda teşhisini ön görmeye yönelik makine öğrenme araştırmalarının sayısında artış olmuştur. Ancak göz izleme verilerinin klinik değerlendirmelerde bir biyobelirteç olarak kullanılması, teşhis veya klinik çalışmalarda pratik uygulamalar için hala yeterince olgunlaşmış düzeyde değildir. Bununla birlikte göz hareketleri ile bilişsel süreçler ve genel gelişimsel beceriler arasındaki belirgin ilişki, gözle bakma ve otizm arasındaki ilişkinin incelenmesini önemli kılmaktadır (Hayhoe ve Ballard, 2005). Öte yandan duyguları yansıtan videolardaki göz hareketleri ve makine öğrenme algoritmalarının kullanıldığı araştırmalar bütüncül olarak değerlendirildiğinde dikkati çeken önemli bir sınırlılık katılımcıların kronik yaş ortalamalarının oldukça büyük olmasıdır. Araştırmalar arasında erişilebilen en küçük katılımcı grubuyla çalışan araştırmacı Liu, Li ve Yi (2016) dir. Bu araştırmada dahi otizmlilerle katılımcıların kronolojik yaş ortalamalarının 7.9 yaş olduğu görülmektedir.

Bu araştırmada da otizmlilerle çocuklarda erken yıllarda klinik gözlemlerde izlenen görsel dikkat farklılıklarından hareketle duygu durumlarına yöneltilen görsel dikkatin ayırt ediciliğinin incelenmesi amaçlanmıştır. Araştırma

kapsamında oldukça erken dönemdeki çocuklar (=28.20 ay) ile çalışılarak yukarıdaki alanyazın tartışmasını bir adım daha öteye taşımak planlamıştır. Duyguları tanıma sergilenen göz hareketleri parametrelerinin otizmliler için çocukları TG'li akranlarından ayırt etmede kullanılabilir bir biyobelirteç olarak kullanılabilirliğini makine öğrenme algoritmalarıyla incelemek bu araştırmanın ana motivasyonudur. Bu doğrultuda, otizmliler için küçük çocukların atipik görsel dikkat yönelimlerinin bir biyobelirteç olarak kullanılabilirliğini incelemek amacıyla üç temel duyu durumunu yansıtan videoları izleme sırasında kaydedilen göz izleme verilerinin öngörücü gücü incelenmiştir.

Yöntem

Makine öğrenmesi

Makine öğrenmesi, insanların öğrenme şeklini taklit ederek verilerden öğrenme, kalıplar tanımlama, sınıflama, kümeleme, tahmin yapmaya odaklanan yapay zeka alanının bir alt araştırma alanıdır. Makine öğrenmesi karmaşık problemlerle başedebilecek çeşitli öğrenme yaklaşımlarını kullanır. Bu yaklaşımlar temel olarak denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir. Denetimli öğrenme etiketli veri setleri kullanılarak sınıflandırılma problemlerinin çözümünde kullanılırken, denetimsiz öğrenme etiketsiz veri setleriyle kümeleme problemlerinde kullanılır. Diğer tarafta pekiştirmeli öğrenme ise süreç başlangıcında veri olmadan ortamla etkileşime girerek öğrenir (Shalev-Shwartz ve Ben-David, 2014). Bu çalışmada ele alınan sınıflandırma probleminin çözümünde denetimli öğrenme algoritmalarından Karar Ağacı (Decision Tree-DT), Naive Bayes ve K- En Yakın Komşu (K Nearest Neighbor-KNN) algoritmaları kullanılmıştır.

Karar Ağacı, veri setini bağımlı değişken üzerindeki farklılıkları maksimize etmek amacıyla belirli karar adımlarına göre bölen ve yapılandıran bir makine öğrenmesi algoritmasıdır. Karar ağaçlarında her bir özellik bir düğümlerle temsil edilmektedir. Bu düğümler en üstten en alta (kökten dallara) doğru entropi tabanlı kriterlere uygun olarak yerleştirilerek karar ağacı oluşturulur. Bir veri örneğinin sınıf etiketini tahmin etmek için algoritma ağacın kökünden başlanır ve kök özneliğinin değerlerini veri örneğinin özneliğiyle karşılaştırılır. Bu işleme, algoritma tahmin edilen bir sınıf etiketine karşılık gelen bir yaprak düğüme ulaşana kadar özyinelemeli olarak devam edilir.

Naive Bayes, veri sınıflandırması için kullanılan istatistiksel bir algoritmadır ve bayes teoremine dayanır. Bu algoritma, iki olay arasındaki koşullu ve marjinal (önsel) olasılıkları ilişkilendirerek çalışır. Algoritmanın temel varsayımı, veri setindeki özelliklerin birbirinden bağımsız

olduğu yönündedir. Bu da Naive Bayes'in çok sayıda özelliği etkili bir şekilde işlemesine ve sınırlı eğitim verileri ile iyi bir performans sergilemesine olanak tanır. Öğrenme aşamasında, Naive Bayes verilerin koşullu olasılıklarını hesaplar, yani verinin belirli bir sınıfa ait olma olasılığını tahmin eder. Bu hesaplamalar sonucunda, test verisi belirli bir sınıfa ait olma olasılığını hesaplar ve bu olasılıkları karşılaştırarak en yüksek olasılığa sahip sınıfı tahmin eder. Naive Bayes'in bu basit yaklaşımı sayesinde, sınıflandırma işlemleri hızlı ve etkili bir şekilde gerçekleştirilebilir.

K- En Yakın Komşu, sınıflandırma problemlerinde sıklıkla kullanılan bir algoritmadır. KNN, veri noktaları arasındaki uzaklığı temel alarak bir verinin hangi sınıfa ait olduğunu tahmin eder. Bu işlem için bir veri noktası, yakınındaki "k" adet veri noktasına bakar ve bu noktaların hangi sınıfa ait olduğunu analiz eder. Sonuç olarak, test verisi, en fazla sayıda olan sınıfa atanır. Ancak KNN'nin başarısı "k" değerinin seçimine ve uzaklık hesaplama yöntemine bağlıdır. Eğer "k" değeri çok düşük veya çok yüksek seçilirse, doğruluk oranı düşebilir. Bu nedenle, farklı "k" değerleri ile algoritmanın tekrarlanması ve en uygun "k" değerinin belirlenmesi önemlidir. Öklid uzaklığı, bu uzaklık hesaplama işlemi için sıkça kullanılan bir metriktir.

Katılımcılar

Araştırmanın katılımcıları, Gazi Üniversitesi, Klinik Araştırmalar Etik Kurulu ve Milli Eğitim Bakanlığı'ndan (MEB) alınan izinlerin ardından Ankara'da MEB'e bağlı Rehberlik ve Araştırma Merkezleri ile yapılan toplantılar aracılığıyla bulunulmuştur. Araştırmacılar yapılacak olan çalışmaya yönelik bilgileri paylaşarak, 18-36 ay aralığında otizmliler için çocuğa sahip, araştırmaya katılmaya istekli olan ebeveynlerin yönlendirilmesi için gerekli iletişim bilgilerini paylaşmışlardır. Araştırmanın katılımcıları hem Rehberlik ve Araştırma Merkezleri kanalı ile hem de web sayfası üzerinden ve sosyal medya hesaplarından yapılan duyurulara dönüş sağlayan ebeveynlerin çocukları arasından belirlenmiştir. Projeye katılmaya istekli olan aileler ve çocukları üniversite bünyesindeki araştırma merkezine davet edilmiştir. İlk aşamada 18-36 ay aralığındaki otizm tanısı olan ya da TG gösteren çocuğa sahip araştırmaya katılmaya istekli ebeveynlere çalışma hakkında ayrıntılı bilgiler verilerek, ayrıntılı gelişimsel değerlendirmeler yapılarak çalışmaların yürütüleceği belirtilmiştir. Araştırmaya katılmayı kabul eden ailelerin çocukları ile ayrıntılı klinik değerlendirmeler gerçekleştirilmiştir. Gerçekleştirilen kapsamlı değerlendirmeler sonucunda araştırma ölçütlerini karşılayan çocuklar araştırmaya dahil edilmiştir.

Çalışmanın katılımcılarının 54 otizmliler (=28.20 ay) ve 70 TG'li çocuk(=27,07 ay) oluşturmuştur. Makine öğren-

mesi yöntemleri, genellikle küçük örneklem boyutlarının eşlik ettiği yüksek boyutlu verilerle ilgilenen çeşitli alanlara başarıyla uygulanmıştır (Stahl ve ark., 2012). Otizm alinyazındaki makine öğrenme araştırmalarını ele alan bir gözden geçirme araştırması incelendiğinde katılımcı sayılarının 15 ile 573 arasında değişebildiği görülmektedir (Nogay ve Adeli, 2020). Bu nedenle bu araştırmanın katılımcı sayısının makine öğrenme araştırması yürütmek için yeterli olduğu belirlenmiştir.

Araştırmanın katılımcıları kronolojik yaşlarına dayalı olarak eşleştirilmiştir. Otizmlı çocukların DSM-V tanı kriterlerine dayalı olarak tıp fakülteleri ve devlet hastanelerinin çocuk ruh sağlığı anabilim dalları tarafından verilmiş resmi otizm tanıları bulunmaktadır. Araştırmanın otizmlı katılımcılarının tümü araştırma verilerinin toplanması sürecinde özel eğitim kurumlarından destek eğitim hizmetlerini almaya devam etmişlerdir.

Araştırmanın katılımcılarını 3 yaş altı otizmlı çocuklar oluşturduğu için katılımcı çocukların otizmden etkilenme düzeyleri Değiştirilmiş Erken Çocukluk Dönemi Otizm Tarama Ölçeği (M-CHAT-R) ile gerçekleştirilmiştir. M-CHAT-R sonuçlarına dayalı olarak çalışmanın katılımcıları orta ve yüksek düzeyde otizm riskleri sergileyen çocuklardan oluşmuştur. Otizmlı ve TG'li çocukların katılımcı özellikleri için Tablo 1'e bakınız.

Çalışmaya otizmlı ve TG'li çocukların katılımı için bazı ön koşullar belirlenmiştir. Otizmlı ve TG'li çocuklarda aranan ortak ön koşul özellikler; a) kronolojik yaşın 18-36 ay aralığında olması, b) ebeveyni tarafından çalışmaya katılım izninin verilmiş olması, c) gözlük kullanmıyor olması, olarak belirlenmiştir. Otizmlı çocuklara özgü belirlenen ön ek koşullar ise a) otizm tanısının DSM-V kriterlerine dayalı olarak resmi klinik tanıyla alınmış olması, b) otizm tanısına eşlik eden görme, işitme yetersizliği gibi duyuşsal, epilepsi gibi nörolojik ve/veya

genetik bir başka bozukluğun bulunmaması şeklinde uygulanmıştır. Son olarak TG'li katılımcıların uygulanan BAYLEY-III ölçeği sonucuna tipik gelişim gösterdiğinin doğrulanması ön koşulu aranmıştır.

Veri Toplama Araçları

Erken Çocukluk Dönemi Otizm Tarama Ölçeği M-CHAT-Revised

Erken çocukluk döneminde otizm belirtilerini belirlemek amacıyla geliştirilen Erken Çocukluk Dönemi Otizm Tarama Ölçeği (M-CHAT-F) Robins ve arkadaşları (2013) tarafından geliştirilmiştir. Değerlendirilmeye alınan çocuğun otizm şüphesi olup olmadığını değerlendirmek amacıyla kullanılan ölçek 23 maddeden oluşmaktadır. M-CHAT-R'da 2, 5 ve 12 haricindeki tüm maddeler için "hayır" yanıtı OSB riskini belirtir; 2,5 ve 12. maddeler için "evet" otizm riskini belirtir. Ölçeğin uygulanması sonucunda "Düşük Risk, Orta Risk ve Yüksek Risk" olmak üzere üç risk durumu rapor edilmektedir. (Ölçeğe ve puanlamasına yönelik ayrıntılı bilgilere https://mchatreen.com/wp-content/uploads/2017/03/M-CHAT-R_Turkish.pdf sayfasından ulaşabilirsiniz)

Türkçe 'ye uyarlanarak geçerlilik ve güvenilirlik çalışması yapılan ölçeğin maddelerinin güvenilirlik kat sayısı 0,74 olarak hesaplanırken ölçekte bulunan altı kritik maddenin güvenilirlik kat sayısı ise 0,69 olarak hesaplanmıştır (TC Sağlık Bakanlığı ve Tohum Otizm Vakfı, 2008). M-CHAT-R otizmlı çocuğa sahip ebeveynlere araştırmanın birinci yazarı tarafından tanıtılarak sunulmuş ve destek istenmesi durumunda gerekli açıklamalar yapılmıştır. M-CHAT-R'ın bu araştırmada kullanılma nedeni araştırmanın otizmlı katılımcılarının otizmden etkilenme durumlarının doğrulanması ve katılımcı çocukların yaşlarının 36 ay altında olmasıdır.

Tablo 1. Katılımcı Demografik ve Klinik Özellikleri

Değişkenler	OSB (n = 54, aralık 18–36)	TG (n = 70, aralık 18–36)	p
Kronolojik yaş	28,20	27,07	0,87
Kız/Erkek	10/44	33/37	0,00*
Bayley bilişsel bileşik puan	77,04	100,00	0,00*
Bayley dil bileşik puan	67,69	99,89	0,00*
Bayley motor bileşik puan	67,89	97,81	0,00*
Risk yok	-	-	-
M-Chat Orta risk	7	-	-
Yüksek risk	47	-	-

Not: *p < 0.05. OSB = Otizm Spektrum Bozukluğu; TG = Tipik Gelişim; M-Chat = Değiştirilmiş Erken Çocukluk Dönemi Otizm Tarama Ölçeği

Bayley-III Bebekler ve Küçük Çocuklar İçin Gelişim Ölçeği

Bayley- III, Bayley Bebek Gelişim Ölçeği İkinci Baskı (BSID- II; Bayley, 1993)'nın revize edilmiş halidir. Yüksek test-tekrar test güvenilirliği ve iç tutarlılığa sahip olan Bayley-III Bebekler ve Küçük Çocuklar Gelişim Ölçeği 1-42 ay aralığındaki bebek ve çocukların gelişimsel işlevlerini değerlendirmek amacıyla geliştirilmiştir (Bayley, 2006). Bayley-III bebekler ve küçük çocukların Dil, Bilişsel, Motor, Sosyal-Duygusal ve Uyumsal alandaki gelişimlerini değerlendirmek amacıyla kullanılmaktadır. Çocuklar ile gerçekleştirilen birebir uygulamalar ile Bayley- III, Bilişsel, Dil, Motor alanların değerlendirilmesi gerçekleştirilirken, Sosyal-Duygusal ve Uyumsal alanların değerlendirilmesi çocuğa birincil bakım verenin anketi verdiği cevaplar kullanılarak değerlendirilmektedir. Bayley-III ölçeğinin uygulaması sonucunda standart puan, birleşik puan, yüzdelik sıra ve büyüme puanları olmak üzere dört farklı türde norm dayalı puan elde edilmektedir (Albers ve Grieve, 2007). Alt testlerde gelişimsel yaş denklikleri kullanılarak uygun güven aralıkları oluşturulmuştur. Bilişsel, Dil, Motor ve Sosyal Duygusal Ölçekler ve tüm alt testler için standart

puanlar hesaplanabilir. Bu puanlar, alt test toplam ham puanlarından elde edilmektedir. Birleşik puanlar çeşitli alt test standart puanların toplamından elde edilir. Birleşik puanlar Dil Ölçeği, Motor Ölçek ve Uyumsal Davranış Ölçeği için oluşturulur. Birleşik puanlar ortalama 100 ve serbestlik derecesi 15 olacak şekilde, 40 ile 160 aralığında ölçeklendirilmiştir. Araştırmada katılımcıların gelişimsel değerlendirmeleri ve TG'li çocukların tipik gelişim göstereceklerinin doğrulaması Bayley-III ile gerçekleştirilmiştir.


Duygu Durumları Veri Seti ve Belirlenen İlgili Alanları

Duygu durumları video seti erkek ve kadın modelin yer aldığı, mutlu, nötr ve üzgün olmak üzere üç farklı duygu durumunu yansıtan videolardan oluşmaktadır. Duygu durumları video seti altı alan uzmanıyla paylaşılarak uzman görüşleri alınmıştır. Alan uzmanlarına videoların hangi duygu durumlarını yansıttığı sorulmuştur. Altı alan uzmanı da videoları üzgün, mutlu ve herhangi bir duygu yansıtmıyor olarak kategorize etmiştir.

Her bir video yaklaşık olarak 10 sn. den oluşmakta ve videoların tamamı 1 dk sürmektedir. Araştırmalar 1 dk lık görsel örneklemin otizmli çocuklarda göz izleme



a



b

Şekil 1. Mutlu veri seti görsel materyalleri

verilerinin ayırt ediciliğini göstermektedir (Pierce, Conant, Hazin, Stoner ve Desmond, 2011). Her bir duygu durumunu temsil eden iki videonun çekilmesinin üç nedeni bulunmaktadır. İlk olarak örneklem sayısını artırarak daha güvenilir veriler elde etmek amaçlanmıştır. İkinci olarak katılımcıların cinsiyete yönelik yönelme ve kaçınma davranışlarının neden olabileceği veri kirliliğinin önüne geçme amaçlanmıştır. Bu nedenle tüm duygu durumlarını bir videoda kadın model sergilerken, diğer bir video da erkek model sergilemiştir. Videoların tümü aynı arka planda çekilmiş olmakla birlikte doğal sosyal durumları yansıtmaması bakımından videoların sesi ve bağlama dayalı olarak ortama dâhil edilen nesnelerin rengi ve boyutlarında duygu durumlarında bir eşleştirme yapılmamıştır. Son olarak ekranın sağına veya soluna dikkatin yönlendirilmesinden kaynaklanabilecek veri kirliliğinin önüne geçmek amacıyla duygu durumunu temsil eden durum bir videoda ekranın sağında yer alırken, diğer videoda ekranın solunda yer almıştır. Tüm setlerde duygu durumunu yansıtan yüz, diğer kişinin yüzü, kişilerin bedenleri, kullanılan nesne ve dış alan olmak üzere altı ilgi alanı belirlenmiştir (Bkz. Şekil 1., 2., ve 3.). Mutlu, nötr ve üzgün duygu durumuna sahip kişilerin


ilgi alanları kendi içinde birleştirilmiştir. Duygu durumunu sergileyen insan yüzü dışında kalan ilgi alanları ise kendi içinde birleştirilmiştir. Her bir duygu durumu seti için örneğin mutlu veri seti için oluşturulan ilgi alanları 1-mutlu kişi yüzü, 2-mutlu kişi beden, 3-diğer kişi yüzü, 4-diğer kişi beden, 5-nesne ve 6-dış alan olmak üzere altı ilgi alanı olarak belirlenmiştir. Belirlenen ilgi alanları için Şekil 1., 2. ve 3'e bakınız.

Göz İzleme Cihazı ve Uygulama

Bu araştırmada katılımcıların duygu durumlarını yansıtan videoları izleme davranışları göz izleme cihazı ile kayıt altına alınmıştır. Göz izleme cihazları sayesinde göz hareketlerini ölçmek yaygın, kolay ve güvenilir bir veri toplama tekniği olarak kabul edilmektedir (Le Meur ve ark., 2020). Göz izleme teknolojileri, görsel dikkati işlemeye karşılık gelen hedefe yönelik göz hareketlerinin ve bakış dağılımının doğrudan ve hassas ölçülmesine fırsat sunmaktadır (Mastergeorge, Kahathuduwa ve Blume, 2021; Van Rijn, Urbanus ve Swaab, 2019). Toplanan göz izleme verilerinden bakışın sabitlenme yerleri ve süreleri gibi çok çeşitli bilgi elde edilir. Katılımcıların göz izleme verileri üniversite bünyesindeki




a



b

Şekil 2. Nötr veri seti görsel materyalleri



Şekil 3. Üzgün veri seti görsel materyalleri

özel olarak hazırlanmış bir göz izleme laboratuvarında toplanmıştır. Laboratuvar gün ışığını geçirmeyen özel perdelerin kullanıldığı bir laboratuvardır. Çift taraflı cam ile ayrılan iki bölümden oluşan laboratuvar da bir bölümde veri toplama ünitesi bir bölümde ise göz izleme cihazı konumlandırılmıştır.

Araştırmada SMI-Red250 göz izleme cihazı 1680×1050 piksel çözünürlükteki 17 inçlik bir LCD monitörün altına sabitlenerek kullanılmıştır. Araştırmanın katılımcılarının göz izleme parametrelerinin kaydedilmesi ve depolanması Experiment Center™ 3.6 yazılımı ile gerçekleştirilmiştir. Kaydedilen verilerin analizinde SMI BeGaze™ (The Behavioral and Gaze Analysis) yazılımı kullanılmıştır. SMI-Red250 göz izleme cihazının göz hareketlerini örnekleme hızı 250 Hertzdir (Hz).

Katılımcıların göz izleme verilerinin toplanması aşamasında birinci araştırmacı her bir ebeveyn çocuk çiftine eşlik etmiştir. Çocuklar bilgisayar ekranı karşına tercih ettikleri ebeveynlerinin kucağında ya da boyu ayarlanabilir bir sandalyede yalnız olarak oturmuşlardır. Ekran ile katılımcıların gözü arasındaki mesafe yaklaşık olarak 60 cm olacak şekilde ayarlanmıştır. Ağlayan bir bebek animasyonu ile beş nokta kalibrasyon uygulaması ta-

manlanmıştır. Kalibrasyon işleminin tamamlanmasının ardından randomize bir sırada her bir duygu durumunu yansıtan videoların bir kez izlenmesi sağlanmıştır. Kalibrasyon aşamasını başarı ile tamamlanmaması durumunda kalibrasyon işlemi tekrarlanmıştır. Çocuğun izlemeyi reddetmesi, ağlaması, ya da dikkatinin dağılması durumunda çocuğun ihtiyacına dayalı olarak 5-10 dk oyun oynaması ya da tercih ettiği bir etkinlikle rahatlaması sağlanarak süreç tekrarlanmıştır. Göz izleme verilerinde uygulama sunum süresi $\geq 50\%$ olan katılımcıların verileri analize dahil edilmiştir (Shic ve ark., 2022). Hiçbir katılımcının izleme süresi belirlenen bu sürenin altında kalmadığı için katılımcı kaybı yaşanmamıştır. Çocukların göz izleme verileri kayıt sırasında eş zamanlı olarak gözlem odasından kontrol edilmiştir.

Verilerin Analizi

Araştırma kapsamında otizm tanısına yardımcı olabilecek biyobelirteçlerin belirlenebilmesi amacıyla duygu durumları videolarına yöneltilen dikkati yöneltme ürünleri incelenmiştir. Bu amaç kapsamında üç duygu durumuna yönelik göz hareketleri parametreleri göz izleme

cihazı ile kaydedilerek her üç duygu durumu için ayrı veri seti oluşturulmuş ve bu veri setleri veri madenciliği yöntemleri ile analiz edilmiştir. Çalışmadaki verilerin analizi (I) veri setlerinin oluşturulması (II) veri setlerinden özniteliklerin belirlenmesi aşamalarından oluşmaktadır.

Araştırmanın veri setleri SMI BeGaze™ yazılımı kullanılarak oluşturulmuştur. Veri setlerinde öncelikli olarak mutlu, üzgün ve nötr duygu durumları videoları üzerinde dinamik ilgi alanları belirlenmiştir. Her bir duygu durumu videosu ele alınan duygu durumunu (mutlu, üzgün ve nötr) farklı iki kişi ve bir nesneyi içermektedir. Duygu durumları veri setinde her bir ilgi alanından 12 özellik çıkartılmıştır. Bu öznitelikler şu şekilde sıralanmaktadır: 1: Net Bekleme Süresi [Net Dwell Time, ms], 2: Bekleme Süresi [Dwell Time ms], 3: Bakış Süresi [Glance Duration, ms], 4: Yönlendirme Süresi [Diversion Duration, ms], 5: İlk Sabitleme Süresi [First Fixation Duration, ms], 6: Bakış Sayısı [Glances Count], 7: Sabitleme Sayısı [Fixation Count], 8: Net Bekleme Süresi [Net Dwell Time, %], 9: Bekleme Süresi [Dwell Time, %], 10: Sabitleme Süresi [Fixation Time, ms], 11: Sabitleme Süresi [Fixation Time, %] ve 12: Ortalama Sabitleme Süresidir [Average Fixation Duration, ms]. Belirlenen altı ilgi alanı için toplam 72 öznitelik olacak şekilde veri setleri oluşturulmuştur. Her veri seti için belirlenen özniteliklere ReliefF, Information Gain, Gain Ratio ve Wrapper öznitelik seçim yöntemleri uygulanmıştır. Mutlu, nötr ve üzgün veri setleri için belirlenen öznitelikler sırasıyla Tablo 2, Tablo 3 ve Tablo 4'te sunulmuştur (Belirlenen özniteliklere ilişkin tanımlar için Ek-1'e bakınız.).

Veri Setleri Üzerinde Özniteliklerin Seçimi

Çalışmada toplanan Mutlu, Nötr ve Üzgün duygu durumları, veri setleri üzerinde öznitelik seçimi için filtre tabanlı ReliefF (RF), Information Gain (IG), Gain Ratio (GR) yöntemleri ve sarmalama tabanlı Wrapper-NG,

Wrapper-J48, Wrapper-KNN yöntemleri kullanılmıştır. Filtre yöntemleri, öznitelik seçim kriteri olarak değişken sıralama tekniklerini kullanır ve özelliklerin bağımlı değişkenle olan ilişkisini istatistiksel metriklerle değerlendirir. Sayısal karmaşıklığın düşük olması ve yüksek sayıda öznitelik ile kullanılabilmesi bu yaklaşımın avantajları olarak kabul edilmektedir. Filtre metodların en büyük dezavantajı seçilen öznitelik alt kümesinin öğrenme algoritması üzerindeki etkisini önemsememesidir (Bolón-Canedo ve ark., 2014).

Sarmalayıcı yöntemler ise özellik alt kümelerinin gerçek bir model üzerinde eğitilerek değerlendirilmesi yoluyla daha görev odaklı bir seçim yaparlar. Bu nedenle, sarmalayıcı yöntemler seçilen özelliklerin belirli bir görev için ne kadar etkili olduğunu daha kesin bir şekilde ölçme avantajına sahiptirler. Ancak, özellikle büyük veri kümeleri üzerinde çalışırken sarmalayıcı yöntemler, hesaplama açısından daha maliyetli ve karmaşıktır (Bolón-Canedo ve ark. 2014). Bu çalışmada farkları açıklanan öznitelik seçim yöntemlerinin ortaya çıkardığı sonuçlar aşağıda detaylı olarak açıklanmıştır.

Mutlu veri setinde öznitelik seçim algoritmaları Mutlu Yüz alanı parametrelerini daha ayrıncı olarak tespit etmiştir. Bakış Sayısı dışındaki tüm parametreler RF, IG ve GR'ye göre ayrıncı öznitelik olarak belirlenmiştir. Diğer Kişi Yüz ilgi alanından ise Bakış Sayısı ve Ortalama Sabitleme Süresi özellikleri ayrıncı nitelikte görülmektedir (Bakınız Tablo 2).

Nötr veri setinde öznitelik seçim algoritmaları Nötr Yüz özelliklerinin parametrelerinin tamamını, nesne ilgi alanında Sabitleme Sayısı Diğer Kişi Yüz ilgi alanında da Ortalama Sabitleme Süresi ayrıncı öznitelik olarak tespit edilmiştir (Bakınız Tablo 3).

Üzgün veri setinden ise yine Üzgün Yüz ilgi alanında Bakış Sayısı dışındaki tüm özellikler ayrıncı öznitelikler olarak belirlenmiştir. Bunlara ek olarak Diğer Kişi Yüz ilgi alanı özelliklerinde Yönlendirme Süresi, Bekleme Süresi, Sabitleme Süresi (ms) ve Sabitleme Süresinin (%) ayrıncı nitelikte olduğu görülmektedir (Bakınız Tab-

Tablo 2. Mutlu Veri Seti Öznitelikleri

	Mutlu Yüz												Mutlu Beden	Nesne	Dış alan	Diğer Kişi Yüz		Diğer Kişi Beden
	1	2	3	4	5	7	8	9	10	11	12	6				12		
RF	x	x	x	x	x	x	x	x	x	x	x					x		
IG	x	x	x	x	x	x	x	x	x	x	x						x	
GR	x	x	x	x	x	x	x	x	x	x	x						x	
W-NB	x															x		
W-J48										x								
W-KNN				x							x			x		x		

RF = ReliefF; IG = InfoGain; GR = Gain Ratio; W-NB = Wrapper Naive Bayes; W-J48 = Wrapper Decision Tree; W-KNN = Wrapper- K-Nearest Neighbors

Tablo 3. Nötr Veri Seti Öznitelikleri

	Nötr Yüz												Nötr Beden		Nesne	Dış alan	Diğer Kişi Yüz		Diğer Kişi Beden
	1	2	3	4	5	6	7	8	9	10	11	12	6	11	7		7	12	
RF	x	x	x	x		x	x	x	x	x	x			x				x	
IG	x	x	x	x		x	x	x	x	x	x					x		x	
GR	x	x	x	x	x	x	x	x	x	x	x							x	
W-NB			x								x	x		x					
W-J48	x		x			x							x	x					
W-KNN	x		x			x							x	x					

RF = ReliefF; IG = InfoGain; GR = Gain Ratio; W-NB = Wrapper Naive Bayes; W-J48 = Wrapper Decision Tree; W- KNN = Wrapper- K-Nearest Neighbors

Tablo 4. Üzgün Veri Seti Öznitelikleri

	Üzgün Yüz												Üzgün Beden		Nesne	Dış alan	Diğer Kişi Yüz				Diğer Kişi Beden
	1	2	3	4	5	8	9	10	11	12	3	6	7	6	7	4	9	10	11		
RF	x	x	x	x	x	x	x	x	x	x	x		x								
IG	x	x	x	x		x	x	x	x	x							x	x	x		
GR	x	x	x	x	x	x	x	x	x	x				x	x						
W-NB																x					
W-J48											x								x		
W-KNN																					

RF = ReliefF; IG = InfoGain; GR = Gain Ratio; W-NB = Wrapper Naive Bayes; W-J48 = Wrapper Decision Tree; W- KNN = Wrapper- K-Nearest Neighbors

lo 4). Buna göre çocuklar daha çok duygu durumu (mutlu, nötr, üzgün) ifade eden yüz ilgi alanlarında belirgin olarak farklılaşmaktadır.

Bulgular

Çalışma kapsamında oluşturulan mutlu, üzgün ve nötr veri setleri üzerinde belirlenen ayırt edici özniteliklere DT, NB ve KNN algoritmaları uygulanması sonrasında elde edilen sayısal bulgular ve bunlara ilişkin değerlendirmeler aşağıda sunulmuştur.

Mutlu veri seti sonuçları

Mutlu veri seti üzerinde öznitelik seçim yöntemlerinin belirlediği özellikler kullanılarak gerçekleştirilen sınıflandırma sonucunda elde edilen sonuçlar Tablo 5'te verilmiştir.

Tablo 5'te yer alan mutlu veri seti sonuçları incelendiğinde sınıflandırma sonuçlarının ReliefF özniteliklerine göre DT %68.54, NB %63.7, KNN %69.35 doğrulukta, InfoGain özniteliklerine göre DT %73.38, NB %62.9, KNN %57.25 doğrulukta, GainRatio özniteliklerine

göre DT %73.38, NB %62.9, KNN %57.25 doğrulukta, son olarak da Wrapper özniteliklerine göre DT %73.38, NB %69.35 ve KNN %76.61 doğrulukta sınıflandırma başarısı üretmiştir. Öznitelik çıkarım algoritmalarından içinde en yüksek başarı oranının Wrapper algoritması, sınıflandırma algoritmaları içinde ise KNN algoritmasında elde edildiği görülmüştür. Mutlu veri setinde KNN algoritması %76.61 oranında sınıflandırma başarısı ile otizmlili çocukları sınıflandırmıştır.

Nötr veri seti sonuçları

Nötr veri seti üzerinde öznitelik seçim yöntemlerinin belirlediği özellikler kullanılarak gerçekleştirilen sınıflandırma sonucunda elde edilen sonuçlar Tablo 6'da verilmiştir.

Tablo 6'da yer alan nötr veri seti sonuçları incelendiğinde sınıflandırma sonuçlarının ReliefF özniteliklerine göre DT %79.03, NB %78.22, KNN %71.77 doğrulukta, InfoGain özniteliklerine göre DT %75.80, NB %76.61, KNN %75.00 doğrulukta, GainRatio özniteliklerine göre DT %75.80, NB %78.22, KNN %63.70 doğrulukta ve Wrapper özniteliklerine göre sınıflandırma sonuçlarının

Tablo 5. Mutlu Veri Seti Özellik Seçim Yöntemlerine Göre Sınıflandırma Sonuçları

Relief	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)	
DT	ASD	0,655	0,29	0,643	0,655	0,667	68.54	
	TD	0,71	0,345	0,721	0,71			
NG	ASD	0.636	0.362	0.583	0.636	0.714	63.7	
	TD	0.638	0.364	0.688	0.638			
KNN	ASD	0,564	0,203	0,689	0,564	0,648	69.35	
	TD	0,797	0,436	0,696	0,797			
InfoGain	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)	
DT	ASD	0.527	0.101	0.806	0.527	0.664	73.38	
	TD	0.899	0.473	0.705	0.899			
NB	ASD	0.673	0.406	0.569	0.6733	0.715	62.9	
	TD	0.594	0.327	0.695	0.594			
KNN	ASD	0,473	0,348	0,52	0,473	0,589	57.25	
	TD	0,473	0,527	0,608	0,652			
GainRatio	DT	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)
DT	ASD	0.527	0.101	0.806	0.527	0.664	73.38	
	TD	0.899	0.473	0.705	0.899			
NB	ASD	0.673	0.406	0.569	0.673	0.715	62.9	
	TD	0.594	0.327	0.695	0.594			
KNN	ASD	0,473	0,348	0,52	0,473	0,589	57.25	
	TD	0,652	0,527	0,608	0,652			
Wrapper	DT	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)
DT	ASD	0.527	0.101	0.806	0.527	0.664	73.38	
	TD	0.899	0.473	0.705	0.899			
NB	ASD	0.6	0.232	0.673	0.6	0.718	69.35	
	TD	0.738	0.4	0.707	0.768			
KNN	ASD	0.673	0.159	0.771	0.673	0.744	76.61	
	TD	0.841	0.327	0.763	0.841			

DT = Karar Ağacı; NB = Naive Bayes; KNN = K-Nearest Neighbors; OSB = Otizm Spektrum Bozukluğu; TG = Tipik Gelişim.

ise DT %75.00, NB %80.64, KNN %81.45 doğrulukta sınıflandırma başarısı ürettiği bulunmuştur. Öznitelik çıkarım algoritmaları içinden en yüksek düzeyde ayırtıcı özniteliklerin Wrapper algoritması tarafından belirlendiği görülmüştür. Sınıflandırma algoritmaları içinde ise KNN algoritması %81.45'lik sınıflandırma başarısı göstererek otizmliler için TG'li akranlarından ayırmıştır.

Üzgün veri seti sonuçları

Üzgün veri seti üzerinde öznitelik seçim yöntemlerinin belirlediği özellikler kullanılarak gerçekleştirilen sınıflandırma sonucunda elde edilen sonuçlar Tablo 7'de verilmiştir.

Tablo 7'de yer alan üzgün veri seti sonuçları incelendiğinde sınıflandırma sonuçlarının ReliefF özniteliklerine göre DT %68.54, NB %75, KNN %73.38 doğrulukta,

Tablo 6. Nötr Veri Seti Özellik Seçim Yöntemlerine Göre Sınıflandırma Sonuçları

Relief	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)	
DT	ASD	0,845	0,283	0,8	0,845	0,752	79.03	
	TD	0,717	0,155	0,776	0,717			
NG	ASD	0,761	0,189	0,844	0,761	0,836	78.22	
	TD	0,811	0,239	0,717	0,811			
KNN	ASD	0,775	0,358	0,743	0,775	0,767	71.77	
	TD	0,642	0,225	0,68	0,642			
InfoGain	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)	
DT	ASD	0,803	0,302	0,781	0,803	0,761	75.80	
	TD	0,698	0,197	0,725	0,698			
NB	ASD	0,746	0,208	0,828	0,746	0,829	76.61	
	TD	0,792	0,254	0,7	0,792			
KNN	ASD	0,803	0,321	0,77	0,803	0,776	75.00	
	TD	0,679	0,197	0,72	0,679			
GainRatio	DT	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)
DT	ASD	0,803	0,302	0,781	0,803	0,742	75.80	
	TD	0,698	0,197	0,725	0,698			
NB	ASD	0,761	0,189	0,844	0,761	0,835	78.22	
	TD	0,811	0,239	0,717	0,811			
KNN	ASD	0,648	0,377	0,697	0,648	0,714	63.70	
	TD	0,623	0,352	0,569	0,623			
Wrapper	DT	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)
DT	ASD	0,803	0,321	0,77	0,803	0,739	75.00	
	TD	0,679	0,197	0,72	0,679			
NB	ASD	0,803	0,189	0,851	0,803	0,853	80.64	
	TD	0,811	0,197	0,754	0,811			
KNN	ASD	0,831	0,208	0,843	0,831	0,863	81.45	
	TD	0,792	0,169	0,778	0,792			

DT = Karar Ağacı; NB = Naive Bayes; KNN = K-Nearest Neighbors; OSB = Otizm Spektrum Bozukluğu; TG = Tipik Gelişim.

InfoGain özneliklerine göre DT %70.16, NB %74.19, KNN %71.77 doğrulukta, GainRatio özneliklerine göre DT %66.93, NB %74.19, KNN %66.12 doğrulukta ve son olarak da Wrapper özneliklerine göre DT %74.19, NB %76.61 ve KNN %74.19 doğruluk sınıflama başarısı üretmiştiği belirlenmiştir. Uygulanan algoritma sonuçları incelendiğinde en yüksek sınıflama başarısının Wrapper algoritması özneliklerinin kullanımı ile NB algoritması tarafından %76,61'lik sınıflandırma başarısı

ile üretildiği görülmüştür.

Tartışma ve Sonuç

Bu çalışmada otizmlı çocukların insan yüzlerine ve insan yüzünde sergilenen duygusal ifadelere görsel dikkati yöneltmede sergiledikleri sınırlılıklardan yararlanarak otizmlı çocukları TG'li akranlarından ayırmak amaçlanmıştır. Araştırma kapsamında göz izleme verileri

Tablo 7. Üzgün Veri Seti Özellik Seçim Yöntemlerine Göre Sınıflandırma Sonuçları

Relief	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)
DT	ASD	0.732	0.377	0.722	0.732	0.625	68.54
	TD	0.623	0.268	0.635	0.623		
NG	ASD	0.789	0.302	0.778	0.789	0.809	75.00
	TD	0.698	0.211	0.712	0.698		
KNN	ASD	0.803	0.358	0.75	0.803	0.753	73.38
	TD	0.642	0.197	0.708	0.642		
InfoGain	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)
DT	ASD	0,746	0,358	0,736	0,746	0,669	70.16
	TD	0,642	0,254	0,654	0,642		
NB	ASD	0.803	0.34	0.76	0.803	0.797	74.19
	TD	0.66	0.197	0.714	0.66		
KNN	ASD	0.789	0.377	0.737	0.789	0.729	71.77
	TD	0.623	0.211	0.688	0.623		
GainRatio	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)
DT	ASD	0,718	0,396	0,708	0,718	0,651	66.93
	TD	0,604	0,282	0,615	0,604		
NB	ASD	0.803	0.34	0.76	0.803	0.814	74.19
	TD	0.66	0.197	0.714	0.66		
KNN	ASD	0.732	0.434	0.693	0.732	0.706	66.12
	TD	0.566	0.268	0.612	0.566		
Wrapper	Group	Positives	Negatives	Precision	Recall	ROC Area	Accuracy (%)
DT	ASD	0,746	0,264	0,791	0,746	0,737	74.19
	TD	0,736	0,254	0,684	0,736		
NB	ASD	0,803	0,283	0,792	0,803	0,793	76.61
	TD	0,717	0,197	0,731	0,717		
KNN	ASD	0.831	0.377	0.747	0.831	0.742	74.19
	TD	0.623	0.169	0.733	0.623		

DT = Karar Ağacı; NB = Naive Bayes; KNN = K-Nearest Neighbors; OSB = Otizm Spektrum Bozukluğu; TG = Tipik Gelişim.

toplanılmış ve makine öğrenmesi uygulanmıştır. Araştırmanın video materyalleri günlük hayatta sıklıkla karşılaşılabilecek iki yetişkin modelin yer aldığı mutlu, üzgün ve nötr duygu durumlarının yer aldığı setler olarak oluşturulmuştur. Bu videolar üzerinde belirlenen ilgi alanlarına dayalı olarak elde edilen özelliklere öz-nitelik seçim algoritmaları uygulanmıştır. Bu uygulamanın sonucunda oluşturulan ilgi alanlarının otizm tanısı ayırt ediciliği belirlenmiştir. Yapılan analizler sonucun-

da duygu durumlarını yansıtan insan yüzlerinin yüksek düzeyde ayırt edici olduğu belirlenmiştir. Ek olarak ilgi alanlarına dayalı olarak belirlenen özelliklere öz-nitelik seçim algoritmaları uygulanarak yüksek derecede ayırt edici olan öz-nitelikler belirlenmiştir. Her bir duygu durumu için ayırt edici öz-niteliklerin belirlenmesinin ardından belirlenen öz-nitelikler kullanılarak DT, NB ve KNN sınıflandırma algoritmaları uygulanmıştır. Araştırma sonuçlarında özellikle mutlu, nötr ve üzgün duygu

durumunu içeren kişilerin yüz ilgi alanı özelliklerinin baskın olarak ayırt edici olduğu görülmüştür. Buna göre duygu ifadesi barındıran video materyaller otizmliler ve TG'li çocukları sınıflamada etkili olmuştur. Araştırmada %81,45'lik önemli bir sınıflama başarımları yakalanmıştır (bz. Tablo 8.)

Bu araştırma sonucunda ayırt edici öznelikleri belirlemeye yönelik uygulanan makine öğrenme algoritmaları ile duygu durumlarını yansıtan yüz bölgesinin yüksek derece ayırt edici olduğu saptanmıştır. Otizmliler ve TG'li çocuklar mutlu, üzgün nötr duygu durumlarını ifade eden yüz ilgi alanında belirgin olarak farklılaşmışlardır. Nitekim alan yazında TG'li çocukların ilk yıllardan itibaren sosyal etkileşim ortakları ile kurdukları etkileşimler sırasında görsel dikkatlerini insan yüzüne yöneltmeye motive oldukları pek çok araştırma ile gösterilmiştir (Begeer ve ark., 2008; Klin ve ark., 2002; Schultz, 2005; Sterling ve ark., 2008). Bu motivasyonun ise TG'li çocuklarda, etkileşim ortaklarının dışsal ve içsel süreçlerine yönelik bilgiyi işlemlerinde açık olarak yardımcı olduğu kabul edilmektedir (Sterling ve ark., 2008). Otizm alanındaki güçlü bir diğer bulgu ise otizmliler çocukların etkileşim halinde oldukları bireylerin duygusal durumlarını anlamada önemli bir bilgi kaynağı olan insan yüzlerine görsel dikkati yöneltmede sınırlılıklar sergiledikleridir (Chawarska ve Volkmar, 2005; Boucher ve ark., 2000; McPartland ve ark., 2011; Pavlova ve ark., 2017). Nitekim çok sayıda araştırma otizmliler çocukların insan yüzlerinden özellikle de gözlerden uzaklaşan bakış örtüsü sergilediklerini göstermektedir (Bal ve ark., 2010; Corden ve ark., 2008; Dalton ve ark., 2005; Hernandez ark., 2009; Król ve Król, 2019; Yi ve ark., 2013). Söz konusu sınırlılıklar görsel dikkate yönelik güvenilir bilgi elde etmemizi sağlayan göz izleme araştırmaları tarafından da yaygın olarak bildirilmektedir (Chawarska ve ark., 2012; Sterling ve ark., 2008). İnsan yüzlerine yönelmede sergilenen bu motivasyon eksikliğini kaynağı net olarak belirlenemese de daha sonra otizm tanısı alan 6 aylık bebeklerin insan yüzlerine görsel dikkati yönlendirme sınırlılıkları göstermeleri, otizmin atipik gelişimsel seyirinin ilk habercilerinden biri olarak nitelendirilmektedir

(Shic, Macari ve Chawarska, 2014). Bu atipik yönelimin doğal bir sonucu olarak da otizmliler çocuklar, TG'li akranlarının ilk gelişim dönemlerinde sergiledikleri ve sosyal uyumun kritik göstergelerinden kabul edilen insan yüzlerinden duyguları tanımadaki sınırlılıklar sergilemektedirler (Chawarska ve Volkmar, 2005).


Otizmliler bireylerin sosyal biliş için önemli bir uyaran olan insan yüzlerine yönelimde sergiledikleri sınırlılıkları rapor eden çalışmalar ne kadar köklü ise makine öğrenme algoritmaları kullanılarak erken dönem biyobelirteçlerin kullanımına yönelik araştırmalar da bilim insanları için o kadar yeni, heyecan ve umut vericidir. Alan yazında otizmliler çocukların sosyal görsel dikkatte sergilemiş oldukları sınırlılıkların, otizmin varlığına yönelik bir biyobelirteç olarak kullanılabilirliğine yönelik bilimsel kanıtlar her geçen gün artsa da (Özdemir ve ark., 2022), otizm alanındaki makine öğrenimi yayınları hala erken aşamdadır. En erken dönemden itibaren otizm biyobelirteçlerine odaklanan araştırmacılar otizmliler çocukları TG'li akranlarından ayırt edecek biyobelirteçleri belirleyerek klinik değerlendirme ortamlarına edindikleri bilginin pratik uygulamalarını aktarmayı amaçlamaktadırlar. Bu motivasyonun doğal bir sonucu olarak da son dönemlerde makine öğrenme algoritmalarını kullanarak otizmliler çocukları sınıflamayı amaçlayan çalışmaların sayısında ciddi bir artış olmuştur. Nitekim bu araştırmada da %81,45'lik sınıflama başarımları yakalanmıştır (bz. Tablo 8.).

Algoritmalarla ilişkin toplu sonuçlar Tablo 8'de incelendiğinde mutlu veri setinde Wrapper algoritmasının belirlediği özneliklere uygulanan KNN sınıflandırma algoritması %76,61 oranındaki sınıflandırma başarımları ile otizmliler çocukları TG'li akranlarından ayırt ettiği görülmektedir. Nötr veri setinde ise Wrapper öznelik seçim algoritmasının KNN sınıflandırma algoritması ile %81,45'lik sınıflandırma başarımları gösterdiği görülmüştür. Son olarak üzgün veri setinde Wrapper yönteminin tespit ettiği öznelikler ile NB algoritması %76,61'lik sınıflama başarımları ulaşmıştır. Araştırma sonuçları bütüncül olarak değerlendirildiğinde en yüksek başarımları oranına Wrapper yönteminin belirlediği öznelikler ile


Tablo 8. Tüm Veri Setleri Sınıflandırma Başarımları Oranları

	Mutlu Veri seti				Nötr Veri seti				Üzgün Veri seti			
	ReliefF	Info Gain	Gain Ratio	Wrapper	ReliefF	Info Gain	Gain Ratio	Wrapper	ReliefF	Info Gain	Gain Ratio	Wrapper
DT	68,54	73,38	73,38	73,38	79,03	75,8	75,8	75,0	68,54	70,16	66,93	74,19
NB	63,70	62,9	62,9	69,35	78,22	76,61	78,22	80,64	75,00	74,19	74,19	76,61
KNN	69,35	57,25	57,25	76,61	71,77	75,00	63,7	81,45	73,38	71,77	66,12	74,19

DT = Karar Ağacı; NB = Naive Bayes; KNN = K-Nearest Neighbors




Şekil 4. Mutlu veri seti başarımları karşılaştırma



Şekil 5. Nötr veri seti başarımları karşılaştırma

ulaşıldığı görülmektedir. En yüksek sınıflama başarısına ise nötr duygu durumunu yansıtan sette KNN sınıflandırma algoritması ile ulaşılmıştır. KNN sınıflandırma algoritması otizmliler için %81.45'lik bir başarımları ile sınıflandırmıştır (Bkz. Şekil 4., Şekil 5. ve Şekil 6.). Araştırmacı gözlemlerine dayalı olarak duygu durumuna ilişkin videolardaki duyguların sergileniş biçimleri göz önünde bulundurulduğunda en güçlü sergileniş biçiminin üzgün duygu durumunda olduğu gözlemlenmiştir.

Örneğin üzgün duygu durumu videosunda kadın model oldukça güçlü bir şekilde ağlamaktadır. Duyguların sergileniş biçimindeki belirginlik düzeyi açısından mutlu veri seti ikinci sırayı almaktadır. Özetle üzgün ve mutlu duygu durumlarının dikkat çekicilik yüksekliğine karşın en belirgin ayırt ediciliğe nötr veri setinde ulaşılmıştır. Bu durumun ortaya çıkmasında duygusal ifadenin belirginleşmesi ile yüze yönelme motivasyonunun artmasının her iki grupta yer alan çocukların yüze yönelmesinin



Şekil 6. Nötr veri seti başarımlar oranları karşılaştırma

artması ile TG'li çocuklar ile otizmliler arasındaki farkın azalmasına neden olmuş olabileceği değerlendirilmiştir. Bu nedenle otizmliler çocukları TG'li çocuklardan ayırmayı amaçlayan çalışmalarda daha nötr yüzlerin kullanılması insan yüzlerine yönelmede doğal bir motivasyon sergileyen TG'li çocuklar ile otizmliler arasındaki farkın belirgin hale gelmesini sağlayabilir.

Bu araştırmadan elde edilen bulgular daha önce duygu durumlarını yansıtan video veya görsel materyaller kullanılarak gerçekleştirilmiş makine öğrenme çalışmalarının bulgularını güçlendirerek geliştirmiştir (Jiang ve ark., 2019; Kennedy ve Adolphs 2012; Król ve Król, 2019; Liu, Li ve Yi, 2016). Aynı zamanda bu araştırmanın oldukça küçük yaşta olan çocuklarla gerçekleştirilmiş olması daha önce gerçekleştirilmiş olan araştırmalarla karşılaştırıldığında önemli bir avantaj sağlamaktadır. Otizm biyobelirteçlerini belirlemek için göz izleme teknolojilerinin makine öğrenme algoritmaları ile kullanımı umut vaat etmesine rağmen, araştırmalara yöneltilen önemli bir eleştiri çoğu çalışmanın 4 yaşından büyük çocuklarla yapılmış olmasıdır (Liu ve ark., 2016; Wan ve ark., 2019; Yaneva ve ark., 2020; Zhao ve ark., 2021). Zhao ve arkadaşları (2021) ileride gerçekleştirilecek olan çalışmalarda erken müdahale uygulamalarına çocukların erişimlerini en erken dönemde sağlamak için çalışmaların daha küçük çocuklar ile gerçekleştirilmesini önermişlerdir. Nitekim duygusal ifadeler kullanılarak gerçekleştirilen araştırmalar incelendiğinde en küçük katılımcı grubu ile (4-11 yaş aralığında) Liu ve arkadaşlarının (2016) çalıştığı görülmektedir. Söz konusu araştırmanın otizmliler

katılımcılarının kronolojik yaş ortalamaları incelendiğinde ise 7.9 yaş olduğu görülmektedir. Bu araştırmanın katılımcılarının kronolojik yaş ortalamaları ise otizmliler için 28,20 ay, TG'li katılımcılar için 27,07 aydır. Bu bağlamda bu araştırma en erken dönemlerden itibaren otizmden etkilenmiş çocuklarda duygu durumlarına yöneltilen görsel dikkatin bir biyobelirteç olarak kullanılabilirliğini ortaya koymak açısından oldukça önemli bir araştırmadır. Bununla birlikte otizm belirtileri göz önünde bulundurulduğunda sosyal uyaranlara ya da bir diğer ifade ile duygu durumlarına yöneltilen görsel dikkat otizm belirtilerinin sadece bir boyutunu temsil etmektedir. Sadece bir boyut üzerinden tanıya gitmek mümkün olmamakla birlikte bu gibi öncü çalışmaların tanıya yönelik olarak geliştirilecek olan materyallerinin içeriğinin oluşturulması bakımından oldukça önemli olduğu düşünülmektedir.

Otizm ile ilişkili belirtiler en erken dönemlerden itibaren otizmlilerde var olsa da ne yazık ki otizm tanısı ilk belirtilerin ortaya çıkmasından iki üç yıl sonra, genellikle de 4 yaşında konulmaktadır (Dawson 2012; Landa, 2008). Gecikmiş bir tanı ise doğrudan etkili müdahalelerin ertelenmesine neden olmakta ve bu da daha sonra otizmlilerde çocukların prognozunu etkilemektedir (Dawson ve ark., 2012). Günümüzde tüm dünyada otizm tanısı genellikle öznel değerlendirmeleri içeren davranışsal değerlendirmelere dayalı olarak gerçekleştirilmektedir (Mörice ve ark., 2016; Tebartz van Elst ve ark., 2013). Otizm biyobelirteçlerin eksikliği nedeniyle otizm tanısı genellikle, birincil bakım verenlerin bildirimlerindeki

yanlılıkları ve klinik uzmanların otizmi tanılamadaki bilgi ve tecrübe sınırlılıkları, otizmin plato ve gerileme dönemleri gibi karmaşık doğası, mevcut tanı prosedürleri nedeniyle uzun muayenelerin, değerlendirme süreçlerinin gerekliliği ve klinik uzmanlara erişim güçlüğü gibi çeşitli faktörlerden olumsuz etkilenmektedir (Crane ve ark., 2016; Möricke ve ark., 2016; Vabalas ve ark., 2020). İnvaziv olmayan göz izleme teknolojileri ise otizmliler çocuklar veya birincil bakım verenleri ve klinik uzmanlar arasındaki lineer olmayan bilgilerin neden olduğu yanlışlık olasılığını nispeten önleyerek nesnel belirteçleri sunmaktadır (Zwaigenbaum ve Penner, 2018). Otizm biyobelirteçlerinin en erken dönemlerde belirlenmesi otizmliler çocukların erken müdahale hizmetlerine erişimi açısından oldukça önemlidir. Bu nedenle tanılama süreçlerini daha verimli hale getirecek, nesnel ve ölçülebilir otizm biyobelirteçlerinin belirlenmesi oldukça önemlidir (Zhao ve ark., 2021). Bu araştırma kapsamında da özellikle nötr yüzlere yöneltilen görsel dikkatin otizme yönelik bir biyobelirteç olarak kullanılabilirliği gösterilmiştir. Elbette ki elde edilen başarı oranlarının klinik ortamlarda kullanılabilir uygulamalar olarak aktarılması için daha çok sayıda nitelikli çalışmanın gerçekleştirilmesi gerekmektedir. Buna karşın bu tür özgün çalışmalar göz

izleme ve makine öğrenmesi metodolojilerinin geliştirilmesine önemli katkılar sunmaktadır.

Özetle çalışmada farklı duygu durumlarına yöneltilen görsel dikkatin otizmliler çocukları TG’li akranlarından ayırmadaki etkisi makine öğrenme algoritmaları ile incelenmiştir. Bu kapsamda öznel seçim yöntemleri ile videolar üzerinde belirlenen ilgi alanlarının ayrılcılığı ve ilgilenilen alandaki hangi özelliklerin etkili olduğu incelenmiştir. Sonuçlar incelendiğinde özellikle AOI olarak belirlenen mutlu, nötr ve üzgün yüzü temsil eden yüz özelliklerinin baskın olarak ayırıcı olduğu görülmüştür. Bu bulgulara dayalı olarak çalışmanın planlanması aşamasında ön görüldüğü gibi duygu ifadesi barındıran görsel materyaller otizmliler ve TG’li çocukları ayırmada belirleyici olmuştur. Makine öğrenme uygulamaları açısından sınıflandırma başarıları dikkate alındığında Wrapper yöntemi öznel özellikleriyle yapılan sınıflandırmalarda daha yüksek sınıflama başarımları elde edilmiştir. Tespit edilen ayırıcı öznel özelliklere göre yapılan sınıflandırmalarda en yüksek başarımların nötr duygu durumunu yansıtan videolardan KNN algoritmaları ile %81,45’lik oranla üretmişlerdir. Bu başarımları %80,64 başarımlarıyla NB algoritmaları izlemiştir.

Kaynaklar

- Abbasi, B., & Goldenholz, D. M. (2019). Machine learning applications in epilepsy. *Epilepsia*, *60*(10), 2037-2047.
- Adolphs, R. (2002). Neural systems for recognizing emotion. *Current Opinion in Neurobiology*, *12*(2), 169-177.
- Akın-Bülbül, I. A., & Özdemir, S. (2017). Ortak dikkat becerileri ve otizm spektrum bozukluğu. *Ondokuz Mayıs University Journal of Education Faculty*, *36*(1), 195-220.
- Akın-Bülbül, I., & Özdemir, S. (2021). An examination of visual attention: An eye tracking study on motor actions in children with ASD and TD children. *Hacettepe University Journal of Education*, *36*(4), 871-885.
- Albers, C. A., & Grieve, A. J. (2007). Test review: Bayley N. (2006). scales of infant and toddler development-third edition. San Antonio, TX: Harcourt assessment. *Journal of Psychoeducational Assessment*, *25*(2), 180-190.
- American Psychiatric Association. (2013). *Diagnostic and statistical manual of mental disorders* (5th ed.). Arlington, VA: American Psychiatric Publishing.
- Bal, E., Harden, E., Lamb, D., Van Hecke, A. V., Denver, J. W., & Porges, S. W. (2010). Emotion recognition in children with autism spectrum disorders: Relations to eye gaze and autonomic state. *Journal of Autism and Developmental Disorders*, *40*(3), 358-370.
- Barna, J., & Legerstee, M. (2005). Nine-and twelve-month-old infants relate emotions to people's actions. *Cognition & Emotion*, *19*(1), 53-67.
- Bayley, N. (1993). *Bayley Scales of Infant Development—Second Edition*. San Antonio, TX: The Psychological Corporation.
- Bayley, N. (2006). *Bayley Scales of Infant and Toddler Development* (3rd ed.). Harcourt Assessment, San Antonio, TX.
- Begeer, S., Koot, H. M., Rieffe, C., Terwogt, M. M., & Stegge, H. (2008). Emotional competence in children with autism: Diagnostic criteria and empirical evidence. *Developmental Review*, *28*(3), 342-369.
- Beyer, J., & Gammeltoft, L. (2007). *Autism & Play*. London, England: Jessica Kingsley Publishers.
- Black, M. H., Chen, N. T., Iyer, K. K., Lipp, O. V., Bölte, S., Falkmer, M., ... & Girdler, S. (2017). Mechanisms of facial emotion recognition in autism spectrum disorders: Insights from eye tracking and electroencephalography. *Neuroscience & Biobehavioral Reviews*, *80*, 488-515.
- Blijd-Hoogewys, E. M. A., Van Geert, P. L. C., Serra, M., & Minderaa, R. B. (2008). Measuring Theory of Mind in children. Psychometric properties of the ToM storybooks. *Journal of Autism and Developmental Disorders*, *38*(10), 1907-1930.
- Bolón-Canedo, V., Sánchez-Marroño, N., Alonso-Bentanzos, A., Benítez, J. M., & Herrera, F. (2014). A review of microarray datasets and applied feature selection methods. *Information Sciences*, *282*, 111-135.
- Bolte, S., Bartl-Pokorny, K.D., Jonsson, U., Berggren, S., Zhang, D., Kostrzewa, ... & Marschik, P. B. (2016). How can clinicians detect and treat autism early? Methodological trends of technology use in research. *Acta Paediatr*, *105*(2), 137-144.
- Bone, D., Goodwin, M. S., Black, M. P., Lee, C. C., Audhkhasi, K., & Narayanan, S. (2015). Applying machine learning to facilitate autism diagnostics: Pitfalls and promises. *Journal of Autism and Developmental Disorders*, *45*, 1121-1136.
- Boraston, Z., & Blakemore, S. J. (2007). The application of eye-tracking technology in the study of autism. *The Journal of Physiology*, *581*(3), 893-898.
- Boucher, J., Lewis, V., & Collis, G. M. (2000). Voice processing abilities in children with autism, children with specific language impairments, and young typically developing children. *The Journal of Child Psychology and Psychiatry and Allied Disciplines*, *41*(7), 847-857.
- Canavan, S., Chen, M., Chen, S., Valdez, R., Yaeger, M., Lin, H., & Yin, L. (2017). Combining gaze and demographic feature descriptors for autism classification. In *Proceedings of the 2017 IEEE International Conference on Image Processing (ICIP)* (pp. 3750-3754). IEEE.
- Chawarska, K., Macari, S., & Shic, F. (2012). Context modulates attention to social scenes in toddlers with autism. *Journal of Child Psychology and Psychiatry*, *53*(8), 903-913.
- Chawarska, K., & Volkmar, F. R. (2005). Autism in infancy and early childhood. *Handbook of Autism and Pervasive Developmental Disorders*, *1*, 223-246.
- Chevallier, C., Kohls, G., Troiani, V., Brodtkin, E. S., & Schultz, R. T. (2012). The social motivation theory of autism. *Trends in Cognitive Sciences*, *16*(4), 231-239.
- Corden, B., Chilvers, R., & Skuse, D. (2008). Avoiding emotionally arousing stimuli predicts social-perceptual impairment in Asperger's syndrome. *Neuropsychologia*, *46* (1), 137-147.
- Crane, L., Chester, J. W., Goddard, L., Henry, L. A., &

- Hill, E. (2016). Experiences of autism diagnosis: A survey of over 1000 parents in the United Kingdom. *Autism*, 20(2), 153-162.
- Dalton, K. M., Nacewicz, B. M., Johnstone, T., Schaefer, H. S., Gernsbacher, M. A., Goldsmith, H. H., ... & Davidson, R. J. (2005). Gaze fixation and the neural circuitry of face processing in autism. *Nature Neuroscience*, 8(4), 519-526.
- Dawson, G., Jones, E. J., Merkle, K., Venema, K., Lowy, R., Faja, S., ... & Webb, S. J. (2012). Early behavioral intervention is associated with normalized brain activity in young children with autism. *Journal of the American Academy of Child & Adolescent Psychiatry*, 51(11), 1150-1159.
- Dawson, G., Meltzoff, A. N., Osterling, J., Rinaldi, J., & Brown, E. (1998). Children with autism fail to orient to naturally occur social stimuli. *Journal of Autism and Developmental Disorders*, 28(6), 479-485.
- Elsabbagh, M., & Johnson, M. H. (2016). Autism and the social brain: The first-year puzzle. *Biological Psychiatry*, 80(2), 94-99.
- Falck-Ytter, T., Bölte, S., & Gredebäck, G. (2013a). Eye tracking in early autism research. *Journal of Neurodevelopmental Disorders*, 5(1), 1-13.
- Frazier, T. W., Klingemier, E. W., Parikh, S., Speer, L., Strauss, M. S., Eng, C., ... & Youngstrom, E. A. (2018). Development and Validation of objective and quantitative eye-tracking-based measures of autism risk and symptom levels. *Journal of the American Academy of Child & Adolescent Psychiatry*, 57(11), 858-866.
- Happé, F., & Frith, U. (2006). The weak coherence account: detail-focused cognitive style in autism spectrum disorders. *Journal of Autism and Developmental Disorders*, 36(1), 5-25.
- Harms, M. B., Martin, A., & Wallace, G. L. (2010). Facial emotion recognition in autism spectrum disorders: A review of behavioral and neuroimaging studies. *Neuropsychology Review*, 20(3), 290-322.
- Hayhoe, M., & Ballard, D. (2005). Eye movements in natural behavior. *Trends in Cognitive Sciences*, 9(4), 188-194.
- Hernandez, N., Metzger, A., Magné, R., Bonnet-Brilhault, F., Roux, S., Barthelemy, C., & Martineau, J. (2009). Exploration of core features of a human face by healthy and autistic adults analyzed by visual scanning. *Neuropsychologia*, 47(4), 1004-1012.
- Jacob, S., Wolff, J. J., Steinbach, M. S., Doyle, C. B., Kumar, V., & Elison, J. T. (2019). Neurodevelopmental heterogeneity and computational approaches for understanding autism. *Translational Psychiatry*, 9(1), 1-12.
- Jiang, M., Francis, S. M., Srishyla, D., Conelea, C., Zhao, Q., & Jacob, S. (2019). Classifying individuals with ASD through facial emotion recognition and eye-tracking. In *Proceedings of the 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 6063-6068). IEEE.
- Jolliffe, T., & Baron-Cohen, S. (1997). Are people with autism and Asperger syndrome faster than normal on the Embedded Figures Test?. *Journal of Child Psychology and Psychiatry*, 38(5), 527-534.
- Kanner, L. (1943). Autistic Disturbances of Affective Contact. *Nervous Child*, 2.
- Kennedy, D.P., & Adolphs, R. (2012). Perception of emotions from facial expressions in high-functioning adults with autism. *Neuropsychologia*, 50(14), 3313-3319.
- Klin, A., Jones, W., Schultz, R., Volkmar, F., & Cohen, D. (2002). Visual fixation patterns during viewing of naturalistic social situations as predictors of social competence in individuals with autism. *Archives of General Psychiatry*, 59(9), 809-816.
- Król, M., & Król, M. (2019). The world as we know it and the world as it is: Eye-movement patterns reveal decreased use of prior knowledge in individuals with autism. *Autism Research*, 12(9), 1386-1398.
- Landa, R. J. (2008). Diagnosis of autism spectrum disorders in the first 3 years of life. *Nature Clinical Practice Neurology*, 4(3), 138-147.
- Le Meur, O., Nebout, A., Cherel, M., & Etchamendy, E. (2020). From Kanner autism to asperger syndromes, the difficult task to predict where ASD people look at. *IEEE Access*, 8, 162132-162140.
- Lindsay, G. W. (2020). Attention in psychology, neuroscience, and machine learning. *Frontiers in Computational Neuroscience*, 14(29), 1-21.
- Liu, W., Li, M., & Yi, L. (2016). Identifying children with autism spectrum disorder based on their face processing abnormality: A machine learning framework. *Autism Research*, 9(8), 888-898.
- Mastergeorge, A. M., Kahathuduwa, C., & Blume, J. (2021). Eye-tracking in infants and young children at risk for autism spectrum disorder: A systematic review of visual stimuli in experimental paradigms. *Journal of Autism and Developmental Disorders*, 51(8), 2578-2599.
- McPartland, J. C., Webb, S. J., Keehn, B., & Dawson, G. (2011). Patterns of visual attention to faces and objects in autism spectrum disorder. *Journal of Autism and Developmental Disorders*, 41(2), 148-157.
- Mei, J., Desrosiers, C., & Frasnelli, J. (2021). Machine

- learning for the diagnosis of Parkinson's disease: A review of literature. *Frontiers in Aging Neuroscience*, 13, 633752.
- Meltzoff, A. N., & Prinz, W. (Eds.). (2002). *The imitative mind: Development, evolution and brain bases* (Vol. 6). Cambridge University Press.
- Mörcke, E., Buitelaar, J. K., & Rommelse, N. N. (2016). Do we need multiple informants when assessing autistic traits? The degree of report bias on offspring, self, and spouse ratings. *Journal of Autism and Developmental Disorders*, 46(1), 164-175.
- Nogay, H. S., & Adeli, H. (2020). Machine learning (ML) for the diagnosis of autism spectrum disorder (ASD) using brain imaging. *Reviews in the Neurosciences*, 31(8), 825-841.
- Ozdemir, S., Akin-Bulbul, I., Kok, I., & Ozdemir, S. (2022). Development of a visual attention based decision support system for autism spectrum disorder screening. *International Journal of Psychophysiology*, 173(2022), 69-81.
- Ozdemir, S., Akin-Bulbul, I., & Yildiz, E. (2024). Visual attention in joint attention bids: A comparison between toddlers with autism spectrum disorder and typically developing toddlers. *Journal of Autism and Developmental Disorders*, (2024), 1-20.
- Ozonoff, S., Strayer, D. L., McMahon, W. M., & Filloux, F. (1994). Executive function abilities in autism and Tourette syndrome: An information processing approach. *Journal of Child Psychology and Psychiatry*, 35(6), 1015-1032.
- Özdemir, S., Gürel-Selimoğlu, Ö., Töret, G., & Suna, H., E. (2017). Otizm spektrum bozukluğu olan çocuklar ve normal gelişim gösteren çocukların statik ve hareketli materyallerde yüz işlemlerinin karşılaştırılması. *Ankara Üniversitesi Eğitim Bilimleri Fakültesi Özel Eğitim Dergisi*, 18 (2), 271-290.
- Öztürk, D., Aydoğan, S., Kök, İ., Akın Bülbül, I., Özdemir, S., Özdemir, S., & Akay, D. (2024). Linguistic summarization of visual attention and developmental functioning of young children with autism spectrum disorder. *Health Information Science and Systems*, 12(1), 39.
- Pavel, A. M., Rennie, J. M., de Vries, L. S., Blennow, M., Foran, A., Shah, D. K., ... & Boylan, G. B. (2020). A machine-learning algorithm for neonatal seizure recognition: A multicentre, randomised, controlled trial. *The Lancet Child & Adolescent Health*, 4(10), 740-749.
- Palumbo, L., Burnett, H. G., & Jellema, T. (2015). Atypical emotional anticipation in high-functioning autism. *Molecular Autism*, 6(1), 47.
- Pavlova, M. A., Guerreschi, M., Tagliavento, L., Gitti, F., Sokolov, A. N., Fallgatter, A. J., & Fazzi, E. (2017). Social cognition in autism: Face tuning. *Scientific Reports*, 7(1), 2734.
- Pelphrey, K. A., Sasson, N. J., Reznick, J. S., Paul, G., Goldman, B. D., & Piven, J. (2002). Visual scanning of faces in autism. *Journal of Autism and Developmental Disorders*, 32(4), 249-261.
- Pierce, K., Conant, D., Hazin, R., Stoner, R., & Desmond, J. (2011). Preference for geometric patterns early in life as a risk factor for autism. *Archives of General Psychiatry*, 68(1), 101-109.
- Pierce, K., Marinero, S., Hazin, R., McKenna, B., Barnes, C. C., & Malige, A. (2016). Eye tracking reveals abnormal visual preference for geometric images as an early biomarker of an autism spectrum disorder subtype associated with increased symptom severity. *Biological Psychiatry*, 79(8), 657-666.
- Robins, D.L., Casagrande, K., Barton, M., Chen, C.M., Dumont-Mathieu, T., Fein, D. (2013). Validation of the modified checklist for autism in toddlers, revised with follow-up (M-CHAT/R). *Pediatrics*, 133(1), 37-45.
- Schaller, U. M., Biscaldi, M., Burkhardt, A., Fleischhacker, C., Herbert, M., Isringhausen, A., ... & Rauh, R. (2021). ADOS-Eye-Tracking: The archimedean point of view and its absence in Autism Spectrum Conditions. *Frontiers in Psychology*, 12, 497.
- Schultz, R. T. (2005). Developmental deficits in social perception in autism: The role of the amygdala and fusiform face area. *International Journal of Developmental Neuroscience*, 23(2-3), 125-141.
- Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge university press.
- Shic, F., Macari, S., & Chawarska, K. (2014). Speech disturbs face scanning in 6-month-old infants who develop autism spectrum disorder. *Biological Psychiatry*, 75(3), 231-237.
- Shic, F., Naples, A. J., Barney, E. C., Chang, S. A., Li, B., McAllister, T., ... & McPartland, J. C. (2022). The autism biomarkers consortium for clinical trials: evaluation of a battery of candidate eye-tracking biomarkers for use in autism clinical trials. *Molecular Autism*, 13(1), 1-17.
- Stahl, D., Pickles, A., Elsabbagh, M., Johnson, M. H., & BASIS Team. (2012). Novel machine learning methods for ERP analysis: a validation from research on infants at risk for autism. *Developmental Neuropsychology*, 37(3), 274-298.
- Sterling, L., Dawson, G., Webb, S., Murias, M., Munson, J., Panagiotides, H., & Aylward, E. (2008). The role of face familiarity in eye tracking of faces by individuals with autism spectrum disorders.

- Journal of Autism and Developmental Disorders*, 38(9), 1666-1675.
- T.C. Sağlık Bakanlığı, Tohum Otizm Vakfı. Türkiye’de otizm spektrum bozuklukları ve özel eğitim. Available from: <https://www.tohumotizm.org.tr/wp-content/uploads/2018/06/Saglik-Bakanligi-Otizm-Platformu-Tarama-Projesi-Raporu.pdf> (Accessed 2022, May 5).
- Tebartz van Elst, L., Pick, M., Biscaldi, M., Fangmeier, T., & Riedel, A. (2013). High-functioning autism spectrum disorder as a basic disorder in adult psychiatry and psychotherapy: Psychopathological presentation, clinical relevance and therapeutic concepts. *European Archives of Psychiatry and Clinical Neuroscience*, 263(2), 189-196.
- Tsang, V. (2018). Eye-tracking study on facial emotion recognition tasks in individuals with high-functioning autism spectrum disorders. *Autism*, 22(2), 161-170.
- Uljarevic, M., & Hamilton, A. (2013). Recognition of emotions in autism: A formal meta-analysis. *Journal of Autism and Developmental Disorders*, 43(7), 1517-1526.
- Vabalas, A., Gowen, E., Poliakoff, E., & Casson, A. J. (2020). Applying machine learning to kinematic and eye movement features of a movement imitation task to predict autism diagnosis. *Scientific Reports*, 10(1), 1-13.
- Van Rijn, S., Urbanus, E., & Swaab, H. (2019). Eyetracking measures of social attention in young children: How gaze patterns translate to real-life social behaviors. *Social Development*, 28(3), 564-580.
- Wang, A. T., Dapretto, M., Hariri, A. R., Sigman, M., & Bookheimer, S. Y. (2004). Neural correlates of facial affect processing in children and adolescents with autism spectrum disorder. *Journal of the American Academy of Child & Adolescent Psychiatry*, 43(4), 481-490.
- Wan, G., Kong, X., Sun, B., Yu, S., Tu, Y., Park, J., ... & Kong, J. (2019). Applying eye tracking to identify autism spectrum disorder in children. *Journal of Autism and Developmental Disorders*, 49(1), 209-215.
- Whitaker, L. R., Simpson, A., & Roberson, D. (2017). Brief report: Is impaired classification of subtle facial expressions in children with autism spectrum disorders related to atypical emotion category boundaries? *Journal of Autism and Developmental Disorders*, 47(8), 2628-2634.
- Widen, S. C., & Russell, J. A. (2003). A closer look at preschoolers’ freely produced labels for facial expressions. *Developmental Psychology*, 39(1), 114.
- Wieckowski, A. T., Flynn, L. T., Richey, J. A., Gracanic, D., & White, S. W. (2020). Measuring change in facial emotion recognition in individuals with autism spectrum disorder: A systematic review. *Autism*, 24(7), 1607-1628.
- Wright, B., Clarke, N., Jordan, J. O., Young, A. W., Clarke, P., Miles, J., ... & Williams, C. (2008). Emotion recognition in faces and the use of visual context Vo in young people with high-functioning autism spectrum disorders. *Autism*, 12(6), 607-626.
- Yaneva, V., Eraslan, S., Yesilada, Y., & Mitkov, R. (2020). Detecting high-functioning autism in adults using eye tracking and machine learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(6), 1254-1261.
- Yeung, M. K., & Chan, A. S. (2020). Executive function, motivation, and emotion recognition in high-functioning autism spectrum disorder. *Research in Developmental Disabilities*, 105, 103730.
- Yi, L., Fan, Y., Quinn, P. C., Feng, C., Huang, D., Li, J., ... & Lee, K. (2013). Abnormality in face scanning by children with autism spectrum disorder is limited to the eye region: Evidence from multi-method analyses of eye tracking data. *Journal of Vision*, 13(10), 1-13.
- Yirmiya, N., Erel, O., Shaked, M., & Solomonica-Levi, D. (1998). Meta-analyses comparing theory of mind abilities of individuals with autism, individuals with mental retardation, and normally developing individuals. *Psychological Bulletin*, 124(3), 283-307.
- Zhao, Z., Zhang, X., Li, W., Hu, X., Qu, X., Cao, X., ... & Lu, J. (2019). Applying machine learning to identify autism with restricted kinematic features. *IEEE Access*, 7, 157614-157622.
- Zhao, Z., Zhu, Z., Zhang, X., Tang, H., Xing, J., Hu, X., ... & Qu, X. (2021). Atypical head movement during face-to-face interaction in children with autism spectrum disorder. *Autism Research*, 14(6), 1197-1208.
- Zwaigenbaum, L., & Penner, M. (2018). Autism spectrum disorder: Advances in diagnosis and evaluation. *British Medical Journal*, 361, k1674.

Teşekkür

Bu çalışma TÜBİTAK 115K459 nolu proje kapsamında yürütülmüştür. Araştırmanın yürütülmesi için finansal destek sunan TÜBİTAK’a, çalışmaya katılım sağlayan tüm çocuk ve ebeveynlerimize teşekkür ederiz.

Summary

Machine Learning in Classification of Autism Spectrum Disorder: Visual Attention Directed to the Emotional States

Işık Akin-Bülbül¹

Hacettepe University

İbrahim Kök²

Ankara University

Selda Özdemir³

Hacettepe University

Facial emotion recognition, a component of social cognition, is a fundamental skill for effective social communication and interaction (Adolphs, 2002; Wang et al., 2004). The development of social cognition starts early in typically developing (TD) infants, and infants have a strong visual preference for people and their faces from the earliest developmental periods compared to other visual stimuli. In addition, babies can distinguish qualitative differences in the emotions displayed on people's faces from an early age (Begeer, Koot, Rieffe, Terwogt, and Stegge, 2008; Schultz, 2005). When TD babies focus on the internal features of a face, they have a strong preference for the eyes area, and TD babies receive social information about external events (e.g., speech) and internal processes (e.g., emotions) from the faces of their communication partners (Sterling et al., 2008).

Children with autism are characterized by diminished eye contact and diminished attention to human faces since the date they were first described by Kanner (1943) in the literature. Currently, similar diagnostic criteria to the first autism definition have been utilized in autism diagnosis. Diagnosing autism and improving observation protocols related to early markers of autism has been a difficult task that requires consistent effort and time (Crane et al., 2016; Vabalas et al., 2020; Zhao et al., 2021). Although the physiological and clinical features accompanying autism cannot be determined based on behavioral observation from the earliest period, many research findings showed that some early markers are highly effective in determining autism (Frazier et al., 2018; Schaller, et al., 2021). Therefore, more objective, accessible, and faster screening methods are needed, especially in young children, to improve the early autism screenings (Bolte et al., 2016; Elsabbagh and Johnson, 2016). The physiological evidence gathered from visual

attention parameters of children with autism can be used as promising biomarkers in autism screening practices. In various current studies, eye tracking and machine learning algorithms were successfully applied to the classification of individuals with autism (Canavan et al., 2017; Kennedy ve Adolphs, 2012; Liu, Li, and Yi, 2016; Özdemir, Akin-Bülbül, Kök, Özdemir, 2022). An accurate algorithm that combines visual attention patterns directed to social stimuli can provide a more reliable and faster screening by gathering physiological data that are not possible with the human eye (Canavan et al., 2017). Within the scope of this research, we plan to take the above literature discussion one step further. We propose using machine learning algorithms to investigate the visual attention data gathered watching emotions to distinguish children with autism from their TD peers. Thus, this study examines the predictive power of eye-tracking data collected from videos reflecting three basic emotions to explore the usability of atypical visual attentional orientations of children with autism as a biomarker.

Method

Machine Learning

Machine learning (ML) is a sub-field of artificial intelligence that focuses on learning from data, identifying patterns, classifying, clustering, and predicting by imitating the way humans learn. ML uses a variety of learning approaches to deal with complex problems. These approaches are basically supervised learning, unsupervised learning and reinforcement learning. Supervised learning is used in solving classification problems using labeled datasets, while unsupervised learning is used in clustering problems with unlabeled datasets. On the other hand, reinforcement learning learns by interacting

Table 1. Participant demographic and clinical characteristics

Variable	Autism group (n = 54, range 18–36)	TD group (n = 70, range 18–36)	<i>p</i>
Age in months	28,20	27,07	0,87
Male/Female	10/44	33/37	0,00*
Bayley Cog. Score	77,04	100,00	0,00*
Bayley Lang. Score	67,69	99,89	0,00*
Bayley Motor Score	67,89	97,81	0,00*
M-Chat	No risk	-	-
Class	Medium risk	7	-
	High risk	47	-

Note: * $p < 0.05$. TD = Typically Developing; M-Chat = Modified Checklist for Autism in Toddlers.

with the environment without data at the beginning of the process (Shalev-Shwartz ve Ben-David, 2014).

Participants

This study was carried out within the scope of an international research project funded by the Scientific and Technological Research Council of Turkey (#115K459). The study participants consisted of children with autism with a mean age of 28.20 and TD children with a mean age of 27.07. Based on the DSM-V diagnostic criteria, children with autism were diagnosed by the child psychiatry clinics of universities or public hospitals. See Table 1 for participant characteristics of children with autism and TD children.

Instruments

Early Childhood Autism Screening Scale M-C-HAT-Revised

The Early Childhood Autism Screening Scale (M-C-HAT-F), developed to identify autism symptoms in early childhood, was developed by Robins, Fein, Barton, and Green (2021). M-CHAT-F is used to evaluate whether a child is suspected of autism. The current study used the scale to display the autism severity levels of children with autism.

Bayley-III Developmental Scale for Infants and Young Children

Bayley-III Infants and Toddlers Developmental Scale, which has high test-retest reliability and internal consistency scores, was developed to assess the developmental functioning levels of infants and children between 1 and 42 months (Bayley, 2006). Bayley-III was used in the current study to determine the developmental levels of the participants in the Language, Cognitive, Motor, So-

cial-Emotional, and Adaptive Subscales.

The Emotional States and Identified Area of Interests

The emotional states video set consists of videos that reflect male and female models' happy, neutral, and sad moods. There are two videos for each emotional state in the dataset, and each video lasts approximately 10 seconds. Six areas of interest were determined in all sets, namely, the face reflecting the mood, the face of the other person, the bodies of the persons, the object used, and the external space (see Figures 1, 2, and 3.).

Eye-Tracking and Procedure

In this study, the data gathering procedure used the SMI-Red 250 eye tracker fixed under a 17-inch LCD monitor with 1680×1050 pixels resolution. The participants sat alone in front of a computer screen, either on their preferred parent's lap or in an adjustable-height chair. A five-point calibration phase was completed with a crying baby animation on the screen. Next, the data sets were tracked in random order.

The participants' social attention parameters were recorded and stored using the Experiment Center™ 3.6 software. In the analysis of the recorded data, the SMI BeGaze™ (The Behavioral and Gaze Analysis) software was utilized. The eye movement sampling rate of the SMI-Red250 eye tracker was 250 Hertz (Hz).

Analysis

Monitoring parameters for three emotional states were recorded using an eye-tracking device, and study data were analyzed by implementing data mining methods. 12 features were extracted from each area of interest in the emotional states dataset. These attributes are numbered as follows. 1: [Net Dwell Time, ms], 2: [Dwell Time ms], 3: [Glance Duration, ms], 4: [Diversion Duration, ms], 5: [First Fixation Duration, ms], 6: [Glances

Table 2. Happy dataset features

	Happy-Face												Happy-Body	Object	Outside	Other Person Face				Other Person Body
	1	2	3	4	5	7	8	9	10	11	12	7		10	6	12				
RF	x	x	x	x	x	x	x	x	x	x	x					x				
IG	x	x	x	x	x	x	x	x	x	x	x							x		
GR	x	x	x	x	x	x	x	x	x	x	x							x		
W-NB	x															x				
W-J48										x										
W-KNN				x							x	x		x	x					

RF = ReliefF; IG = InfoGain; GR = Gain Ratio; W-NB = Wrapper Naive Bayes; W-J48 = Wrapper Decision Tree; W- KNN = Wrapper- K-Nearest Neighbors

Table 3. Neutral dataset features

	Neutral Face												Neutral Body		Object	Outside	Other Person Face			Other Person Body
	1	2	3	4	5	6	7	8	9	10	11	12	6	11	7		7	12		
RF	x	x	x	x	x	x	x	x	x	x	x	x			x					x
IG	x	x	x	x	x	x	x	x	x	x	x	x						x		x
GR	x	x	x	x	x	x	x	x	x	x	x	x								x
W-NB			x						x				x		x					
W-J48	x		x									x		x	x					
W-KNN	x		x									x		x	x					

RF = ReliefF; IG = InfoGain; GR = Gain Ratio; W-NB = Wrapper Naive Bayes; W-J48 = Wrapper Decision Tree; W- KNN = Wrapper- K-Nearest Neighbors

Table 4. Sad dataset features

	Sad Face												Sad Body		Object	Outside	Other Person Face				Other Person Body
	1	2	3	4	5	8	9	10	11	12	3	6	7	6	7	4	9	10	11		
RF	x	x	x	x	x	x	x	x	x	x	x		x								
IG	x	x	x	x	x	x	x	x	x	x	x								x	x	x
GR	x	x	x	x	x	x	x	x	x	x	x					x	x				
W-NB																					x
W-J48												x									
W-KNN																					x

RF = ReliefF; IG = InfoGain; GR = Gain Ratio; W-NB = Wrapper Naive Bayes; W-J48 = Wrapper Decision Tree; W- KNN = Wrapper- K-Nearest Neighbors

Count], 7: [Fixation Count], 8: [Net Dwell Time, %], 9: [Dwell Time, %], 10: [Fixation Time, ms], 11: [Fixation Time, %], and 12: [Average Fixation Duration, ms]. (See Appendix-1 for definitions of specified attributes).

Datasets with a total of 72 features were created for the six identified areas of interest. ReliefF, Information

Gain, Gain Ratio, and Wrapper feature selection methods were applied to the features determined for each dataset set. The attributes selected for the happy, neutral, and sad datasets are presented in Table 2, Table 3, and Table 4, respectively.

Table 5. Classification success rates for all datasets

	Happy Dataset				Neutral Dataset				Sad Dataset			
	RelieFF	Info Gain	Gain Ratio	Wrapper	RelieFF	Info Gain	Gain Ratio	Wrapper	RelieFF	Info Gain	Gain Ratio	Wrapper
DT	68,54	73,38	73,38	73,38	79,03	75,8	75,8	75,0	68,54	70,16	66,93	74,19
NB	63,70	62,9	62,9	69,35	78,22	76,61	78,22	80,64	75,00	74,19	74,19	76,61
KNN	69,35	57,25	57,25	76,61	71,77	75,00	63,7	81,45	73,38	71,77	66,12	74,19

DT = Decision Tree; NB = Naïve Bayes; KNN = K-Nearest Neighbour

Results

The feature selection methods applied to the current study features obtained based on the area of interest were determined as highly distinctive in the faces of the model reflecting the emotional states. When the machine learning algorithm results were examined, the KNN classification algorithm applied to the features determined by the Wrapper method in the happy data set distinguished children with autism from their peers with TG with a classification success of 76.61%. The Wrapper feature selection method showed a classification success of 81.45% with the KNN classification algorithm from the neutral mood data set. See Table 5 for the aggregated results of machine learning algorithms.

Discussion and Conclusion

This study's results showed that the faces of the models, which reflect the emotional states, were highly distinctive when machine learning algorithms were applied to identify the distinctive features. Children with autism and TD differed significantly in the facial area of interest, expressing happy and sad neutral moods. Many studies in the literature showed that children with TD are highly motivated to direct their visual attention to human faces during social interactions with an interaction partner from the earliest periods of development. Another well-established finding in the autism literature is that children with autism exhibit diminished visual attention to faces, which is an essential source of information in understanding the other person's emotional state. Although the source of this limited motivation toward human faces cannot be clearly identified in the current literature, studies report that diminished visual attention to human faces was observed in infants younger than six months. This early marker was considered one of the first signs of the atypical developmental course of autism (Shic, Macari, and Chawarska, 2014). When the current study findings are evaluated as a whole, we observed that the highest success rate was achieved with the features determined by the Wrapper met-

hod. The highest classification success was performed with the KNN classification algorithm in the set, reflecting the neutral emotional state. The KNN classification algorithm classified children with autism with a success rate of 81.45%. Considering how the emotions displayed in the videos related to the emotional states, it is possible to say that the strongest expression was the sad emotion. For example, the female model cried quite strongly in the video, which reflects a sad mood. The happy data set takes second place in terms of the clarity of how emotions are displayed.

On the other hand, the most significant differentiation between groups was reached in the neutral data set. The clarification of the emotional expressions may have increased the motivation of children with autism to direct visual attention to the face area, resulting in a decrease in the difference between children with autism and TD children. Therefore, the use of neutral faces in future studies aiming to distinguish children with autism from TD children can better identify children with autism from TD children. The current study was designed based on a growing machine learning literature that was previously carried out using video and/or visual material that reflects emotional states (Jiang et al., 2019; Kennedy & Adolphs, 2012; Król & Król, 2019; Liu, Li, and Yi, 2016). At the same time, the fact that this research was conducted with very young children provides a strong advantage compared to previous study results. Although the use of eye-tracking technologies with machine learning algorithms to identify autism biomarkers is promising, one criticism directed at studies is that most studies were conducted with children older than four years old (Liu et al., 2016; Yaneva et al., 2020; Wan et al., 2019; Zhao et al., 2021). The mean chronological age of the participants of this study is 28.20 for children with autism and 27.07 for TD participants. This is a critical study in demonstrating the usability of visual attention directed to emotional states as a biomarker in children affected by moderate and severe autism symptoms from the earliest developmental stages. Although autism -related symptoms are present in children with autism from the earliest

stages, unfortunately, the diagnosis of autism is usually made two to three years after the first symptoms appear, usually at the age of 4 (Dawson, 2012). On the other hand, a late diagnosis causes a delay in the early intervention implementations, which subsequently affects the prognosis of the diagnosis (Dawson et al., 2012). Overall, the study findings indicated the KNN algorithms produced the highest performance rate of 81.45%, when children watched the videos that reflect the neutral emotional state. Finally, our study results suggested that eye tracking data of visual attention directed towards neutral faces can be used as a biomarker for autism screening in young children.

Ek 1. Göz İzleme Parametreleri ve Tanımları

Parametre/Parameter	Birim /Unit	Tanım	Description
Sabitlenme Sayısı Fixation Count	[sayı] [count]	Denemede ki sabitleme sayısı.	Number of fixations in the trial.
Net Bekleme Süresi Net Dwell Time	[ms]	AOI'ye isabet eden tüm bakış veri örnekleri için örnek sürelerinin toplamı.	Sum of sample durations for all gaze data samples that hit the AOI.
Bekleme Süresi Dwell Time	[ms]	Toplam (seçilen tüm katılımcılar için bir AOI içindeki tüm sabitlemeler ve sakkadlar).	Sum (all fixations and saccades within an AOI for all selected participants).
Bakış Süresi Glance Duration	[ms]	Nesneye girmek için sakkad süresi + gözler AOI'den ayrılmaya başlamadan önce tüm sabitleme süreleri ve sakkad sürelerinin toplamı = bekleme süresi + AOI'ye giren sakkad süresi.	Saccade duration for entering the object + sum of all fixation durations and saccade durations before the eyes begin to leave the AOI = dwell time + duration of saccade entering AOI.
Yönlendirme Süresi Diversion Duration	[ms]	Tüm katılımcıların sapma süresinin toplamının katılımcı sayısına bölümü.	Sum of diversion duration of all participants divided by number of the participants.
İlk Sabitleme Süresi First Fixation Duration	[ms]	Bir AOI'daki ilk sabitleme süresi.	The duration of the first fixation in an AOI.
Bakış Sayısı Glances Count	[sayı] [count]	Belirli bir süre içinde bir hedefe bakış sayısı	Number of glances to a target within a certain period
Net Bekleme Süresi Net Dwell Time	[%]	Net bekleme süresi (ms) / (bitiş zamanı - başlangıç zamanı)	Net dwell time (ms) / (end time - start time)
Bekleme Süresi Dwell Time	[%]	Bekleme süresi ortalaması % = bekleme süresi ortalaması * 100 / (geçerli zaman - başlangıç zamanı)	Dwell time average % = dwell time average * 100 / (current time - start time)
Sabitlenme Süresi Fixation Time	[ms]	AOI içindeki sabitleme sürelerinin toplamı	Sum of the fixation durations inside the AOI
Sabitlenme Süresi Fixation Time	[%]	Sabitlenme süresi (ms) / (bitiş zamanı - başlangıç zamanı)	Fixation time (ms) / (end time - start time)
Ortalama Sabitleme Süresi Average Fixation Duration	[ms]	Bir AOI içindeki sabitleme sayısına bölünen sabitleme sürelerinin toplamı.	The sum of fixation times divided by number of fixations inside an AOI.

Not: Tablo 26.04.2022 tarihinde <http://www.humre.vu.lt/files/doc/Instrukcijos/SMI/BeGaze2.pdf> adresinden erişilen SMI BeGaze Manual (Versiyon 3.7) isimli kullanım kitapçığından yararlanarak oluşturulmuştur. Daha ayrıntılı açıklamalar için kullanım kitapçığına bakınız.