



## Göz Özelliklerinin UKSB - PSO Modeli kullanılarak Otizm Sınıflandırılması

*Autism Classification of Eye Features using the LSTM-PSO Model*Dilber ÇETİNTAŞ<sup>1\*</sup>, Taner TUNCER<sup>2</sup><sup>1</sup> Bilgi İşlem Daire Başkanlığı, Fırat Üniversitesi, [dcetintas@firat.edu.tr](mailto:dcetintas@firat.edu.tr)ORCID: <https://orcid.org/0000-0003-0710-2280><sup>2</sup> Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, [ttuncer@firat.edu.tr](mailto:ttuncer@firat.edu.tr)ORCID: <https://orcid.org/0000-0003-0526-4526>

## MAKALE BİLGİLERİ

## Makale Geçmişi:

Geliş 14 Temmuz 2023  
Revizyon 11 Kasım 2023  
Kabul 2 Aralık 2023  
Online 31 Aralık 2023

## Anahtar Kelimeler:

Göz hareketleri, UKSB, PSO,  
Pencere Boyutu

## ÖZ

Otizm, birçok biyobelirteci olan karmaşık bir rahatsızlıktır. Bu karmaşık rahatsızlığı tanımlamak ve ayırt edebilmek, birden fazla biyolojik özelliği kullanarak mümkün olabilmektedir. Bu özelliklerden biri de göz hareketleridir. Çalışma, kullanıcılara özgü gözbebeği boyutu, göz pozisyonları (X-Y koordinatları), ilgi alanının noktaları, iris yarıçapı parametrelerinden oluşan dizileri kullanarak otizm spektrum bozukluğu olan (OSB) ve otizm spektrum bozukluğu olmayan (TS) bireyleri UKSB ağı ile otomatik olarak sınıflandırmayı amaçlamaktadır. Klinik bulgular ve uzman görüşüyle tanısı belirlenen bu rahatsızlık günlük bilgisayar etkileşimiyle, göz hareketlerinin takibi sonucunda belirlenebilecektir. Böylelikle hem erken teşhis ile zaman kazancı sağlanacak hem de tedavi süreci hızlandırılmış olacaktır. Bu doğrultuda ilk adım olarak, herbir hareketin tüm parametreleri ayrı bir dizi olarak alınır. Alınan diziler ikinci basamakta UKSB ağına işlenir. İşleme aşamasında pencere boyutunun doğru seçilmesi, sonucu etkileyen en önemli faktörlerden biridir. Bu doğrultuda modelde pencere boyutunun optimum seçilebilmesi için PSO (Parçacık Sürü Optimizasyonu) algoritması kullanılır. UKSB-PSO hibrit modeli kullanılarak iki senaryo gerçekleştirilir. Bu senaryolardan biri tüm özellikleri içerirken, senaryo 2'de sadece gözbebeği boyutu ve ilgi alanı özellikleri mevcuttur. DVM (Destek Vektör Makinesi) sınıflandırıcısı ile başarı oranı senaryo 2'de %98,64 olarak maximum ölçülmüştür. Sonuçlar, göz izleme verileri kullanılarak otizmin UKSB ile sınıflandırılmasının mümkün olduğunu ve bu yöntemin otizm tanısı ve tedavisi için potansiyel olarak faydalı olabileceğini göstermektedir.

## ARTICLE INFO

## Article history:

Received 14 July 2023  
Received in revised form 11  
November 2023  
Accepted 2 December 2023  
Available online 31 December 2023

## Keywords:

Eye-Tracking, LSTM, PSO, Window  
Size

## ABSTRACT

Autism is a complex disorder with many biomarkers. Identifying and differentiating this complex disorder is possible by using more than one biological feature. One of these features is eye movements. The study aims to automatically classify individuals with autism spectrum disorder (ASD) and without autism spectrum disorder (TS) with the LSTM network, using user-specific sequences consisting of pupil size, eye positions (X-Y coordinates), points of interest, iris radius parameters. This disorder, which is diagnosed based on clinical findings and expert opinion, can be determined as a result of daily computer interaction and monitoring eye movements. In this way, early diagnosis will save time and the treatment process will be accelerated. As a first step in this direction, all parameters of each movement are taken as a separate set. The received sequences are processed in the LSTM network in the second step. Choosing the correct window size during the processing stage is one of the most important factors affecting the result. Accordingly, PSO (Particle Swarm Optimization) algorithm is used to select the optimum window size in the model. Two scenarios are implemented using the LSTM-PSO hybrid model. While one of these scenarios includes all features, scenario 2 only has pupil size and area of interest features. With the SVM (Support Vector Machine) classifier, the success rate was measured to be maximum 98.64% in scenario 2. The results show that it is possible to classify autism with LSTM using eye-tracking data and that this method may be potentially useful for autism diagnosis and treatment.

Doi: 10.24012/dumf.1327654

\* Sorumlu Yazar

## Giriş

Otizm spektrum bozukluğu, hastaların genellikle sosyal iletişim, etkileşim ve hayal gücü eksikliklerine sahip olduğu en yaygın nörolojik bozukluklardan biridir [1]. Bununla birlikte, OSB'nin temel bilişsel eksikliği henüz bulunamamıştır ve bozukluğun temel semptomlarına yönelik etkili tıbbi tedaviler hala eksiktir [2]. Etiyopatogenezi hala belirsizdir, ancak genellikle genetik kusurlar, beyin iltihabı ve hamilelik sırasındaki anormal durumlar gibi biyolojik faktörlerle ilişkili olduğuna inanılmaktadır.

OSB teşhisi konan çocuk sayısındaki keskin artış, bu popülasyon hakkında daha fazla araştırma yapılması gerekliliğini vurgulamaktadır. Özellikle doğru klinik yöntemler gerekmektedir. Şu anda, otizm rahatsızlığının tanısı için otizm davranışı kontrol listesi [3] ve Çocukluk Otizmi Derecelendirme Ölçeği (CARS) kullanılmaktadır [4]. Bunlar dışında Otizm Spektrum Bozukluğu olan bireylerin, genellikle yüz ifadesi, atipik gözlerle bakma tepkisi gibi farklı sözel olmayan iletişim ipuçlarında ortaya çıkan, önemli ölçüde sınırlı sosyal etkileşim yeteneklerine sahip oldukları bilinmektedir [5]. Bu durum geleneksel yöntem ve müdahaleler dışında alternatif daha az maliyetli bir yol arayışını doğurmuştur. Biyolojik tepkilerin takibi ile teşhis yoluna gidilmiştir. Elektroensefalograf (EEG), VR(Virtual Reality), göz izleme tabanlı teknolojiler OSB'li bireyler için daha nesnel tanı araçları olmuştur. Elektroensefalografi, beyin aktivitesini yüksek zamansal çözünürlükle analiz etmeyi sağlarken göz izleme teknolojileriyle bilinçdışı oluşan verilerin alınıp değerlendirilmesi sağlanır. Biyometrik ölçümlerden yararlanmak, uzman puanlama sürecinde yanlılığı ve öznelliği önlemek açısından da avantajlıdır [6].

Otistik çocukları belirlemek için EEG ve göz verilerinin birleştirilerek kullanıldığı bir çalışmada, DVM sınıflandırıcıları ile birleştirilmiş minimum fazlalık maksimum alaka (MRMR) öznelik seçim yöntemi tercih edilmiştir. 32 özellik seçildiğinde %85.44'e başarıya ulaşılmıştır [7]. Wang'ın inceleme araştırması, OSB'nin dinlenme durumu EEG'sinin elektrofizyolojik güç değişikliklerinin U şeklinde bir profil çizdiğini göstermiştir. Düşük frekans ve yüksek frekans bantlarında aşırı güç ve alfa bandında yetersiz güç olduğu saptanmıştır [8]. Kang ve arkadaşları, OSB'li çocukların sosyal uyaranlar karşısındaki dikkat tepkilerinin normal çocuklardan farklı olduğunu saptamıştır. Normal yetişkinler, yüzlere bakarken, gözlerle aynı zamanda burun ve ağıza da odaklanarak belirli bir bakış kalıbı gösterirken OSB'li bireyler daha dağınık bir bakış rotası göstermişlerdir [9].

Sheikhani [10], nicel EEG'yi (qEEG) değerlendirmek için spektrogram ve tutarlılık değerlerini kullanmış OSB'li çocukların sol beyin yarıküresinde önemli ölçüde daha düşük spektrogram kriter değerlerine sahip olduğunu göstermiştir. Ham verilerden tanı koyma alanında ilk girişim olan çalışmada 136 OSB çocuk ve 136 TS çocuktan alınan 272 video içeren veriseti üzerindeki deneysel sonuçlar, UKSB ağının geleneksel makine öğrenme yöntemlerinden, örneğin Destek Vektör Makinesinden daha iyi performans gösterdiği kanıtlanmıştır. %92,6 oranında doğruluk elde edilmiştir.

Göz verileri, araç verileri ve çevresel veriler birleştirilerek sürücülerin dikkatinin araştırıldığı çalışmada evrişimli sinir

ağları (CNN) ve uzun kısa süreli bellek (UKSB) hibrit modeli önerilmiş %95,5'lik bir doğrulukla en son modellerden daha iyi performans gösterdiği bulunmuştur [11]. Kang ve arkadaşları tarafından güç spektrumu analizi, çift tutarlılık, entropi ve tutarlılık yöntemleri dahil olmak üzere mümkün olduğu kadar çok özelliği ayıklamak için EEG sinyaline dayalı çok özellikli birleştirme yöntemi kullanılmış, mRMR algoritması kullanılarak seçim yapılmıştır. Sonuçta DVM-doğrusal sınıflandırıcı kullanılarak dokuz özellik seçildiğinde doğruluğun %91,38'e kadar çıktığı gösterilmiştir [12].

Yavaş göz hareketleri (SEM'ler) uykuya başlama dönemini gösterir. SEM'leri algılamak için, fizyolojik sinyallerdeki zamansal bilgiler ve çok modlu bilgilerle başa çıkmak için iki modlu UKSB ağı kullanılır. Ayırt edici bilgileri genişletmek için, iki yatay elektrookülogram (EOG) kanalından gelen sinyallerin toplamı olan yeni bir yatay toplam (HSUM) sinyali tanımlanır. Sinyallerinden gelen özellikleri sınıflandırmak için çift modlu UKSB kullanarak SEM'leri saptamaya yönelik önerilen yöntem, %76,5'lik ortalama F-skorumu elde eder [13]. Bu çalışmada, sanal bir ajanla sosyal etkileşime dayalı olarak gözbebeği tepkilerini (gözbebeği çapı, sabitleme süresi ve sabitleme yeri) yakalayan bir UKSB modeli tasarlanılır. Uygulanan farklı duyu (kızgın, mutlu, nötr) uyaranlara yanıt olarak tüm gözbebeği tepkilerinin OSB oturumlarında önemli ölçüde değiştiği gözlemlenir. Bu bulgular OSB taramasını ortalama %77 doğrulukla desteklerken, kızgın ve mutlu duyu uyaranlarına göre doğruluk daha da artmakta %80 doğruluk değerine ulaşmaktadır [14].

VR sanal ortamında yürürken elde edilen veriler kullanılarak verilerin 2,5 saniyelik bölümlerinden kaydedilen konum, yön ve göz izleme özellikleri, kullanıcının 2,5 saniye sonraki konumunu tahmin edecek bir UKSB modelini eğitmek için kullanıldı. Gelecekteki konumların ortalama 65 cm'lik bir hatayla tahmin edilebileceği bulundu [15].

Genellikle davranışsal bir hedefe yönelik göz hareketleri, diğer herhangi bir motor eylemden önce gelir [16]. Bu nedenle, eylem niyetinin tahmini için zengin bir sinyal sunarlar [17, 18]. DiCriscio ve Troiani, gözbebeği genişlemesinin, sosyal yanıt vermenin klinik OSB ölçüsü ile ilişkili olduğunu göstermişlerdir [19].

Ahmed ve arkadaşları tarafından yapılan çalışmada otizmin erken teşhisi için makine öğrenmesi, derin öğrenme ve hibrit teknikler olmak üzere farklı yapay zeka tekniği geliştirmişlerdir. GoogleNet ve ResNet-18 modelleri sırasıyla %93,6 ve %97,6 doğruluğa ulaşılmıştır. Hibrit teknikler olan GoogleNet + SVM ve ResNet-18 + SVM için sırasıyla %95,5 ve %94,5 doğruluk elde edilmiştir [20].

Uzun kısa süreli bellek (LSTM) algoritması çeşitli alanlarda yaygın olarak kullanılmaktadır ancak otizm tespiti için doğrudan LSTM algoritmasının kullanımı sınırlıdır. Lakhan ve arkadaşları VGG16-LSTM, VGG19-LSTM ve MobileNet-LSTM modellerini sunarak karşılaştırmalı bir analiz gerçekleştirdiler. MobileNet-LSTM modeli ile en yüksek otistik sınıflandırma doğruluğuna (%96,60) ulaşılmıştır [21].

## Göz Hareketleri ve Veriseti

Göz hareketlerinin kaydedilmesi ve değerlendirilmesi 1800'lü yıllara dayansa da bilgisayar grafiklerinin gelişmesi, görüntü işlemedeki iyileşmeler, gözlerdeki saklı bilgilerin anlaşılır olmasını sağlamıştır. Gözler bilinç dışı yapılan hareketler olduğu için bireylerin fikir, düşünce, ilgi alanı gibi kişisel verileri hakkında örtük bilgiler içermektedir. Bu bilgilere erişebilmek için göz hareketleri ve nasıl yorumlanacağı tablo 1'de belirtilmiştir.

Tablo 1. Göz Hareketleri ve Açıklamaları.

Göz Hareketleri	Anlam ve Yorumu
Odaklanma	Kullanıcın gözlerini sabitleyerek bakmasıdır. Odaklanma süresinin uzun olması bakılan alanın kullanıcın ilgisini çektiği olarak yorumlanır.
Sıçrama	A noktasına bakıldıktan sonra B noktasına geçiş sırasında yapılan harekettir. Çok sayıda olması ekran üzerinde birşeyler arandığı anlamına gelir.
Geri yönlü sıçrama	Sağa doğru ilerleyen metin ya da görsellerde geçilen alanlara geri dönme (sola doğru) davranışdır. Bu durum dikkat dağınıklığı veya geçilen alanın anlaşılmadığı bilgisine ulaştırır.
Gözbebeği Boyutu	Bilişsel yük ve duygu durum değişikliklerinden etkilenir. Yapılan aktivitenin zorluğu, duygu durum tespitinde kullanılabilir.
Göz Kırpma	Gözünü koruma, nemli tutma görevleri bulunan bir reflekstir. Yorgunluk, uykusuzluk çıkarımlarında tercih edilir.
Göz Koordinatları	Gözün eksen üzerindeki bakış noktalarıdır. Bakış alanları incelenerek bireyle ilgili kişisel tercih çıkarımları yapılabilir.

[22]'deki çalışmada Fransa'nın Hauts-de-France bölgesindeki Fransız okullarından katılan 59 katılımcıdan veriler toplanmıştır. 29 OSB, 30 TS olan katılımcıların yaş aralığı 3-12 arasında değişmektedir. Göz hareketlerini kaydetmeden önce ebeveyn izinleri alınır ve oryantasyon eğitimi verilir. Normal gelişim gösterenler ve otizm spektrum bozukluğu olanlar diye iki gruba ayrılırlar. Verisetinde yer alan parametreler Tablo 2'de verilmiştir. Tablodaki parametrelerin dışında CARS skor değerlerinin ve cinsiyetlerin tutulduğu veri dosyası bulunmaktadır.

Tablo 2. Verisetinde yer alan parametreler.

Pupil Diameter (Right -Left)	Gözbebeği çapı
Point of Regard X-Y(Right - Left)	İlgi alanlarının Koordinatları

Eye Position X-Y(Right - Left)	Bakış noktaları
Pupil Size (Right -Left)	Gözbebeği Boyutu
Category (Right -Left)	Bakış Türü(Odaklanma,Sıçrama, Göz Kırpma)
Participant	Katılımcı numarası
Recording Time	Zaman
Color	Gösterilen imgenin rengi
Tracking Ratio	Katılımcının takip oranı
Stimulus	İzletilen video adı
Time of Day	Kayıt yapılan gün

## Veriseti Analizi

Veri setinin sayısal olarak özeti Tablo 3'te verilmiştir. Gruplardaki katılımcı sayısı eşit dağılımlıdır. Daha önceki çalışmalarda belirtildiği gibi otizmin erkek bireylerde daha fazla görülmesi sebebiyle erkek katılımcı sayısı daha fazladır. Ayrıca verilen CARS skor değerlerine göre 14 katılımcı normal, 8 katılımcı düşük, 7 katılımcı şiddetli otizm seviyesinde yer almaktadır. Katılımcıların yaşları 3-12 arasında değişmektedir.

Tablo 3. Verisetinin Özeti.

Katılımcı Sayısı (OSB, TS)	59 (29, 30)
Cinsiyet Dağılımı (E, K)	38 ( $\approx$ 64%), 21 ( $\approx$ 36%)
Yaş Ortalaması	7.88
CARS Skor Ortalaması	32.97

## Motivasyon

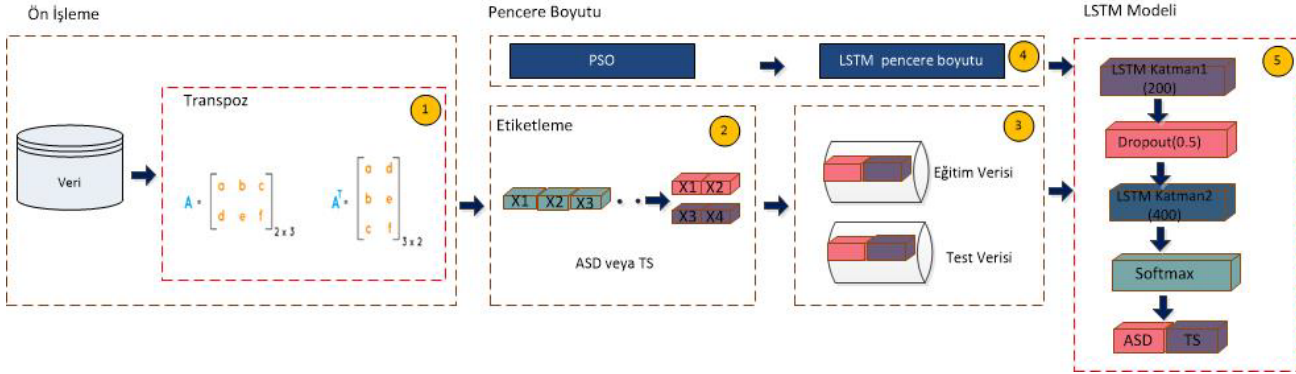
- Otizm değerlendirmesinde etkili olan biyolojik göz parametrelerin tümünü sürece dahil ederek etkisini gözlemlemek
- Bakış trafiğinin sonraki bakış yolunu etkileme oranını ölçmek
- Hiperparametre seçiminde optimum değeri optimizasyonla belirleyebilmek
- Bu alanda kısıtlı yapılmış olan çalışmalara katkı sağlamak

## Metot

UKSB algoritması zaman serisi verilerinin işlenmesinde sıklıkla kullanılan bir yapay sinir ağı modelidir. UKSB modeli, girdi olarak bir dizi zaman serisi verisi alır ve çıktı olarak gelecekteki değerleri tahmin eder. Yapılan göz hareketleri de zaman içerisinde değişim gösterdiği için bu veriler zaman serisi olarak işlendi. Kurgulanan modelde bir adım önceki veriler üzerinden ne kadar geriye gidileceği pencere boyutu ile belirlendi. Pencere boyutu ne kadar büyükse, model o kadar önceki veriye erişebilir. Bu durum modelin daha uzun vadeli tahminler yapmasına olanak tanır.

Ancak, pencere boyutunun çok büyük olması, modelin daha yavaş çalışmasına ve daha az öğrenme yapmasına neden olur. Bu sebeple optimal boyutun seçilmesi gerekir.

• **UKSB modelinin eğitilmesi:** En iyi pencere boyutu belirlendikten sonra, UKSB modeli bu pencere boyutu ile eğitilir ve test veri setinde performansı ölçülür.



Şekil 1. Tasarlanan Metot.

Bu çalışmada PSO algoritması, UKSB modelinin pencere boyutunu optimize etmek için kullanıldı. Bu işlem için, PSO algoritması, pencere boyutunu değiştirerek farklı UKSB modelleri oluşturur ve bunları bir hedef fonksiyonu kullanarak değerlendirir. Hedef fonksiyonu, UKSB modelinin performansını ölçmek için kullanılır. Örneğin, hedef fonksiyonu, UKSB modelinin tahminlerinin gerçek verilerle ne kadar iyi eşleştiğini ölçerek gerekli en uygun değeri seçer. UKSB modelinin pencere boyutunu otomatik olarak ayarlamak ve daha iyi performans sağlayabilmek için takip edilecek adımlar:

**Veri setinin hazırlanması:** PSO algoritmasını kullanarak, pencere boyutunu belirlemek istediğimiz UKSB modelinin eğitim ve test verileri hazırlanır. Eğitim veri seti, modelin öğrenmesi için kullanılırken test veri seti, modelin performansını ölçmek için kullanılır.

• **PSO parametrelerinin belirlenmesi:** PSO algoritmasının performansını etkileyen parametreler belirlenir. Bu parametreler arasında sürü boyutu, maksimum iterasyon sayısı, hız sabitleri ve bireylerin en iyi konumlarını güncellemek için kullanılan ağırlıklar gibi parametreler bulunur.

• **Hedef fonksiyonunun tanımlanması:** Hedef fonksiyonu, UKSB modelinin performansını ölçmek için kullanılır. Bu fonksiyon, UKSB modelinin tahminlerinin gerçek verilerle ne kadar iyi eşleştiğini ölçer. Bu fonksiyon, özellikle UKSB modelinin doğru tahminler yapması için belirli bir pencere boyutuna ihtiyaç duyulduğunda daha yüksek bir değer döndürür.

• **PSO algoritmasının çalıştırılması:** PSO algoritması, farklı pencere boyutlarını deneyerek UKSB modelleri oluşturur ve bu modellerin hedef fonksiyonu kullanarak performansını değerlendirir. Algoritma, sürüsündeki bireylerin konumlarını güncelleyerek en iyi pencere boyutunu bulmaya çalışır.

• **En iyi pencere boyutunun seçilmesi:** PSO algoritması, birçok pencere boyutunu deneyerek en iyi pencere boyutunu bulur. Bu pencere boyutu, en iyi performansı gösteren UKSB modelinin pencere boyutu olarak seçilir.

Bu çalışmada göz izleme teknolojilerinden elde edilen parametre dizilerini UKSB modeli ile otizm sınıflandırılmasında kullanabilecek PSO-UKSB birlikteliğinden oluşan bir metod tasarlanmıştır. Uygulanacak bu metod şekil 1’de belirtilmiştir. Şekil 1’deki basamaklar adım adım açıklanmıştır.

**Veri:** Göz izleme ile otizm değerlendirmesi yapabilmek için veriseti parametrelerinden oluşan  $N \times 15$  bir veriseti hazırlanır. N değeri yapılan göz hareketidir ve kullanıcıya bağlı olarak değişmektedir. Veriler ön işleme adımında eksik bilgi içeriyorsa manuel olarak silinir. Ayrıca satırlar bireyleri sütunlar 52 nitelik içeren değerleri belirtir. Herbir nitelik değerinin tüm kullanıcılardan oluşan veri dizisini alabilmek için transpozuz adımına geçilir.

**Transpozuz:** Verilerde yer alan eksik göz özelliği içeren satırlar manuel olarak silinir. Ardından matris olarak tutulan herbir harekete ait parametre içeriklerinin transpozuz alınır. Böylelikle tüm parametreleri içeren satır elde edilmiş olur.

**Etiketleme:** Satır dizilerinin en sonuna yeni kolon oluşturularak yapılan hareketin OSB’li birey mi yoksa TS’li birey mi olduğunu belirlenerek sınıf etiketleri atanır.

**Ayrırma :** Dizilere parçalanmış ve etiketlenmiş veriler %70-%30 oranında ayrılarak eğitim ve test bölümleri oluşturulur.

Herbir göz hareketi bir satır olarak dosyada yer almaktadır. Bu satırlar genellikle 1 ms lik aralıklarla kaydedilmektedir. Birçok çalışmada deneysel olarak pencere boyutlarına bölünen diziler bir sonraki adıma iletilir. Deneysel olarak alınan pencere boyutunda rastgele seçilen değerler arasından en iyi sonuç veren pencere boyutları seçilmiştir. Fakat bu durum elde edilen başarı oranının en yüksek mi daha iyisi var mı? Sorusunu cevaplayamamaktadır. Zaman serisi verilerinin tahmininde sıklıkla kullanılan UKSB modelleri, daha iyi sonuçlar elde etmek için optimal hiperparametrelerin belirlenmesini gerektirir. Bunlardan biri de pencere boyutudur. Pencere boyutunun belirlenmesi, tahmin doğruluğunu önemli ölçüde etkiler. Bu nedenle, bu çalışmada, PSO algoritması kullanarak UKSB modeli için optimal pencere boyutunun belirlenmesi hedeflenmiştir.

PSO algoritması kullanılarak optimal pencere boyutunun belirlenmesi için bir MATLAB kodu geliştirilmiştir. PSO algoritması, hiperparametre olarak pencere boyutunu alır. Tahmin edilen ile gerçek değer arasındaki farkın en az olduğu pencere boyutu seçilir. Daha sonra, belirlenen optimal pencere boyutu kullanılarak UKSB modeli eğitilir ve tahminler yapılır. UKSB modelinin parametreleri tablo 4’de verilmiştir.

Tablo 4. Model Parametreleri.

Parametreler	Değerler
UKSB Katman I	Neuron size :200
Dropout	0.5
UKSB Katman II	Neuron size :400
Epoch	30
Aktivasyon Fonksiyonu	Softmax
Optimizasyon Fonksiyonu	Adam
Batch Boyutu	30

Tasarlanan metotta PSO ile UKSB için pencere boyutu belirlenmenin sözde kodu :

1- Başlangıçta, rastgele olarak birkaç pencere boyutu seçilir ve bunlar PSO ile optimize edilir.

2- Sürü boyutu, maksimum adım sayısı,  $c1$ ,  $c2$  ve  $w$  gibi PSO parametreleri belirlenir.

3- Uygunluk(fitness) fonksiyonu tanımlanır. Bu fonksiyon, veri kümesini belirtilen pencere boyutuna göre bölerek bir UKSB modeli oluşturur ve modelin tahminleri ile gerçek değerler arasındaki ortalama kare hatayı (OKH) hesaplar.

4- PSO algoritması tanımlanır:

a. Sürü boyutu oluşturulur ve başlangıç pozisyonları rastgele atanır.

b. Sürü boyutu'nun her bir bireyinin uygunluğu, uygunluk fonksiyonu kullanılarak hesaplanır.

c. Sürü boyutu'nun  $n$  kişisel en iyi ve global en iyi pozisyonları güncellenir.

d. Hızlar ve pozisyonlar güncellenir.

e. Maksimum adım sayısına veya belirli bir duruma ulaşıncaya kadar  $b$ ,  $c$  ve  $d$  adımları tekrar edilir.

5- En iyi pencere boyutu çıktısı verilir.

Kullandığımız metotta ilk katman 200 nöron içerir. Nöron sayısı hafızadaki bilgi sayısını belirtir. Aktivasyon fonksiyonu olarak tanh ve sigmoid kullanır. İkinci UKSB katmanı 400 nöron içerir. Ezberleme durumunun önüne

geçebilmek için nöronların yarısı aktif edilir ve DVM ile ikili sınıflandırma gerçekleştirilir.

## Sonuçlar ve Tartışma

Otizm sınıflandırmasını incelemek için iki uygulama gerçekleştirildi. İlk uygulamada mevcut tüm göz özellikleri ikinci uygulamada ise ilgi alanı noktaları, gözbebeği boyut değişimi özellikleri UKSB ağında işlenmesinin ardından sınıflandırmaya gidildi. Satır dizileri UKSB ağına verildi ve sonuçlar kıyaslandı. Her iki uygulamada da sınıflandırma başarımlarının performans değerlendirmesini yapabilmek için karmaşıklık matrisi kullanıldı. Bu matriste satırlar gerçek sınıfları sütunlar tahmin edilen sınıflandırmaları belirtmektedir. Tablolarda doğruluk, duyarlılık, kesinlik ve F1 metrikleri tercih edildi. Tercih edilen metriklerin formülleri denklem1, denklem2, denklem3 ve denklem4’te verilmiştir. Bu metrikleri ölçebilmek için  $dp$  (doğru pozitif),  $dn$  (doğru negatif),  $yp$  (yanlış pozitif),  $yn$  (yanlış negatif) değerleri kullanılır.

$$\text{Doğruluk} = \frac{dp+dn}{dp+dn+yp+yn} \quad (1)$$

$$\text{Duyarlılık} = \frac{dp}{dp+yp} \quad (2)$$

$$\text{Kesinlik} = \frac{dp}{dp+yn} \quad (3)$$

$$\text{F1 Skor} = \frac{2dp}{2dp+yp+yn} \quad (4)$$

## Uygulama 1:

UKSB sıralı veriler üzerinde etkili bir şekilde çalışan bir derin öğrenme algoritmasıdır. Göz izleme verileri, sıralı verilerdir. Kişinin bakış odakları ve süreleri, sırayla birbirine bağlıdır. Bu nedenle, UKSB, göz izleme verilerini sınıflandırmak için kullanılabilir. UKSB algoritması, bu tür çok boyutlu verileri işlemek için etkili bir seçenektir. UKSB, önceki girdilerin geçmiş bilgilerini hatırlayarak ve gelecekteki girdileri tahmin ederek sıralı verileri analiz eder. Bu sebeple göz izleme teknolojisi yardımıyla alınan göz hareketlerine ait veri kümesi UKSB ile değerlendirilir. Bu değerlendirme yapılırken göz bebeği, göz pozisyonu, ilgi alanı parametreleri farklı kombinasyonlarla UKSB ağına uygulanır.

Veriseti, belirlenen modele göre farklı pencere boyutlarına göre eğitilip başarımların değerleri elde edilmiştir. Veriseti 15 kolondan oluştuğu için PSO için alt sınır=1 üst sınır=15 seçilerek pencere boyutunun 1-15 aralığında alınması sağlanmıştır. Yapılan testler sonucunda pencere boyutunun başarı oranını önemli ölçüde etkilediği görülmüştür. Adım sayısı modelin kaç kez eğitildiğini temsil etmektedir. Adım sayısı ve sürü boyut değerleri 2 olarak seçilerek elde edilen değerler Tablo 5’te yansıtılmıştır.

Tablo 5. Adım sayısı=2 Sürü boyutu=2 için başarı değerleri.

Pencere Boyutu	Eğitim	Doğrulama	Test
6	92.25	92.34	89.56
4	93.80	93.46	92.81
13	<b>98.25</b>	<b>98.5</b>	<b>98.5</b>
5	93.07	93.25	91.93

Bu değerlerin ardından en optimum sonuca pencere boyutunun 13 seçilmesi durumunda ulaşılabileceği gözlemlendi. Göz hareketleri ile otizm teşhisinde UKSB modelinin avantajı saptandı. Bu avantajda geçmiş göz hareketlerinin gelecek göz hareketlerindeki etkisi sorgulanıp pencere boyutları değiştirildiğinde gerçekleşen sonuçlar incelendi. Pencere boyutunun başarımlarını etkilemede oldukça önemli bir faktör olduğu saptandı.

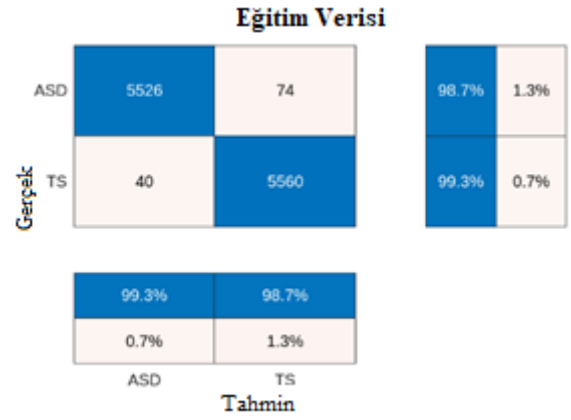
### Uygulama 2:

Daha önce CNN kullanarak gerçekleştirdiğimiz çalışmalarda [23,24] gözbebeği boyutu ve ilgi alanı özellikleri sınıflandırmada oldukça belirleyici özellikler olarak karşımıza çıkmıştı. Bu özelliklerin UKSB ile değerlendirilmesini yaptığımızda Tablo 6'daki oranlara ulaşıldı. Gözbebeği boyutu alınan birey sayısında eksiklik mevcut olduğu için alınan veri sayısı da azdır.


Tablo 6. Adım sayısı=2 Sürü boyutu=2 için başarı değerleri

Pencere Boyutu	Eğitim	Doğrulama	Test
7	95.34	95.59	95.18
6	98.98	98.96	98.62
2	91.15	90.96	90.37
5	<b>98.97</b>	<b>98.96</b>	<b>98.64</b>

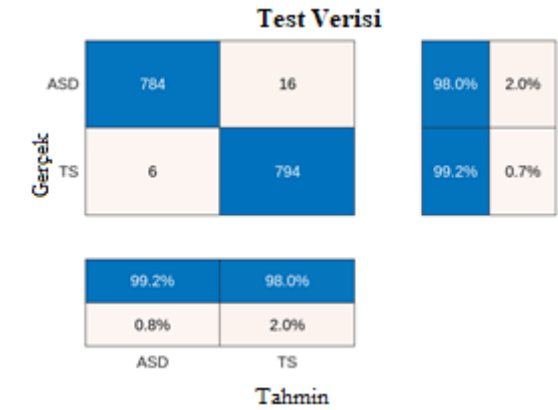
Gözbebeği boyutu ve ilgi alanı özellikleri tasarladığımız modele girdi olarak verilip sürü boyutu ve adım sayılarını uygulamalardaki ile aynı tuttuğumuzda daha iyi oranlar elde edildi. Böylelikle göz bebeği boyutu ve ilgi alanı parametrelerinin sınıflandırmada oldukça etkili özellikler olduğu birkez daha kanıtlanmıştır. En başarılı oran pencere boyutunun 6 gelmesi ile elde edilirken en iyi durumun karmaşıklık matrisi şekil 2.a,2.b,2.c'de gösterilmiştir.



Şekil 2. a) Eğitim Verilerinin Karmaşıklık Matrisi



Şekil 2. b) Doğrulama Verilerinin Karmaşıklık Matrisi



Şekil 2. c) Test Verilerinin Karmaşıklık Matrisi

### Tartışma

Göz izleme ile otizm rahatsızlığını tanımlayabilmek için yapılan bazı çalışmalar ve elde ettikleri sonuçlar tablo 7'de verilmiştir. Farklı verisetleri ve algoritmalar kullanılarak yapılan çalışmalardan daha iyi başarı oranları tarafımızca elde edilmiştir. Göz izleme ile otizm rahatsızlığını tanımlayabilmek için yapılan bazı çalışmalar ve elde edilen sonuçlar tablo 7'de verilmiştir.

Tablo 7. Farklı veri setleri ile yapılan çalışmalar

Yazarlar	Kullanılan Veriseti	Algoritma	Doğruluk (%)
Romuald Carette,2018 [25]	17 OSB,25TS	UKSB	83
Chen Xia,2020 [26]	31 OSB,43TS	DVM	93
Victoria Yaneva,2020 [27]	20 OSB,20TS	Lojistik Regresyon	75.3
KenjiJ. Tsuchiya,2021 [28]	39 OSB,102TS	Random Forest	78

Literatürde bizimle aynı veriyi kullanan çalışmalar tablo8'de belirtilmiştir. Bu çalışmalar arasında UKSB algoritmasını içeren bir uygulama mevcut değildir. Buna rağmen yapılan uygulamalarla kıyasladığımızda burada da en iyi başarı oranlarına ulaştığımız görülmektedir. Bu çalışmada kullanılan veri seti ile yapılmış çalışmaların özeti tablo8'de belirtilmiştir. Bu çalışmalar arasında LSTM algoritmasını içeren bir uygulama mevcut değildir. Elde edilen sonuçlar tablo 8 ile karşılaştırıldığında önerilen yöntemin doğruluk değeri daha yüksek elde edilmiştir.

Tablo 8. Aynı veri setleri ile yapılan çalışmalar

Yazarlar	Kullanılan Veriseti	Algoritma	Doğruluk (%)
Federica Cilia, [29]	29 OSB,30TS	ESA	93
Carette ve ark.) [30]	29 OSB,30TS	Lojistik Regresyon	81.9
Elbattah ve ark. [31]	29 OSB,30TS	Autoencoders	K= 3 için 94
Elbattah ve ark. [31]	29 OSB,30TS	VAE model	70
<b>Önerilen Yöntem</b>	<b>29 OSB,30TS</b>	<b>LSTM</b>	<b>98,64</b>

UKSB ile gerçekleştirdiğimiz uygulamamızda geçmiş göz hareketlerinin hafızaya alınarak değerlendirilmesinin sınıflandırmaya etkisi gözlemlendiğinde oldukça başarılı sonuçlara erişilmektedir. Uygulama 1 ile göz hareketlerine ait tüm özelliklerin kullanılması ile iyi düzeyde sınıflandırmanın

gerçekleştirilebileceği gösterilmiştir. Bu başarının oranını belirleyen en önemli faktörün pencere boyutu olduğu ispatlanmıştır.

Pencere boyutu literatürde deneysel yöntemlerle seçilmektedir. Bu duruma çözüm olarak sunulan PSO- UKSB hibrit modeli optimum pencere boyutunu belirleyerek eğitimi gerçekleştirir. Uygulama 1'de tüm özellikler dahil edildiğinde pencere boyutu 13 olduğunda, Uygulama 2'de sınırlı sayıda özellik ile yapılan eğitimde pencere boyutu 5 olduğunda maximum başarıya ulaşıldı.

Otizm sınıflandırma çalışmasında gözbebeği boyutunun ve ilgi alanı parametrelerinin belirleyici özellikler olduğu bu çalışma ile bir kez daha kanıtlanmaktadır. Özellikle TS bireyleri ayırt etmede bu özelliklerin pozitif etkisinin olduğu görüldü.

Uygulama 1'de mevcut tüm özellikler eğitime dahil edildiğinde OSB'li bireyleri sınıflandırma oranında daha iyi bulgulara ulaşıldı. Bu durum biyolojik parametre sayısı arttıkça otizm rahatsızlığını bulma oranının artacağını göstermektedir.

Göz hareketlerinin veri sayısı maddi sebeplerle hep kısıtlı tutulmaktadır. Bu nedenle derin öğrenme alanında kısıtlı çalışma olması sebebiyle çalışmamız bu alanda öncü olabilecektir.

#### Kaynakça

- [1] Wing, L., & Gould, J. (1979). Severe impairments of social interaction and associated abnormalities in children: Epidemiology and classification. *Journal of autism and developmental disorders*, 9(1), 11-29.
- [2] Loth, E., Spooren, W., Ham, L. M., Isaac, M. B., Auriche-Benichou, C., Banaschewski, T., ... & Murphy, D. G. (2016). Identification and validation of biomarkers for autism spectrum disorders. *Nature reviews Drug discovery*, 15(1), 70-70.
- [3] Volkmar, F. R., Cicchetti, D. V., Dykens, E., Sparrow, S. S., Leckman, J. F., & Cohen, D. J. (1988). An evaluation of the autism behavior checklist. *Journal of autism and developmental disorders*, 18(1), 81-97.
- [4] Schopler, E., Reichler, R. J., DeVellis, R. F., & Daly, K. (1980). Toward objective classification of childhood autism: Childhood Autism Rating Scale (CARS). *Journal of autism and developmental disorders*.
- [5] Ghosh, S., & Guha, T. (2021, November). Towards Autism Screening through Emotion-guided Eye Gaze Response. In 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) (pp. 820-823). IEEE.
- [6] Minissi ME, Chicchi Giglioli IA, Mantovani F, Alcañiz Raya M. Assessment of the Autism Spectrum Disorder Based on Machine Learning and Social Visual Attention: A Systematic Review. *J Autism Dev Disord*. 2022 May;52(5):2187-2202. doi: 10.1007/s10803-021-05106-5. Epub 2021 Jun 8. PMID: 34101081; PMCID: PMC9021060.

- [7] M. Okano and M. Asakawa, "Eye tracking analysis of consumer's attention to the product message of web advertisements and TV commercials," 2017 5th International Conference on Cyber and IT Service Management (CITSM), 2017, pp. 1-5, doi: 10.1109/CITSM.2017.8089270.
- [8] Kang, J., Han, X., Song, J., Niu, Z., & Li, X. (2020). The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data. *Computers in biology and medicine*, 120, 103722.
- [9] Wang, J., Barstein, J., Ethridge, L. E., Mosconi, M. W., Takarae, Y., & Sweeney, J. A. (2013). Resting state EEG abnormalities in autism spectrum disorders. *Journal of neurodevelopmental disorders*, 5(1), 1-14.
- [10] Kang, J., Han, X., Song, J., Niu, Z., & Li, X. (2020). The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data. *Computers in biology and medicine*, 120, 103722.
- [11] Sheikhan, A., Behnam, H., Mohammadi, M. R., Noroozian, M., & Mohammadi, M. (2012). Detection of abnormalities for diagnosing of children with autism disorders using of quantitative electroencephalography analysis. *Journal of medical systems*, 36(2), 957-963.
- [12] Mou, L., Zhou, C., Zhao, P., Nakisa, B., Rastgoo, M. N., Jain, R., & Gao, W. (2021). Driver stress detection via multimodal fusion using attention-based CNN-LSTM. *Expert Systems with Applications*, 173, 114693.
- [13] Kang, J., Zhou, T., Han, J., & Li, X. (2018). EEG-based multi-feature fusion assessment for autism. *Journal of Clinical Neuroscience*, 56, 101-107.
- [14] Kang, J., Zhou, T., Han, J., & Li, X. (2018). EEG-based multi-feature fusion assessment for autism. *Journal of Clinical Neuroscience*, 56, 101-107.
- [15] Stein, N., Bremer, G., & Lappe, M. (2022, March). Eye tracking-based lstm for locomotion prediction in vr. In 2022 IEEE Conference on Virtual Reality and 3D User Interfaces (VR) (pp. 493-503). IEEE.
- [16] A S DiCriscio and V Troiani, "Pupil adaptation corresponds to quantitative measures of autism traits in children," *Scientific reports*, vol. 7, no. 1, pp. 1–9, 2017.
- [17] A Klin, W Jones, R Schultz, F Volkmar, and D Cohen, "Visual fixation patterns during viewing of naturalistic social situations as predictors of social competence in individuals with autism," *Archives of General Psychiatry*, vol. 59(9), pp. 809–816, 2002.
- [18] Z Akhtar and T Guha, "Computational analysis of gaze behavior in autism during interaction with virtual agents," in *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2019, pp. 1075–1079.
- [19] Ghosh, S., & Guha, T. (2021, November). Towards Autism Screening through Emotion-guided Eye Gaze Response. In 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) (pp. 820-823). IEEE.
- [20] Ahmed, I. A., Senan, E. M., Rassem, T. H., Ali, M. A., Shatnawi, H. S. A., Alwazer, S. M., & Alshahrani, M. (2022). Eye tracking-based diagnosis and early detection of autism spectrum disorder using machine learning and deep learning techniques. *Electronics*, 11(4), 530.
- [21] Lakhan, A., Mohammed, M. A., Abdulkareem, K. H., Hamouda, H., & Alyahya, S. (2023). Autism Spectrum Disorder detection framework for children based on federated learning integrated CNN-LSTM. *Computers in Biology and Medicine*, 166, 107539.
- [22] Cilia, F., Carette, R., Elbattah, M., Guérin, J. L., & Dequen, G. (2022). Eye-tracking dataset to support the research on autism spectrum disorder.
- [23] Cetintas, Dilber & Tuncer, Taner. (2021). Eye-Tracking Analysis with Deep Learning Method. 512-515. 10.1109/3ICT53449.2021.9581943.
- [24] Cetintas, Dilber & Tuncer, Taner. (2022). Determining the Type of Document Read Using Eye Movement Properties by Hybrid CNN Method. *Traitement du Signal*. 39. 10.18280/ts.390402.
- [25] R. Carette, F. Cilia, G. Dequen, J. Bosche, J.L. Guerin, L. Vandromme, Automatic Autism Spectrum Disorder Detection Thanks to Eye-Tracking and Neural Network-Based Approach. In: Bastel JB, Ahmed MU, Begum S, "editors'.: Springer Verlag, 2018. p. 75-81.
- [26] C. Xia, K. Chen, K. Li, H. Li (Eds.), Identification of autism spectrum disorder via an eye-tracking based representation learning model 2020 2020-01-01: Association for Computing Machinery.
- [27] V. Yaneva, H. Le An, S. Eraslan, Y. Yesilada, R. Mitkov Detecting High-Functioning Autism in Adults Using Eye Tracking and Machine Learning *Ieee T Neur Sys Reh.*, 28 (6) (2020), pp. 1254-1261.
- [28] K.J. Tsuchiya, S. Hakoshima, T. Hara, et al. Diagnosing Autism Spectrum Disorder Without Expertise: A Pilot Study of 5- to 17-Year-Old Individuals Using Gazefinder *Front. Neurol.*, 11 (2021).
- [29] F. Cilia, R. Carette, M. Elbattah, et al. Computer-Aided Screening of Autism Spectrum Disorder: Eye-Tracking Study Using Data Visualization and Deep Learning *JMIR Hum. Factors*, 8 (4) (2021), p. e27706.
- [30] R. Carette, F. Cilia, G. Dequen, J. Bosche, J.L. Guerin, L. Vandromme, Automatic Autism Spectrum Disorder Detection Thanks to Eye-Tracking and Neural Network-Based Approach. In: Bastel JB, Ahmed MU, Begum S, "editors'.: Springer Verlag, 2018. p. 75-81.
- [31] Elbattah M, Loughnane C, Guérin J-L, Carette R, Cilia F, Dequen G. Variational Autoencoder for Image-Based Augmentation of Eye-Tracking Data. *Journal of Imaging*. 2021; 7(5):83. <https://doi.org/10.3390/jimaging7050083>.