



GÖRÜNTÜ SINIFLANDIRMADA AŞIRI ÖĞRENME MAKİNESİ VE VARYANTLARININ PERFORMANS KARŞILAŞTIRMASI

Kübra BOZOĞLAN¹, Uğur YÜZGEÇ^{2*}

¹Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü, Tezli Yüksek Lisans Öğrencisi, Bilecik, Türkiye

²Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Bilecik, Türkiye

Anahtar Kelimeler	Öz
Aşırı Öğrenme Makineleri Görüntü Sınıflandırma Makine Öğrenmesi	Görüntü sınıflandırma tıp, tarım, güvenlik ve daha fazlası gibi çeşitli alanlarda kritik bir teknolojidir. Makine öğrenmesi algoritmaları, özellikle de Aşırı Öğrenme Makineleri (ELM), hızlı öğrenme yetenekleri ve yüksek doğruluk oranları nedeniyle dikkat çekmiştir. Bununla birlikte, ELM'nin performansı veri kümesine ve uygulama senaryosuna bağlı olarak değişebilir. Bu çalışma, ELM modelinin ve geliştirilmiş varyantlarının (artımlı aşırı öğrenme makinesi (IELM), çevrimiçi sıralı aşırı öğrenme makinesi (OSELM), düzenli aşırı öğrenme makinesi (RELM) ve kısıtlı aşırı öğrenme makinesi (CELM)) performansını görüntü sınıflandırma bağlamında değerlendirmeyi ve karşılaştırmayı amaçlamaktadır. Bu modeller dört farklı veri kümesi üzerinde test edilmiştir: MNIST, beyin MRI görüntüleri, pirinç görüntüleri ve araç sürücülerinin görüntüleri. Modellerin performansları başarı oranları, kesinlik, geri çağırma ve F1 puanlarına göre değerlendirilmiştir. Sonuçlar, CELM modelinin en yüksek başarı oranını elde ettiğini, IELM modelinin ise en düşük performansı gösterdiğini ortaya koymuştur. Bu bulgular, her modelin kendine özgü yapısal özelliklerinin sınıflandırma başarısını nasıl etkilediğine dair değerli bilgiler sağlamaktadır. Ayrıca, veri kümeleri arasındaki performans farklılıkları, veri kümesi özelliklerine göre en etkili modelin seçilmesi için önemli ipuçları sunmaktadır. Araştırmacılar ve uygulayıcılar, her modelin güçlü yönlerini ve sınırlamalarını anlayarak, görüntü sınıflandırma zorluklarını ele alırken bilinçli kararlar verebilirler.

PERFORMANCE COMPARISON OF EXTREME LEARNING MACHINE AND ITS VARIANTS IN IMAGE CLASSIFICATION

Keywords	Abstract
Extreme Learning Machines Image Classification Machine Learning	Image classification is a critical technology in various fields such as medicine, agriculture, security, and more. Machine learning algorithms, particularly Extreme Learning Machines (ELM), have gained attention due to their fast learning capabilities and high accuracy rates. However, the performance of ELM can vary depending on the dataset and application scenario. This study aims to evaluate and compare the performance of the ELM model and its improved variants—namely, the incremental extreme learning machine (IELM), online sequential extreme learning machine (OSELM), regularized extreme learning machine (RELM), and constrained extreme learning machine (CELM)—in the context of image classification. These models were tested on four distinct datasets: MNIST, brain MRI images, rice images, and images of vehicle drivers. The models' performances were evaluated based on success rates, precision, recall, and F1 scores. The results indicate that the CELM model achieved the highest success rate, while the IELM model demonstrated the lowest performance. These findings provide valuable insights into how the unique structural features of each model influence classification success. Furthermore, the differences in performance across the datasets offer important clues for selecting the most effective model based on dataset characteristics. By understanding the strengths and limitations of each model, researchers and practitioners can make informed decisions when addressing image classification challenges.

Alıntı / Cite

Bozoğlan, K., Yüzgeç, U., (2025). Görüntü Sınıflandırmada Aşırı Öğrenme Makinesi Ve Varyantlarının Performans Karşılaştırması, Mühendislik Bilimleri ve Tasarım Dergisi, 13(3), 856-871.

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process
K. Bozoğlan, 0009-0006-6548-6023	Başvuru Tarihi / Submission Date
U. Yüzgeç, 0000-0002-5364-6265	Revizyon Tarihi / Revision Date
	Kabul Tarihi / Accepted Date
	Yayın Tarihi / Published Date

* İlgili yazar / Corresponding author: ugur.yuzgec@bilecik.edu.tr, +90-228-214-1555

PERFORMANCE COMPARISON OF EXTREME LEARNING MACHINE AND ITS VARIANTS IN IMAGE CLASSIFICATION

Kübra BOZOĞLAN¹, Uğur YÜZGEÇ^{2†}

¹Bilecik Şeyh Edebali University, Institute of Graduate Education, Master's Student with Thesis, Bilecik, Türkiye

²Bilecik Şeyh Edebali University, Faculty of Engineering, Department of Computer Engineering, Bilecik, Türkiye

Highlights

- Image classifications were made with ELM and its improved models (IELM, OSELM, RELM and CELM).
- The performance of ELM and its variants for different scenarios was evaluated using four datasets with different structures.
- The IELM model exhibited the lowest performance.
- The most successful results were obtained using the CELM model.

Purpose and Scope

The aim of this study is to compare the performance of the Extreme Learning Machine (ELM) and its variants, namely IELM, OSELM, RELM, and CELM, in image classification problems by applying them to four different datasets with varying structures.

Design/methodology/approach

In this study, a methodology was developed using ELM, IELM, OSELM, RELM, and CELM for different image classification problems.

Findings

When the ELM, IELM, OSELM, RELM and CELM models were compared according to precision recall and F1 score metrics, it was seen that the lowest success rate belonged to the IELM model and the highest success rate belonged to the CELM model.

Research limitations/implications

In future studies, ELM models can be compared with various deep learning and supervised learning algorithms, and a new hybrid model can be created that will improve the performance of image classification from the models that show the best performance.

Practical implications

This study evaluated the effectiveness of different ELM variants in image classification problems and contributed to the selection of the most appropriate model for different data structures.

Social Implications

This study aims to contribute to different sectors by providing a successful solution to image classification problems in fields such as medicine and agriculture.

Originality

There are limited studies in the literature that compare ELM and its variants over a wide range. The originality of this study is that it compares ELM and its variants in detail, using data from different sectors with different structures.

[†] Corresponding author: ugur.yuzgec@bilecik.edu.tr, +90-228-214-1555

1. Giriş (Introduction)

Gelişen bilgisayar teknolojileri, özellikle işlemcilerin hızındaki ve depolama alanlarındaki artışla birlikte, veri analizi konusunda büyük bir devrim yaratmıştır. Bu teknolojik ilerlemeler, daha önce hiç olmadığı kadar büyük miktarda verinin işlenebilmesine olanak sağlamaktadır. Ancak bu büyük veri setlerinin analizi, geleneksel yöntemlerle oldukça zor ve zaman alıcı hale gelmiştir. Bu durum, verilerden anlamlı ve kullanışlı bilgi çıkarabilmek için daha gelişmiş ve etkili tekniklerin kullanılmasını zorunlu kılmıştır (Coşkun ve Baykal, 2014). Bu noktada istatistiksel yöntemler ve yapay zeka tabanlı makine öğrenmesi (ML) algoritmaları devreye girmektedir.

Makine öğrenmesi, bilgisayarların verilerden öğrenmesini sağlayan bir yapay zeka dalıdır ve temel olarak veriler üzerinde örüntüler ve ilişkiler keşfetmeye dayanır. Bu tür algoritmalar, belirli görevleri yerine getirebilmek için veriden otomatik olarak öğrenirler. Bu öğrenme süreci, bilgisayarın daha önce görmediği verilerle karşılaştığında bile belirli tahminlerde bulunmasını ya da kararlar almasını mümkün kılar (Kaynar vd., 2016). Örneğin, bir sağlık sisteminde, makine öğrenmesi algoritmaları, çeşitli hasta verileri üzerinden çalışarak hastalıkların tanısını koymada kullanılabilir. Ya da tarımda, bir algoritma belirli iklim koşullarına ve toprak özelliklerine bakarak hangi mahsulün en verimli şekilde yetiştirilebileceğine dair tahminlerde bulunabilir.

Makine öğrenmesi, sadece teorik bir alan olmanın ötesine geçerek çok çeşitli endüstrilerde yaygın olarak kullanılmaktadır. Tıptan finansal analize, perakendeden otomotive kadar geniş bir uygulama yelpazesine sahiptir. Bu kadar geniş bir kullanım alanına sahip olan makine öğrenmesinin temel amacı, veriden anlamlı sonuçlar elde etmek, karmaşık sorunları çözmek ve genellikle insan müdahalesini minimize etmektir. Makine öğrenmesi algoritmalarından biri de aşırı öğrenme makineleridir (ELM). Aşırı öğrenme makineleri, özellikle sınıflandırma ve regresyon gibi problemlerde oldukça başarılı sonuçlar vermektedir.

Aşırı öğrenme makineleri (ELM), Huang ve arkadaşları tarafından geliştirilen bir yapay sinir ağı modelidir. ELM, tek gizli katmanlı ileri beslemeli bir yapıdır. Bu yapının özelliği, giriş ağırlıklarının ve eşik değerlerinin rastgele belirlenmesidir (Huang, Zhu ve Siew, 2004). Geleneksel yapay sinir ağlarında, bu ağırlıkların belirlenmesi genellikle zorlu bir eğitim süreci gerektirirken, ELM'de bu işlem çok daha hızlı bir şekilde gerçekleştirilir. Çıkış ağırlıkları ise analitik yöntemlerle hesaplanır. Bu özellik, ELM'yi geleneksel yapay sinir ağlarına kıyasla daha hızlı ve verimli hale getirir. Ayrıca, ELM'nin öğrenme süreci daha basit olup, yüksek doğruluk oranlarına ulaşabilmesiyle dikkat çeker.

Özellikle regresyon, sınıflandırma ve zaman serisi tahminleme gibi alanlarda çok başarılı sonuçlar veren ELM, geniş veri setleriyle çalışırken zaman kazandırmakta ve performans açısından güçlü bir alternatif sunmaktadır. ELM'nin performansı, verinin doğruluğunu artırmak ve daha genelleştirilmiş tahminlerde bulunmak açısından önemli avantajlar sağlar. Aynı zamanda, uygulama açısından oldukça basit ve esnek bir yapıya sahip olduğundan, bu algoritmalar farklı alanlarda kullanılabilir. Özellikle büyük veri analizinde, ELM'nin avantajları daha da belirginleşir, çünkü bu tür veri setleriyle çalışırken geleneksel yöntemlerin zorluklarıyla karşılaşmadan hızlı sonuçlar alınabilir.

ELM'nin öğrenme süreci de oldukça hızlıdır. Bu, özellikle zamanın kritik olduğu uygulamalarda büyük bir avantaj sağlar. Giriş ağırlıklarının rastgele belirlenmesi ve sabitlenmesi, modeli daha hızlı eğitilebilir hale getirir, böylece sistem hız kazanır. Aynı zamanda, analitik hesaplamalar sayesinde modelin doğruluğu da yüksek seviyede tutulabilir. Bu nedenle, ELM pek çok farklı alanda etkili bir şekilde kullanılmaktadır.

Bununla birlikte, ELM'nin bazı sınırlamaları da bulunmaktadır. Örneğin, çok karmaşık veri setlerinde, doğru tahminler yapabilmek için daha ileri düzey optimizasyon teknikleri gerekebilir. Ayrıca, aşırı öğrenme makineleri genellikle lineer olmayan ilişkileri modellemek için bazı zorluklar yaşayabilirler, bu da daha gelişmiş modellerin kullanılmasını gerektirebilir. Bu sebeple ELM'nin bu dezavantajlarına çözüm sunmak amacıyla çeşitli ELM varyantları geliştirilmiştir (Ding ve Nie, 2014).

Bu çalışmada farklı sınıf sayısına ve boyuta sahip veri setlerinde aşırı öğrenme makine modeli (ELM) ve bu modelin geliştirilmiş varyantlarından artımlı aşırı öğrenme makine modeli (IELM), çevrimiçi sıralı aşırı öğrenme makine modeli (OSELM), düzenlenmiş aşırı öğrenme makine modeli (RELM) ve kısıtlanmış aşırı öğrenme makine modeli (CELM) kullanılarak modellerin görüntü sınıflandırma üzerindeki başarımları kıyaslanmıştır.

Çalışmanın ilerleyen bölümlerinde sırasıyla kaynak araştırması, materyal ve yöntem, deneysel sonuçlar, sonuç ve tartışma bölümleri sunulmaktadır.

2. Kaynak Araştırması (Literature Survey)

Görüntü sınıflandırma, günümüz dijital dünyasında büyük bir öneme sahiptir çünkü bu teknoloji, bilgisayarların ve yapay zekanın görsel veriyi anlamasına ve analiz etmesine olanak tanır. Görüntü sınıflandırma, bir görüntüdeki öğeleri tanımlayıp, onları belirli kategorilere ayırma işlemidir (Lu ve Weng, 2007). Bu süreç, tıptan güvenliğe, perakendeden otomotive kadar geniş bir yelpazede kullanılır. Örneğin, tıbbi görüntülerin analiziyle hastalıkların erken teşhisi yapılabilir, güvenlik alanında ise yüz tanıma sistemleri suçluların tespitinde kullanılabilir. Görüntü sınıflandırma teknolojisi, hızlı ve doğru veri analizi sağladığı için, insan müdahalesini azaltmakta ve verimliliği artırmaktadır. Bu nedenle, görüntü sınıflandırma, birçok endüstride verimliliği artıran, zaman kazandıran ve hatta hayat kurtaran bir teknoloji olarak büyük bir öneme sahiptir.

Aşırı öğrenme makineleri (ELM), görüntü sınıflandırma problemi için son derece etkili bir çözüm sunmaktadır çünkü bu algoritma, hızlı öğrenme süreci ve yüksek doğruluk oranlarıyla dikkat çeker. Görüntü sınıflandırma gibi büyük veri setleriyle çalışan problemler, genellikle karmaşık ve zaman alıcı olabilir. Ancak ELM, giriş ağırlıklarını rastgele belirleyerek ve sadece çıkış ağırlıklarını analitik olarak hesaplayarak, geleneksel yapay sinir ağlarından çok daha hızlı bir eğitim süreci sağlar. Bu hızlı öğrenme, özellikle büyük ve etiketlenmiş veri setlerinin bulunduğu görüntü sınıflandırma uygulamalarında zaman kazandırır ve verimliliği artırır.

Çalışmanın bu bölümü, görüntü sınıflandırmada aşırı öğrenme makinelerinin kullanımına yönelik bir literatür araştırması sunmaktadır. Bu amaç doğrultusunda, görüntü sınıflandırma üzerine yapılmış çalışmaların bulunduğu literatür detaylı bir şekilde incelenmiştir. Literatürde görüntü sınıflandırma problemlerinin çözümü amacıyla aşırı öğrenme makinelerinin kullanıldığı bazı örnek çalışmalar Tablo 1’de verilmiştir.

Literatürdeki çalışmalar incelendiğinde görüntü sınıflandırma problemlerinde aşırı öğrenme makinelerinin hız ve performans açısından geleneksel yapay sinir ağlarına kıyasla daha başarılı olduğu gözlemlendiğinden bu çalışmada aşırı öğrenme makineleri kullanılmıştır. Aşırı öğrenme makineleri birçok avantaj sağlasa da bazı sınırlandırmalarından dolayı performansını geliştirmek amacıyla bazı varyantlar geliştirilmiştir (Ding vd., 2014).

Bu çalışmada ELM’in sınıflandırma problemlerindeki başarısı çeşitli veri setlerinde test edilmiş ve performansı ELM’in literatürde sıklıkla kullanılması ve başarılı sonuçlar elde edilmiş olması sebebiyle artırılmış aşırı öğrenme makine modeli (IELM), çevrimiçi sıralı aşırı öğrenme makine modeli (OSELM), düzenlenmiş aşırı öğrenme makine modeli (RELM) ve kısıtlanmış aşırı öğrenme makine modeli (CELM) varyantları kıyaslanmıştır. Bu varyantlar, aşırı öğrenme makinelerinin özgün yapısındaki bazı zayıf noktaları gidermeyi hedeflemektedir. Özellikle, IELM modelinin daha fazla özellik ve etkileşim sağlayarak sınıflandırma doğruluğunu artırması beklenirken (Huang vd. 2007, Ding vd. 2014), OSELM çevrimiçi öğrenme süreçlerinde daha hızlı ve verimli sonuçlar elde etmek için geliştirilmiştir (Huang vd., 2005). RELM ise sınıflandırma sırasında belirli bir düzeni koruyarak hataları minimize etmeyi amaçlamaktadır (Deng vd., 2009). CELM ise kısıtlamalar altında çalışarak modelin genel performansını optimize etmek için belirli parametreler üzerinde odaklanmaktadır (Zhu vd., 2014). Literatürde aşırı öğrenme makinelerinin varyantlarının kullanıldığı bazı çalışmalar Tablo 2’de verilmiştir.

Bu literatür araştırması, görüntü sınıflandırmasında aşırı öğrenme makinesi (ELM) ve varyantlarının başarısını değerlendirmek amacıyla yapılmış çeşitli çalışmaları kapsamlı bir şekilde incelemektedir. Yapılan incelemeler, bu ELM varyantlarının, orijinal ELM’nin dezavantajlarını ortadan kaldırarak daha başarılı sonuçlar verdiğini göstermektedir. Literatürde yer alan çalışmalar, her bir varyantın farklı veri setleri ve uygulamalar üzerinde nasıl performans gösterdiğini ortaya koymuştur. Bu çalışmaların genel amacı, ELM ve onun varyantlarının sınıflandırma sorunlarında etkinliğini arttırmak ve daha iyi sonuçlar elde etmektir.

Bu bağlamda, literatüre ek kaynak sağlamak ve aşırı öğrenme makine modelinin varyantlarını kıyaslamak için bu çalışmada, daha önce birçok alanda başarılı sonuçlar elde etmiş olan standart aşırı öğrenme makinesi modeli (ELM), artımlı aşırı öğrenme makinesi modeli (IELM), çevrimiçi sıralı aşırı öğrenme makinesi modeli (OSELM), düzenlenmiş aşırı öğrenme makinesi modeli (RELM) ve kısıtlanmış aşırı öğrenme makinesi modeli (CELM) kullanılmıştır. Çalışmada, bu modellerin performansları, el yazısı rakam sınıflandırma, beyin MR görüntülerinden tümör tespiti, pirinç türü sınıflandırma ve araç sürücülerinin uyku durumlarının tespiti gibi farklı veri setleri üzerinde kıyaslanmıştır.

Çalışmada kullanılan veri setlerinin her biri, farklı kullanım alanları, sınıf sayıları, veri seti boyutları ve sınıflardaki veri dağılımı gibi çeşitli özellikler bakımından çeşitlenmiştir. Bu çeşitlilik, ELM, IELM, OSELM, RELM ve CELM modellerinin performanslarını geniş bir yelpazede incelemeyi mümkün kılmakta ve her bir modelin farklı senaryolarda nasıl değişik sonuçlar verdiğini gözler önüne sermektedir. Özellikle pirinç veri setiyle yapılan analiz, tarım alanındaki uygulamalara, tümör veri seti ile yapılan çalışmalar ise tıp alanındaki sınıflandırma ve teşhis süreçlerine katkı sağlamaktadır. Ayrıca, araç sürücülerinin uyku durumu tespiti için kullanılan veri seti, güvenlik

ve denetleme sektörlerinde önemli bir yer tutmaktadır.

Tablo 1. Literatürde aşırı öğrenme makinelerinin kullanıldığı çalışmalar (Studies in the literature using extreme learning machines)

MODEL	ÇALIŞMA	GELİŞTİRMELER	VERİ SETİ
ELM	Wang, ve Huang (Wang ve Huang, 2005)	ELM algoritması, protein dizilerinin sınıflandırılmasında kullanılmış ve geleneksel yöntemlere göre daha hızlı ve verimli sonuçlar elde edilmiştir.	Protein dizisi
ELM	Liang vd. (Liang, Saratchandran, Huang ve Sundararajan, 2006)	EEG sinyallerinden zihinsel görevlerin sınıflandırılması için ELM uygulanmıştır.	EEG Sinyalleri
ELM	Vani vd. (Vani, Savitha ve Sundararajan, 2010)	Meme kanseri teşhisi için dijital mamogramlarda ELM kullanılmış, doğruluk oranı artırılmış ve işlem süresi azaltılmıştır.	Dijital mamogram
ELM	Ouyang vd. (Ouyang, Chen, Zhao ve Lin, 2013)	Çalışmada soya sosunun kalitesi tespit edilip, veri seti belirli değişken sayısına göre bölünerek model kombinasyonları hesaplanmış ve optimize edilmiştir.	Soya sosunda bulunan amino asit azotu miktarı
ELM	Kaya (Kaya, 2014)	Çalışma dört blokta oluşmakta; ilk blokta veri toplanmış, ikinci blokta özellikler normalize edilmiş, üçüncü blokta ELM ile sınıflandırılmış ve son blokta tiroid hastalığı teşhis edilmiştir.	Tiroid hastalığı.
ELM	Sezgin (Sezgin, 2016)	Çalışmada giriş katmanı 5, gizli katmanı 25, çıkış katmanı ise 3 hücreye sahip, aktivasyon fonksiyonu olarak Sigmoid kullanılan bir ELM mimarisi oluşturularak epilepsi hastalığı sınıflandırılmıştır.	Epileptik EEG işaretleri
ELM	Lama vd. (Lama, Gwak, Park ve Lee, 2017)	MRI görüntüleri üzerinden Alzheimer teşhisi yapmak için ELM kullanılmıştır.	MRI Görüntüleri
ELM	Baran (Baran, 2019)	Su kalitesini ölçmek için belirlenen dört sınıf ELM ile sınıflandırılmıştır. Üç farklı aktivasyon fonksiyonu ve farklı nöron sayıları denenmiştir ve en iyi sonuca sine fonksiyonu ve 10 nöronla ulaşılmıştır.	Atık su numuneleri
ELM	Huang vd. (Huang, Lei, Xie, Zhang, Hu ve Zhou, 2020)	ELM kullanılarak akciğer nodülleri tespit edilmiştir	Bilgisayarlı tomografi görüntüleri
ELM	Al-Yaseen vd. (Al-Yaseen, Idrees ve Almasoudy, 2022)	Sarmalayıcı özellik seçimi yöntemi ve diferansiyel evrim algoritması ile birlikte ELM kullanılarak siber saldırılara karşı bir saldırı tespit sistemi geliştirilmiştir.	Ağ izleme verileri
ELM	Zhao ve Chen (Zhao ve Chen, 2022)	Transfer öğrenme yaklaşımı ile birlikte ELM kullanılarak uçak motorlarının arıza teşhisi yapılmıştır.	Uçak motoru verileri
ELM	Prakash vd. (Prakash, Chandan, Karthik, Devanathan, Kumar, Nagaraja ve Prasannakumara, 2023)	ELM ile dalgalı bir kanat üzerindeki termal analiz incelenmiştir.	Isıl veri setleri
ELM	Chen vd. (Chen, Li, Liu, Bai, Zhu, Gao vd., 2024)	Parçacık sürü optimizasyonu (Particle Swarm Optimization) algoritması ile birlikte ELM kullanılarak lityum-iyon pillerin sağlık durumu tahmin edilmiştir.	Pil performans verileri
ELM	Maurya vd. (Maurya, Mahapatra, Dutta, Singh, Karnati, Sahu ve Pandey, 2024)	Çalışmada görüntülerin uzamsal özelliklerini öğrenen Spatial ve görüntüleri frekans alanına çevirerek dokusal desenleri öğrenen FFT autoencoder'leri ile cilt lezyonlarından özellikler çıkarılmış, bu özellikler ELM ile işlenerek cilt kanseri teşhisi yapılmıştır.	HAM10000 ISIC-2017
ELM	Wang vd. (Wang, Li, Zhang, Yin, Zhang, Shi ve Men, 2025)	Küresel uzantılı ELM ile elektrikli yangınların erken uyarı sistemleri için bir gaz algılama sistemi geliştirilmiştir.	Gaz sensör verileri

Bu çalışma, kullanılan veri setleri ve farklı alanlardaki uygulamalarla, literatüre önemli katkılar sunmayı ve aşırı öğrenme makinesi yöntemlerinin farklı sektörlerdeki potansiyelini vurgulamayı hedeflemektedir. ELM ve varyantlarının başarısı, her bir modelin farklı özellikleri ve performansları üzerinden değerlendirildiğinde, bu modellerin gelecekteki sınıflandırma ve veri analizi uygulamalarında etkin bir şekilde kullanılabileceği görülmektedir.

Tablo 2. Literatürde aşırı öğrenme makine modeli varyantlarının kullanıldığı çalışmalar (Studies in the literature using extreme learning machine model variants)

MODEL	ÇALIŞMA	GELİŞTİRMELER	VERİ SETİ
OSELM	Chacko vd. (Chacko, Vimal Krishann, Raju ve Babu Anto, 2012)	Çalışmada el yazısı Malayalam karakterlerinin tanınması için OSELM kullanılmıştır. Gizli nöronların optimal sayısını belirlemek için deneyler yapılmış ve en iyi sonuç 1200 gizli nöronla elde edilmiştir.	El yazısı Malayalam karakterleri
RELM	Iosifidis vd. (Iosifidis, Teflas ve Pitas, 2015)	Çalışmada, RELM'in büyük ölçekli medya analizindeki performansı incelenmiş ve giriş verilerindeki bozulmalarla ağır çıkış ağırlıkları hesaplanmıştır.	Yüz görüntüleri
CELM	Zhu vd. (Zhu, Miao ve Qing, 2015)	Çalışmada beş farklı CELM modeli geleneksel ELM, SVM ve diğer modellerle karşılaştırılmıştır.	CIFAR-10 MNIST UCI
OSELM	Anam ve Al-Jumaily (Anam ve Al-Jumaily, 2015)	Sistem, iki EMG sensör verisiyle 10 parmak hareketini sınıflandırmakta ve OS-ELM'in başlatma ve sıralı öğrenme fazlarıyla 110 gizli nöronla optimize edilmiştir.	Parmak hareketleri
IELM	Lazarevska (Lazarevska, 2016)	Klasik IELM'yi modifiye ederek her yeni nöron eklendiğinde tüm çıkış parametrelerinin yeniden hesaplanması önerilmiştir.	Rüzgar hızı
OSELM	Lu vd. (Lu, Wang, Wu ve Wang, 2016)	Sistemde özellik çıkarımı dalgacık dönüşümüyle, özellik indirgeme dalgacık entropisiyle yapılmış ve patolojik beyin tespiti için OSELM kullanılmıştır.	Beyin MR görüntüleri
IELM	Guangyu vd. (Guangyu, Shaoping ve Jieato, 2017)	Stratosferik zeplinlerin sabit kalabilmesi için rüzgar hızı tahmini yapılmış, faz uzayı yeniden yapılandırmasıyla doğrusal olmayan seri analiz edilmiştir. Yığın yöntemiyle eğitim örnekleri güncellenmiş ve IELM modeliyle gizli katman düğüm sayısı otomatik olarak ayarlanmıştır.	Rüzgar hızı
RELM	He vd. (He, Kang, Yao ve Li, 2019)	Yüz tanıma için Genetik Algoritma ile optimize edilmiş RELM kullanılmıştır.	ORL
RELM	Gumaei vd. (Gumaei, Hassan, Alelaiwi ve Fortino, 2019)	MR görüntüleri Gabor filtresi ile işlenip PCA ile en önemli özellikler seçilmiş ve ardından RELM sınıflandırıcısı ile beyin tümörleri üç sınıfa ayrılmıştır.	Beyin MR görüntüleri
CELM	Wong vd. (Wong, Yap ve Li, 2020)	ELM algoritmasının çıktılarını doğrudan olasılık olarak yorumlanabilir hale getirmek için olasılıksal çıktı kısıtlı optimizasyonlu aşırı öğrenme makinesi (CPP-POELM) modeli geliştirilmiş ve model ELM, CELM gibi modellerle kıyaslanmıştır.	Diyabet Kolon kanseri Muz vd.
OSELM	Al-Dhief vd. (Al-Dhief, Baki, Latiff, Malik, Salim, Albader ve Mohammed, 2021)	Çalışmada ses patolojilerinin Mel-Frekans Cepstral Katsayıları yöntemi ile özellikleri çıkarılmıştır. Ardından ses patolojileri OSELM ile dört sınıfa ayrılmıştır.	Saarbücken ses veritabanı
IELM	Malik vd. (Malik, Anees, Naeem, Naqvi ve Loh, 2023)	Çalışmada, akciğer CT taramalarından enfeksiyon özellikleri CapsNet ile çıkarılmış, ardından IELM ile işlenerek COVID-19 teşhisi yapılmıştır.	CT Taraması
RELM	Walid vd. (Walid, Mallick, Rastogi, Chauhan ve Vidy, 2023)	Çalışmada, deri lezyonlarının dermoskopik görüntülerinin özellikleri CNN ile çıkarılmış, ardından bu özellikler RELM'e aktarılıp görüntüler iki sınıfa ayrılmıştır.	Dermoskopik görüntüler
CELM	Serin vd. (Serin, Karakuzu, Yüzgeç, 2024)	Çalışmada Meta-ELM ve CELM modelleri kullanılarak Meta-Constrained ELM adında hibrid bir model geliştirilmiş ve geliştirilen bu model 10 farklı veri setinde uygulanarak performansı ELM, CELM gibi modellerle kıyaslanmıştır.	MNIST Fashion MNIST Diyabet Kuru fasulye vd.
OSELM	Albadr vd. (Albadr, Al-Dhief, Man, Arram, Abbas ve Homod, 2024)	Çalışmada, meme kanserini iyi ve kötü huylu sınıflandırmak için OSELM algoritması kullanılmış, tümör özellikleri girişte, rastgele ağırlık ve bias değerleri gizli katmanda, sınıflandırma ise çıktı katmanında yapılmıştır.	WDBC WBCD
RELM	Hameed vd. (Hameed, Razali, Mohtar, Alsaydani ve Yaseen, 2024)	Çalışmada, kuraklık tahmini için RELM algoritması kullanılmış ve modelin ağırlık, bias ve düzenleme parametreleri Snake Optimizer ile optimize edilmiştir.	Akarsu akışı

3. Materyal ve Yöntem (Material and Method)

Çalışmada MNIST, beyin MR görüntüleri, pirinç görüntüleri ve araç sürücüsü uyku durumu olmak üzere 4 adet veri seti sınıflandırma yapmak amacıyla kullanılmıştır. Her bir veri setinde sınıflandırma, standart aşırı öğrenme makine modeli, artırılmış aşırı öğrenme makine modeli, çevrimiçi sıralı aşırı öğrenme makine modeli, düzenlenmiş aşırı öğrenme makine modeli ve kısıtlanmış aşırı öğrenme makine modeli kullanılarak yapılmıştır. Bu bölümün devamında kullanılan aşırı öğrenme makine modellerinin detayları, kullanılan veri setleri ve modellerin kıyaslamasında kullanılan metriklere yer verilmektedir.

3.1. Kullanılan Modeller-ELM ve onun türevleri (Used Models-ELM and its variants)

Aşırı öğrenme makineleri (ELM), tek gizli katmanlı, ileri beslemeli bir yapay sinir ağı modelidir. ELM'in temel özelliği, klasik yapay sinir ağlarından farklı olarak, gizli katmandaki ağırlıkları rastgele belirleyip sabit tutması ve yalnızca çıkış katmanındaki ağırlıkları öğrenmesidir. Bu yaklaşım, eğitim sürecini büyük ölçüde hızlandırır ve modelin verimli bir şekilde öğrenmesini sağlar. ELM'nin yapısında giriş katmanından gizli katmana, oradan da


çıkış katmanına geçiş vardır. Gizli katmandan çıkan çıkışlar genellikle bir aktivasyon fonksiyonu kullanılarak hesaplanır (Huang vd., 2004). Gizli katman çıkış matrisi Eşitlik (1)'de verildiği şekilde ifade edilir.

$$(h(x) = g(Wx + b)) \quad (1)$$

Burada $(h(x))$ gizli katmandaki çıkış, $(g(\cdot))$ aktivasyon fonksiyonu (örneğin, sigmoid veya ReLU), (W) gizli katmandaki ağırlıklar, (x) giriş verisi, (b) ise bias terimidir. Çıkış katmanındaki sonuç Eşitlik (2)'deki gibi ifade edilir.

$$\beta = H^+T \quad (2)$$

Burada (β) çıkış katmanındaki ağırlık matrisi, (H^+) H matrisinin Moore-Penrose genelleştirilmiş tersi, (T) ise hedef çıktı matrisidir. ELM, özellikle hızlı eğitim süresi ve basit yapısı ile öne çıkar. Ancak, gizli katman ağırlıklarının rastgele seçilmesi, bazen modelin performansını etkileyebilir. Bu nedenle, hiperparametrelerin dikkatlice seçilmesi ve modelin uygun veri setleriyle test edilmesi önemlidir. Şekil 1'de genel bir ELM mimarisi gösterilmiştir.



Şekil 1. ELM Mimarisi (ELM Architecture) (GeeksforGeeks, 2025)

Artımlı aşırı öğrenme makinelerinde (IELM) ilk olarak yalnızca birkaç gizli katman nöronu belirlenir. Daha sonra eğitim aşamasında, algoritma, önceden belirlenen maksimum gizli katman nöron sayısına ulaşınca kadar gizli katmana rastgele bir nöron ekler. Bu süreç, her yeni eklenen nöronun çıktısı ile önceki nöronların çıktılarının birleşimini kullanarak modeli geliştirmeye devam eder. Bu sayede yalnızca yeni eklenen nöron ile çıktı katmanı arasındaki bağlantı ağırlıkları hesaplanır. Diğer tüm ağırlıklar sabit tutulur, çünkü IELM, modelin genel yapısını değiştirmeden yalnızca yeni nöronlar ekleyerek öğrenmeye devam etmeyi amaçlar. Bu yöntem, eğitim sürecinde zamanla daha verimli hale gelmesini sağlar, çünkü eklenen her yeni nöron yalnızca çıktıyı iyileştirmek için kullanılır ve modelin karmaşıklığı kontrol altında tutulur (Huang vd., 2007, Ding vd., 2014).

Çevrimiçi sıralı aşırı öğrenme makineleri (OSELM), standart aşırı öğrenme makinesi (ELM) algoritmasında karşılaşılan verimlilik sorunlarını çözmek amacıyla geliştirilmiştir. Standart ELM, tüm eğitim verisi üzerinde tekrarlı eğitim yapar. Ancak, bu yaklaşım büyük veri setlerinde zaman ve işlem kaybına yol açar, çünkü her yeni veri eklendiğinde tüm veri seti tekrar üzerinden geçilir ve model yeniden eğitilir. Bu durum, büyük verilerle çalışırken verimlilik problemleri yaratabilir ve eğitim sürecini oldukça yavaşlatabilir. OSELM, yalnızca yeni gelen verilerin kullanarak modelin güncellenmesini sağlayarak, daha hızlı ve verimli bir eğitim süreci sunar. Bu yöntemde, önceki verilerle yapılan hesaplamalar sabit tutulur ve yalnızca yeni gelen verilerin etkisiyle modelin ağırlıkları güncellenir. Böylece, büyük veri setleri üzerinde daha hızlı bir şekilde öğrenme gerçekleştirilir ve işlem yükü önemli ölçüde azaltılır. OSELM, özellikle zamanla değişen veri akışları veya sürekli öğrenme gerektiren uygulamalarda oldukça kullanışlıdır. Bu yaklaşım, daha az bellek ve işlem gücü gerektirerek, gerçek zamanlı öğrenme ve güncelleme imkanı sunar (Huang vd., 2005).

Düzenlenmiş aşırı öğrenme makineleri (RELM), standart aşırı öğrenme makinelerinin (ELM) bir geliştirmesi olarak ortaya çıkmıştır ve modelin aşırı öğrenmesini engellemek amacıyla ağırlık düzenleme tekniklerini kullanır. Standart aşırı öğrenme makinesi modeli, gizli katmandaki nöronların ağırlıklarını rastgele atar ve çıktı katmanındaki ağırlıkları en küçük kareler yöntemiyle çözer. Ancak bu basit yaklaşım, özellikle karmaşık ve büyük veri setleriyle çalışırken aşırı öğrenmeye (overfitting) yol açabilir. Aşırı öğrenme, modelin eğitim verilerine çok iyi

uyum sağlasa da, yeni ve görülmemiş veriler üzerinde zayıf performans göstermesine sebep olabilir. RELM, bu problemi çözmek için çeşitli düzenleme yöntemleri kullanır. Bu düzenleme teknikleri, modelin öğrenme sürecinde aşırı uyumu (overfitting) engellemeye ve daha genelleştirilebilir bir model elde etmeye yardımcı olur. RELM, özellikle çıktı katmanındaki ağırlıkları hesaplamak için L2 normu, L1 normu, gradyan bazlı yöntemler veya erken durdurma gibi farklı düzenleme tekniklerini uygulayarak, modelin genelleme yeteneğini artırır. Bu düzenleme yöntemleri, modelin daha düşük bir hata oranıyla ve daha sağlam bir performansla yeni veriler üzerinde çalışmasına olanak tanır. RELM, modelin hem eğitim verilerine iyi uyum sağlamasını hem de yeni verilere karşı daha sağlam ve güvenilir performans göstermesini sağlar. Ayrıca, bu tür düzenlemeler modelin daha az karmaşık olmasına da yardımcı olur, bu da daha hızlı eğitim süreçleri ve daha düşük hesaplama gereksinimleri anlamına gelir. RELM, özellikle küçük veri setlerinde, gürültülü verilerle çalışırken veya çok fazla parametreyle karşılaşılan durumlarda etkili bir çözüm sunar. Sonuç olarak, RELM, modelin genelleme yeteneğini artırırken, aşırı öğrenme sorununu minimize eder ve daha güvenilir tahminler yapılmasına olanak tanır (Deng vd., 2009).

Kısıtlanmış aşırı öğrenme makineleri (CELM), geleneksel ELM'in rastgele gizli katman ağırlık seçiminden kaynaklanan verimsizliklerini gidermek için geliştirilmiş bir yaklaşımdır (Zhu vd., 2014). ELM, hızlı öğrenme kabiliyetiyle bilinir ancak iyi genelleme yapabilmesi için çok sayıda gizli nörona ihtiyaç duyar, bu da test sürecinde verimsizliğe neden olur. CELM, gizli düğümleri tamamen rastgele seçmek yerine, örnek dağılımına dayalı olarak belirli kısıtlar altında seçerek bu sorunu çözmeyi hedefler. CELM, farklı yöntemler kullanarak gizli katmandaki düğümleri belirler.

Kısıtlanmış toplam aşırı öğrenme makineleri (CSELM), aynı sınıfa ait iki örneğin toplam vektörlerini kullanarak gürültüye daha dayanıklı özellikler çıkarır. Örnek aşırı öğrenme makineleri (SELM), eğitim kümesindeki örnekleri doğrudan gizli katman ağırlıkları olarak kullanır ve bu örnek vektörleri normalize edilerek modele bağlanır (Zhu vd., 2014). Rastgele toplam aşırı öğrenme makineleri (RSELM), rastgele seçilen örneklerin toplam vektörlerini kullanarak hesaplama hızını artırır (Zhu vd., 2014). Kısıtlanmış karışık aşırı öğrenme makineleri (CMELM) ise hem fark vektörlerini hem de toplam vektörlerini içeren hibrit bir yaklaşım sunarak CDELM ve CSELM'in avantajlarını birleştirir (Zhu vd., 2014).


Kısıtlanmış fark aşırı öğrenme makineleri (CDELM), fark vektörlerini kullanarak sınıflar arası ayrımı artırmayı amaçlar. Rastgele ağırlıklar yerine, farklı sınıflara ait örnekler arasındaki fark vektörleri seçilir ve böylece daha ayırtıcı özellikler elde edilir. Fark vektörü kullanılarak ağırlıkların oluşturulması Eşitlik (3)'de verilen formüle göre gerçekleşir.

$$W = \alpha(X_c^u - X_c^l) \quad (3)$$

Burada, X_c^l ve X_c^u farklı sınıflardan rastgele seçilen iki örnek, α ise normalizasyon faktörüdür (Zhu vd. 2014). Bu çalışmada Serin vd'nin (2024) yaptığı çalışmada elde edilen başarılı sonuçlardan dolayı CDELM modeli tercih edilmiştir (Serin vd. 2024).

3.2. Kullanılan Veri Setleri (Used Datasets)

El yazısı ile yazılmış rakamları sınıflandırmak amacıyla MNIST veri setinden elde edilen 70.000 el yazısı görüntüsü 0-9 arası rakamlar olmak üzere 10 sınıfa ayrılmıştır. MNIST veri setindeki sınıf dağılımı tamamen dengeli değildir; eğitim verisinde sınıf başına düşen örnek sayısı yaklaşık 5400 ila 6700 arasında, test verisinde ise 900 ila 1100 arasındadır. MNIST veri setine ait 10 sınıfa ait görüntü örnekleri Şekil 2'de verilmiştir.




Şekil 2. MNIST veri setindeki sınıflara ait görüntüler (Images of classes in the MNIST dataset)


Beyin tümörlerinin türlerini belirlemek amacıyla Figshare, SARTAJ ve Br35H isimli üç farklı veri setinin birleştirilmesiyle elde edilen 7023 beyin MR görüntüsü üzerinde glioma, meningioma, tümörsüz ve hipofiz olmak üzere 4 sınıfa ayrılmıştır. Eğitim verisi içi glioma sınıfına ait 1322, meningioma sınıfına ait 1340, tümörsüz sınıfına ait 1596, hipofiz sınıfına ait ise 1458 görüntü bulunmakta olup her sınıfta farklı sayıda görsel bulunmaktadır (Masoudnickparvar, 2023). Tümör veri setine ait 4 sınıfa ait görüntü örnekleri Şekil 3'de verilmiştir.

Pirinç türlerini sınıflandırmak amacıyla 5 adet sınıfın her birinden 15.000 görüntü olacak şekilde toplamda 75.000 pirinç görüntüsü sınıflara eşit şekilde dağılmış ve pirinçler Arborio, Basmati, Ipsala, Jasmine ve Karacadağ olmak üzere 5 sınıfa ayrılmıştır (Soroush, 2024). Pirinç veri setine ait 5 sınıfa ait görüntü örnekleri Şekil 4'de verilmiştir.

Araç sürücülerinin uykulu olma durumlarını tespit etmek amacıyla gerçek hayatta uykulu olma veri setindeki videolardan, araç sürücülerinin yüzlerinin çıkarılıp kırılmış halini içeren bir veri seti kullanılmıştır. 41.796 adet araç sürücü görüntüsü uykulu ve uyanık olmak üzere 2 sınıfa ayrılmıştır. Uykulu sınıfında 22.349, uyanık sınıfında ise 19.446 görsel bulunmaktadır ve görüntüler sınıflara eşit şekilde ayrılmamıştır (Nasri, 2023). Araç sürücü uyku durumu veri setine ait 2 sınıfa ait görüntü örnekleri Şekil 5'de verilmiştir. Tüm veri setlerine ait temel özellikler Tablo 3'de sunulmuştur.



Şekil 3. Tümör veri setindeki sınıflara ait görüntüler (Images of classes in the tumor dataset)



Şekil 4. Pirinç veri setindeki sınıflara ait görüntüler (Images of classes in the rice dataset)



Şekil 5. Araç sürücüsü uyku durumu veri setindeki sınıflara ait görüntüler (Images of classes in the driver drowsiness dataset)

Tablo 3. Kullanılan veri setlerinin özellikleri (Characteristics of the data sets used)

Veri Seti	Sınıf Sayısı	Toplam Görsel Sayısı	Eğitim/Test Dağılımı	Sınıflar Arası Dağılım
MNIST	10	70.000	%80 Eğitim / %20 Test	Dengesiz (5400-6700 eğitim, 900-1100 test)
Beyin MR Görüntüleri	4	7023	%80 Eğitim / %20 Test	Dengesiz (1322-1596 eğitim, 300-400 test)
Pirinç Görüntüleri	5	75.000	%80 Eğitim / %20 Test	Dengeli (Her sınıf için 15.000)
Araç Sürücüsü Uyku Durumu	2	41.796	%80 Eğitim / %20 Test	Dengesiz (Uykulu: 22.349, Uyanık: 19.446)

3.3. Performans Değerlendirme Kriterleri (Performance Evaluation Criteria)

Çalışmada kullanılan görüntü sınıflandırma modellerinin değerlendirilmesi için hassasiyet, geri çağırma, F1 puanı metrikleri kullanılmıştır. Bu ölçütlerin hesaplanabilmesi için karmaşıklık matrisinde Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP), Yanlış Negatif (YN) verilerine ihtiyaç duyulmaktadır. Bu verilerden DP; gerçek pozitif örneklerin doğru bir şekilde pozitif olarak tahmin edilmesi, DN; gerçek negatif örneklerin doğru bir şekilde negatif olarak tahmin edilmesi, YP; gerçek negatif örneklerin yanlış bir şekilde pozitif olarak tahmin edilmesi, YN; gerçek pozitif örneklerin yanlış bir şekilde negatif olarak tahmin edilmesi olarak tanımlanmaktadır (Goutte ve Gaussier, 2005). Elde edilen bu değerler sayesinde hassasiyet (Precision, P), geri çağırma (Recall, R), F1-puanı (F1) değerleri Eşitlik (4-6)'da gösterildiği şekilde hesaplanmaktadır.

$$P = \frac{DP}{DP + YP} \quad (4)$$


$$R = \frac{DP}{DP + YN} \quad (5)$$

$$F1 = 2x \frac{P \times R}{P + R} \quad (6)$$

4. Deneysel Sonuçlar (Experimental Results)

Çalışmanın bu bölümünde dört farklı veri setinden elde edilen görüntüler ELM, IELM, OSELM, RELM, CELM modelleri ile yapılan sınıflandırma işlemi sonucunda elde edilen sonuçlar karşılaştırmalı olarak sunulmaktadır. Modellerin uygulanması için 256 GB disk, macOS Monterey 12.0.1 işletim sistemi, 8 GB belleğe ve Apple M1 işlemciye sahip bir bilgisayar kullanılmıştır. Python ortamı ve paketlerin yönetilmesi için Anaconda-Navigator kullanılmıştır. Veri setinin %80'i eğitim, %20'si ise test için rastgele olarak iki kısma ayrılmıştır. Test veri seti model performansını değerlendirirken kullanılmıştır.

Önerilen sınıflandırma yöntemlerinin her biri, veri yükleme, veri arttırma, model oluşturma, model eğitimi ve model değerlendirmesi olmak üzere beş temel adımdan oluşmaktadır. Eğitim ve test veri setlerindeki görüntülerin boyutları 64x64 olarak ayarlanmıştır. Var olan görüntülere veri arttırma yöntemleri uygulanmıştır. Arttırılmış veriler standart aşırı öğrenme makine modeli, arttırılmış aşırı öğrenme makine modeli, çevrimiçi sıralı aşırı öğrenme makine modeli, düzenlenmiş aşırı öğrenme makine modeli ve kısıtlanmış aşırı öğrenme makine modeli kullanılarak eğitilmiştir. Elde edilen sonuçlar hassasiyet, geri çağırma ve F1 puanı metrikleri ile kıyaslanmıştır. Çalışmada kullanılan bütün modeller için gizli nöron sayısı 1000 ve aktivasyon fonksiyonu ise Sigmoid olarak belirlenmiştir. Standart ELM modeline ait her bir veri seti için karmaşıklık matrisleri (confusion matrix) Şekil 6'da gösterilmiştir.



Şekil 6. ELM modeline ait karmaşıklık matrisleri (Confusion matrices of the ELM model)

Şekil 6’da verilen karmaşıklık matrisleri her bir modelin sınıflandırma doğruluğunu ve hatalı sınıflandırma oranlarını detaylı bir şekilde göstererek, modellerin karşılaştırılmasında önemli bir rol oynamaktadır. Modellerin performansındaki farklılıklar, kullanılan veri artırma tekniklerinin ve model varyantlarının etkililiğini daha iyi anlamamıza yardımcı olmaktadır. Bu bölümde sunulan sonuçlar, önerilen ELM modelinin çeşitli veri setleri üzerindeki başarılarını kapsamlı bir şekilde incelemektedir.

Kullanılan tüm modellerin başarımlarının daha iyi kıyaslanabilmesi için en çok kullanılan metrikler üzerinde kıyaslamalar yapılmıştır. Tablo 4’de MNIST veri seti için modellerin hassasiyet, geri çağırma ve F1 skor sonuçları verilmiştir. En iyi skora sahip model metrikleri koyu ile gösterilmiştir.

Tablo 4. MNIST veri seti için modellerin performans karşılaştırmaları (Performance comparisons of models for the MNIST dataset)

Model	Hassasiyet	Geri Çağırma	F1-Skoru
ELM	0.8926	0.8928	0.8923
IELM	0.8729	0.8726	0.8715
OSELM	0.9386	0.9387	0.9386
RELM	0.9318	0.9320	0.9318
CELM	0.9547	0.9548	0.9547

Tablo 4’teki metrik sonuçları incelendiğinde 10 sınıfa ait sınıflarda eşit sayıda görüntü bulunmayan MNIST veri seti için en yüksek başarıya sahip sonucu kısıtlatmalı aşırı öğrenme makinesi (CELM) modelinin, en düşük başarıya sahip modelin ise artımlı aşırı öğrenme makine modeli (IELM) olduğu gözlemlenmiştir. Bu sonuçlara göre CELM modeli fazla sınıf sayısına sahip veriler için başarılı sonuçlar göstermektedir.

Tablo 5'te verilen metrik sonuçlarına göre sınıflara eşit dağılım göstermeyen 4 sınıflı tümör veri seti için en yüksek başarımlı CELM ve en düşük başarımlı ise IELM modeline aittir. Tümör sınıflandırma gibi hayati öneme sahip bir konuda hızlı ve yüksek performansa sahip CELM modelinin kullanılması bu alanda çalışan sağlık çalışmalarına büyük katkı sağlayacaktır.

Tablo 5. Tümör veri seti için modellerin performans karşılaştırmaları (Performance comparisons of models for the tumor dataset)

Model	Hassasiyet	Geri Çağırma	F1-Skoru
ELM	0.7805	0.7895	0.7796
IELM	0.7047	0.7170	0.7006
OSELM	0.7261	0.7384	0.7257
RELM	0.7750	0.7849	0.7727
CELM	0.8521	0.8551	0.8528

Her sınıfta eşit sayıda görüntünün bulunduğu 5 sınıflı pirinç veri seti için Tablo 6'da verilen metrik kıyaslamasına göre en yüksek performansı gösteren model CELM, en düşük performansı gösteren model ise IELM modeli olmuştur. Bu sonuçlara göre tarım ürünlerinin sınıflandırılmasına CELM modelinin kullanımı bu sektöre büyük katkılar sağlayabilir.

Tablo 6. Pirinç veri seti için modellerin performans karşılaştırmaları (Performance comparisons of models for the rice dataset)

Model	Hassasiyet	Geri Çağırma	F1-Skoru
ELM	0.9202	0.9195	0.9190
IELM	0.8507	0.8432	0.8350
OSELM	0.9022	0.9023	0.9018
RELM	0.9243	0.9237	0.9233
CELM	0.9362	0.9348	0.9345

Tablo 7'de verilen metriklere göre 2 sınıflı araç sürücüsü uyku durumu veri setine göre başarımlı oranı en yüksek olan model CELM olmuş olup, en düşük başarımlı olan model yine IELM olmuştur. Tablo 4-7'de verilen performans metriklerinin kıyaslamalarına göre çalışmada kullanılan bütün veri setleri için CELM en iyi sonuçlara sahip model olmuştur. Gerek ikili gerekse çoklu sınıflandırmada en yüksek başarımlı göstermesinden dolayı kullanılan veri setinin yapısı fark etmeksizin görüntü sınıflandırma problemlerinde CELM modelinin kullanımının pozitif sonuçlar doğuracağı değerlendirilmektedir. CELM modelinin, özellikle sınıflar arası dengesizliklerin ve veri setindeki çeşitliliğin etkili bir şekilde yönetilmesi sayesinde, daha kararlı ve doğru sonuçlar elde edilmesini sağladığı söylenebilir. Modelin sınıf kısıtlamaları ve denetimli öğrenme süreçleri, daha karmaşık veri setlerinde bile yüksek doğrulukla sonuçlar vermesine olanak tanımaktadır. Bu da CELM modelinin farklı veri setlerine uyum sağlayabilme kapasitesini güçlendirmekte ve görüntü sınıflandırma gibi önemli alanlarda tercih edilmesini haklı çıkaran bir faktör olarak öne çıkmaktadır.

Tablo 7. Araç sürücüsü uyku durumu veri seti için modellerin performans karşılaştırmaları (Performance comparisons of models for the driver drowsiness dataset)

Model	Hassasiyet	Geri Çağırma	F1-Skoru
ELM	0.9474	0.9474	0.9474
IELM	0.8350	0.8004	0.8001
OSELM	0.9174	0.9174	0.9173
RELM	0.9478	0.9478	0.9478
CELM	0.9624	0.9624	0.9624

Öte yandan, çalışmada kullanılan dört veri seti için de en düşük performansı gösteren IELM modelinin görüntü sınıflandırma gibi hassas bir konuda kullanılmasının uygun olmadığı görüşüne varılmaktadır. IELM modelinin düşük performans göstermesi, özellikle sınıf dengesizliği ve veri çeşitliliği yüksek olan durumlarda modelin yeterli

doğruluğu sağlayamadığını ortaya koymaktadır. Bu model, daha sınırlı veri setlerinde veya daha homojen yapıya sahip verilerle çalıştığında belki daha iyi sonuçlar verebilirken, özellikle daha karmaşık ve çeşitlendirilmiş veri setlerinde genellikle yetersiz kalmaktadır. IELM'nin başarısızlığı, modelin veriye uyum sağlama ve sınıflar arasındaki ince farkları öğrenme kapasitesinin sınırlı olmasından kaynaklanıyor olabilir. Bu nedenle, görüntü sınıflandırma gibi hassas ve kritik görevlerde IELM modelinin kullanılmasından kaçınılması gerektiği sonucuna varılmaktadır.

Genel olarak değerlendirildiğinde, CELM modeli tüm veri setlerinde en yüksek başarıyı göstermiştir. Özellikle sınıf sayısı fazla olan veya dengesiz dağılım içeren veri setlerinde (örneğin MNIST ve Araç Sürücüsü Uyku Durumu), CELM'nin veri setinin örnek dağılımına bağlı çalışmasının avantajı ortaya çıkmıştır. IELM modeli ise büyük ve karmaşık veri setlerinde düşük performans göstermiş, ancak küçük ve dengeli veri setlerinde (örneğin Pirinç Görüntüleri) daha iyi sonuçlar verebileceği gözlemlenmiştir. RELM ve OSELM modelleri orta düzeyde performans göstermişlerdir; özellikle RELM, tıbbi görüntüleme gibi kritik alanlarda iyi sonuçlar vermiştir. ELM modeli ise basit yapısı sayesinde hızlı eğitim sürelerine sahip olmasına rağmen, sınıflar arası dengesizlik ve karmaşıklık arttığında performansı düşmektedir.

Sonuç olarak, CELM'nin üstün performansı, onu geniş bir uygulama alanı için ideal bir model haline getirmektedir. Aynı zamanda, IELM modelinin sınırlı verilerle daha başarılı sonuçlar verebileceği düşünülebilir ancak, veri çeşitliliği ve karmaşıklığı arttıkça, daha güçlü ve esnek modellerin tercih edilmesi gerektiği ortaya çıkmaktadır. Bu çalışma, farklı model varyantlarının veri setlerine olan uyumunu ve performansını değerlendirerek, hangi modellerin hangi tür problemlerde daha etkili olacağını anlamamıza önemli katkılarda bulunmaktadır.

Genel olarak yüksek doğruluk elde eden modeller arasında performans açısından yalnızca küçük farklar bulunduğundan, eğitim süresi daha kısa olan modellerin tercih edilmesi daha uygun görülmektedir. Modellerin eğitim sürelerine ilişkin karşılaştırma, saniye cinsinden olmak üzere Tablo 8'de sunulmuştur.

Tablo 8. Modellerin eğitim sürelerinin saniye türünden karşılaştırması (Comparison of training times of models in seconds)

Veri Seti	ELM	IELM	OSELM	RELM	CELM
MNIST	3.15	10.50	10.55	1.87	1.78
Tümör	3.18	106.25	2.68	2.57	2.72
Pirinç	10.18	437.87	28.33	30.31	221.67
Araç Sürücüsü Uyku Durumu	6.23	116.91	15.64	9.96	77.47

Tabloya göre, farklı modellerin eğitim süreleri incelendiğinde, her bir modelin veri setlerine göre farklı performanslar sergilediği görülmektedir. CELM modeli, özellikle MNIST veri setinde en kısa eğitim süresine sahip olup (1.78 saniye), diğer modellere kıyasla daha hızlı eğitim süreci sunmaktadır. Bu, CELM'nin bu veri setine daha verimli uyum sağladığını gösteriyor. Diğer yandan, IELM modeli tüm veri setlerinde en uzun eğitim sürelerine sahip olup, özellikle MNIST (10.50 saniye) ve Tümör (106.25 saniye) gibi veri setlerinde dikkat çeken bir şekilde uzun süreler almıştır. IELM'nin karmaşık yapısı ve parametre ayarlamaları, eğitim süresini uzatan faktörler arasında yer almaktadır. OSELM ve RELM ise genellikle orta seviyede eğitim sürelerine sahip olup, bazı veri setlerinde daha hızlı çalışırken, diğerlerinde daha uzun süreler gerektirebilmektedir. OSELM, Tümör veri setinde (2.68 saniye) oldukça hızlı bir eğitim süresi gösterirken, RELM özellikle Uyku veri setinde (9.96 saniye) verimli bir performans sergilemiştir. ELM modeli ise tüm veri setlerinde genellikle kısa eğitim süreleri sunarak (örneğin, MNIST veri setinde 3.15 saniye), daha basit yapısının avantajını kullanarak verimli çalışmaktadır. Genel olarak, CELM modeli daha küçük ve yapılandırılmış veri setlerinde hızlı sonuçlar verirken, IELM gibi daha karmaşık modeller büyük ve karmaşık veri setlerinde daha uzun eğitim süreleri gerektirmektedir. Bu, her modelin kendi yapısına ve veri setinin özelliklerine göre verimli çalıştığını gösteren önemli bir bulgudur.

Literatürdeki farklı sınıflandırma yöntemleriyle elde edilen doğruluk oranları ve bu çalışma kapsamında elde edilen CELM modelinin başarımları Tablo 9'da özetlenmiştir. Bu karşılaştırma, CELM modelinin MNIST veri seti üzerinde oldukça yüksek doğrulukla çalıştığını ve farklı makine öğrenme modelleri arasında öne çıktığını göstermektedir.

Tablo 9. MNIST veri seti için en iyi ELM varyantı (CELM) ile literatürden alınan bazı modellerin karşılaştırılması (Comparison of the best ELM variant (CELM) with some models from the literature for the MNIST dataset)

Model	Doğruluk
Decision Tree Classifier (Xiao vd., 2017)	0.8730
Extra Tree Classifier (Xiao vd., 2017)	0.8060
Linear SVC (Xiao vd., 2017)	0.9170
KNeighbors Classifier [Xiao et al., 2017]	0.9590
Passive Aggressive Classifier (Xiao vd., 2017)	0.8770
SGD Classifier (Xiao vd., 2017)	0.9140
Perceptron (Xiao vd., 2017)	0.8870
Gradient Boosting Classifier (Xiao vd., 2017)	0.9690
CELM (En iyi ELM varyantı)	0.9547

Tablo 9’da sunulan karşılaştırmalar, bu çalışmanın literatüre önemli bir katkı sağladığını açıkça göstermektedir. Özellikle, CELM modelinin MNIST veri seti üzerinde elde ettiği %95.47 doğruluk değeri, literatürde bildirilen birçok geleneksel makine öğrenmesi ve derin öğrenme modeliyle rekabetçi bir performans sergilemektedir. Çalışmamızın özgünlüğü, ELM ve varyantlarının farklı yapıdaki veri setlerinde kapsamlı bir şekilde test edilmesiyle ortaya çıkmaktadır. Literatürde genellikle tek bir veri seti veya belirli bir uygulama alanı üzerinde odaklanılırken, bu çalışma dört farklı veri seti (MNIST, beyin MR görüntüleri, pirinç türü sınıflandırma ve araç sürücüsü uyku durumu) kullanarak modellerin genelleştirilebilirliğini değerlendirmiştir. Ayrıca, IELM modelinin düşük performansının nedenleri detaylı bir şekilde analiz edilmiş ve bu modelin büyük ve heterojen veri setlerinde sınırlı kaldığı tespit edilmiştir. Bu bulgular, gelecekteki araştırmalar için yeni ipuçları sunmaktadır. Çalışmanın bir diğer önemli katkısı ise, özellikle karmaşık ve dengesiz veri setlerinde CELM modelinin üstün performans göstermesidir. Bu, sınıf kısıtlamalarının ve düzenlenmiş öğrenme süreçlerinin etkinliğini vurgulamakta ve bu modelin farklı disiplinlerde tercih edilmesini sağlamaktadır.

5. Sonuç ve Tartışma (Result and Discussion)

Bu çalışmada, aşırı öğrenme makine modelleri (ELM) ve geliştirilmiş varyantları olan IELM, OSELM, RELM ve CELM modellerinin görüntü sınıflandırma üzerindeki performansları karşılaştırılmıştır. Her bir model, klasik ELM yapısına farklı iyileştirmeler getirerek çeşitli sınıflandırma problemlerine uygunluğunu artırmayı hedeflemektedir. Çalışmada, bu modellerin performansı dört farklı veri seti üzerinde test edilmiştir. Bu veri setleri, basit ve karmaşık özelliklere sahip görüntüler içermekte olup, modellerin genel başarı oranlarını değerlendirmek için farklı senaryolar sunmaktadır. Testler sonucunda, CELM modeli genel performans açısından en yüksek başarıyı gösterirken, IELM modeli ise genellikle düşük performans sergilemiştir. Bu bulgular, her modelin özgün yapısal özelliklerinin ve iyileştirmelerinin sınıflandırma başarısını önemli ölçüde etkilediğini ortaya koymaktadır. CELM modelinin başarısı, özellikle veri setine ait örneklerin dağılımı üzerinde çalışarak daha güçlü genelleme yeteneği kazanmasından kaynaklanmaktadır. Öte yandan, IELM modelinin düşük performansı, belirli sınıflandırma sorunlarına uygunluğunun daha ayrıntılı incelenmesi gerektiğini işaret etmektedir. ELM ve varyantlarının performanslarını daha iyi anlamak için bu modellerin temel özelliklerini, avantajlarını, dezavantajlarını ve kullanım alanlarını kapsayan bir karşılaştırma Tablo 10’da sunulmuştur. Bu tablo, her bir modelin yapısal farklılıklarını ve uygulama senaryolarına uygunluğunu net bir şekilde ortaya koymaktadır.

Bu çalışmanın literatüre en önemli katkısı, ELM ve varyantlarının farklı senaryolarda kapsamlı bir şekilde test edilmesi ve özellikle CELM modelinin karmaşık veri setlerindeki üstün performansının ortaya konmasıdır. Ayrıca, IELM modelinin sınırlılıkları üzerine yapılan analizler, gelecekteki araştırmalar için yeni bir araştırma alanına işaret etmektedir. Gelecek çalışmalar için, aşırı öğrenme makine modellerinin denetimli öğrenme algoritmaları ve derin öğrenme modelleri ile kıyaslanması önerilmektedir. Bu kıyaslamalar, her bir modelin güçlü ve zayıf yönlerini ortaya çıkararak hangi modellerin hangi tür görüntü sınıflandırma problemlerine daha uygun olduğunu belirlememize yardımcı olacaktır. Ayrıca, farklı model türlerinin avantajlarını birleştiren hibrit modellerin geliştirilmesi, performans açısından önemli iyileştirmeler sağlayabilir. CELM modelinin başarısının daha derinlemesine incelenmesi de faydalı olacaktır. Özellikle, bu modelin sınıflandırma yeteneğini artıran kısıtlamaların farklı parametrelerle optimize edilmesi ve farklı veri türlerindeki performansının araştırılması önerilmektedir. ELM’nin farklı çekirdek fonksiyonları (Kernel-ELM, Meta-Kernel ELM, Multi-layer Kernel ELM, Multi-layer Meta Kernel ELM vb.) ile nasıl bir performans sergilediği de incelenecek ve bu doğrultuda daha özgün katkılar sağlanacaktır. Son olarak, mevcut modellerin hız ve hesaplama maliyetleri göz önünde bulundurularak,

büyük veri setlerinde ve gerçek zamanlı uygulamalarda daha verimli ve hızlı çalışabilen varyantların geliştirilmesi hedeflenmektedir.

Tablo 10. Görüntü sınıflandırma için ELM ve varyantlarının özellik karşılaştırması (Feature comparison of ELM and variants for image classifications)

Özellik	ELM	IELM	OSEL	RELM	CELM
Yapısal Özellikler	Tek gizli katmanlı, rastgele ağırlık ataması	Gizli katmana nöron eklenerek artırılır	Çevrimiçi öğrenme, yeni verilerle güncellenir	Düzenleme parametreleri ile aşırı öğrenme engellenir	Sınıf kısıtlamaları ile daha ayırıştırıcı özellikler elde edilir
Eğitim Süresi	Kısa	Uzun	Orta	Kısa	Orta
Performans	Genel performans iyi	Düşük	İyi	İyi	En yüksek
Veri Seti Türü	Basit veri setleri	Küçük ve homojen veri setleri	Büyük ve sürekli veri akışları	Gürültülü veya küçük veri setleri	Karmaşık ve dengesiz veri setleri
Avantajlar	Hızlı eğitim, basit yapı	Dinamik olarak genişleyebilir	Gerçek zamanlı öğrenme	Aşırı öğrenmeyi önler	Yüksek doğruluk, sınıflar arası ayrımı güçlendirir
Dezavantajlar	Rastgele ağırlıklar genelleme yeteneğini etkileyebilir	Eğitim süresi uzun	Veri akışı gerektirir	Düzenleme parametreleri optimize edilmeli	Kısıtlamaların doğru ayarlanması gereklidir

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Albadr, M. A. A., AL-Dhief, F. T., Man, L., Arram, A., Abbas, A. H., & Homod, R. Z. (2024). Online sequential extreme learning machine approach for breast cancer diagnosis. *Neural Computing and Applications*, 1-17.
- Al-Yaseen, W. L., Idrees, A. K., & Almasoudy, F. H. (2022). Wrapper feature selection method based differential evolution and extreme learning machine for intrusion detection system. *Pattern Recognition*, 132, 108912.
- Anam, K., & Al-Jumaily, A. (2015, August). A robust myoelectric pattern recognition using online sequential extreme learning machine for finger movement classification. In 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 7266-7269). IEEE.
- Baran, B. (2019). Sınır Değerler Arasında Kalan Evsel Atık Su Numune Analizi Sonucunun Aşırı Öğrenme Makineleri ile Sınıflandırılması. *Mühendislik Bilimleri ve Tasarım Dergisi*, 7(1), 18-25.
- Chacko, B. P., Vimal Krishnan, V. R., Raju, G., & Babu Anto, P. (2012). Handwritten character recognition using wavelet energy and extreme learning machine. *International Journal of Machine Learning and Cybernetics*, 3, 149-161.
- Chen, K., Li, J., Liu, K., Bai, C., Zhu, J., Gao, G., ... & Laghrouche, S. (2024). State of health estimation for lithium-ion battery based on particle swarm optimization algorithm and extreme learning machine. *Green Energy and Intelligent Transportation*, 3(1), 100151.
- Coşkun, C., & Baykal, A. (2011). Veri madenciliğinde sınıflandırma algoritmalarının bir örnek üzerinde karşılaştırılması. *Akademik Bilişim*, 2011, 1-8.
- Deng, W., Zheng, Q., & Chen, L. (2009, March). Regularized extreme learning machine. In 2009 IEEE symposium on computational intelligence and data mining (pp. 389-395). IEEE.
- Ding, S., Xu, X., & Nie, R. (2014). Extreme learning machine and its applications. *Neural Computing and Applications*, 25, 549-556.
- GeeksforGeeks. (2025). Extreme Learning Machine . <https://www.geeksforgeeks.org/extreme-learning-machine/>
- Guangyu, X., Shaoping, S., & Jietao, S. (2017, July). Wind speed forecast for the stratospheric airship by incremental extreme learning machine. In 2017 36th Chinese Control Conference (CCC) (pp. 4088-4092). IEEE.
- Goutte, C., & Gaussier, E. (2005, March). A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In European conference on information retrieval (pp. 345-359). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Gumaei, A., Hassan, M. M., Hassan, M. R., Alelaiwi, A., & Fortino, G. (2019). A hybrid feature extraction method with regularized extreme learning machine for brain tumor classification. *IEEE Access*, 7, 36266-36273.
- Hameed, M. M., Razali, S. F. M., Mohtar, W. H. M. W., Alsaydalani, M. O. A., & Yaseen, Z. M. (2024). Deep learning versus hybrid regularized extreme learning machine for multi-month drought forecasting: A comparative study and trend analysis in tropical region. *Heliyon*, 10(1).
- He, C., Kang, H., Yao, T., & Li, X. (2019). An effective classifier based on convolutional neural network and regularized extreme learning machine. *Mathematical biosciences and engineering*, 16(6), 8309-8321.
- Huang, G. B., Liang, N. Y., Rong, H. J., Saratchandran, P., & Sundararajan, N. (2005). On-line sequential extreme learning machine. *Computational Intelligence*, 2005, 232-237.

- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2004, July). Extreme learning machine: a new learning scheme of feedforward neural networks. In 2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541) (Vol. 2, pp. 985-990). IEEE.
- Huang, G. B., & Chen, L. (2007). Convex incremental extreme learning machine. *Neurocomputing*, 70(16-18), 3056-3062.
- Huang, X., Lei, Q., Xie, T., Zhang, Y., Hu, Z., & Zhou, Q. (2020). Deep transfer convolutional neural network and extreme learning machine for lung nodule diagnosis on CT images. *Knowledge-Based Systems*, 204, 106230.
- Iosifidis, A., Tefas, A., & Pitas, I. (2015). Regularized Extreme Learning Machine for large-scale media content analysis. *Procedia Computer Science*, 53, 420-427.
- Ismail Nasri. (2023). Driver Drowsiness Dataset (DDD). <https://www.kaggle.com/datasets/ismailnasri20/driver-drowsiness-dataset-ddd>.
- Kaynar, O., Görmez, Y., Yıldız, M., & Albayrak, A. (2016, September). Makine öğrenmesi yöntemleri ile Duygu Analizi. In *International Artificial Intelligence and Data Processing Symposium (IDAP'16)* (Vol. 17, No. 18, pp. 17-18).
- Lama, R. K., Gwak, J., Park, J. S., & Lee, S. W. (2017). Diagnosis of Alzheimer's disease based on structural MRI images using a regularized extreme learning machine and PCA features. *Journal of healthcare engineering*, 2017(1), 5485080.
- Lazarevska, E. (2016). Wind speed prediction based on incremental extreme learning machine. In *Proceedings of The 9th EUROSIM Congress on Modelling and Simulation*, EUROSIM (pp. 544-550).
- Liang, N. Y., Saratchandran, P., Huang, G. B., & Sundararajan, N. (2006). Classification of mental tasks from EEG signals using extreme learning machine. *International journal of neural systems*, 16(01), 29-38.
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International journal of Remote sensing*, 28(5), 823-870.
- Lu, S., Wang, H., Wu, X., & Wang, S. (2016, December). Pathological brain detection based on online sequential extreme learning machine. In 2016 International Conference on Progress in Informatics and Computing (PIC) (pp. 219-223). IEEE.
- Malik, H., Anees, T., Naeem, A., Naqvi, R. A., & Loh, W. K. (2023). Blockchain-federated and deep-learning-based ensembling of capsule network with incremental extreme learning machines for classification of COVID-19 using CT scans. *Bioengineering*, 10(2), 203.
- Masoudnickparvar. (2023). Brain Tumor MRI Dataset. <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>.
- Maurya, R., Mahapatra, S., Dutta, M. K., Singh, V. P., Karnati, M., Sahu, G., & Pandey, N. N. (2024). Skin cancer detection through attention guided dual autoencoder approach with extreme learning machine. *Scientific Reports*, 14(1), 17785.
- Ouyang, Q., Chen, Q., Zhao, J., & Lin, H. (2013). Determination of amino acid nitrogen in soy sauce using near infrared spectroscopy combined with characteristic variables selection and extreme learning machine. *Food and Bioprocess Technology*, 6(9), 2486-2493.
- Prakash, S. B., Chandan, K., Karthik, K., Devanathan, S., Kumar, R. V., Nagaraja, K. V., & Prasannakumara, B. C. (2023). Investigation of the thermal analysis of a wavy fin with radiation impact: an application of extreme learning machine. *Physica Scripta*, 99(1), 015225.
- Serin, Z., Karakuzu, C., & Yüzgeç, U. (2024). Meta-Constrained Extreme Learning Machines: A Novel Approach For Classification Problems. Available at SSRN 5061376.
- Sezgin, N. (2016). Epileptik EG İşaretlerin Aşırı Öğrenme Makineleri ile Sınıflandırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 7(3), 481-490.
- Vani, G., Savitha, R., & Sundararajan, N. (2010, December). Classification of abnormalities in digitized mammograms using extreme learning machine. In 2010 11th International Conference on Control Automation Robotics & Vision (pp. 2114-2117). IEEE.
- Walid, M. A. A., Mallick, S. P., Rastogi, R., Chauhan, A., & Vidya, A. (2023, March). Melanoma skin cancer detection using a CNN regularized extreme learning machine (RELM) based Model. In 2023 Second International Conference on Electronics and Renewable Systems (ICEARS) (pp. 1239-1245). IEEE.
- Wang, D., & Huang, G. B. (2005, July). Protein sequence classification using extreme learning machine. In *Proceedings. 2005 IEEE International Joint Conference on Neural Networks, 2005* (Vol. 3, pp. 1406-1411). IEEE.
- Wang, Y., Li, Q., Zhang, J., Yin, C., Zhang, Q., Shi, Y., & Men, H. (2025). A gas detection system combined with a global extension extreme learning machine for early warning of electrical fires. *Sensors and Actuators B: Chemical*, 423, 136801.
- Wong, S. Y., Yap, K. S., & Li, X. C. (2020). A new probabilistic output constrained optimization extreme learning machine. *IEEE Access*, 8, 28934-28946.
- Xiao, H., Rasul, K., & Vollgraf, R. (2017). Fashion-mnist: a novel image dataset for benchmarking machine learning algorithms. arXiv preprint arXiv:1708.07747.
- Zhao, Y. P., & Chen, Y. B. (2022). Extreme learning machine based transfer learning for aero engine fault diagnosis. *Aerospace science and technology*, 121, 107311.
- Zhu, W., Miao, J., & Qing, L. (2014, July). Constrained extreme learning machine: a novel highly discriminative random feedforward neural network. In 2014 International Joint Conference on Neural Networks (IJCNN) (pp. 800-807). IEEE.