



T.C.

BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

**SINIFLANDIRMA PROBLEMLERİ İÇİN AŞIRI ÖĞRENME MAKİNE
MODELLERİNİN İNCELENMESİ**

YÜKSEK LİSANS TEZİ

KÜBRA BOZOĞLAN

TEZ DANIŞMANI

PROF. DR. UĞUR YÜZGEÇ

BİLECİK, 2026

10677091

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

**SINIFLANDIRMA PROBLEMLERİ İÇİN AŞIRI ÖĞRENME MAKİNE
MODELLERİNİN İNCELENMESİ**

YÜKSEK LİSANS TEZİ

KÜBRA BOZOĞLAN

TEZ DANIŞMANI
PROF. DR. UĞUR YÜZGEÇ

BİLECİK, 2026
10677091

BEYAN

Sınıflandırma Problemleri için Aşırı Öğrenme Makine Modellerinin İncelenmesi başlıklı yüksek lisans tezinin hazırlık ve yazım aşamasında bilimsel araştırma ve etik kurallarına uyduğumu, Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Faaliyetlerinde Üretken Yapay Zekâ Kullanımına Dair Etik Rehberine uygun olarak tez hazırladığımı, başkalarının eserlerinden yararlandığım bölümlerde bilimsel etik kurallarına uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, çalışmamın herhangi bir kısmının başka bir tez/dönem projesi olarak sunulmadığını, aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Kübra Bozoğlan

../../20..

İmza:

ÖN SÖZ

Bu tez çalışmasında, sınıflandırma problemlerinde kullanılan Aşırı Öğrenme Makinesi ve varyantlarının performansları incelenmiş ve elde edilen bulgular doğrultusunda yeni bir kısıtlanmış Aşırı Öğrenme Makinesi modeli geliştirilmiştir.

Bu tez çalışmasının hazırlanması sürecinde bilgi, deneyim ve değerli yönlendirmeleriyle bana yol gösteren, çalışmamın her aşamasında bilimsel yaklaşımı ve desteğiyle katkı sağlayan kıymetli tez danışmanım Prof. Dr. Uğur YÜZGEÇ'e en içten teşekkürlerimi sunarım.

Tez çalışmamın gerçekleştirilmesi sürecinde göstermiş olduğu anlayış, sabır ve destek için kendisine teşekkür eder, akademik hayatıma sağladığı değerli katkılardan dolayı minnettarlığımı ifade ederim.

ÖZET

Bu tez çalışmasında, sınıflandırma problemlerinde kullanılan ELM ve varyantlarının performansları incelenmiş ve elde edilen bulgular doğrultusunda CELM temel alınarak yeni bir model geliştirilmiştir. Çalışmanın ilk aşamasında ELM ve varyantları farklı görüntü sınıflandırma veri kümeleri üzerinde karşılaştırılmış ve CELM yaklaşımının yeni modelin geliştirilmesi için uygun bir temel sunduğu belirlenmiştir. Bununla birlikte, tek bir kısıtlama stratejisinin kullanılması farklı sınıf ilişkilerinin birlikte değerlendirilmesini sınırlandırabildiğinden, bu sınırlılığın giderilmesi amacıyla ReSQu-CELM modeli önerilmiştir. ReSQu-CELM'de gizli katman dört bölüme ayrılmış ve farklı örnek ilişkilerini temel alan dört kısıtlama stratejisi bu bölümlere rastgele atanmıştır. Böylece sınıflar arası ve sınıf içi ilişkilerden aynı öğrenme yapısı içerisinde yararlanılması amaçlanmıştır. Farklı gizli nöron sayılarının değerlendirildiği deneylerde 100 gizli nöronlu yapı 1,93 ortalama sıralama değeriyle en uygun yapı olarak belirlenmiştir. Önerilen model WaveformEW, Ecoli, Breast Cancer, Madelon, Hill-Valley ve Digits veri kümeleri üzerinde değerlendirilmiş; deneylerde 10 katlı tabakalı çapraz doğrulama kullanılarak doğruluk, hassasiyet, geri çağırma, Makro-F1, Ağırlıklı-F1 ve eğitim süresi ölçütleri incelenmiştir. ELM tabanlı modellerle yapılan karşılaştırmalar, ReSQu-CELM'in başarımının veri kümesinin özelliklerine göre değiştiğini ve özellikle bazı karmaşık veri yapılarında avantaj sağlayabildiğini göstermiştir. Geleneksel makine öğrenmesi yöntemleriyle yapılan genel karşılaştırmada ReSQu-CELM 2,70 ortalama sıralama değeriyle SVM (2,47) ve RF'nin (2,60) ardından üçüncü sırada yer almıştır. Eğitim süresi açısından ise 1,83 ortalama sıralama değeri elde edilmiştir. Sonuç olarak, farklı kısıtlama stratejilerinin aynı ELM tabanlı yapı içerisinde kullanılmasının veri yapısına bağlı olarak sınıflandırma performansına katkı sağlayabildiği görülmüştür. ReSQu-CELM, her veri kümesinde en yüksek başarıyı sağlamamakla birlikte, farklı örnek ilişkilerini birlikte değerlendiren ve sınıflandırma başarımı ile hesaplama maliyeti arasında dengeli sonuçlar sunan alternatif bir ELM yaklaşımı ortaya koymaktadır.

Anahtar Kelimeler: Aşırı Öğrenme Makinesi, Kısıtlanmış Aşırı Öğrenme Makinesi, Makine Öğrenmesi, ReSQu-CELM, Sınıflandırma

ABSTRACT

In this thesis, the performance of ELM and its variants used in classification problems was investigated, and a new model was developed based on CELM in accordance with the findings obtained. In the first stage of the study, ELM and its variants were compared on different image classification datasets, and CELM was determined to provide a suitable basis for the development of the new model. However, since the use of a single constraint strategy may limit the simultaneous consideration of different class relationships, the ReSQu-CELM model was proposed to address this limitation. In ReSQu-CELM, the hidden layer was divided into four sections, and four constraint strategies based on different sample relationships were randomly assigned to these sections. Thus, the model was designed to utilize both inter-class and intra-class relationships within the same learning structure. In experiments evaluating different numbers of hidden neurons, the 100-hidden-neuron configuration achieved the best overall performance with an average rank of 1.93. The proposed model was evaluated on the WaveformEW, Ecoli, Breast Cancer, Madelon, Hill-Valley, and Digits datasets. A 10-fold stratified cross-validation procedure was employed, and accuracy, precision, recall, Macro-F1, Weighted-F1, and training time were considered as evaluation metrics. Comparisons with ELM-based models showed that the performance of ReSQu-CELM varied depending on the characteristics of the dataset and that it provided advantages particularly on certain complex data structures. In the overall comparison with conventional machine learning methods, ReSQu-CELM ranked third with an average rank of 2.70, following SVM (2.47) and RF (2.60). In terms of training time, it achieved an average rank of 1.83. Overall, the results indicate that employing different constraint strategies within the same ELM-based structure can contribute to classification performance depending on the characteristics of the data. Although ReSQu-CELM did not achieve the highest performance on every dataset, it provides an alternative ELM approach that jointly considers different sample relationships and offers a balanced trade-off between classification performance and computational cost.

Keywords: Classification, Constrained Extreme Learning Machine, Extreme Learning Machine, Machine Learning, ReSQu-CELM

İÇİNDEKİLER

	Sayfa
ÖN SÖZ	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	viii
ALGORİTMA LİSTESİ	ix
KISALTMALAR VE SİMGELER LİSTESİ	x
1. GİRİŞ.....	1
2. METOT.....	9
2.1. Standart Aşırı Öğrenme Makineleri (ELM)	9
2.2. Artırılmış Aşırı Öğrenme Makineleri (IELM).....	10
2.3. Çevrimiçi Sıralı Aşırı Öğrenme Makineleri (OSELm)	11
2.4. Düzenlenmiş Aşırı Öğrenme Makineleri (RELM).....	11
2.5. Kısıtlanmış Aşırı Öğrenme Makineleri (CELM)	11
2.6. IntelELM Kütüphanesi	13
2.7. Rastgele Stratejili Çeyreklenmiş Kısıtlanmış Aşırı Öğrenme Makinesi (Randomized Strategy Quartered Constrained Extreme Learning Machine- ReSQu-CELM)	14
2.8. Veri Setleri.....	18
2.8.1. MNIST Veri Seti	19
2.8.2. Beyin Tümörü MRI Görüntüleri Veri Seti	20
2.8.3. Pirinç Görüntü Veri Seti	21
2.8.4. Araç Sürücüsü Uyku Durumu Veri Seti	22

2.8.5. WaveformEW Veri Seti.....	22
2.8.6. Ecoli Veri Seti	23
2.8.7. Breast Cancer Veri Seti	24
2.8.8. Madelon Veri Seti	25
2.8.9. Hill-Valley Veri Seti.....	26
2.8.10. Digits Veri Seti	27
2.8.11. Başarım Değerlendirme Metrikleri.....	28
3. DENEYSEL SONUÇLAR VE TARTIŞMA.....	31
3.1. ELM ve Varyantlarının Başarım Analizi	32
3.2. Önerilen ReSQu-CELM Modelinin DeneySEL Değerlendirmesi	38
3.2.1. Model Bileşenlerinin Etkisinin Analizi	38
3.2.2. ELM Tabanlı Modeller ile Karşılaştırma	42
3.2.3. Makine Öğrenmesi Modelleri ile Karşılaştırma	49
4. SONUÇLAR VE ÖNERİLER.....	59

TABLÖLER LİSTESİ

Sayfa

Tablo 1.1. Literatür taramasına dayalı karşılaştırmalı analiz	4
Tablo 2.1 ReSQu-CELM modelinde kullanılan kısıtlama stratejilerinin matematiksel formülü	16
Tablo 2.2 Kullanılan veri setlerinin temel özellikleri	18
Tablo 3.1. MNIST veri seti için modellerin performans karşılaştırmaları.....	33
Tablo 3.2. Beyin tümörü veri seti için modellerin başarımlar karşılaştırmaları.....	34
Tablo 3.3. Piriç veri seti için modellerin başarımlar karşılaştırmaları.....	34
Tablo 3.4. Araç sürücüsü uyku durumu veri seti için modellerin başarımlar karşılaştırmaları ...	35
Tablo 3.5. Modellerin eğitim süreleri	36
Tablo 3.6. MNIST veri seti için en iyi ELM varyantı (CELM) ile literatürden alınan bazı modellerin karşılaştırılması.....	37
Tablo 3.7. Önerilen ReSQu-CELM modelinde farklı gizli nöron sayılarının performansa etkisi	39
Tablo 3.8. ReSQu-CELM modelinin farklı varyantlarına ilişkin bileşen analizi sonuçları.....	40
Tablo 3.9. WaveformEW veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması	44
Tablo 3.10. Digits veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması.....	45
Tablo 3.11. Madelon veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması.....	45
Tablo 3.12. Breast Cancer veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması	46
Tablo 3.13. Ecoli veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması.....	46
Tablo 3.14. Hill-Valley veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile	

performans karşılaştırması	47
Tablo 3.15. Karşılaştırmada kullanılan modellerin deneysel yapılandırmaları.....	49
Tablo 3.16. WaveformEW veri seti için ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin performans karşılaştırması	50
Tablo 3.17. Digits veri seti için ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin performans karşılaştırması	51
Tablo 3.18. Madelon veri seti için ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin performans karşılaştırması	51
Tablo 3.19. Breast Cancer veri setinde ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin karşılaştırmalı performans analizi.....	52
Tablo 3.20. Ecoli veri setinde ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin karşılaştırmalı performans analizi	53
Tablo 3.21. Hill-Valley veri setinde ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin karşılaştırmalı performans analizi.....	53
Tablo 3.22. Modellerin farklı performans ölçütlerine göre ortalama sıralama sonuçları	54
Tablo 3.23. Ağırlıklı-F1 skorları için Wilcoxon İşaretli Sıralar Testi sonuçları.....	56

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1. Önerilen ReSQu-CELM modelinin işlem aşamaları	15
Şekil 2.2 MNIST veri setindeki sınıflara ait görüntüler	20
Şekil 2.3 Beyin tümörü veri setindeki sınıflara ait görüntüler.....	21
Şekil 2.4 Pirinç veri setindeki sınıflara ait görüntüler.....	21
Şekil 2.5 Araç sürücüsü uyku durumu veri setindeki sınıflara ait görüntüler	22
Şekil 2.6. PCA kullanılarak iki boyuta indirgenen WaveformEW veri setindeki örneklerin sınıf dağılımı	23
Şekil 2.7. Ecoli veri setindeki mikroorganizma örneklerinin mcg ve gvh biyokimyasal özelliklerine göre sınıf dağılımı	24
Şekil 2.8. PCA kullanılarak iki boyuta indirgenen Breast Cancer veri setindeki örneklerin sınıf dağılımı	25
Şekil 2.9. PCA kullanılarak iki boyuta indirgenen Madelon veri setindeki örneklerin sınıf dağılımı	26
Şekil 2.10. PCA kullanılarak iki boyuta indirgenen Hill-Valley veri setindeki örneklerin sınıf dağılımı	27
Şekil 2.11. PCA kullanılarak iki boyuta indirgenen Digits veri setindeki el yazısı rakam örneklerinin sınıf dağılımı	28
Şekil 2.12. Karmaşıklık matrisi örneği.....	29
Şekil 3.1. ELM modeline ait karmaşıklık matrisi grafikleri.....	33
Şekil 3.2. Tüm veri setleri için ReSQu-CELM modeline ait karmaşıklık matrisleri.....	43

ALGORİTMA LİSTESİ

Sayfa

Algoritma 2.1. Önerilen ReSQu-CELM modelinin eğitim süreci	17
---	-----------

KISALTMALAR VE SİMGELER LİSTESİ

CDELM: Constrained Difference Extreme Learning Machine

CELM: Constrained Extreme Learning Machine

CMELM: Constrained Mixed Extreme Learning Machine

CSELM: Constrained Sum Extreme Learning Machine

DE: Differential Evolution

DT: Decision Tree

ELM: Extreme Learning Machine

GA: Genetic Algorithm

GWO: Grey Wolf Optimizer

IELM: Incremental Extreme Learning Machine

IntelELM: Intelligent Metaheuristic-based Extreme Learning Machine

Meta-CELM: Meta Constrained Extreme Learning Machine

MLP: Multilayer Perceptron

MNIST: Modified National Institute of Standards and Technology

MRI: Magnetic Resonance Imaging

OSELM: Online Sequential Extreme Learning Machine

PCA: Principal Component Analysis

PSO: Particle Swarm Optimization

RELM: Regularized Extreme Learning Machine

ReSQu-CELM: Randomized Strategy Quartered Constrained Extreme Learning Machine

RF: Random Forest

SELM: Sample Extreme Learning Machine

SVM: Support Vector Machine

1. GİRİŞ

Günümüzde üretilen verinin miktarı ve çeşitliliği, bilgisayar sistemlerinin işlem gücü ve depolama kapasitesindeki gelişmelere paralel olarak hızla artmaktadır. Bununla birlikte, büyük ve karmaşık veri kümelerinin yalnızca saklanması veya işlenmesi yeterli olmamakta; bu veriler içerisindeki anlamlı ilişkilerin ortaya çıkarılması ve elde edilen bilginin karar süreçlerinde kullanılabilir hâle getirilmesi gerekmektedir. Geleneksel analiz yöntemlerinin özellikle yüksek boyutlu ve geniş ölçekli problemlerde yetersiz kalabilmesi, veriye dayalı öğrenme yöntemlerini önemli bir araştırma alanı hâline getirmiştir (Coşkun ve Baykal, 2011). Bu doğrultuda makine öğrenmesi, verilerde bulunan örüntüleri otomatik olarak belirleyebilmesi ve daha önce görülmemiş örnekler hakkında tahmin üretebilmesi sayesinde farklı disiplinlerde yaygın biçimde kullanılmaktadır.

Makine öğrenmesi yöntemleri; sınıflandırma, regresyon, tahminleme ve örüntü tanıma gibi birçok problemin çözümünde etkili sonuçlar sunmaktadır. Özellikle görüntü verilerinin analizinde, örneklerin yüksek boyutlu olması ve sınıflar arasındaki ayrımın her zaman açık biçimde gözlenememesi, kullanılan öğrenme modelinin hem doğruluğunu hem de hesaplama verimliliğini önemli hâle getirmektedir (Kaynar vd., 2016). Bu nedenle eğitim süresi düşük, uygulanması kolay ve farklı veri yapılarına uyarlanabilir algoritmaların geliştirilmesi önem taşımaktadır.

Bu kapsamda öne çıkan yöntemlerden biri, tek gizli katmanlı ileri beslemeli sinir ağları için geliştirilen Aşırı Öğrenme Makineleridir (Extreme Learning Machine, ELM). Geleneksel yapay sinir ağlarında ağ parametreleri çoğunlukla yinelemeli optimizasyon işlemleriyle güncellenirken ELM’de giriş ağırlıkları ile gizli katman eşik değerleri başlangıçta belirlenmekte, çıkış ağırlıkları ise analitik olarak hesaplanmaktadır (Huang vd., 2004). Böylece uzun süren geri yayılım işlemlerine ihtiyaç duyulmadan model eğitimi gerçekleştirilebilmekte ve özellikle büyük veri kümelerinde önemli bir zaman avantajı sağlanabilmektedir. Basit mimarisi ve hızlı öğrenme özelliği, ELM’nin sınıflandırma ve regresyon başta olmak üzere çeşitli problemlerde tercih edilmesine katkıda bulunmuştur.

ELM’nin sahip olduğu bu avantajlara karşın, gizli katman parametrelerinin verinin sınıfsal ve yapısal özelliklerinden bağımsız biçimde belirlenmesi model performansını doğrudan etkileyebilmektedir. Rastgele oluşturulan ağırlıkların her çalıştırmada değişmesi, bazı durumlarda elde edilen sonuçların kararlılığını azaltabilmekte ve benzer deney koşullarında farklı başarı düzeylerinin ortaya çıkmasına neden olabilmektedir. Ayrıca veri kümesinin

boyutu, sınıf sayısı, sınıf dağılımı ve özellik yapısı gibi unsurlar, ELM tabanlı modellerin başarımını farklı biçimlerde etkileyebilmektedir. Bu sınırlılıkların giderilmesi amacıyla öğrenme yapısı, ağırlık üretim yöntemi ve düzenleştirme yaklaşımı bakımından birbirinden ayrılan çeşitli ELM türevleri geliştirilmiştir (Ding vd., 2014).

Bu tez kapsamında gerçekleştirilen ilk çalışmada ELM ile birlikte Artırımlı Aşırı Öğrenme Makinesi (Incremental Extreme Learning Machine -IELM), Çevrim İçi Sıralı Aşırı Öğrenme Makinesi (Online Sequential Extreme Learning Machine -OSELM), Düzenlenmiş Aşırı Öğrenme Makinesi (Regularized Extreme Learning Machine -RELM) ve Kısıtlanmış Aşırı Öğrenme Makinesi (Constrained Extreme Learning Machine -CELM) ele alınmıştır. Söz konusu yöntemlerin farklı sınıf sayılarına, veri büyüklüklerine ve görüntü özelliklerine sahip sınıflandırma problemlerindeki davranışları karşılaştırılarak modellerin güçlü ve sınırlı yönlerinin belirlenmesi amaçlanmıştır. Böylece yalnızca tek bir yöntemin elde ettiği doğruluk değerine odaklanmak yerine, farklı ELM yapılarının değişen veri koşulları altında nasıl bir performans gösterdiği bütüncül biçimde değerlendirilmiştir. Bu karşılaştırma, ELM ailesindeki yöntemlerin eğitim yapıları ile veri kümelerine verdikleri tepkilerin anlaşılması ve sonraki aşamada geliştirilecek modelin kuramsal dayanağının oluşturulması bakımından önem taşımaktadır.

Karşılaştırmalı deneylerden elde edilen sonuçlara göre, incelenen ELM tabanlı yöntemler arasında CELM, ortalama F1 skoru açısından en yüksek genel performansı göstermiştir. CELM'i diğer varyantlardan ayıran temel özellik, gizli katman ağırlıklarının bütünüyle rastgele belirlenmesi yerine eğitim örnekleri ve bu örneklerle ait sınıf bilgilerinden yararlanılarak oluşturulmasıdır. Bu yapı, verinin sınıfsal özelliklerinin doğrudan öğrenme sürecine aktarılmasına imkân vermekte ve gizli katmanda daha ayırt edici temsillerin elde edilmesine katkı sağlamaktadır. Dolayısıyla ilk çalışmanın bulguları, ELM'nin rastgele parametre seçiminden kaynaklanan sınırlılıklarının azaltılmasında kısıtlanmış ağırlık üretiminin umut verici bir yaklaşım olduğunu ortaya koymuştur.

CELM'in karşılaştırılan yöntemler arasındaki başarılı sonuçları, tezin devamında bu model ailesine odaklanılmasının temel gerekçesini oluşturmuştur. Bununla birlikte, ilk çalışmada kullanılan CELM yapısının ve literatürde önerilen diğer kısıtlanmış ELM modellerinin incelenmesi, veri bilgisinden yararlanılmasına rağmen bu yaklaşımların da bazı sınırlılıklara sahip olduğunu göstermiştir. CELM, Kısıtlanmış Fark Aşırı Öğrenme Makinesi (Constrained Difference Extreme Learning Machine -CDEL), Kısıtlanmış Toplam Aşırı

Öğrenme Makinesi (Constrained Sum Extreme Learning Machine -CSELM), Örnek Tabanlı Aşırı Öğrenme Makinesi (Sample Extreme Learning Machine-SELM), Kısıtlanmış Karma Aşırı Öğrenme Makinesi (Constrained Mixed Extreme Learning Machine -CMELM), ve Meta Kısıtlanmış Aşırı Öğrenme Makinesi (Meta Constrained Extreme Learning Machine -Meta-CELM) gibi yöntemlerde gizli katman parametreleri aynı veya farklı sınıflara ait örnekler arasındaki ilişkiler kullanılarak oluşturulmakta, ancak modellerin önemli bir bölümünde gizli katmanın tamamı için yalnızca tek bir kısıtlama stratejisi uygulanmaktadır.

Tek bir stratejinin kullanılması, modelin veri içerisindeki farklı yapısal ilişkileri eş zamanlı olarak temsil edebilmesini güçleştirmektedir. Örneğin yalnızca farklı sınıflara ait örnekler arasındaki ayrımlara dayanan bir yaklaşım, aynı sınıf içerisindeki ortak özellikleri yeterince dikkate alamayabilir. Benzer şekilde, yalnızca sınıf içi benzerlikleri temel alan bir yöntem de sınıflar arasındaki ayırt edici sınırların oluşturulmasında sınırlı kalabilir. Bu nedenle CELM'nin veri odaklı ağırlık üretme avantajını koruyan, ancak tek bir kısıtlama stratejisine bağlı kalmadan sınıflar arası ve sınıf içi ilişkileri birlikte kullanabilen daha kapsamlı bir yapıya ihtiyaç duyulmuştur.

Bu gereksinim doğrultusunda tezin ikinci çalışmasında Rastgele Stratejili Çeyreklenmiş Kısıtlanmış Aşırı Öğrenme Makinesi (Randomized Strategy Quartered Constrained Extreme Learning Machine -ReSQu-CELM) adı verilen yeni bir model geliştirilmiştir. Önerilen modelde gizli katman dört eşit bölüme ayrılmakta ve her bir bölümde farklı bir kısıtlama stratejisi kullanılmaktadır. Bu stratejiler, farklı sınıflara ait örneklerin fark ve toplam ilişkileri ile aynı sınıfa ait örneklerin fark ve toplam ilişkileri temelinde oluşturulmaktadır. Böylece gizli katmandaki nöronların tamamının yalnızca tek bir veri ilişkisini temsil etmesi yerine, sınıflar arası ayrıştırıcı bilgiler ile sınıf içi ortak yapıların aynı model içerisinde birlikte değerlendirilmesi sağlanmaktadır.

Gizli katmanın farklı stratejiler arasında bölüştürülmesi, modelin farklı veri dağılımlarına karşı daha esnek bir öğrenme davranışı göstermesini amaçlamaktadır. Bunun yanı sıra stratejilerin gizli katmandaki bölümlere atanma sırası her çalıştırmada rastgele permüte edilmektedir. Bu işlem sayesinde modelin sabit bir strateji yerleşimine bağımlı kalmasının önüne geçilmekte ve farklı nöron gruplarının öğrenme sürecine değişen sıralamalarla katılması sağlanmaktadır. Önerilen yapının, klasik ELM'nin rastgele ağırlık üretiminden kaynaklanan kararsızlığı azaltması ve tek stratejiye dayalı kısıtlanmış ELM modellerine kıyasla veri içerisindeki farklı örüntüleri daha kapsamlı biçimde temsil etmesi hedeflenmektedir.

Bu yönüyle tezde, ELM ailesindeki mevcut yöntemlerin karşılaştırılması ile yeni bir modelin geliştirilmesi birbirinden bağımsız iki uygulama olarak değil, birbirini tamamlayan bir araştırma süreci olarak ele alınmıştır. Mevcut modeller üzerinde gerçekleştirilen deneysel incelemeler, farklı ELM yapılarının avantajlarının ve sınırlılıklarının belirlenmesini sağlamış; bu değerlendirmeler sonucunda gizli katmanın oluşturulmasında tek bir stratejiye bağlı kalmanın doğurduğu eksiklikler ortaya konulmuştur. ReSQu-CELM modeli ise belirlenen bu eksikliği gidermek amacıyla farklı kısıtlama stratejilerini ortak bir öğrenme yapısında birleştirecek biçimde tasarlanmıştır. Böylece tez kapsamında hem ELM tabanlı yöntemlerin görüntü sınıflandırma problemlerindeki davranışlarına ilişkin kapsamlı bir değerlendirme sunulmakta hem de sınıflar arası ve sınıf içi ilişkileri eş zamanlı olarak dikkate alan yeni bir kısıtlanmış ELM yaklaşımı literatüre kazandırılmaktadır. ELM ve varyantlarının sınıflandırma problemlerindeki performansını geliştirmeye yönelik çalışmalar, farklı kısıtlama stratejilerinin ve model yapılarının geliştirilmesine odaklanmaktadır. Literatürde, özellikle rastgele atanan gizli katman ağırlıklarının neden olduğu kararsızlığın azaltılması ve sınıflandırma başarımının artırılması amacıyla çeşitli ELM tabanlı yaklaşımlar önerilmiştir. Bu çalışmaların temel özellikleri, kullanılan yöntemler ve elde edilen sonuçlar Tablo 1.1’de özetlenmiştir.

Tablo 1.1. Literatür taramasına dayalı karşılaştırmalı analiz

Model	Yıl/Yazar	Geliştirmeler	Veri Seti
ELM	(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
RELM	(He vd., 2019)	Yüz tanıma için Genetik Algoritma ile optimize edilmiş RELM kullanılmıştır.	ORL
CPP-POELM	(Wong vd., 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.
ELM	(Huang vd., 2020)	ELM kullanılarak akciğer nodülleri tespit edilmiştir	Bilgisayarlı tomografi görüntüleri

Tablo 1.1. (Devamı) Literatür taramasına dayalı karşılaştırmalı analiz.

OSELM	(Al-Dhief vd., 2021)	Çalışmada ses patolojilerinin Mel-Frekans Cepstral Katsayıları yöntemi ile özellikleri çıkarılmıştır. Ardından ses patolojileri OSELM ile dört sınıfa ayrılmıştır.	Saarbücken ses veritabanı
OS-CELM (Çevrim İçi Ardışık Kısıtlı Aşırı Öğrenme Makinesi)	(Tosun ve Eryiğit, 2021)	Kısıtlı Aşırı Öğrenme Makinesini, Çevrim İçi Ardışık Aşırı Öğrenme Makinesine entegre ederek geliştirilmiş bir çevrim içi ardışık öğrenme modeli önermektedir. Çevrim içi sınıflandırmada hızlı eğitim yeteneği korunurken genelleme performansını artırmak amacıyla rastgele gizli katman parametreleri, sınıflar arası farklara dayalı kısıtlı ağırlıklarla değiştirilmiştir.	Wi-Fi İç Mekân Konumlandırma, Cilt Bölütleme, Cleveland Kalp Hastalığı, MNIST
ELM	(Zhao ve Chen, 2022)	Transfer öğrenme yaklaşımı ile birlikte ELM kullanılarak uçak motorlarının arıza tespiti yapılmıştır.	Uçak motoru verileri
IELM	(Malik vd., 2023)	Çalışmada, akciğer CT taramalarından enfeksiyon özellikleri CapsNet ile çıkarılmış, ardından IELM ile işlenerek COVID-19 tespiti yapılmıştır.	CT Taraması
RELM	(Subramani an vd., 2023)	Çalışmada, deri lezyonlarının dermoskopik görüntülerinin özellikleri CNN ile çıkarılmış, ardından bu özellikler RELM'e aktarılıp görüntüler iki sınıfa ayrılmıştır.	Dermoskopik görüntüler
M-OS-ELM (Geliştirilmiş Çevrim İçi Sıralı Aşırı Öğrenme Makinesi)	(Wibawa vd., 2023)	Ardışık verilerde öğrenme dinamiklerini ve kararlılığı geliştirmek amacıyla, kontrol teorisine dayalı doğrusal zamanla değişen dinamik sistem ve model öngörülü kontrol yöntemleri kullanılarak OS-ELM geliştirilmiştir.	Trafik kontrolüne yönelik insan hareketi tanıma.
ELM	(Prakash vd., 2024)	ELM ile dalgalı bir kanat üzerindeki termal analiz incelenmiştir.	Isıl veri setleri
ELM	(Chen vd., 2024)	Parçacık sürü optimizasyonu (Particle Swarm Optimization) algoritması ile birlikte ELM kullanılarak lityum-iyon pillerin sağlık durumu tahmin edilmiştir.	Pil performans verileri

Tablo 1.1. (Devamı) Literatür taramasına dayalı karşılaştırmalı analiz.

ELM	(Maurya vd., 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 ve ISIC-2017
Çekirdek / Meta-sezgisel Yöntemle Optimize Edilmiş Aşırı Öğrenme Makinesi (Gübre Böceği Optimizasyonu + Kernel ELM)	(Mo vd., 2024)	Çekirdek Aşırı Öğrenme Makinesi parametreleri, gübre böceği optimizasyonu ile ayarlanmış ve doğruluk artırılmıştır.	NASA, Maryland Üniversitesi ve Oxford Üniversitesine ait lityum iyon pil veri setleri.
ENR-ELM (Etkili Rastgele Olmayan Aşırı Öğrenme Makinesi),	(De Canditiis ve Veglianti, 2025)	ELM'de model seçimini iyileştirmek ve rastgele başlatmaya duyarlılığı ortadan kaldırmak amacıyla, sinir ağı Gauss süreci çekirdeğinin özdeğer ayrışımına dayalı, rastgele olmayan ve veriye bağlı bir gizli katman ağırlık seçimi uygulanmıştır.	Sentetik: 48 veri seti Gerçek: Abalone, Otomobil, Yakıt Tüketimi, Kaliforniya Konut, Delta Ailerons, Los Angeles Ozon, Makine İşlemci, Prostat Kanseri ve Servo veri setleri.
ELM	(Wang vd., 2025)	Küresel uzantılı ELM ile elektrikli yangınların erken uyarı sistemleri için bir gaz algılama sistemi geliştirilmiştir.	Gaz sensör verileri
IHHO-ELM-AdaBoost	(Gao ve Yi, 2025)	HHO ile ELM ağırlık ve bias değerleri optimize edilmiş, AdaBoost ile birleştirilmiştir.	Atış açısı ve başlangıç hızından üretilen 12.000 balistik veri

Tablo 1.1. (Devamı) Literatür taramasına dayalı karşılaştırmalı analiz.

OSRELM (Çevrimiçi sıralı düzenlenmiş aşırı öğrenme makinesi)	(Zhang vd., 2025)	Rüzgâr hızı serisi yüksek ve düşük frekanslı bileşenlere ayrılmış; yüksek frekanslı bileşenler CNN-BiGRU, düşük frekanslı bileşenler OSRELM ile tahmin edilmiştir. IDO (Geliştirilmiş Karahindiba Optimizasyon) algoritması üç farklı stratejiyle geliştirilmiştir.	Çin'deki rüzgâr çiftliklerinden alınan 15 dakikalık ve saatlik rüzgâr hızı verileri
Meta- Constrained / Meta-ELM	(Serin vd., 2026)	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.
HHO-PSO- KELM (Harris Şahinleri Optimizasyon u-Parçacık Sürü Optimizasyon u-Çekirdek Aşırı Öğrenme Makinesi)	(Yi vd., 2026)	KELM parametreleri, küresel ve yerel aramayı birleştiren hibrit HHO-PSO ile optimize edilmiştir. Lévy uçuşu ve entropi tabanlı kaçış stratejisi eklenmiştir.	CALCE ve Oxford lityum iyon pil veri setleri
CH-PSO-ELM (Kaos Tabanlı Parçacık Sürü Optimizasyon)	(Rasa vd., 2026)	ELM'nin giriş ağırlıkları ve gizli katman bias değerleri, yerel optimumdan kaçmayı sağlayan kaos operatörlü PSO ile optimize edilmiştir.	12 UCI ve 6 tıbbi olmak üzere 18 sınıflandırma veri seti

Tablo 1.1'de sunulan literatür taramasında, Aşırı Öğrenme Makinesinin farklı problem alanlarındaki başarımını geliştirmeye yönelik çalışmalar incelenmiştir. Bu kapsamda çevrim içi sıralı öğrenme, kısıtlı ve rastgele olmayan ağırlık üretimi, çekirdek tabanlı modelleme, düzenleştirme ve meta-sezgisel yöntemlerle parametre belirleme yaklaşımları üzerinde durulmuştur. İncelenen çalışmalarda ELM'nin hızlı eğitim yapısının korunmasıyla birlikte doğruluk, kararlılık ve genelleme performansının geliştirilmesinin amaçlandığı görülmektedir.

Kısıtlı ve rastgele olmayan ELM yaklaşımlarında gizli katman parametrelerinin tamamen rastgele belirlenmesi yerine eğitim verilerinden yararlanılarak oluşturulmasına yönelik yöntemler ele alınmıştır. Çevrim içi ardışık modellerde yeni örneklerin mevcut modele dâhil edilmesi, çekirdek tabanlı modellerde doğrusal olmayan ilişkilerin daha etkili temsil edilmesi, meta-sezgisel yöntemlerle geliştirilen modellerde ise ağırlık, bias, çekirdek ve düzenleştirme parametrelerinin uygun değerlerinin belirlenmesi üzerinde durulmuştur. Bu

yöntemlerin sınıflandırma, tahmin, tıbbi veri analizi, rüzgâr hızı tahmini ve lityum iyon pil sağlığı kestirimi gibi farklı uygulama alanlarında değerlendirildiği görülmüştür.

Literatür taramasından elde edilen bulgular doğrultusunda, tez kapsamında ReSQu-CELM modeli önerilmiştir. Önerilen modelde gizli katman dört eşit bölüme ayrılmakta ve her bölümde farklı bir kısıtlı ağırlık üretim stratejisi kullanılmaktadır. Bu stratejiler, aynı sınıfa ve farklı sınıflara ait örneklerin toplam ve fark ilişkilerine dayalı olarak oluşturulmakta; stratejilerin gizli katmandaki yerleşimi ise rastgele belirlenmektedir. Böylece farklı örnek ilişkilerinden elde edilen bilgilerin tek bir model yapısı içerisinde birlikte kullanılması amaçlanmaktadır. Çalışmanın literatüre temel katkısı, kısıtlı ağırlık üretimini tek bir stratejiyle sınırlandırmak yerine farklı sınıf ilişkilerini temsil eden dört stratejiyi bölümlendirilmiş ve rastgele düzenlenen bir gizli katman yapısında bir araya getirmesidir.

Tablo 1.1’de özetlenen çalışmaların yanı sıra, giriş bölümünde ve deneysel sonuçlar ile tartışma bölümünde ELM varyantları ve karşılaştırma amacıyla kullanılan makine öğrenmesi yöntemlerine ilişkin diğer araştırmalardan da yararlanılmış; bu bağlamda literatür taramasından elde edilen bilgiler tezin ilgili bölümleri içerisinde sunulmuştur.

2. METOT

Tez kapsamında gerçekleştirilen deneysel çalışmalar, kapsamaları ve değerlendirme süreçleri bakımından iki ayrı aşamada yürütülmüştür. İlk aşamada standart ELM ile IELM, OSELM, RELM ve CELM modelleri, farklı görüntü sınıflandırma problemleri üzerinde karşılaştırılmıştır. Bu kapsamda el yazısı rakam görüntülerinden oluşan el yazısı rakamlarını tanıma (Modified National Institute of Standards and Technology-MNIST), beyin tümörü sınıflarını içeren manyetik rezonans (Magnetic Resonance Imaging-MRI) görüntüleri, farklı pirinç türlerine ait görüntüler ve sürücülerin uyanıklık durumlarını temsil eden görüntüler kullanılmıştır. Veri kümelerinin hazırlanması, eğitim ve test örneklerinin oluşturulması ile model parametrelerinin belirlenmesi, ilgili veri yapılarının gerektirdiği işlemler doğrultusunda gerçekleştirilmiştir.

İkinci aşamada önerilen ReSQu-CELM modelinin deneysel değerlendirmesi WaveformEW, Ecoli, Breast Cancer, Madelon, Hill-Valley ve Digits veri kümeleri üzerinde yapılmıştır. Bu aşamada ReSQu-CELM; ELM, CDELM, Destek Vektör Makineleri (Support Vector Machine -SVM), Çok Katmanlı Algılayıcı (Multilayer Perceptron -MLP), Karar Ağacı (Decision Tree -DT) ve Rastgele Orman (Random Forest -RF) yöntemleriyle karşılaştırılmıştır. Deneylerde veri kümelerine Min–Max normalizasyonu uygulanmış ve modellerin performansı tabakalı 10 katlı çapraz doğrulama yöntemiyle değerlendirilmiştir. Ayrıca gizli nöron sayısının model başarımına etkisi incelenmiş, farklı strateji düzenlemelerinin katkısını belirlemek amacıyla bileşen karşılaştırmaları gerçekleştirilmiş ve yöntemler arasındaki performans farklılıkları istatistiksel testlerle analiz edilmiştir.

Değerlendirme ölçütleri, çalışmaların problem yapıları ve deneysel amaçları doğrultusunda belirlenmiştir. İlk aşamada modellerin görüntü sınıflandırma performansları doğruluk, hassasiyet, geri çağırma ve F1-skoru üzerinden incelenmiştir. İkinci aşamada ise doğruluk değerinin yanı sıra özellikle dengesiz sınıf dağılımlarındaki model davranışını değerlendirebilmek amacıyla makro F1 ve ağırlıklı-F1 ölçütlerinden yararlanılmıştır. Bunlara ek olarak eğitim süreleri kaydedilerek modellerin hesaplama maliyetleri de karşılaştırmalı biçimde ele alınmıştır. Kullanılan veri kümeleri, ön işleme adımları, model yapılandırmaları ve değerlendirme süreçleri izleyen alt bölümlerde ayrıntılı olarak açıklanmaktadır.

2.1. Standart Aşırı Öğrenme Makineleri (ELM)

ELM, tek gizli katmanlı ileri beslemeli yapay sinir ağı modelidir. Klasik yapay sinir

ağlarından farklı olarak ELM'nin temel özelliği, gizli katmandaki ağırlıkları rastgele belirlemesi ve bu ağırlıkları sabit tutarak yalnızca çıkış katmanındaki ağırlıkları öğrenmesidir (Huang vd., 2006). Bu yaklaşım, eğitim sürecini önemli ölçüde hızlandırmakta ve modelin etkin bir şekilde öğrenmesini sağlamaktadır. ELM'nin yapısı, giriş katmanından gizli katmana, ardından ise çıkış katmanına gerçekleşen bilgi aktarımından oluşmaktadır. Gizli katmandaki çıktılar ise genellikle bir aktivasyon fonksiyonu kullanılarak hesaplanmaktadır.

$X \in \mathbb{R}^{N \times d}$ ile gösterilen bir eğitim veri kümesi için, ELM'nin gizli katman çıktı matrisi aşağıdaki gibi ifade edilmektedir:

$$H = g(XW + \mathbf{1}b) \quad (D.1)$$

Burada; $X \in \mathbb{R}^{N \times d}$ eğitim veri matrisini, $X \in \mathbb{R}^{N \times d}$ giriş katmanı ile gizli katman arasındaki ağırlık matrisini, $b \in \mathbb{R}^{1 \times L}$ eşik (bias) vektörünü, $H \in \mathbb{R}^{N \times L}$ gizli katman çıktı matrisini, N örnek sayısını, d özellik sayısını, L ise gizli katmandaki nöron sayısını ifade etmektedir.

Çıkış katmanına ait ağırlıklar ise Moore–Penrose genelleştirilmiş tersi kullanılarak analitik olarak aşağıdaki şekilde hesaplanmaktadır:

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

Burada; β çıkış katmanı ağırlık matrisini, T one-hot kodlanmış hedef matrisini, H^+ H matrisinin Moore-Penrose psödotesini ifade etmektedir.

D.1 ve D.2'de görüldüğü üzere, ELM gizli katman parametrelerini rastgele atayıp çıkış katmanı ağırlıklarını analitik olarak hesaplayarak hızlı bir öğrenme süreci gerçekleştirmektedir. Bununla birlikte, gizli katman ağırlıklarının rastgele başlatılması, modelde kararsızlığa ve gizli katman temsillerinin dengesiz oluşmasına neden olabilmektedir. Bu nedenle, literatürde birçok çalışma, gizli katman parametrelerinin tamamen rastgele başlatılması yerine veri odaklı kısıtlamalara dayalı olarak oluşturulmasına odaklanmıştır

2.2. Artırımlı Aşırı Öğrenme Makineleri (IELM)

IELM, başlangıç aşamasında gizli katman sınırlı sayıda nöron ile oluşturulmaktadır. Eğitim süreci ilerledikçe algoritma, önceden tanımlanan en yüksek gizli katman nöron sayısına ulaşıncaya kadar gizli katmana her adımda rastgele yeni bir nöron eklemektedir. Her ekleme işleminden sonra yalnızca sonradan ilave edilen nöron ile çıkış katmanı arasındaki bağlantılara

ait ağırlıklar hesaplanarak model güncellenmektedir (Huang ve Chen, 2007; Ding vd., 2014).

2.3. Çevrimiçi Sıralı Aşırı Öğrenme Makineleri (OSELM)

ELM algoritması, model eğitimi sırasında mevcut eğitim verilerinin tamamını birlikte kullanmaktadır. Ancak bu yaklaşım, özellikle büyük ölçekli veri kümelerinde hesaplama süresini uzatmakta ve işlem yükünü artırmaktadır. Bu sınırlılığı gidermek amacıyla, yalnızca sisteme sonradan eklenen verileri kullanarak model parametrelerini güncelleyen OSELM geliştirilmiştir (Huang vd., 2005).

2.4. Düzenlenmiş Aşırı Öğrenme Makineleri (RELM)

RELM, standart ELM yaklaşımının genelleme performansını artırmayı amaçlayan geliştirilmiş bir sürümüdür. Klasik ELM’de gizli katmana ait ağırlıklar rastgele oluşturulurken, çıkış katmanı ağırlıkları en küçük kareler yöntemi kullanılarak hesaplanmaktadır. Bu yaklaşım bazı durumlarda modelin eğitim verisine aşırı uyum göstermesine neden olabilmektedir. RELM’de ise bu sorunun önüne geçebilmek amacıyla çıkış katmanı ağırlıkları çeşitli düzenleme teknikleri uygulanarak elde edilmektedir. Düzenleme yaklaşımı, modelin karmaşıklığını dengeleyerek aşırı öğrenme eğilimini sınırlandırmakta ve böylece eğitim sürecinde karşılaşmadığı veriler üzerinde daha başarılı bir genelleme performansı sergilemesine katkı sağlamaktadır. Böylece RELM, hem eğitim verisini etkili biçimde temsil edebilmekte hem de yeni örnekler üzerinde daha kararlı ve güvenilir sonuçlar üretebilmektedir (Deng vd., 2009).

2.5. Kısıtlanmış Aşırı Öğrenme Makineleri (CELM)

CELM, ELM yaklaşımında gizli katman ağırlıklarının rastgele oluşturulmasından kaynaklanan sınırlılıkları azaltmak amacıyla önerilmiş bir yöntemdir (Zhu vd., 2014). ELM, yüksek öğrenme hızıyla öne çıkmasına karşın, yeterli genelleme performansına ulaşabilmek için çoğu zaman fazla sayıda gizli katman nöronu gerektirmektedir. Bu durum ise özellikle tahmin aşamasında hesaplama maliyetinin artmasına neden olabilmektedir. CELM yaklaşımında, gizli katman nöronları tamamen rastgele oluşturulmak yerine eğitim örneklerinin dağılımını dikkate alan belirli kısıtlar doğrultusunda belirlenmektedir. Bu amaçla, gizli katman yapısının oluşturulmasında farklı örnek seçme ve ağırlık üretme stratejilerinden yararlanılmaktadır.

CSELM, aynı sınıfa ait iki eğitim örneğinin toplamından elde edilen vektörleri kullanarak gizli katman ağırlıklarını oluşturmaktadır. Bu yaklaşım, gürültülü veri yapılarının

olumsuz etkisini azaltmayı hedefleyerek daha dayanıklı özellik temsillerinin elde edilmesine katkı sağlamaktadır (Zhu vd., 2014).

Örnek Tabanlı Aşırı Öğrenme Makinesi (Sample Extreme Learning Machine-SELM) yönteminde ise eğitim kümesinde yer alan örnekler doğrudan gizli katman ağırlıkları olarak değerlendirilmektedir. Bu örnek vektörleri normalize edildikten sonra modele aktarılmakta ve böylece gizli katman yapısı oluşturulmaktadır (Zhu vd., 2014). Buna karşılık, Rastgele Toplam Aşırı Öğrenme Makinesi (Random Sum Extreme Learning Machine-RSELM) yaklaşımında rastgele seçilen eğitim örneklerinin toplam vektörlerinden yararlanılarak gizli katman ağırlıkları belirlenmekte, bu sayede hesaplama süreci daha verimli hâle getirilmektedir (Zhu vd., 2014).

CMELM, gizli katmanın oluşturulmasında hem fark hem de toplam vektörlerinden yararlanan hibrit bir yöntemdir. Bu yapı sayesinde CSELM yaklaşımlarının güçlü yönleri tek bir model içerisinde birleştirilmektedir (Zhu vd., 2014).

CDELM ise gizli katman parametrelerini rastgele belirlemek yerine, farklı sınıflara ait eğitim örnekleri arasındaki fark vektörlerinden yararlanmaktadır. Geleneksel ELM’de gizli katman ağırlıkları rastgele oluşturulurken, CDELM’de sınıflar arasındaki ayırt edici bilgiyi daha etkili şekilde temsil edebilmek amacıyla bu fark vektörleri doğrudan gizli katman ağırlıklarının oluşturulmasında kullanılmaktadır. Böylece oluşturulan gizli katman temsili, sınıflar arasındaki ayırt edici bilgiyi daha etkili biçimde yansıtarak karar sınırlarının daha başarılı oluşturulmasına katkı sağlamaktadır. Buna bağlı olarak gizli katman ağırlık vektörü aşağıdaki matematiksel ifade yardımıyla hesaplanmaktadır:

$$\mathcal{W} = \frac{2(X_i - X_j)}{\|X_i - X_j\|_{L_2}^2} \quad (D.3)$$

Burada X_i ve X_j farklı sınıflardan rastgele seçilen iki eğitim örneğini temsil ederken, $\|\cdot\|$ ifadesi normalizasyon amacıyla kullanılan Öklid normunu göstermektedir. Öklid normu ile gerçekleştirilen normalizasyon işlemi, ağırlık değerlerinin aşırı büyümesini önleyerek eğitim sürecinin sayısal açıdan daha kararlı yürütülmesine katkı sağlamaktadır.

Aynı gizli katman nöronuna ait bias değeri ise aşağıdaki denklem kullanılarak hesaplanmaktadır

$$b = \frac{(X_i + X_j)^T (X_i - X_j)}{\|X_i - X_j\|_{L_2}^2} \quad (D.4)$$

D.3 ve D.4'te gösterildiği gibi, gizli katman nöronları sınıflar arası örnekler arasındaki ilişkiler dikkate alınarak konumlandırılmaktadır. Bu sayede model, ayırt edici örüntüleri daha etkili bir şekilde yakalayabilmekte ve rastgele ağırlık başlatmasına dayanan geleneksel ELM yapılarına kıyasla gizli katmanda daha zengin ve çeşitli temsiller oluşturabilmektedir. Bu çalışmada, CELM yapısı temel bir model ve önerilen çok stratejili ReSQu-CELM modelinin kavramsal altyapısı olarak benimsenmiştir. Bu tercih, son yıllarda önerilen Meta-CELM çalışmalarında kısıtlı ELM yapılarının başarılı bir şekilde kullanılmasına dayandırılarak yapılmıştır (Serin vd., 2026).

2.6. IntelELM Kütüphanesi

Bu çalışmada ELM tabanlı modellerin geliştirilmesi, uygulanması ve karşılaştırılması amacıyla açık kaynaklı Python kütüphanesi olan IntelELM (Intelligent Metaheuristic-based Extreme Learning Machine) kullanılmıştır (Van Thieu vd., 2025).

IntelELM, klasik ELM algoritmasının esnek ve modüler bir şekilde yeniden tasarlanmış halidir. Temel ELM mimarilerini (ElmClassifier ve ElmRegressor) doğrudan desteklemenin yanı sıra, CELM, Evrimsel ELM (Evolutionary ELM -E-ELM) ve çeşitli meta-sezgisel optimizasyon tabanlı ELM varyantlarının uygulanmasına da olanak tanımaktadır. Bu yapı, ELM'nin geleneksel rastgele ağırlık başlatma sürecini meta-sezgisel yöntemlerle optimize ederek modelin genelleme yeteneğini artırmayı amaçlamaktadır.

Kütüphane, Genetik Algoritma (Genetic Algorithm -GA), Parçacık Sürü Optimizasyonu (Particle Swarm Optimization -PSO), Diferansiyel Evrim (Differential Evolution -DE), Gri Kurt Optimizasyonu (Grey Wolf Optimizer -GWO) gibi optimizasyon tekniklerinin ELM eğitim sürecine entegre edilmesi için hazır modüller sunmaktadır. Bu sayede hem temel ELM modelleri hem de hibrit varyantlar için esnek parametre kontrolü ve başarımların izleme imkânı sağlanmaktadır.

Bu çalışmada IntelELM, hem klasik ELM ve CELM modellerinin uygulanması hem de önerilen ReSQu-CELM modelinin geliştirilmesi için temel yazılım altyapısı olarak kullanılmıştır. ReSQu-CELM modelinin eğitim, test ve başarımların değerlendirme süreçleri IntelELM'in sınıflandırma modülleri kullanılarak gerçekleştirilmiş ve deneyler boyunca aynı

veri işleme altyapısı korunarak tutarlı karşılaştırmalar yapılmıştır.


Deneyler, Python 3.11.5 ortamında IntelELM v1.3.0 kullanılarak gerçekleştirilmiştir. IntelELM'in bağımlılıkları arasında NumPy (numpy), Scikit-learn (scikit-learn), Pandas (pandas) ve Matplotlib (matplotlib) kütüphaneleri yer almaktadır. Bu yapı, önerilen modelin farklı veri setleri üzerinde yeniden üretilebilirliğini kolaylaştırmış ve ELM tabanlı yaklaşımların karşılaştırmalı analizleri için standart bir deneysel çerçeve sunmuştur.

2.7. Rastgele Stratejili Çeyreklenmiş Kısıtlanmış Aşırı Öğrenme Makinesi (Randomized Strategy Quartered Constrained Extreme Learning Machine- ReSQu-CELM)

Bu çalışmada, CELM yaklaşımına dayanan ve gizli katman oluşturma sürecine çoklu ve rastgeleleştirilmiş stratejiler kazandıran ReSQu-CELM modeli önerilmektedir. Önerilen model, ELM yapılarında gizli katman parametrelerinin tamamen rastgele belirlenmesinden kaynaklanan başarımların kararsızlığını azaltmayı ve veri odaklı bir yaklaşımla daha ayırt edici bir özellik uzayı oluşturmaya hedeflemektedir.

Standart ELM yaklaşımında gizli katman ağırlıkları ve bias değerleri rastgele atanmakta, yalnızca çıkış katmanı ağırlıkları analitik olarak hesaplanmaktadır. CELM yöntemi ise bu süreci, örnek dağılımına dayalı belirli kısıtlar altında gizli katman parametrelerini oluşturarak iyileştirmektedir. Ancak klasik CELM yapısında genellikle tek bir kısıt stratejisi tüm gizli nöronlara homojen biçimde uygulanmaktadır.

Buna karşılık, ReSQu-CELM modeli, aynı ağ mimarisi içerisinde birden fazla tamamlayıcı kısıt stratejisini bir arada kullanarak gizli katmanın temsil gücünü artırmayı amaçlamaktadır. Bu sayede model, farklı veri özelliklerini daha etkili bir şekilde yakalayabilmekte ve daha dengeli bir öğrenme süreci sunmaktadır. Şekil 2.1'de önerilen ReSQu-CELM modelinin temel çalışma prensibi ve ana aşamalarını gösteren şematik yapı sunulmaktadır.



Şekil 2.1. Önerilen ReSQu-CELM modelinin işlem aşamaları

Şekil 2.1’de, önerilen ReSQu-CELM algoritmasının genel iş akışı gösterilmektedir. Süreç; veri kümesinin hazırlanması, eğitim-test ayrımı, Min-Max normalizasyonu, modelin oluşturulması, gizli katman nöronlarının dört gruba ayrılarak rastgele strateji atanması, karar katmanının oluşturulması ve performans değerlendirme aşamalarından oluşmaktadır.

ELM ve standart CELM yaklaşımlarından farklı olarak, ReSQu-CELM modelinde her bir gizli katman nöronunun ağırlık ve bias değerleri, sınıf etiketlerine göre seçilen örnek çiftleri kullanılarak doğrudan eğitim verisinden elde edilmektedir. Bu aşamada eğitim örnekleri, aynı sınıfa veya farklı sınıflara ait olacak biçimde eşleştirilmekte ve böylece gizli katman nöronlarının hem sınıf içindeki benzerlikleri hem de sınıflar arasındaki ayırt edici özellikleri öğrenebilmesi amaçlanmaktadır.

ReSQu-CELM modelinin temel yeniliği, gizli katmanın çeyrek tabanlı olarak yapılandırılmasıdır. Bu yapıda gizli katman nöronları eşit büyüklükte dört gruba ayrılmakta ve her bir gruba dört farklı kısıt stratejisinden biri atanmaktadır: (1) farklı sınıflara ait örneklerin farkına dayalı, (2) farklı sınıflara ait örneklerin toplamına dayalı, (3) aynı sınıfa ait örneklerin farkına dayalı ve (4) aynı sınıfa ait örneklerin toplamına dayalı stratejiler. Bu stratejiler her çalıştırmada rastgele permüte edilerek gruplara atanmakta, böylece farklı çalıştırmalarda (örneğin 1–4–2–3 gibi) farklı strateji–grup eşleşmeleri elde edilmektedir. Her bir kısıt stratejisi için ağırlık ve bias parametrelerinin hesaplanmasında kullanılan matematiksel ifadeler Tablo 2’de özetlenmektedir.

Tablo 2.1 ReSQu-CELM modelinde kullanılan kısıtlama stratejilerinin matematiksel formülü

Strateji	Örnekleme Koşulu	Ağırlık Vektörü	Bias Terimi
(1) Farklı sınıf farkı	$y_i \neq y_j$	$w = \frac{2(X_j - X_i)}{\ X_j - X_i\ _{L_2}^2}$	$b = \frac{(X_i + X_j)^T \cdot (X_i - X_j)}{\ X_i - X_j\ _{L_2}^2}$
(2) Farklı sınıf toplamı	$y_i \neq y_j$	$w = \frac{2(X_i + X_j)}{\ X_j - X_i\ _{L_2}^2}$	$b = \frac{(X_i + X_j)^T \cdot (X_i - X_j)}{\ X_i - X_j\ _{L_2}^2}$
(3) Aynı sınıf farkı	$y_i = y_j$	$w = \frac{2(X_j - X_i)}{\ X_j - X_i\ _{L_2}^2}$	$b = \frac{(X_i + X_j)^T \cdot (X_i - X_j)}{\ X_i - X_j\ _{L_2}^2}$

(4) Aynı sınıf toplamı	$y_i = y_j$	$w = \frac{2(X_i + X_j)}{\ X_j - X_i\ _{L_2}^2}$	$b = \frac{(X_i + X_j)^T \cdot (X_i - X_j)}{\ X_i - X_j\ _{L_2}^2}$
------------------------	-------------	--	---

Tablo 2.1’de gösterildiği üzere, dört strateji hem örnek seçim koşulları hem de gizli nöron parametrelerinin matematiksel olarak oluşturulma biçimi açısından birbirinden farklıdır. Farklı sınıf temelli stratejiler, koşulunu sağlayan örnek çiftlerini kullanarak sınıflar arası ayrımı artırmayı amaçlarken; aynı sınıf temelli stratejiler, koşulunu sağlayan örnek çiftlerini kullanarak sınıf içi tutarlılığı korumaya odaklanmaktadır. Benzer şekilde, fark temelli stratejiler örnekler arasındaki ayırt edici yönsel bilgiyi vurgularken, toplam temelli stratejiler veri dağılımına ait temsil edici yapısal bilgiyi kodlamaktadır. Buna bağlı olarak, her strateji kendi matematiksel formülasyonunu kullanarak gizli nöronların ağırlık ve bias parametrelerini üretmekte, böylece gizli katmanın birbirini tamamlayıcı özellik temsilleri öğrenmesi sağlanmaktadır. Ayrıca, dört stratejinin tamamında aynı bias formülasyonu kullanılırken, ağırlık vektörü formülasyonu stratejinin fark temelli ya da toplam temelli olmasına göre değişmektedir. Önerilen ReSQu-CELM modelinin genel eğitim süreci ise Algoritma 2.1’de özetlenmiştir.

Algoritma 2.1. Önerilen ReSQu-CELM modelinin eğitim süreci

Girdi: Eğitim verisi X , sınıf etiketleri y , gizli nöron sayısı L , aktivasyon fonksiyonu $g(\cdot)$

Çıktı: Eğitilmiş ReSQu-CELM modeli

- 1) Gizli katman ağırlık matrisi W ve bias vektörü b başlatılır.
 - 2) L adet gizli nöron dört eşit parçaya ayrılır.
 - 3) Farklı sınıf farkı, farklı sınıf toplamı, aynı sınıf farkı ve aynı sınıf toplamı olmak üzere dört kısıt stratejisi tanımlanır.
 - S_1 : farklı sınıf farkı temelli strateji
 - S_2 : farklı sınıf toplam temelli strateji
 - S_3 : aynı sınıf fark temelli strateji
 - S_4 : aynı sınıf toplam temelli strateji
 - 4) Dört kısıt stratejisi $\{S_1, S_2, S_3, S_4\}$ rastgele permüte edilir.
 - 5) Permüte edilen her strateji gizli katmandaki bir çeyreğe atanır.
 - 6) **for** her gizli katman çeyreği $q = 1, 2, 3, 4$ **do**
 - 7) S_q, q . çeyreğe atanan strateji olarak belirlenir.
-

-
- 8) **for** q . çeyrekteki her gizli nöron h **do**
 - 9) S_q 'nın sınıf etiketi koşuluna göre bir eğitim örnek çifti (x_i, x_j) seçilir.
 - 10) S_q 'ya karşılık gelen formülasyon kullanılarak gizli nöron ağırlık vektörü (w_h) oluşturulur.
 - 11) Ortak bias formülasyonu kullanılarak bias terimi b_h hesaplanır.
 - 12) w_h , W matrisine; b_h ise b vektörüne kaydedilir.
 - 13) **end for**
 - 14) **end for**
 - 15) Gizli katman çıkış matrisi hesaplanır:

$$H = g(XW + \mathbf{1}b)$$
 - 16) Moore-Penrose psödotesi kullanılarak çıkış ağırlık matrisi hesaplanır:

$$\beta = H^+T$$
 - 17) W , b ve β parametrelerini içeren eğitilmiş ReSQu-CELM modeli döndürülür.
-

2.8. Veri Setleri

Deneyisel değerlendirmelerde, farklı yapısal özelliklere sahip veri setlerinden yararlanılmıştır. Çalışmanın ilk aşamasında ELM tabanlı yöntemlerin karşılaştırılması amacıyla görüntü tabanlı dört veri seti kullanılmıştır. Eğitim ve test veri setlerindeki görüntülerin boyutları 64x64 olarak ayarlanmıştır. Var olan görüntülere veri arttırma yöntemleri uygulanmıştır. İkinci aşamada ise önerilen ReSQu-CELM modelinin farklı veri karakteristikleri altındaki davranışını incelemek amacıyla altı ek veri seti değerlendirmeye dahil edilmiştir. Böylece model performansı; örnek sayısı, öznitelik boyutu, sınıf sayısı ve veri dağılımı bakımından birbirinden farklı problemlerde analiz edilmiştir. Kullanılan veri kümelerinin temel özellikleri Tablo 2.2’de özet olarak verilmiştir.

Tablo 2.2 Kullanılan veri setlerinin temel özellikleri


Veri Seti	Sınıf Sayısı	Veri Sayısı	Sınıflar Arası Dağılım	Veri türü/Öznitelik Boyutu
MNIST	10	70.000	Dengesiz	Görüntü verisi; eğitim ve test görüntüleri 64×64 boyutuna ayarlanmıştır.
Beyin MR Görüntüleri	4	7023	Dengesiz	Görüntü verisi; eğitim ve test görüntüleri 64×64 boyutuna ayarlanmıştır.
Pirinç Görüntüleri	5	75.000	Dengeli	Görüntü verisi; eğitim ve test görüntüleri 64×64 boyutuna ayarlanmıştır.

Araç Sürücüsü Uyku Durumu	2	41.796	Dengesiz	Görüntü verisi; eğitim ve test görüntüleri 64×64 boyutuna ayarlanmıştır.
WaveformEW	3	5.000	Dengeli	Sayısal veri; 40 öznitelik
Ecoli	7	336	Dengesiz	Sayısal veri; 7 öznitelik
Breast Cancer	2	699	Dengesiz	Sayısal veri; 9 öznitelik
Madelon	2	2.600	Dengeli	Sayısal veri; 500 öznitelik
Hill-Valley	2	606	Dengeli	Sayısal/zaman serisi verisi; 100 öznitelik.
Digits	10	1.796	Dengeli	Görüntü verisi; özgün görüntü boyutu 8×8 piksel, 64 öznitelik.

Tablo 2.2’de deneysel çalışmalarda kullanılan veri setlerinin temel özellikleri özetlenmektedir. Veri kümeleri; örnek sayısı, sınıf yapısı ve öznitelik özellikleri bakımından birbirinden farklılık göstermektedir. Bu çeşitlilik, önerilen yöntemin farklı problem tiplerindeki davranışının kapsamlı biçimde incelenmesine olanak sağlamaktadır. Bu çalışmada yararlanılan veri setlerine ilişkin sınıf dağılımları ile ayrıntılı açıklamalar, izleyen alt başlıklarda ayrı ayrı ele alınmıştır.

2.8.1. MNIST Veri Seti

MNIST, el yazısıyla oluşturulmuş rakam görüntülerini içeren ve makine öğrenmesi ile bilgisayarlı görü alanında en yaygın kullanılan kıyaslama veri setlerinden biridir (LeCun, 1998). Veri seti, Amerika Birleşik Devletleri Ulusal Standartlar ve Teknoloji Enstitüsü (NIST) tarafından hazırlanan farklı rakam veri koleksiyonlarının yeniden düzenlenmesiyle oluşturulmuş olup, uzun yıllardır sınıflandırma algoritmalarının başarımlarını değerlendirmek amacıyla kullanılmaktadır. Basit yapısı, standart formatı ve literatürde geniş kabul görmesi nedeniyle yeni yöntemlerin karşılaştırılmasında referans veri seti olarak tercih edilmektedir (Kadam vd., 2020). Veri setine ait örnek görüntüler Şekil 2.2’de gösterilmektedir.




Şekil 2.2 MNIST veri setindeki sınıflara ait görüntüler

MNIST veri seti, el yazısı rakamların sınıflandırılması amacıyla yaygın olarak kullanılan standart bir görüntü veri setidir. Veri seti, 0'dan 9'a kadar olan rakamları içeren 10 farklı sınıftan oluşmaktadır. Her bir örnek, 28×28 boyutunda gri seviye (grayscale) görüntülerden oluşmakta olup toplamda 70.000 adet görüntü içermektedir. Bu görüntüler, düşük çözünürlüklü ancak sınıflandırma algoritmalarının başarımını değerlendirmek için yeterli ayırt edici özellikler barındırmaktadır.

2.8.2. Beyin Tümörü MRI Görüntüleri Veri Seti

Beyin tümörü MRI görüntüleri veri seti, farklı beyin tümörü tiplerine ait manyetik rezonans görüntülerini ve sağlıklı bireylere ait MRI kesitlerini içeren tıbbi bir görüntü veri setidir. Veri kümesi, görüntü işleme ve bilgisayar destekli tanı çalışmalarında sınıflandırma modellerinin değerlendirilmesi amacıyla yaygın olarak kullanılmaktadır. Farklı doku yapıları ve tümör tipleri nedeniyle yüksek görsel çeşitlilik içeren bu veri seti, özellikle tıbbi görüntüler üzerinde çalışan makine öğrenmesi yöntemleri için önemli bir değerlendirme ortamı sunmaktadır. Veri setinden seçilen örnek görüntüler Şekil 2.3'te verilmiştir (Masoudnickparvar, 2023).




Şekil 2.3 Beyin tümörü veri setindeki sınıflara ait görüntüler

Veri kümesi, Figshare, SARTAJ ve Br35H veri setlerinin birleştirilmesiyle oluşturulmuş toplam 7023 MR görüntüsünden meydana gelmektedir. Görüntüler; glioma, meningioma, hipofiz tümörü ve tümör bulunmayan (no tumor) olmak üzere dört farklı sınıfa ayrılmıştır.

2.8.3. Pirinç Görüntü Veri Seti

Pirinç görüntü veri seti, farklı pirinç çeşitlerine ait görselleri içeren ve tarımsal ürünlerin otomatik sınıflandırılmasına yönelik çalışmalarda yaygın olarak kullanılan bir veri kümesidir. Görüntüler, her bir pirinç çeşidinin şekil, boyut ve yüzey özelliklerini yansıtacak biçimde standart koşullarda hazırlanmıştır. Bu özellikleri sayesinde veri seti, hem geleneksel makine öğrenmesi yöntemlerinin hem de derin öğrenme tabanlı yaklaşımların performansını değerlendirmek için uygun bir test ortamı sunmaktadır (Köklü vd., 2021). Veri setinden seçilen örnek görüntüler Şekil 2.4'te gösterilmektedir.



Şekil 2.4 Pirinç veri setindeki sınıflara ait görüntüler

Veri seti, Arborio, Basmati, Ipsala, Jasmine ve Karacadağ olmak üzere beş farklı pirinç

çeşidini kapsamaktadır. Her sınıf için 15.000 görüntü bulunmakta olup toplam örnek sayısı 75.000'dir. Dengeli sınıf dağılımına sahip olması nedeniyle sınıflandırma algoritmalarının performansının tarafsız biçimde değerlendirilmesine olanak sağlamaktadır.

2.8.4. Araç Sürücüsü Uyku Durumu Veri Seti

Araç sürücüsü uyku durumu veri seti, sürücülerin uyanık ve uykulu olduğu anlara ait yüz görüntülerini içeren gerçek yaşam temelli bir veri kümesidir. Görüntülerde göz açıklığı, baş duruşu ve yüz ifadeleri gibi uykululukla ilişkili görsel ipuçları yer almaktadır. Farklı aydınlatma koşulları ve kamera açıları altında elde edilen örnekler, geliştirilen modellerin gerçek kullanım senaryolarındaki dayanıklılığının değerlendirilmesine olanak sağlamaktadır (Nasri, 2023). Veri setinden seçilen örnek görüntüler Şekil 2.5'te sunulmaktadır.




Şekil 2.5 Araç sürücüsü uyku durumu veri setindeki sınıflara ait görüntüler

Veri seti, gerçek sürüş videolarından elde edilen yüz görüntülerinin işlenmesiyle oluşturulmuştur. Toplam 41.796 görüntü, sürücünün uyanık veya uykulu olma durumuna göre iki ayrı sınıfa ayrılmıştır. Bu yapı, sürücü dikkatinin otomatik olarak belirlenmesine yönelik geliştirilen sınıflandırma yöntemlerinin değerlendirilmesi için uygun bir deney ortamı sağlamaktadır.

2.8.5. WaveformEW Veri Seti

WaveformEW veri seti, yapay olarak oluşturulmuş ve çok sınıflı sınıflandırma problemleri için kullanılan bir benchmark veri setidir. Veri seti, dalga formu sinyallerinin farklı kombinasyonlarından türetilmiş örnekleri içermektedir. Her bir örnek, belirli temel dalga formlarının lineer birleşimi ve gürültü bileşenleri ile oluşturulmuştur. Bu yapı, veri setinin sınıflar arası ayrımın zor olduğu ve gürültü etkisinin belirgin olduğu bir problem sunmasına neden olmaktadır. Bu yönüyle WaveformEW veri seti, sınıflandırma algoritmalarının genelleme yeteneğini değerlendirmek amacıyla sıklıkla kullanılan sentetik veri setlerinden

biridir (Dua ve Graff, 2019). Şekil 2.6’da, WaveformEW veri setine ait örneklerin Temel Bileşenler Analizi (Principal Component Analysis -PCA) yöntemi ile iki boyuta indirgenmiş dağılımı gösterilmektedir. Farklı renkler üç ayrı sınıfı temsil etmektedir. Veri setindeki örnekler yüksek boyutlu dalga formu özelliklerinden oluşmakta olup, sınıflar arasında kısmi örtüşmeler gözlemlenmektedir.




Şekil 2.6. PCA kullanılarak iki boyuta indirgenen WaveformEW veri setindeki örneklerin sınıf dağılımı

Veri seti, üç sınıfa ait toplam 5.000 örnekten oluşmakta olup her örnek 40 öznitelikle temsil edilmektedir. Bu özniteliklerin 21’i özgün dalga formu özelliklerini, kalan 19’u ise gürültü bileşenlerini içermektedir. Gürültülü yapısı ve doğrusal olmayan sınıf sınırları nedeniyle, veri seti sınıflandırma modellerinin genelleme kabiliyetini değerlendirmek için uygun bir kıyaslama ortamı sunmaktadır.

2.8.6. Ecoli Veri Seti

Ecoli veri seti, *Escherichia coli* bakterisine ait proteinlerin hücre içindeki lokalizasyonunu tahmin etmeye yönelik oluşturulmuş bir biyoinformatik veri setidir. Veri seti, proteinlerin farklı hücresel bölgelere ait sınıflarını içermekte olup, her bir örnek belirli biyolojik özellikleri temsil eden özniteliklerden oluşmaktadır. Sınıflar arasındaki dengesiz dağılım ve sınırlı örnek sayısı, veri setini sınıflandırma algoritmaları açısından zorlu hale getirmektedir. Bu nedenle Ecoli veri seti, özellikle dengesiz veri problemlerinin incelenmesinde yaygın olarak kullanılmaktadır (Horton ve Nakai, 1996). Şekil 2.7’de, Ecoli veri setindeki mikroorganizma örneklerinin iki temel biyokimyasal özellik (mcg ve gvh) eksenleri boyunca görselleştirilmiş

dağılımı sunulmaktadır. Renkler, farklı hücre içi lokalizasyon sınıflarını temsil etmektedir.




Şekil 2.7. Ecoli veri setindeki mikroorganizma örneklerinin mcg ve gvh biyokimyasal özelliklerine göre sınıf dağılımı

Veri kümesi, yedi farklı sınıfa ait toplam 336 örnek ve yedi öznitelikten oluşmaktadır. Sınıflar arasındaki belirgin dengesizlik ve sınırlı örnek sayısı, özellikle küçük ölçekli ve dengesiz veri problemlerinde geliştirilen yöntemlerin başarısını değerlendirmek açısından veri setini önemli hâle getirmektedir.

2.8.7. Breast Cancer Veri Seti


Breast Cancer veri seti, meme kanseri teşhisine yönelik oluşturulmuş ve tıbbi veri analizi çalışmalarında sıkça kullanılan bir veri setidir. Veri seti, hücre çekirdeği özelliklerinden elde edilen sayısal öznitelikleri içermektedir. İki sınıftan oluşan, 699 örnek ve 10 öznitelik içeren bir veri setidir. Veri seti, örneklerin iyi huylu (benign) ve kötü huylu (malign) olarak sınıflandırıldığı tıbbi bir ikili sınıflandırma problemini temsil etmektedir. Sınıf dağılımındaki dengesizlik nedeniyle, tıbbi karar destek sistemlerinde kullanılan sınıflandırma modellerinin dayanıklılığı ve güvenilirliğinin değerlendirilmesi açısından uygun bir referans sunmaktadır. Veri setindeki özniteliklerin büyük bölümü hücre çekirdeğine ait şekil ve doku karakteristiklerini yansıtmaktadır (Dua ve Graff, 2019). Şekil 2.8’de, Breast Cancer veri setine ait örneklerin PCA kullanılarak iki boyuta indirgenmiş uzaydaki dağılımı gösterilmektedir. Her bir renk farklı bir sınıfı temsil etmektedir.



Şekil 2.8. PCA kullanılarak iki boyuta indirgenen Breast Cancer veri setindeki örneklerin sınıf dağılımı

2.8.8. Madelon Veri Seti


Madelon veri seti, yüksek boyutlu ve yapay olarak oluşturulmuş bir sınıflandırma veri setidir. Veri seti, doğrusal olmayan bir problem yapısına sahip olup, az sayıda anlamlı öznitelik ile çok sayıda gürültü özniteliği içermektedir. Bu özellik, veri setini özellikle öznitelik seçimi ve yüksek boyutlu veri analizi problemleri için uygun hale getirmektedir. Madelon veri seti, sınıflandırma yöntemlerinin ilgisiz ve gereksiz özellikler karşısındaki dayanıklılığını değerlendirmek amacıyla literatürde yaygın biçimde kullanılan kıyaslama veri setlerinden biridir. Veri seti; iki sınıftan oluşan, 2.600 örnek ve 500 öznitelik içeren bir veri setidir (Guyon vd., 2004). Şekil 2.9’da, Madelon veri setinin PCA kullanılarak iki boyuta indirgenip görselleştirilmiş hali sunulmaktadır. Madelon veri seti sentetik olarak üretildiğinden, bu görselleştirme veri noktalarının istatistiksel dağılımını temsil etmektedir. Farklı renkler farklı sınıfları göstermektedir.



Şekil 2.9. PCA kullanılarak iki boyuta indirgenen Madelon veri setindeki örneklerin sınıf dağılımı

2.8.9. Hill-Valley Veri Seti

Hill-Valley veri seti, zaman serisi verilerinden oluşan ve sınıflandırma amacıyla kullanılan bir veri setidir. Her bir örnek, belirli bir fonksiyonun örneklenmiş değerlerini temsil etmekte olup, bu fonksiyonların “tepe” (hill) veya “vadi” (valley) yapısına sahip olup olmadığına göre sınıflandırılmaktadır. Veri seti hem gürültülü hem de gürültüsüz versiyonlara sahip olup, özellikle zaman serisi sınıflandırma problemlerinde model başarımını değerlendirmek için kullanılmaktadır (Dua ve Graff, 2019). Şekil 2.10’da, Hill-Valley veri setinin PCA ile iki boyuta indirgenmiş hali sunulmaktadır. Sınıflar farklı renklerle gösterilmektedir.




Şekil 2.10. PCA kullanılarak iki boyuta indirgenen Hill-Valley veri setindeki örneklerin sınıf dağılımı

Veri seti, iki sınıfa ait toplam 606 örnekten oluşmakta olup her örnek 100 öznitelikle temsil edilmektedir. Zaman serisi yapısına sahip olması nedeniyle, ardışık özellikler arasındaki ilişkileri öğrenbilme kapasitesinin değerlendirilmesinde uygun bir test ortamı sağlamaktadır.

2.8.10. Digits Veri Seti

Digits veri seti, el yazısıyla yazılmış rakam görüntülerini içeren ve çok sınıflı sınıflandırma problemlerinin değerlendirilmesinde yaygın olarak kullanılan bir veri kümesidir. Veri setindeki görüntüler genellikle düşük çözünürlüklü olup, sayısal piksel değerleri şeklinde temsil edilmektedir. Bu veri seti, temel görüntü sınıflandırma algoritmalarının başarımını değerlendirmek amacıyla sıklıkla tercih edilmektedir. Özellikle klasik makine öğrenmesi yöntemlerinin karşılaştırılmasında yaygın olarak kullanılan bir veri setidir (Dua ve Graff, 2019). Şekil 2.11’de, Digits veri setine ait örneklerin dağılımı gösterilmektedir. Veriler PCA kullanılarak iki boyuta indirgenmiş olup, farklı renkler farklı sınıfları temsil etmektedir.



Şekil 2.11. PCA kullanılarak iki boyuta indirgenen Digits veri setindeki el yazısı rakam örneklerinin sınıf dağılımı

Veri kümesi, 10 farklı sınıfa ait toplam 1.796 örnek içermektedir. Her örnek 8×8 piksel çözünürlüğünde bir rakam görüntüsünü temsil etmekte ve 64 öznitelikten oluşmaktadır. Görüntü tabanlı yapısı sayesinde veri seti, sınıflandırma modellerinin görsel örüntüleri öğrenme yeteneğinin değerlendirilmesine olanak sağlamaktadır.


Çalışmanın iki aşamasında da el yazısı rakamlarına ait veri kümelerinden yararlanılmıştır. İlk aşamada yaygın bir kıyaslama veri seti olan MNIST tercih edilirken, ikinci aşamada IntelELM kütüphanesinde hazır olarak sunulan Digits veri seti kullanılmıştır. Her iki veri seti benzer problem alanını temsil etmesine rağmen örnek sayısı, görüntü çözünürlüğü ve öznitelik yapısı bakımından farklılık göstermektedir. Bu nedenle iki veri seti, farklı deneysel amaçlar doğrultusunda değerlendirilmiştir.

2.8.11. Başarım Değerlendirme Metrikleri

Makine öğrenmesi ve derin öğrenme yaklaşımlarının değerlendirilmesinde, tek bir ölçüte dayanmak çoğu zaman model davranışını yeterince açıklamaz. Bu nedenle sınıflandırma problemlerinde birden fazla başarımlar göstergesinin birlikte ele alınması, modelin farklı yönlerden incelenmesine imkân verir.

Bu çalışmada modellerin başarımları; doğruluk (accuracy), hassasiyet (precision), geri çağırma (recall) ve F1 skoru gibi temel ölçütlerin yanı sıra karmaşıklık matrisi üzerinden analiz edilmiştir. Bu ölçütler, modelin hem genel başarımlarını hem de sınıflar bazındaki davranışını değerlendirmeyi mümkün kılar.

Karmaşıklık matrisi, sınıflandırma sonuçlarını ayrıntılı biçimde sunan temel bir araçtır. Bu matris sayesinde yalnızca doğru tahminlerin sayısı değil, hataların hangi sınıflar arasında yoğunlaştığı da görülebilir. Özellikle çok sınıflı problemlerde, modelin belirli sınıfları diğerleriyle karıştırma eğilimi bu yapı üzerinden açık biçimde incelenebilir. Matrisin köşegeninde doğru tahminler yer alırken, köşegen dışındaki değerler hatalı sınıflandırmaları temsil eder. Bu ölçütler, Şekil 2.12’de verilen örnek karmaşıklık matrisi üzerinde gösterilmiştir.



Şekil 2.12. Karmaşıklık matrisi örneği

Bu yapıdan elde edilen Doğru Pozitif (TP), Doğru Negatif (TN), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) değerleri, diğer başarımların temelini oluşturur. Yanlış pozitif durum, modele ait olmayan bir örneğin ilgili sınıfa atanması anlamına gelir; yanlış negatif durum, ilgili sınıfa ait bir örneğin farklı bir sınıf altında değerlendirilmesini ifade eder. Doğru pozitif ve doğru negatif değerleri ise modelin doğru tahminlerini temsil eder. Bu ayrım, model başarımının yalnızca genel doğrulukla değil, hata türleri üzerinden de analiz edilmesini sağlar. Bu bileşenler kullanılarak doğruluk (accuracy), hassasiyet (precision), geri çağırma (recall) ve F1 skoru hesaplanmakta olup, ilgili matematiksel ifadeler Eşitlikler D.5–D.8’de sunulmuştur (Naidu vd., 2023; Yacoub ve Axman, 2020). Çok sınıflı problemlerde hassasiyet ve geri çağırma değerleri ağırlıklı ortalama yaklaşımıyla hesaplanmıştır. Ayrıca, özellikle dengesiz veri setlerinde model performansının daha güvenilir biçimde değerlendirilebilmesi amacıyla Makro-F1 ve Ağırlıklı-F1 ölçütleri de kullanılmıştır. Makro-F1 skoru, her sınıfı eşit ağırlıkta değerlendirilerek sınıf bazlı performansın dengeli biçimde analiz edilmesini sağlarken; Ağırlıklı

-F1 skoru, sınıf örnek sayıları dikkate alınarak veri dağılımının performans üzerindeki etkisini yansıtmaktadır. Böylece modeller, yalnızca genel doğruluk performansları açısından değil, aynı zamanda farklı sınıflar üzerindeki sınıflandırma davranışları dikkate alınarak da kapsamlı bir şekilde değerlendirilebilmiştir.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (D.5)$$

$$P = \frac{TP}{TP + FP} \quad (D.6)$$

$$R = \frac{TP}{TP + FN} \quad (D.7)$$

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (D.8)$$

Bu çalışma kapsamında kullanılan başarımlar metrikleri, önerilen modellerin sınıflandırma başarımlarını farklı açılardan değerlendirmeye imkân tanımaktadır. Yalnızca genel doğruluk oranına odaklanmak yerine, modelin sınıf bazlı başarısı, hatalı sınıflandırma eğilimleri ve veri dağılımına karşı gösterdiği davranış da dikkate alınmıştır. Bu yaklaşım sayesinde modelin güçlü ve zayıf yönleri daha açık bir biçimde ortaya konulabilmektedir. Bu bölümde ele alınan değerlendirme ölçütlerinin birlikte kullanılması, elde edilen sonuçların daha güvenilir ve kapsamlı biçimde yorumlanmasına katkı sağlamaktadır.

3. DENEYSEL SONUÇLAR VE TARTIŞMA

Bu bölümde, önerilen ReSQu-CELM modelinin başarımı ile karşılaştırma kapsamında ele alınan diğer yöntemlerin deneysel sonuçları ayrıntılı biçimde sunulmakta ve kapsamlı olarak tartışılmaktadır. Deneysel değerlendirmeler iki farklı aşamada yürütülmüştür. İlk aşamada ELM tabanlı yöntemlerin farklı veri kümeleri üzerindeki performansları karşılaştırılmış, ikinci aşamada ise önerilen ReSQu-CELM modelinin mevcut yöntemlere göre sağladığı katkılar ayrıntılı olarak incelenmiştir. Elde edilen bulgular, özellikle CELM modelinin diğer ELM tabanlı yaklaşımlara kıyasla daha başarılı sonuçlar ürettiğini ortaya koymuştur. Bu doğrultuda, çalışmanın ikinci aşamasında önerilen ReSQu-CELM modelinin başarımı hem ELM tabanlı yöntemler hem de literatürde yaygın olarak kullanılan makine öğrenmesi algoritmaları ile karşılaştırılarak değerlendirilmiştir.


Deneysel sonuçlar sunulurken yalnızca genel doğruluk değerleri dikkate alınmamış, aynı zamanda modellerin farklı veri setleri üzerindeki davranışları, sınıf dağılımlarına karşı gösterdikleri başarımların değişimleri ve hatalı sınıflandırma eğilimleri de göz önünde bulundurulmuştur. Bu yaklaşım, modellerin yalnızca ortalama başarı düzeylerini değil, aynı zamanda farklı veri yapıları altında sergiledikleri genelleme yeteneklerini daha açık bir şekilde ortaya koymayı amaçlamaktadır. Özellikle farklı örnek sayıları, öznitelik boyutları ve sınıf sayıları içeren veri setleri kullanılarak yapılan değerlendirmeler, önerilen modelin değişen veri koşulları altındaki kararlılığını ve tutarlılığını analiz etme imkânı sağlamıştır.

Ayrıca, karşılaştırmalı analiz sürecinde elde edilen bulgular yalnızca sayısal metrikler üzerinden değil, aynı zamanda modellerin güçlü ve zayıf yönlerini ortaya koyacak şekilde yorumlanmıştır. Bu kapsamda, önerilen modelin hangi veri setlerinde daha belirgin bir üstünlük sağladığı, hangi durumlarda benzer başarımlar sergilediği ve hangi koşullarda sınırlı kaldığı detaylı biçimde tartışılmıştır. Böylece, çalışmanın deneysel sonuçları yalnızca başarımların karşılaştırması sunmakla kalmayıp, aynı zamanda model davranışlarına yönelik daha derinlemesine bir analiz sağlamaktadır.


Bu bölümde sunulan deneysel değerlendirmeler, önerilen ReSQu-CELM modelinin farklı veri yapıları üzerindeki sınıflandırma performansını kapsamlı biçimde ortaya koymaktadır. Elde edilen bulgular yalnızca modeller arasındaki başarı farklılıklarını göstermekle kalmamış, aynı zamanda önerilen yaklaşımın değişen veri karakteristikleri altındaki davranışının ve genelleme yeteneğinin ayrıntılı olarak incelenmesine de olanak sağlamıştır.

3.1. ELM ve Varyantlarının Başarım Analizi


Bu bölümde, çalışmanın ilk aşamasında gerçekleştirilen deneylerden elde edilen bulgular sunulmaktadır. Standart ELM, IELM, OSELM, RELM ve CELM modellerinin dört farklı görüntü veri seti üzerindeki sınıflandırma performansları karşılaştırmalı olarak değerlendirilmiştir. Deneyler, 256 GB depolama alanına, 8 GB RAM'e, Apple M1 işlemciye ve macOS Monterey 12.0.1 işletim sistemine sahip bir bilgisayarda yürütülmüştür. Uygulamalar Python ortamında geliştirilmiş, paket yönetimi ise Anaconda Navigator aracılığıyla gerçekleştirilmiştir. Veri kümeleri rastgele olarak %80 eğitim ve %20 test alt kümelerine ayrılmıştır. Eğitim verileri üzerinde gerekli veri artırma işlemleri uygulandıktan sonra ELM tabanlı yöntemlerin tamamı aynı deneysel koşullar altında eğitilmiştir. Karşılaştırmaların tutarlı biçimde yapılabilmesi amacıyla bütün modellerde gizli katman nöron sayısı 1000, aktivasyon fonksiyonu ise sigmoid olarak belirlenmiştir. Model performansları hassasiyet, geri çağırma ve F1-skoru ölçütleri kullanılarak değerlendirilmiştir. Ayrıca, Standart ELM modeline ait her bir veri seti için elde edilen karmaşıklık matrisleri Şekil 3.1'de sunulmuştur.



(a) ELM-MNIST



(b) ELM-Pirinç



Şekil 3.1. ELM modeline ait karmaşıklık matrisi grafikleri

Şekil 3.1’de sunulan karmaşıklık matrisleri, ELM modelinin farklı veri setleri üzerindeki sınıflandırma davranışını ayrıntılı olarak ortaya koymaktadır. Matrisler incelendiğinde, doğru ve hatalı tahminlerin sınıflara göre dağılımı gözlemlenebilmekte, böylece modelin güçlü olduğu ve hata yapma eğilimi gösterdiği sınıflar belirlenebilmektedir. Bu görsel değerlendirmeler, sayısal performans ölçütlerini destekleyerek ELM modelinin farklı veri yapıları altındaki başarısının daha kapsamlı biçimde yorumlanmasına katkı sağlamaktadır.

ELM varyantlarının performanslarını karşılaştırmak amacıyla en yaygın sınıflandırma ölçütleri dikkate alınmıştır. Tablo 3.1’de MNIST veri seti üzerinde elde edilen Doğruluk, Hassasiyet, Geri Çağırma ve F1-skoru değerleri sunulmaktadır. Karşılaştırmayı kolaylaştırmak amacıyla her performans ölçütünde en başarılı sonuçlar koyu yazı ile belirtilmiştir.

Tablo 3.1. MNIST veri seti için modellerin performans karşılaştırmaları.

Model	Doğruluk	Hassasiyet	Geri Çağırma	F1-Skoru
ELM	0,8928	0,8926	0,8928	0,8923
IELM	0,8726	0,8729	0,8726	0,8715
OSEL	0,9387	0,9386	0,9387	0,9386
RELM	0,9320	0,9318	0,9320	0,9318
CELM	0,9548	0,9547	0,9548	0,9547

Tablo 3.1’de sunulan performans sonuçları değerlendirildiğinde, MNIST veri setinde en başarılı sınıflandırma sonuçlarının CELM modeli ile elde edildiği görülmektedir. Buna karşılık,

aynı veri setinde en düşük performans IELM modeline aittir. Elde edilen bulgular, özellikle çok sınıflı problemlerde CELM yaklaşımının daha etkili bir sınıflandırma davranışı sergilediğini ve diğer ELM varyantlarına göre daha başarılı sonuçlar üretebildiğini göstermektedir.

Tablo 3.2’de yer alan sonuçlar, dört sınıftan oluşan Beyin tümörü veri setinde en yüksek performansın CELM modeli tarafından elde edildiğini göstermektedir. Buna karşın, değerlendirme ölçütleri dikkate alındığında en düşük performansın IELM modeline ait olduğu görülmektedir. Tıbbi görüntü sınıflandırma uygulamalarında doğruluk ve güvenilirlik büyük önem taşıdığından, CELM modelinin elde ettiği başarılı sonuçlar bu tür karar destek sistemlerinde kullanılabilecek güçlü bir alternatif olduğunu ortaya koymaktadır.

Tablo 3.2. Beyin tümörü veri seti için modellerin başarımlarını karşılaştırmaları

Model	Doğruluk	Hassasiyet	Geri Çağırma	F1-Skoru
ELM	0,7895	0,7805	0,7895	0,7796
IELM	0,7170	0,7047	0,7170	0,7006
OSEL	0,7384	0,7261	0,7384	0,7257
RELM	0,7849	0,7750	0,7849	0,7727
CELM	0,8551	0,8521	0,8551	0,8528

Tablo 3.3’te sunulan performans sonuçları incelendiğinde, dengeli sınıf dağılımına sahip pirinç veri setinde en başarılı sınıflandırma sonuçlarının CELM modeli ile elde edildiği görülmektedir. Buna karşılık, aynı veri setinde en düşük performans IELM modeli tarafından sergilenmiştir. Elde edilen bulgular, özellikle sınıflar arasında dengeli dağılıma sahip tarımsal görüntü verilerinde CELM yaklaşımının etkili bir sınıflandırma performansı sunduğunu göstermektedir. Bu durum, tarımsal ürünlerin otomatik sınıflandırılmasına yönelik uygulamalarda CELM modelinin kullanılabilecek güçlü yöntemlerden biri olduğunu ortaya koymaktadır.

Tablo 3.3. Pirinç veri seti için modellerin başarımlarını karşılaştırmaları

Model	Doğruluk	Hassasiyet	Geri Çağırma	F1-Skoru
ELM	0,9195	0,9202	0,9195	0,9190
IELM	0,8432	0,8507	0,8432	0,8350
OSEL	0,9023	0,9022	0,9023	0,9018
RELM	0,9237	0,9243	0,9237	0,9233
CELM	0,9348	0,9362	0,9348	0,9345

Tablo 3.4'te sunulan performans sonuçları, araç sürücüsü uyku durumu veri setinde en yüksek başarımın CELM modeli ile elde edildiğini, en düşük performansın ise IELM modeline ait olduğunu göstermektedir. Tablo 3.1 ve Tablo 3.4 birlikte değerlendirildiğinde, CELM modelinin çalışmada kullanılan tüm görüntü veri setlerinde diğer ELM varyantlarına kıyasla daha başarılı sonuçlar ürettiği görülmektedir. Bu durum, modelin hem ikili hem de çok sınıflı sınıflandırma problemlerinde istikrarlı bir performans sergileyebildiğini göstermektedir. Özellikle sınıf dağılımının ve veri yapısının değiştiği farklı senaryolarda yüksek sınıflandırma başarısını koruyabilmesi, CELM yaklaşımının güçlü genelleme yeteneğine sahip olduğunu düşündürmektedir. Elde edilen bulgular, modelin farklı görüntü sınıflandırma problemlerinde güvenilir bir alternatif olarak değerlendirilebileceğini ortaya koymaktadır.

Tablo 3.4. Araç sürücüsü uyku durumu veri seti için modellerin başarımlarını karşılaştırmaları

Model	Doğruluk	Hassasiyet	Geri Çağırma	F1-Skoru
ELM	0,9474	0,9474	0,9474	0,9474
IELM	0,8004	0,8350	0,8004	0,8001
OSELM	0,9174	0,9174	0,9174	0,9173
RELM	0,9478	0,9478	0,9478	0,9478
CELM	0,9624	0,9624	0,9624	0,9624

Öte yandan, gerçekleştirilen deneyler boyunca IELM modeli tüm veri setlerinde diğer ELM varyantlarının gerisinde kalmıştır. Özellikle sınıf dağılımının dengesiz olduğu ve veri çeşitliliğinin arttığı problemlerde modelin sınıflandırma başarısında belirgin bir düşüş gözlenmiştir. Bu durum, IELM yaklaşımının daha karmaşık veri yapılarında yeterli temsil gücünü oluşturmada zorlanabileceğini göstermektedir. Buna karşılık, daha düşük karmaşıklığa sahip problemlerde kabul edilebilir sonuçlar elde etme potansiyeline sahip olsa da çalışmada kullanılan veri setleri dikkate alındığında genel performansının sınırlı kaldığı görülmektedir. Bu nedenle, özellikle yüksek doğruluk gerektiren görüntü sınıflandırma uygulamalarında daha güçlü genelleme yeteneğine sahip alternatif yöntemlerin tercih edilmesi daha uygun görünmektedir.

Deney sonuçları genel olarak değerlendirildiğinde, CELM modeli incelenen tüm veri setlerinde en başarılı ELM varyantı olarak öne çıkmıştır. Modelin farklı sınıf sayıları, veri büyüklükleri ve dağılım özellikleri altında benzer düzeyde yüksek performans sergilemesi, yöntemin kararlı bir öğrenme davranışı ortaya koyduğunu göstermektedir. Buna karşılık,

RELM ve OSELM modelleri çoğu veri setinde orta seviyede sonuçlar üretirken, ELM modeli basit yapısı sayesinde düşük eğitim süresine sahip olmasına rağmen veri karmaşıklığının arttığı durumlarda performans kaybı yaşamıştır. Bu bulgular, gizli katman ağırlıklarının oluşturulma biçiminin sınıflandırma başarısı üzerinde belirleyici bir etkiye sahip olduğunu desteklemektedir.

Elde edilen bulgular, CELM yaklaşımının farklı veri karakteristikleri altında güvenilir ve istikrarlı sonuçlar üretebildiğini göstermektedir. Bununla birlikte, model seçiminin yalnızca doğruluk değerine göre yapılmaması, veri yapısı, problemin özellikleri ve hesaplama maliyeti gibi unsurların da birlikte değerlendirilmesi önem taşımaktadır. Bu çalışma kapsamında gerçekleştirilen karşılaştırmalar, ELM tabanlı yöntemlerin farklı veri yapıları karşısındaki davranışlarını ortaya koyarak sonraki aşamada geliştirilen ReSQu-CELM modelinin oluşturulmasına temel teşkil etmiştir.

Performans değerleri birbirine oldukça yakın olan modeller arasında seçim yapılırken eğitim süresi de önemli bir değerlendirme ölçütü olarak dikkate alınmalıdır. Bu nedenle, çalışmada incelenen tüm yöntemlerin eğitim süreleri saniye cinsinden hesaplanmış ve karşılaştırmalı sonuçlar Tablo 3.5’te sunulmuştur.

Tablo 3.5. Modellerin eğitim süreleri

Veri Seti	ELM	IELM	OSELM	RELM	CELM
MNIST	3,15	10,50	10,55	1,87	1,78
Beyin tümör	2,91	106,25	2,68	2,57	2,72
Pirinç	10,18	437,87	28,33	30,31	221,67
Uyku	6,23	116,91	15,64	9,96	77,47

Tablo 3.5’te sunulan eğitim süreleri incelendiğinde, modeller arasında hesaplama maliyeti açısından belirgin farklılıklar olduğu görülmektedir. CELM modeli, özellikle MNIST veri setinde 1.78 saniyelik eğitim süresiyle en hızlı sonuçlardan birini üretmiştir. Buna karşılık, IELM modeli tüm veri setlerinde en yüksek eğitim sürelerine sahip olup, özellikle MNIST ve Beyin tümörü veri setlerinde hesaplama maliyetinin önemli ölçüde arttığı gözlenmiştir. Bu durum, modelin artımlı yapısı nedeniyle eğitim sürecinde daha fazla hesaplama yükü oluşturmasıyla açıklanabilir. OSELM ve RELM modelleri ise veri setinin özelliklerine bağlı olarak değişen eğitim süreleri sergilemiş; bazı veri setlerinde ELM ve CELM’e yakın sonuçlar üretirken, bazı durumlarda daha uzun eğitim süresine ihtiyaç duymuştur. Standart ELM modeli ise basit mimarisi sayesinde tüm veri setlerinde düşük eğitim sürelerini koruyarak hesaplama

açısından verimli bir yaklaşım olduğunu göstermiştir. Genel olarak değerlendirildiğinde, eğitim süresi bakımından elde edilen bulgular, model karmaşıklığı arttıkça hesaplama maliyetinin de yükseldiğini ortaya koymaktadır.

Çalışmada elde edilen en başarılı ELM varyantı olan CELM modeli, literatürde raporlanan farklı sınıflandırma yöntemleriyle Tablo 3.6’da karşılaştırılmıştır. Bu karşılaştırma, önerilen deneysel düzenekte elde edilen sonuçların literatürde bildirilen yöntemlerle benzer düzeyde rekabetçi olduğunu göstermekte ve özellikle MNIST veri setinde CELM modelinin yüksek doğruluk performansını desteklemektedir.

Tablo 3.6. MNIST veri seti için en iyi ELM varyantı (CELM) ile literatürden alınan bazı modellerin karşılaştırılması

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 vd., 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 3.6’da verilen karşılaştırmalı sonuçlar, bu çalışma kapsamında elde edilen CELM performansının literatürde raporlanan yöntemlerle rekabet edebilir düzeyde olduğunu göstermektedir. Özellikle MNIST veri setinde ulaşılan %95,47 doğruluk değeri, geleneksel makine öğrenmesi ve derin öğrenme tabanlı birçok yöntemle benzer düzeyde başarı sağlamıştır. Bu çalışmanın temel katkılarından biri, ELM ve varyantlarının yalnızca tek bir veri kümesi üzerinde değil, farklı karakteristiklere sahip dört görüntü veri seti üzerinde birlikte değerlendirilmiş olmasıdır. Böylece yöntemlerin değişen veri yapıları altındaki davranışları karşılaştırmalı olarak analiz edilmiş ve özellikle CELM yaklaşımının farklı problem türlerinde istikrarlı sonuçlar üretebildiği ortaya konulmuştur. Ayrıca IELM modelinin büyük ve heterojen veri kümelerinde performans kaybı yaşadığı gözlemlenmiş, bu durum modelin kullanım alanlarına ilişkin önemli değerlendirmeler yapılmasına olanak sağlamıştır.

3.2. Önerilen ReSQu-CELM Modelinin DeneySEL Değerlendirmesi

İlk çalışma kapsamında elde edilen sonuçlar, ELM tabanlı yaklaşımlarda gizli katman parametrelerinin oluşturulma biçiminin model performansı üzerinde önemli bir etkisi olduğunu göstermiştir. Özellikle kısıt tabanlı yöntemlerin rastgele ağırlık üretimine dayanan yaklaşımlara kıyasla daha başarılı sonuçlar üretmesi, gizli katman temsiline daha da zenginleştirilebileceği fikrini ortaya çıkarmıştır. Bu doğrultuda çalışmanın ikinci aşamasında, farklı kısıt stratejilerini aynı mimari içerisinde bir araya getiren ReSQu-CELM modeli önerilmiş ve modelin başarımı kapsamlı deneylerle değerlendirilmiştir. İlk olarak önerilen model, ELM ve CDELM başta olmak üzere ELM tabanlı yöntemlerle karşılaştırılmış; ardından SVM, MLP, DT ve RF gibi yaygın makine öğrenmesi algoritmaları karşısındaki performansı incelenmiştir. Böylece önerilen yaklaşımın hem ELM tabanlı yöntemler arasındaki konumu hem de yaygın sınıflandırma algoritmalarına kıyasla sergilediği performans farklı veri yapıları üzerinde değerlendirilmiştir.

Model performanslarının güvenilir ve dengeli biçimde değerlendirilebilmesi amacıyla deneySEL analizlerde 10 katlı tabakalı çapraz doğrulama yöntemi kullanılmıştır. Her bir deney grubu içinde karşılaştırılan yöntemlere aynı çapraz doğrulama bölünmeleri uygulanmış ve sınıf dağılımlarının katlar boyunca korunması sağlanmıştır. Model eğitiminden önce öznitelikler Min–Max yöntemiyle $[0,1]$ aralığına ölçeklendirilmiştir. Böylece aynı deney grubu içerisindeki yöntemlerin ortak veri ön işleme ve değerlendirme koşulları altında karşılaştırılması amaçlanmıştır.

3.2.1. Model Bileşenlerinin Etkisinin Analizi

Önerilen modelin sınıflandırma performansı üzerindeki gizli katman kapasitesi etkisini incelemek amacıyla farklı gizli nöron sayıları kullanılarak ek deneyler gerçekleştirilmiştir. Bu kapsamda ReSQu-CELM modeli, her bir veri seti üzerinde 24, 48, 100, 200 ve 500 gizli nöron kullanılarak ayrı ayrı değerlendirilmiştir. Tüm deneyler aynı deneySEL koşullar altında ve 10 katlı çapraz doğrulama yöntemi kullanılarak yürütülmüş; elde edilen sonuçlar doğruluk, hassasiyet, geri çağırma, F-1 skoru ve eğitim süresi ölçütleri açısından analiz edilmiştir. Daha sonra farklı gizli nöron yapılandırmalarının genel performanslarını karşılaştırmak amacıyla bir sıralama analizi gerçekleştirilmiştir. Elde edilen ortalama sıralama sonuçlarına göre, 100 gizli nöronlu yapı sınıflandırma başarımı ile hesaplama maliyeti arasında daha dengeli bir performans sergilemiş ve bu nedenle çalışmada sunulan temel karşılaştırmalı deneylerde tercih

edilmiştir. Gizli nöron analizine ilişkin ayrıntılı performans ve sıralama sonuçları Tablo 3.7’de sunulmaktadır.

Tablo 3.7. Önerilen ReSQu-CELM modelinde farklı gizli nöron sayılarının performansa etkisi

Model	Doğruluk Sıralaması	Hassasiyet Sıralaması	Geri Çağırma Sıralaması	F1-Skoru Sıralaması	Eğitim Süresi Sıralaması	Ortalama Sıralama
ReSQu-CELM (24)	4,17	4,17	4,17	4,17	1,17	3,57
ReSQu-CELM (48)	2,67	2,5	2,67	2,67	1,83	2,47
ReSQu-CELM (100)	1,67	1,67	1,67	1,67	3	1,93
ReSQu-CELM (200)	2,83	2,83	2,83	2,83	4	3,07
ReSQu-CELM (500)	3,67	3,83	3,67	3,67	5	3,97

Tablo 3.7’de verilen sonuçlar incelendiğinde, farklı gizli nöron sayıları arasında en başarılı genel performansın 100 gizli nöronlu yapı tarafından elde edildiği görülmektedir. Bu yapı, sınıflandırma başarımına ilişkin ölçütlerde üst sıralarda yer alırken, eğitim süresi açısından da dengeli bir performans sergilemiştir. Daha düşük gizli nöron sayılarına sahip modellerin hesaplama maliyeti daha düşük olmasına rağmen, sınıflandırma başarımlarının aynı düzeyde olmadığı gözlemlenmiştir. Buna karşılık, gizli nöron sayısının artırılması her zaman performans artışı sağlamamış, özellikle 200 ve 500 nöronlu yapılarda elde edilen kazanımlar sınırlı kalmıştır. Bu durum, model performansının yalnızca gizli nöron sayısına bağlı olmadığını, belirli bir noktadan sonra eklenen nöronların sınıflandırma başarımına anlamlı katkı sağlamayabileceğini göstermektedir. Elde edilen bulgular doğrultusunda, başarımlar ve hesaplama maliyeti birlikte değerlendirilerek sonraki deneylerde 100 gizli nöronlu yapı kullanılmıştır.

Önerilen gizli katman organizasyonunun performansa olan katkısını daha ayrıntılı inceleyebilmek amacıyla bir bileşen analizi daha gerçekleştirilmiştir. Bu analiz kapsamında, modelin farklı bileşenleri ayrı ayrı değerlendirilerek kısıt tabanlı öğrenme stratejilerinin ve rastgele çeyrek atama mekanizmasının sınıflandırma performansına etkileri araştırılmıştır. Elde edilen sonuçlar Tablo 3.8’de sunulmaktadır. Strateji-1 geleneksel CDELM’de kullanılan farklı sınıf örneklerinin farkına dayalı nöron oluşturma mekanizmasıyla matematiksel olarak eşdeğerdir. Bu nedenle bileşen analizinde ayrı bir CDELM satırı yerine Strateji-1 sonuçları verilmiştir.

Bileşen analizinde Strateji-1 farklı sınıflara ait örneklerin farkına dayalı gizli nöron oluşturma mekanizmasını, Strateji-2 farklı sınıflara ait örneklerin toplamına dayalı yaklaşımı, Strateji-3 aynı sınıfa ait örneklerin farkına dayalı yaklaşımı ve Strateji-4 ise aynı sınıfa ait örneklerin toplamına dayalı yaklaşımı temsil etmektedir. Bunun yanında, sabit sıralı varyantta bu stratejiler gizli katman çeyreklerine önceden belirlenmiş bir sıraya göre atanırken, rastgele sıralı varyantta strateji atamaları her çalıştırmada rastgele permüte edilmektedir.

Tablo 3.8. ReSQu-CELM modelinin farklı varyantlarına ilişkin bileşen analizi sonuçları

Veri Seti	Varyantı	Doğruluk	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
WaveformEW	ELM	0,8378 ± 0,0112	0,8375 ± 0,0112	0,8374 ± 0,0112	0,0257 ± 0,0045
	Strategy-1(CDELm ile eşdeğer)	0,8620 ± 0,0091	0,8618 ± 0,0092	0,8617 ± 0,0093	0,0097 ± 0,0024
	Strategy-2	0,8379 ± 0,0191	0,8374 ± 0,0192	0,8373 ± 0,0192	0,0478 ± 0,0004
	Strategy-3	0,8547 ± 0,0086	0,8547 ± 0,0086	0,8545 ± 0,0086	0,0720 ± 0,0011
	Strategy-4	0,8189 ± 0,0185	0,8182 ± 0,0188	0,8180 ± 0,0188	0,0698 ± 0,0007
	ReSQu-CELM (Sabit Sıralı)	0,8525 ± 0,0119	0,8523 ± 0,0120	0,8522 ± 0,0120	0,0537 ± 0,0012
	ReSQu-CELM (Rastgele Sıralı)	0,8560 ± 0,0128	0,8559 ± 0,0128	0,8558 ± 0,0128	0,0550 ± 0,0104
	ELM	0,7205 ± 0,0459	0,6983 ± 0,0569	0,7003 ± 0,0560	0,0056 ± 0,0019
Hill-Valley	Strategy-1(CDELm ile eşdeğer)	0,5464 ± 0,0731	0,5190 ± 0,0884	0,5213 ± 0,0871	0,0072 ± 0,0054
	Strategy-2	0,7967 ± 0,0403	0,7964 ± 0,0402	0,7965 ± 0,0403	0,0138 ± 0,0005
	Strategy-3	0,7422 ± 0,0349	0,7410 ± 0,0350	0,7412 ± 0,0350	0,0134 ± 0,0001
	Strategy-4	0,8028 ± 0,0323	0,8022 ± 0,0326	0,8024 ± 0,0325	0,0096 ± 0,0002
	ReSQu-CELM (Sabit Sıralı)	0,7732 ± 0,0493	0,7723 ± 0,0499	0,7724 ± 0,0499	0,0106 ± 0,0001
	ReSQu-CELM (Rastgele Sıralı)	0,7732 ± 0,0493	0,7723 ± 0,0499	0,7724 ± 0,0499	0,0106 ± 0,0001

	ReSQu-CELM (Rastgele Sıralı)	0,7952 ± 0,0592	0,7946 ± 0,0596	0,7946 ± 0,0596	0,0139 ± 0,0086
	ELM	0,9544 ± 0,0171	0,9541 ± 0,0177	0,9540 ± 0,0177	0,0105 ± 0,0016
	Strategy-1(CDELM ile eşdeğer)	0,9616 ± 0,0214	0,9611 ± 0,0220	0,9612 ± 0,0218	0,0058 ± 0,0036
	Strategy-2	0,9599 ± 0,0186	0,9597 ± 0,0185	0,9601 ± 0,0182	0,0168 ± 0,0002
Digits	Strategy-3	0,9610 ± 0,0208	0,9604 ± 0,0215	0,9605 ± 0,0213	0,0500 ± 0,0007
	Strategy-4	0,9409 ± 0,0099	0,9404 ± 0,0109	0,9406 ± 0,0107	0,0464 ± 0,0004
	ReSQu-CELM (Sabit Sıralı)	0,9632 ± 0,0151	0,9632 ± 0,0151	0,9633 ± 0,0149	0,0355 ± 0,0006
	ReSQu-CELM (Rastgele Sıralı)	0,9655 ± 0,0155	0,9652 ± 0,0158	0,9654 ± 0,0157	0,0411 ± 0,0121

Tablo 3.8’de sunulan bileşen analizi sonuçları, önerilen modelde kullanılan farklı gizli katman oluşturma stratejilerinin performansa olan katkılarını ortaya koymaktadır. Bileşen analizi sonuçları, kısıt tabanlı stratejilerin performansının veri setinin yapısına göre değiştiğini göstermektedir. Bazı stratejiler klasik ELM’e göre daha yüksek başarımlar sağlarken, bazı stratejiler belirli veri setlerinde daha düşük sonuçlar üretmiştir. Bu durum, farklı kısıtlama stratejilerinin sınıflandırma performansına katkısının veri setinin özelliklerine bağlı olduğunu göstermektedir.

WaveformEW veri setinde Strateji-1 en yüksek performans değerini elde etmiştir. Buna karşılık, Strateji-4 diğer varyantlara göre daha düşük sonuç üretmiştir. Bu durum, farklı sınıf örneklerinin farkına dayalı stratejinin bu veri setinde daha ayırt edici bir temsil sağlayabildiğini göstermektedir.


Hill-Valley veri setinde ise Strateji-2 ve Strateji-4 en yüksek performans değerlerini elde etmiştir. Gürültülü ve doğrusal olmayan yapıya sahip bu veri setinde toplam temelli stratejilerin daha etkili sonuçlar üretmesi, bu stratejilerin veri içerisindeki yapısal ilişkileri daha iyi temsil edebildiğini düşündürmektedir. Bununla birlikte, varyantlar arasında gözlenen performans farklılıkları, her stratejinin etkinliğinin veri setinin özelliklerine bağlı olarak değişebileceğini göstermektedir.

Digits veri setinde ReSQu-CELM (Rastgele Sıralı) en yüksek performans değerini elde ederken, bunu Strateji-1 ve diğer bileşenler izlemiştir. Bu sonuç, farklı kısıtlama stratejilerinin birlikte kullanılmasının el yazısı rakamların sınıflandırılmasında daha güçlü bir temsil oluşturabildiğini göstermektedir. Bununla birlikte, stratejilerin tek başına kullanımında elde edilen sonuçlar, farklı örnek ilişkilerini dikkate alan yaklaşımların performansa katkısının veri yapısına göre değişebildiğini ortaya koymaktadır.


Genel olarak bileşen analizi sonuçları, farklı gizli katman oluşturma stratejilerinin veri setinin yapısına bağlı olarak farklı davranışlar sergilediğini ortaya koymaktadır. Elde edilen sonuçlar, tekil stratejilerin ve çok stratejili yapıların üstünlüğünün veri setine bağlı olarak değiştiğini göstermektedir. Çok stratejili yapı bazı veri setlerinde en başarılı veya rekabetçi sonuçları üretirken, Hill-Valley veri setinde bazı tekil stratejiler daha yüksek performans göstermiştir. Bu bulgu, strateji etkinliğinin veri yapısına duyarlı olduğunu ve sabit bir strateji birleşiminin her veri setinde üstünlük sağlamadığını ortaya koymaktadır.

3.2.2. ELM Tabanlı Modeller ile Karşılaştırma


Model performansları; doğruluk, hassasiyet, geri çağırma, Makro-F1 ve Ağırlıklı-F1 ölçütleri kullanılarak değerlendirilmiştir. Ayrıca önerilen modelin sınıf bazındaki tahmin davranışlarını daha ayrıntılı inceleyebilmek amacıyla karmaşıklık matrislerinden yararlanılmıştır. ELM tabanlı modellerde deneylerin tamamında sigmoid aktivasyon fonksiyonu kullanılmış ve böylece gözlemlenen performans farklılıklarının model mimarisinden kaynaklanması hedeflenmiştir. ELM tabanlı olmayan yöntemlerde ise karşılaştırmaların tutarlı ve adil bir şekilde gerçekleştirilebilmesi amacıyla yaygın olarak kullanılan varsayılan hiperparametre ayarları tercih edilmiştir. Şekil 3.2’de, önerilen ReSQu-CELM modelinin 10 katlı çapraz doğrulama sürecinde elde edilen karmaşıklık matrisleri tüm veri setleri için sunulmaktadır.




(a) WaveformEW




(b) Ecoli




(c) Breast Cancer



(d) Madelon



(e) Hill-Valley



(f) Digits

Şekil 3.2. Tüm veri setleri için ReSQu-CELM modeline ait karmaşıklık matrisleri

Şekil 3.2’de sunulan karmaşıklık matrisleri incelendiğinde, ReSQu-CELM modelinin genel olarak sınıflar arasında dengeli bir tahmin performansı sergilediği görülmektedir. Çoğu veri setinde hatalı sınıflandırmaların belirli bir sınıfta yoğunlaşmak yerine daha dengeli bir dağılım gösterdiği dikkat çekmektedir. Bu durum, önerilen çok stratejili gizli katman yapısının öğrenme sürecinde hem sınıflar arası ayrımı koruyabildiğini hem de sınıf içi örüntüleri etkili bir şekilde temsil edebildiğini göstermektedir.

ELM tabanlı yöntemler ile önerilen modelin başarımlarını ayrıntılı biçimde karşılaştırmak amacıyla tüm veri setleri için doğruluk, hassasiyet, geri çağırma, Makro-F1 ve Ağırlıklı-F1 ölçütleri hesaplanmıştır. Tablo 3.9’da WaveformEW veri setine ilişkin ortalama performans değerleri ile standart sapmalar birlikte sunulmaktadır. Ayrıca eğitim süreleri de değerlendirmeye dahil edilmiş ve her veri setinde en başarılı sonuçlar koyu yazı ile gösterilmiştir.

Tablo 3.9. WaveformEW veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
ELM	0,8378 ± 0,0112	0,8387 ± 0,0113	0,8378 ± 0,0112	0,8375 ± 0,0112	0,8374 ± 0,0112	0,0257 ± 0,0045
CDELM	0,8620 ± 0,0091	0,8626 ± 0,0093	0,8620 ± 0,0091	0,8618 ± 0,0092	0,8617 ± 0,0093	0,0097 ± 0,0024
ReSQu-CELM	0,8560 ± 0,0128	0,8564 ± 0,0130	0,8560 ± 0,0128	0,8559 ± 0,0128	0,8558 ± 0,0128	0,0550 ± 0,0104

Tablo 3.9 incelendiğinde WaveformEW veri setinde, ELM tabanlı modeller arasında en yüksek performans CDELM modeli tarafından elde edildiği gözlemlenmektedir. Veri setinin dengeli sınıf dağılımına sahip olması ve sınıflar arasındaki ayrımın görece belirgin olması, CDELM’de kullanılan tek kısıt tabanlı yapının etkili sonuçlar üretmesine katkı sağlamış olabilir. Bu durumun, veri setindeki sınıf yapısı ile CDELM’in farklı sınıf örneklerinin farkına dayalı mekanizmasının uyumundan kaynaklanmış olabileceği değerlendirilmektedir. Bununla birlikte, ReSQu-CELM modeli de tüm değerlendirme ölçütlerinde CDELM’e oldukça yakın sonuçlar elde etmiş ve çapraz doğrulama katları boyunca kararlı bir performans sergilemiştir. Tablo 3.10’da Digits veri setine ait performans değerleri sunulmaktadır.

Tablo 3.10. Digits veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
ELM	0.9544 ± 0.0171	0.9575 ± 0.0163	0.9544 ± 0.0171	0.9541 ± 0.0177	0.9540 ± 0.0177	0.0105 ± 0.0016
CDELm	0.9616 ± 0.0214	0.9632 ± 0.0211	0.9616 ± 0.0214	0.9611 ± 0.0220	0.9612 ± 0.0218	0.0058 ± 0.0036
ReSQu-CELM	0.9655 ± 0.0155	0.9676 ± 0.0145	0.9655 ± 0.0155	0.9652 ± 0.0158	0.9654 ± 0.0157	0.0411 ± 0.0121

Tablo 3.10 incelendiğinde çok sınıflı el yazısı rakam tanıma probleminde, ReSQu-CELM'in çok stratejili gizli katman yapısının avantajının daha belirgin hale geldiği gözlemlenmektedir. Farklı gizli katman oluşturma stratejilerinin birlikte kullanılması, veri集中的 sınıflara ait farklı özelliklerin daha etkili bir şekilde temsil edilmesine katkı sağlamıştır. Bu sonuç, Digits veri seti özelinde farklı stratejilerin birlikte kullanılmasının çok sınıflı örüntülerin temsil edilmesine katkı sağlayabildiğini düşündürmektedir. Tablo 3.11'de Madelon veri setine ait performans değerleri sunulmaktadır.

Tablo 3.11. Madelon veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
ELM	0,5444 ± 0,0210	0,5447 ± 0,0213	0,5444 ± 0,0210	0,5440 ± 0,0206	0,5440 ± 0,0206	0,0332 ± 0,0083
CDELm	0,5729 ± 0,0357	0,5731 ± 0,0358	0,5729 ± 0,0357	0,5724 ± 0,0359	0,5724 ± 0,0359	0,0157 ± 0,0032
ReSQu-CELM	0,5848 ± 0,0305	0,5851 ± 0,0305	0,5848 ± 0,0305	0,5844 ± 0,0306	0,5844 ± 0,0306	0,0889 ± 0,0679

Madelon veri seti, yüksek boyutlu yapısı ve çok sayıda gürültülü öznitelik içermesi nedeniyle sınıflandırma açısından zorlayıcı veri setlerinden biridir. Tablo 3.11'de sunulan ELM tabanlı modeller arasındaki karşılaştırmada ReSQu-CELM modeli hem ELM hem de CDELm modellerine kıyasla daha başarılı sonuçlar elde etmiştir. Bu durum, farklı kısıt stratejilerinin aynı gizli katman içerisinde birlikte kullanılmasının, yüksek boyutlu ve gürültülü veri

yapılarında daha ayırt edici özellik temsilleri oluşturabildiğini göstermektedir. Bununla birlikte, elde edilen performans değerlerinin diğer bazı veri setlerine kıyasla daha düşük seviyelerde kalması, Madelon veri setinin önerilen model açısından da zorlu bir sınıflandırma problemi olmaya devam ettiğini ortaya koymaktadır. Tablo 3.12’de Breast Cancer veri setine ait performans değerleri sunulmaktadır.

Tablo 3.12. Breast Cancer veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
ELM	0,9599 ± 0,0262	0,9601 ± 0,0263	0,9599 ± 0,0262	0,9556 ± 0,0291	0,9598 ± 0,0263	0,0072 ± 0,0026
CDELm	0,9670 ± 0,0213	0,9672 ± 0,0213	0,9670 ± 0,0213	0,9636 ± 0,0235	0,9670 ± 0,0213	0,0055 ± 0,0028
ReSQu-CELM	0,9685 ± 0,0210	0,9691 ± 0,0209	0,9685 ± 0,0210	0,9654 ± 0,0229	0,9686 ± 0,0209	0,0095 ± 0,0030

Tablo 3.12 incelendiğinde Breast Cancer veri setinde tüm modellerin yüksek sınıflandırma performansı sergilediği incelenmektedir. Bununla birlikte, ReSQu-CELM modeli çoğu değerlendirme ölçütünde diğer ELM tabanlı yaklaşımlara göre daha başarılı sonuçlar elde etmiştir. Makro-F1 ile Ağırlıklı-F1 değerlerinin birbirine yakın olması, çoğunluk sınıfının genel performansı aşırı ölçüde yönlendirmediğine ve modelin sınıflar arasında görece dengeli sonuçlar ürettiğine işaret etmektedir. Bu bulgu, önerilen modelin yalnızca genel doğruluk açısından değil, farklı sınıflar üzerindeki başarımlar bakımından da tutarlı sonuçlar üretebildiğini ortaya koymaktadır. Tablo 3.13’te Ecoli veri setine ait performans değerleri sunulmaktadır.

Tablo 3.13. Ecoli veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
ELM	0,8208 ± 0,0680	0,8027 ± 0,0788	0,8208 ± 0,0680	0,6775 ± 0,1426	0,8065 ± 0,0753	0,0036 ± 0,0010
CDELm	0,8807 ± 0,0422	0,8758 ± 0,0408	0,8807 ± 0,0422	0,8085 ± 0,0987	0,8740 ± 0,0424	0,0054 ± 0,0056

ReSQu- CELM	0,8565 ± 0,0628	0,8692 ± 0,0536	0,8565 ± 0,0628	0,7774 ± 0,0954	0,8566 ± 0,0609	0,0328 ± 0,0340
----------------	--------------------	--------------------	--------------------	--------------------	--------------------	--------------------

Tablo 3.13’e göre Ecoli veri seti üzerinde gerçekleştirilen deneylerde, CDELM modeli doğruluk ve Makro-F1 ölçütlerinde ReSQu-CELM modeline kıyasla daha yüksek performans göstermiştir. Veri setinin sınırlı örnek sayısına sahip olması ve sınıflar arasındaki dağılımın düzensiz yapısı göz önüne alındığında, daha sade bir kısıt tabanlı gizli katman mekanizmasının bu veri yapısına daha uygun bir temsil oluşturabildiği değerlendirilmektedir. Bununla birlikte, ReSQu-CELM modeli de rekabetçi sonuçlar elde etmiş ve farklı stratejilerin birlikte kullanılmasının her veri setinde aynı düzeyde avantaj sağlamayabileceğini göstermiştir. Bu durum, önerilen yaklaşımın etkinliğinin veri setinin yapısal özellikleriyle yakından ilişkili olduğunu ortaya koymaktadır. Tablo 3.14’te Hill-Valley veri setine ait performans değerleri sunulmaktadır.

Tablo 3.14. Hill-Valley veri seti için ReSQu-CELM modelinin diğer ELM tabanlı modeller ile performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
ELM	0,7205 ± 0,0459	0,7808 ± 0,0386	0,7205 ± 0,0459	0,6983 ± 0,0569	0,7003 ± 0,0560	0,0056 ± 0,0019
CDELM	0,5464 ± 0,0731	0,5455 ± 0,0818	0,5464 ± 0,0731	0,5190 ± 0,0884	0,5213 ± 0,0871	0,0072 ± 0,0054
ReSQu- CELM	0,7952 ± 0,0592	0,7989 ± 0,0585	0,7952 ± 0,0592	0,7946 ± 0,0596	0,7946 ± 0,0596	0,0139 ± 0,0086

Hill-Valley veri seti, gürültülü yapısı nedeniyle bu çalışmada kullanılan en zor veri setlerinden biri olarak değerlendirilmektedir. Tablo 3.14’e göre bu veri seti üzerinde gerçekleştirilen deneylerde ReSQu-CELM modeli hem ELM hem de CDELM modellerine kıyasla daha başarılı sonuçlar elde etmiştir. Elde edilen bulgular, çeyrek tabanlı çok stratejili gizli katman yapısının gürültülü ve karmaşık veri yapılarında daha esnek karar sınırları oluşturulmasına katkı sağladığını göstermektedir. Bu durum, önerilen modelin özellikle doğrusal olmayan ve ayırt edilmesi güç örüntüler içeren problemlerde daha etkili bir temsil mekanizması sunabildiğine işaret etmektedir.

Genel olarak sonuçlar incelendiğinde, değerlendirilen ELM tabanlı modellerin performansları veri setlerinin karmaşıklığına ve öznitelik yapılarına bağlı olarak değişiklik

göstermiştir. Klasik ELM modeli genel olarak daha kısa eğitim süreleri sunmasına rağmen, sınıflandırma performansı veri setleri arasında daha belirgin dalgalanmalar göstermiştir. Buna karşılık, CDELM ve ReSQu-CELM birçok veri setinde ELM'e göre daha yüksek ortalama performans değerleri üretmiştir. Bu durum, kısıt tabanlı gizli katman oluşturma yaklaşımlarının veri yapısına ilişkin ayırt edici bilgileri daha etkili şekilde temsil edebildiğini göstermektedir.

CDELM modelinin, sınıf dağılımlarının daha belirgin olduğu ve daha basit kısıt tabanlı temsillerin yeterli olduğu WaveformEW ve Ecoli veri setlerinde güçlü bir sınıflandırma performansı sergilediği görülmektedir. Buna karşılık, Digits, Madelon, Hill-Valley ve Breast Cancer gibi gürültülü, doğrusal olmayan veya yüksek boyutlu yapılar içeren daha karmaşık veri setlerinde önerilen ReSQu-CELM modeli daha başarılı ya da en azından benzer düzeyde kararlı sonuçlar üretmiştir. Özellikle gürültülü veya yüksek boyutlu veri yapılarında bu eğilim daha belirgin hale gelmektedir. Bunun temel nedeni, farklı gizli katman oluşturma stratejilerinin veri setinin farklı yapısal özelliklerini yakalayabilmesi ve birbirini tamamlayan temsil biçimleri oluşturabilmesidir. Bu sayede ReSQu-CELM, karmaşık veri yapılarında daha esnek ve ayırt edici özellik temsilleri üreterek sınıflandırma performansını artırabilmektedir.

DeneySEL sonuçlardan elde edilen bir diğer önemli bulgu, önerilen ReSQu-CELM modelinin farklı değerlendirme ölçütleri arasında dengeli bir performans sergilemesidir. Birçok veri setinde doğruluk, Makro-F1 ve Ağırlıklı-F1 değerlerinin birbirine yakın olması, modelin öğrenme sürecinde hem sınıflar arası ayrımı koruyabildiğini hem de sınıf içi örüntüleri tutarlı bir şekilde temsil edebildiğini göstermektedir. Özellikle gürültülü ve yüksek boyutlu veri setlerinde elde edilen performans artışları, farklı gizli katman oluşturma stratejilerinin birlikte kullanılmasının öğrenilen karar sınırlarının esnekliğini artırdığını göstermektedir.

Önerilen model, çok stratejili gizli katman oluşturma mekanizması nedeniyle geleneksel ELM ve CDELM yaklaşımlarına kıyasla bir miktar daha yüksek eğitim süresine ihtiyaç duymaktadır. Bununla birlikte, özellikle zor sınıflandırma problemlerinde elde edilen performans kazanımları dikkate alındığında, bu ek hesaplama maliyetinin kabul edilebilir düzeyde olduğu değerlendirilmektedir. Sunulan performans bulguları genel olarak incelendiğinde, ReSQu-CELM modelinin farklı yapısal özelliklere ve veri dağılımlarına sahip veri setlerinde daha uyarlanabilir ve rekabetçi bir sınıflandırma çerçevesi sunduğu görülmektedir.

3.2.3. Makine Öğrenmesi Modelleri ile Karşılaştırma

ELM tabanlı modeller arasındaki karşılaştırmalardan elde edilen bulguların ardından, önerilen modelin literatürde yaygın olarak kullanılan makine öğrenmesi yöntemleri karşısındaki etkinliğini değerlendirmek amacıyla ek deneyler gerçekleştirilmiştir. Bu kapsamda ReSQu-CELM modeli; SVM, MLP, DT ve RF algoritmaları ile karşılaştırılmıştır. Tüm modeller için sınıf dağılımlarının korunması ve adil bir değerlendirme yapılabilmesi amacıyla 10 katlı tabakalı çapraz doğrulama yöntemi kullanılmıştır. Ayrıca tüm veri setlerine Min-Max normalizasyon uygulanmış ve deneysel süreç boyunca tutarlılığı sağlamak amacıyla sınıf etiketleri sayısal forma dönüştürülmüştür.

Çalışmada kullanılan modellerin temel yapılandırmaları ve deneysel ayarları Tablo 3.15'te özetlenmektedir. Bu bilgiler, sonraki tablolarda sunulan veri seti bazlı sonuçların daha tutarlı ve şeffaf bir şekilde yorumlanmasına yardımcı olmaktadır.

Tablo 3.15. Karşılaştırmada kullanılan modellerin deneysel yapılandırmaları

Model	Temel Parametreler	Veri Bölme	Ön İşleme	Etiket Kodlama	Açıklama
ReSQu-CELM	n_hidden=100, sigmoid, çeyrek tabanlı çoklu strateji (rastgeleleştirilmiş)	10 katlı tabakalı çapraz doğrulama	Min-Maks ölçekleme	LabelEncoder + One-Hot	Gizli katmanı çeyreklere ayırarak farklı stratejileri bir arada kullanan önerilen ELM modelidir.
SVM	RBF kernel, C=1.0, gamma=scale	10 katlı tabakalı çapraz doğrulama	Min-Maks ölçekleme	LabelEncoder	RBF çekirdeği aracılığıyla doğrusal olmayan karar sınırları oluşturabilen, destek vektörlerine dayalı sınıflandırma yöntemidir.
MLP	1 gizli katman (100 nöron), logistic, Adam, max_iter=500	10 katlı tabakalı çapraz doğrulama	Min-Maks ölçekleme	LabelEncoder	Gizli katmanında doğrusal olmayan ilişkileri öğrenebilen ileri beslemeli yapay sinir ağıdır.
DT	criterion=gini, max_depth=None	10 katlı tabakalı çapraz doğrulama	Min-Maks ölçekleme	LabelEncoder	Özellikler üzerinden ardışık bölünmeler yaparak karar kuralları oluşturan ağaç tabanlı sınıflandırıcıdır.
RF	n_estimators=100, criterion=gini, max_depth=None	10 katlı tabakalı çapraz doğrulama	Min-Maks ölçekleme	LabelEncoder	Birden fazla karar ağacının tahminlerini birleştiren topluluk öğrenmesi yöntemidir.

Tablo 3.15'te görüldüğü üzere, tüm modeller aynı veri ön işleme ve doğrulama prosedürleri altında değerlendirilmiştir. Böylece elde edilen performans farklılıklarının büyük ölçüde kullanılan öğrenme algoritmalarının özelliklerinden kaynaklanması amaçlanmıştır. Ayrıca tüm modellerde aynı çapraz doğrulama yaklaşımının kullanılması, karşılaştırmaların daha adil ve tutarlı bir şekilde gerçekleştirilmesine olanak sağlamıştır. Özellikle sınıf dağılımlarının çapraz doğrulama katları boyunca korunması, dengesiz veri setlerinde elde edilen sonuçların güvenilirliğini artırmış ve modellerin gerçek performanslarının daha sağlıklı bir biçimde değerlendirilmesini sağlamıştır.

Tablo 3.16. WaveformEW veri seti için ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
MLP	0,8672 ± 0,0082	0,8678 ± 0,0085	0,8672 ± 0,0082	0,8670 ± 0,0082	0,8668 ± 0,0082	1,7914 ± 0,2602
SVM	0,8624 ± 0,0078	0,8633 ± 0,0078	0,8624 ± 0,0078	0,8621 ± 0,0078	0,8620 ± 0,0079	0,2010 ± 0,0242
DT	0,7401 ± 0,0149	0,7409 ± 0,0151	0,7401 ± 0,0149	0,7403 ± 0,0149	0,7402 ± 0,0149	0,1246 ± 0,0081
RF	0,8496 ± 0,0124	0,8514 ± 0,0120	0,8496 ± 0,0124	0,8490 ± 0,0128	0,8488 ± 0,0128	1,2303 ± 0,0113
ReSQu-CELM	0,8560 ± 0,0128	0,8564 ± 0,0130	0,8560 ± 0,0128	0,8559 ± 0,0128	0,8558 ± 0,0128	0,0550 ± 0,0104

WaveformEW veri seti, dengeli sınıf yapısı ve görece düzenli öznitelik dağılımı sayesinde modellerin genel sınıflandırma davranışlarını değerlendirmek için uygun bir test ortamı sunmaktadır. Tablo 3.16'da görüldüğü üzere, en yüksek performans değerleri MLP modeli tarafından elde edilmiştir. ReSQu-CELM, SVM'den daha düşük ortalama performans üretmekle birlikte, eğitim süresi açısından belirgin bir avantaj sağlamıştır. Buna karşılık, DT modelinin veri setindeki doğrusal olmayan sınıf sınırlarını yeterince temsil edemediği ve diğer yöntemlere kıyasla daha düşük performans sergilediği görülmektedir.

Tablo 3.17. Digits veri seti için ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
MLP	0,9777 ± 0,0129	0,9788 ± 0,0126	0,9777 ± 0,0129	0,9776 ± 0,0131	0,9776 ± 0,0131	3,3674 ± 0,3777
SVM	0,9861 ± 0,0134	0,9870 ± 0,0125	0,9861 ± 0,0134	0,9861 ± 0,0135	0,9861 ± 0,0135	0,0444 ± 0,0093
DT	0,8586 ± 0,0225	0,8637 ± 0,0236	0,8586 ± 0,0225	0,8583 ± 0,0224	0,8583 ± 0,0226	0,0142 ± 0,0007
RF	0,9755 ± 0,0141	0,9771 ± 0,0129	0,9755 ± 0,0141	0,9754 ± 0,0143	0,9754 ± 0,0144	0,1916 ± 0,0033
ReSQu- CELM	0,9655 ± 0,0155	0,9676 ± 0,0145	0,9655 ± 0,0155	0,9652 ± 0,0158	0,9654 ± 0,0157	0,0411 ± 0,0121

Digits veri seti, çok sınıflı yapısı ve düzenli öznitelik dağılımı sayesinde sınıflar arasındaki karar sınırlarının belirlenmesine dayalı öğrenme yaklaşımları için uygun bir test ortamı sunmaktadır. Tablo 3.17’de verilen sonuçlara göre, en yüksek sınıflandırma performansı SVM modeli tarafından elde edilmiş, onu MLP ve RF modelleri takip etmiştir. Önerilen ReSQu-CELM modeli de değerlendirme ölçütlerinin tamamında DT modeline kıyasla daha başarılı sonuçlar üretmiştir. Her ne kadar SVM ve MLP modellerinin performans seviyesine ulaşamamış olsa da ReSQu-CELM’in düşük eğitim süresi ile dengeli ve kararlı sonuçlar elde etmesi, farklı sınıflandırma problemlerinde uygulanabilir bir alternatif olduğunu göstermektedir.

Tablo 3.18. Madelon veri seti için ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin performans karşılaştırması

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
MLP	0,5752 ± 0,0267	0,5816 ± 0,0305	0,5752 ± 0,0267	0,5683 ± 0,0272	0,5683 ± 0,0272	3,8733 ± 0,8601
SVM	0,5991 ± 0,0284	0,5996 ± 0,0286	0,5991 ± 0,0284	0,5986 ± 0,0284	0,5986 ± 0,0284	1,2642 ± 0,0550
DT	0,7410 ± 0,0400	0,7419 ± 0,0407	0,7410 ± 0,0400	0,7408 ± 0,0399	0,7408 ± 0,0399	0,4844 ± 0,0370

RF	0,7191 ± 0,0296	0,7205 ± 0,0306	0,7191 ± 0,0296	0,7187 ± 0,0294	0,7187 ± 0,0294	1,6825 ± 0,0089
ReSQu- CELM	0,5848 ± 0,0305	0,5851 ± 0,0305	0,5848 ± 0,0305	0,5844 ± 0,0306	0,5844 ± 0,0306	0,0889 ± 0,0679

Madelon veri seti, yüksek boyutlu yapısı ve çok sayıda gürültülü ve bilgi taşımayan öznitelik içermesi nedeniyle bu çalışmada kullanılan en zorlu veri setlerinden biridir. Tablo 3.18’de görüldüğü üzere, karşılaştırmaya dahil edilen makine öğrenmesi modelleri arasında en yüksek performans DT ve RF algoritmaları tarafından elde edilmiştir. ReSQu-CELM modeli, ELM tabanlı yaklaşımlara kıyasla daha başarılı sonuçlar üretmiş olsa da genel karşılaştırmada ağaç tabanlı yöntemlerin gerisinde kalmıştır. Bu durum, Madelon veri setinde bilgi taşıyan ve taşımayan özniteliklerin ayrıştırılmasında ağaç tabanlı yöntemlerin daha etkili olabildiğini göstermektedir. Öte yandan, elde edilen sonuçlar önerilen gizli katman oluşturma mekanizmasının yüksek boyutlu ve yoğun gürültü içeren veri yapılarında hâlen belirli zorluklarla karşılaşabildiğini ortaya koymaktadır.

Tablo 3.19. Breast Cancer veri setinde ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin karşılaştırmalı performans analizi

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
MLP	0,9670 ± 0,0192	0,9674 ± 0,0192	0,9670 ± 0,0192	0,9637 ± 0,0212	0,9671 ± 0,0192	0,4890 ± 0,0904
SVM	0,9685 ± 0,0140	0,9695 ± 0,0141	0,9685 ± 0,0140	0,9655 ± 0,0153	0,9686 ± 0,0140	0,0024 ± 0,0018
DT	0,9399 ± 0,0261	0,9407 ± 0,0266	0,9399 ± 0,0261	0,9334 ± 0,0290	0,9398 ± 0,0262	0,0014 ± 0,0009
RF	0,9714 ± 0,0221	0,9721 ± 0,0220	0,9714 ± 0,0221	0,9687 ± 0,0241	0,9715 ± 0,0221	0,0609 ± 0,0100
ReSQu- CELM	0,9685 ± 0,0210	0,9691 ± 0,0209	0,9685 ± 0,0210	0,9654 ± 0,0229	0,9686 ± 0,0209	0,0095 ± 0,0030

Breast Cancer veri setinden elde edilen sonuçlar, değerlendirilen tüm modellerin genel olarak yüksek sınıflandırma performansı sergilediğini göstermektedir. Tablo 3.19’da görüldüğü üzere, en yüksek performans değerleri RF modeli tarafından elde edilmiştir. SVM ve ReSQu-CELM modelleri ise benzer şekilde dengeli ve başarılı sonuçlar üretmiştir. Doğruluk, Makro-F1 ve Ağırlıklı-F1 değerlerinin birbirine yakın olması, modellerin sınıf dağılımını dengeli bir

şekilde öğrenebildiğini ve belirli bir sınıfa yönelik yanlış bir davranış sergilemediğini göstermektedir. Ayrıca ReSQu-CELM modeli, veri setinin görece düşük boyutlu yapısına rağmen güvenilir ve tutarlı sonuçlar üreterek farklı veri karakteristiklerine uyum sağlayabildiğini ortaya koymuştur.

Tablo 3.20. Ecoli veri setinde ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin karşılaştırmalı performans analizi

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
MLP	0,7702 ± 0,0292	0,6671 ± 0,0327	0,7702 ± 0,0292	0,5006 ± 0,0629	0,7096 ± 0,0278	0,2537 ± 0,0366
SVM	0,8716 ± 0,0523	0,8705 ± 0,0467	0,8716 ± 0,0523	0,8095 ± 0,0830	0,8661 ± 0,0513	0,0022 ± 0,0015
DT	0,8029 ± 0,0362	0,8267 ± 0,0320	0,8029 ± 0,0362	0,6805 ± 0,1103	0,7995 ± 0,0364	0,0012 ± 0,0006
RF	0,8806 ± 0,0462	0,8707 ± 0,0588	0,8806 ± 0,0462	0,8146 ± 0,1130	0,8707 ± 0,0533	0,0604 ± 0,0181
ReSQu-CELM	0,8565 ± 0,0628	0,8692 ± 0,0536	0,8565 ± 0,0628	0,7774 ± 0,0954	0,8566 ± 0,0609	0,0328 ± 0,0340

Ecoli veri seti, dengesiz sınıf dağılımına sahip çok sınıflı biyolojik bir sınıflandırma problemi sunmakta ve bu nedenle modellerin performanslarının daha hassas bir şekilde değerlendirilmesine olanak sağlamaktadır. Tablo 3.20’de görüldüğü üzere, karşılaştırılan yöntemler arasında en yüksek performans değerleri RF ve SVM modelleri tarafından elde edilmiştir. ReSQu-CELM modeli bu yöntemlerin gerisinde kalmasına rağmen, özellikle Makro-F1 ve Ağırlıklı-F1 ölçütlerinde MLP ve DT modellerine kıyasla daha dengeli sonuçlar üretmiştir. Bu durum, önerilen yapının öğrenme sürecinde sınıf dengesizliğinin neden olduğu olumsuz etkileri belirli ölçüde azaltabildiğini ve farklı sınıflar üzerindeki performansı daha tutarlı bir şekilde koruyabildiğini göstermektedir.

Tablo 3.21. Hill-Valley veri setinde ReSQu-CELM ve geleneksel makine öğrenmesi modellerinin karşılaştırmalı performans analizi

Model	Doğruluk	Hassasiyet	Geri Çağırma	Makro-F1	Ağırlıklı-F1	Eğitim Süresi (sn)
-------	----------	------------	--------------	----------	--------------	--------------------

MLP	0,5062 ± 0,0366	0,4828 ± 0,1181	0,5062 ± 0,0366	0,4072 ± 0,0439	0,4130 ± 0,0439	0,0534 ± 0,0243
SVM	0,5046 ± 0,0241	0,4873 ± 0,0520	0,5046 ± 0,0241	0,4133 ± 0,0388	0,4189 ± 0,0385	0,0213 ± 0,0041
DT	0,5545 ± 0,0601	0,5544 ± 0,0607	0,5545 ± 0,0601	0,5524 ± 0,0612	0,5529 ± 0,0611	0,0314 ± 0,0044
RF	0,5948 ± 0,0512	0,5976 ± 0,0524	0,5948 ± 0,0512	0,5891 ± 0,0527	0,5900 ± 0,0525	0,2278 ± 0,0101
ReSQu- CELM	0,7952 ± 0,0592	0,7989 ± 0,0585	0,7952 ± 0,0592	0,7946 ± 0,0596	0,7946 ± 0,0596	0,0139 ± 0,0086

Hill-Valley veri seti, gürültülü yapısı ve karmaşık doğrusal olmayan özellikleri nedeniyle sınıflandırma modellerinin genelleme yeteneğini zorlayan veri setlerinden biridir. Tablo 3.21’de görüldüğü üzere, önerilen ReSQu-CELM modeli tüm değerlendirme ölçütlerinde karşılaştırmaya dahil edilen diğer yöntemlerden daha yüksek performans elde etmiştir. SVM, MLP ve DT modellerinin görece düşük sonuçlar üretmesi, geleneksel yöntemlerin veri setindeki karmaşık doğrusal olmayan ilişkileri yeterince temsil etmekte zorlanabildiğini göstermektedir. Buna karşılık, ReSQu-CELM modelinde kullanılan çok stratejili kısıt tabanlı gizli katman yapısının veri setindeki karmaşık örüntülerin daha etkili bir şekilde öğrenilmesine katkı sağladığı görülmektedir.

Modellerin farklı değerlendirme ölçütleri altındaki genel performanslarını daha kapsamlı biçimde inceleyebilmek amacıyla doğruluk, hassasiyet, geri çağırma, F1-skoru ve eğitim süresi değerleri temel alınarak bir ortalama sıralama analizi gerçekleştirilmiştir. Bu analizde her veri seti için en iyi performansı gösteren modele 1. sıra verilmiş, diğer modeller ise elde ettikleri sonuçlara göre sıralandırılmıştır. Eşit performans gösteren modeller aynı sıralama değerini almıştır. Son olarak, tüm veri setlerinden elde edilen sıralama değerlerinin ortalaması hesaplanarak modellerin genel başarı düzeyleri belirlenmiştir. Elde edilen ortalama sıralama sonuçları Tablo 3.22’de sunulmaktadır.

Tablo 3.22. Modellerin farklı performans ölçütlerine göre ortalama sıralama sonuçları

Model	Doğruluk Sıralaması	Hassasiyet Sıralaması	Geri Çağırma Sıralaması	F1-Skoru Sıralaması	Eğitim Süresi Sıralaması	Ortalama Sıralama
SVM	2,5	2,5	2,5	2,33	2,5	2,47
RF	2,17	2,33	2,17	2,17	4,17	2,6

ReSQu- CELM	2,83	3,17	2,83	2,83	1,83	2,7
DT	3,83	3,83	3,83	3,83	1,67	3,4
MLP	3,5	3,17	3,5	3,67	4,83	3,73

Tablo 3.22’de görüldüğü üzere, değerlendirilen modeller arasında en iyi ortalama sıralama değeri SVM modeli tarafından elde edilmiştir. SVM’yi sırasıyla RF ve ReSQu-CELM modelleri takip etmektedir. Önerilen ReSQu-CELM modeli en düşük ortalama sıralama değerine sahip olmamasına rağmen, farklı değerlendirme ölçütlerinde rekabetçi sonuçlar üretmiş ve aynı zamanda en düşük eğitim süresi sıralamalarından birini elde etmiştir. Bu durum, modelin sınıflandırma başarımı ile hesaplama maliyeti arasında etkili bir denge kurabildiğini göstermektedir. RF modelinin yüksek sıralama performansı, topluluk öğrenmesine dayalı yaklaşımların karmaşık ve yüksek boyutlu veri yapılarında hâlen oldukça etkili olduğunu ortaya koymaktadır. Benzer şekilde, SVM modelinin elde ettiği başarılı sonuçlar, özellikle sınıflar arası ayrımın daha belirgin olduğu veri setlerinde karar sınırı temelli öğrenme mekanizmalarının avantajlarını göstermektedir. Buna karşılık, MLP ve DT modellerinin daha düşük ortalama sıralama değerleri elde etmesi, bu yöntemlerin performanslarının veri seti özelliklerinden daha fazla etkilenebildiğine işaret etmektedir.

Genel olarak değerlendirildiğinde, sıralama analizi sonuçları önerilen ReSQu-CELM modelinin farklı yapısal özelliklere sahip veri setlerinde rekabetçi ve hesaplama açısından verimli bir sınıflandırma yaklaşımı sunduğunu göstermektedir. Çeyrek tabanlı çok stratejili gizli katman yapısı, modelin farklı değerlendirme ölçütlerinde dengeli performans sergilemesine katkı sağlarken, birçok geleneksel makine öğrenmesi yöntemine kıyasla düşük eğitim süresi avantajını da koruyabilmektedir.

Önerilen ReSQu-CELM modeli ile karşılaştırılan yöntemler arasında gözlenen performans farklılıklarının istatistiksel olarak anlamlı olup olmadığını incelemek amacıyla ek bir anlamlılık analizi gerçekleştirilmiştir. Bu kapsamda parametrik olmayan Wilcoxon İşaretli Sıralar Testi kullanılmıştır. Test, 10 katlı çapraz doğrulama deneylerinden elde edilen Ağırlıklı-F1 değerleri üzerinde uygulanmıştır. Karşılaştırılan modellerin performanslarının normal dağılım varsayımını sağlamayabileceği göz önünde bulundurularak parametrik olmayan Wilcoxon testi tercih edilmiştir. Analiz boyunca anlamlılık düzeyi $p < 0,05$ olarak kabul edilmiştir.

İstatistiksel analizde hesaplama kapsamını sınırlandırmak ve üç temel veri yapısını temsil etmek amacıyla, deneylerden önce WaveformEW dengeli, Ecoli dengesiz ve Hill-Valley

gürültülü veri yapısının temsilcisi olarak seçilmiştir. Karşılaştırmalara hem ELM tabanlı yöntemler hem de geleneksel makine öğrenmesi algoritmaları dahil edilerek önerilen modelin başarımı daha kapsamlı bir şekilde incelenmiştir. Elde edilen Wilcoxon İşaretli Sıralar Testi sonuçları Tablo 3.23’te sunulmaktadır.

Tablo 3.23. Ağırlıklı-F1 skorları için Wilcoxon İşaretli Sıralar Testi sonuçları

Veri Seti	Karşılaştırma	Test İstatistiği	p-değeri	Sonuç
WaveformEW	ReSQu-CELM vs ELM	18.0	0,3750	Anlamlı Değil
	ReSQu-CELM vs CDELM	3.0	0,0098	Anlamlı
	ReSQu-CELM vs MLP	0.0	0,0020	Anlamlı
	ReSQu-CELM vs SVM	5.0	0,0195	Anlamlı
	ReSQu-CELM vs DT	0.0	0,0020	Anlamlı
	ReSQu-CELM vs RF	15.0	0,2324	Anlamlı Değil
Ecoli	ReSQu-CELM vs ELM	11.0	0,1054	Anlamlı Değil
	ReSQu-CELM vs CDELM	5.0	0,0381	Anlamlı
	ReSQu-CELM vs MLP	0.0	0,0019	Anlamlı
	ReSQu-CELM vs SVM	12.0	0,1308	Anlamlı Değil
	ReSQu-CELM vs DT	12.0	0,1308	Anlamlı Değil
	ReSQu-CELM vs RF	5.0	0,0381	Anlamlı
	ReSQu-CELM vs ELM	12.0	0,1308	Anlamlı Değil
	ReSQu-CELM vs CDELM	0.0	0,0019	Anlamlı

	ReSQu-CELM vs MLP	0.0	0,0019	Anlamlı
	ReSQu-CELM vs SVM	0.0	0,0019	Anlamlı
Hill-Valley	ReSQu-CELM vs DT	0.0	0,0019	Anlamlı
	ReSQu-CELM vs RF	0.0	0,0019	Anlamlı

Tablo 3.23’te sunulan Wilcoxon İşaretli Sıralar Testi sonuçlarına göre, önerilen ReSQu-CELM modeli ile karşılaştırılan yöntemler arasındaki performans farklılıklarının anlamlılığı veri setlerinin yapısal özelliklerine bağlı olarak değişiklik göstermektedir. WaveformEW veri setinde ReSQu-CELM ile CDELM, MLP, SVM ve DT arasında anlamlı farklılıklar belirlenmiştir. Ortalama Ağırlıklı-F1 değerleri dikkate alındığında CDELM, MLP ve SVM ReSQu-CELM’den daha yüksek performans üretirken, ReSQu-CELM, DT modelinden daha başarılı olmuştur. ELM ve RF ile gözlenen farklılıklar ise istatistiksel olarak anlamlı bulunmamıştır.

Ecoli veri setinde ise ReSQu-CELM modeli ile CDELM, MLP ve RF modelleri arasında istatistiksel olarak anlamlı farklılıklar tespit edilmiştir. Veri setinin dengesiz sınıf dağılımına ve sınırlı örnek sayısına sahip olduğu dikkate alındığında, elde edilen bulgular önerilen modelin zorlu öğrenme koşulları altında da rekabetçi bir sınıflandırma performansı sergileyebildiğini göstermektedir.

En güçlü istatistiksel bulgular Hill-Valley veri setinde elde edilmiştir. Bu veri setinde ELM dışında karşılaştırılan tüm modeller ile ReSQu-CELM arasında istatistiksel olarak anlamlı farklılıklar gözlenmiştir. Hill-Valley veri setinin gürültülü ve doğrusal olmayan yapısı göz önüne alındığında, bu sonuçlar önerilen modelin karmaşık örüntüleri öğrenme ve daha esnek karar sınırları oluşturma konusunda etkili olduğunu ortaya koymaktadır.

Genel olarak değerlendirildiğinde, Wilcoxon analizi, ReSQu-CELM ile karşılaştırılan yöntemler arasındaki farkların veri setine bağlı olarak değiştiğini göstermiştir. Hill-Valley veri setinde önerilen model lehine güçlü istatistiksel bulgular elde edilirken, WaveformEW ve Ecoli veri setlerinde anlamlı farklılıkların yönü karşılaştırılan yönteme göre değişmiştir.

Elde edilen sonuçlar, önerilen ReSQu-CELM modelinin farklı sınıflandırma problemlerindeki etkinliğini ortaya koymakla birlikte, modelin bazı sınırlılıkları ve geliştirilebilecek yönleri de bulunmaktadır. Bu kapsamda, önerilen yaklaşımın mevcut

sınırlılıkları ve gelecekte gerçekleştirilebilecek araştırma çalışmaları bir sonraki bölümde ele alınmaktadır.

4. SONUÇLAR VE ÖNERİLER

Bu tez kapsamında, ELM tabanlı sınıflandırma yöntemleri iki aşamalı bir araştırma süreci içerisinde incelenmiştir. İlk aşamada standart ELM ile IELM, OSELM, RELM ve CELM modellerinin farklı görüntü sınıflandırma problemlerindeki başarımları karşılaştırılmıştır. İkinci aşamada ise bu karşılaştırmalardan elde edilen bulgular doğrultusunda, farklı sınıf ilişkilerini aynı gizli katman yapısı içerisinde bir araya getiren ReSQu-CELM modeli geliştirilmiştir. Böylece tezde mevcut ELM varyantlarının güçlü ve sınırlı yönleri ortaya konulmuş, ardından belirlenen gereksinimlere yönelik yeni bir model önerilmiştir.

İlk çalışma kapsamında MNIST, Beyin tümörü MR görüntüleri, pirinç görüntüleri ve araç sürücüsü uyku durumu veri setleri kullanılmıştır. Elde edilen sonuçlar, incelenen modellerin başarımının veri setinin yapısına göre değiştiğini göstermiştir. MNIST veri setinde CELM modeli 0,9547 F1-skoru, pirinç görüntü veri setinde 0,9345 F1-skoru, beyin tümörü veri setinde 0,8528 F1-skoru ve araç sürücüsü uyku durumu veri setinde 0,9624 F1-skoru değeriyle diğer modellerin önüne geçmiştir. Buna karşılık IELM modeli tüm veri setlerinde daha düşük sonuçlar vermiştir. Bu bulgular, özellikle CELM yaklaşımının farklı görüntü sınıflandırma problemlerinde standart ELM ve diğer varyantlara göre daha dengeli sonuçlar sağlayabildiğini göstermiştir.

İlk çalışmanın genel bulguları, gizli katman parametrelerinin oluşturulma biçiminin ELM tabanlı modellerin başarımı üzerinde önemli bir etkiye sahip olduğunu ortaya koymuştur. Özellikle eğitim örnekleri ve sınıf bilgilerinden yararlanılarak oluşturulan kısıtlı ağırlıkların, tamamen rastgele belirlenen gizli katman yapılarına göre daha ayırt edici temsiller sağlayabildiği görülmüştür. Bu değerlendirme, tezin ikinci aşamasında kısıtlanmış ELM yaklaşımının geliştirilmesinin temel gerekçesini oluşturmuştur.

Bu doğrultuda geliştirilen ReSQu-CELM modelinde gizli katman dört eşit bölüme ayrılmış ve her bir bölüme farklı bir kısıtlama stratejisi atanmıştır. Modelde farklı sınıflara ait örneklerin farkı, farklı sınıflara ait örneklerin toplamı, aynı sınıfa ait örneklerin farkı ve aynı sınıfa ait örneklerin toplamı temelinde oluşturulan dört strateji birlikte kullanılmıştır. Stratejilerin gizli katman çeyreklerine rastgele permüte edilerek atanmasıyla, modelin yalnızca tek bir örnek ilişkisine bağlı kalmadan farklı yapısal örüntüleri birlikte temsil etmesi amaçlanmıştır.

Modelin gizli katman kapasitesini belirlemek amacıyla 24, 48, 100, 200 ve 500 nöronlu

yapılar karşılaştırılmıştır. Ortalama sıralama sonuçlarında 100 gizli nöronlu yapı 1,93 değeriyle en iyi genel performansı göstermiştir. Daha düşük nöron sayıları daha kısa eğitim süresi sunmasına rağmen sınıflandırma başarımı bakımından aynı düzeye ulaşamamış, daha yüksek nöron sayıları ise belirgin ve tutarlı bir iyileşme sağlamamıştır. Bu nedenle temel karşılaştırmalarda 100 gizli nöronlu yapı kullanılmıştır.

ELM tabanlı modellerle yapılan karşılaştırmalarda ReSQu-CELM, Digits, Madelon, Breast Cancer ve Hill-Valley veri setlerinde en yüksek Ağırlıklı-F1 sonuçlarını üretmiştir. Modelin Ağırlıklı-F1 değerleri bu veri setlerinde sırasıyla 0,9654, 0,5844, 0,9686 ve 0,7946 olarak elde edilmiştir. Özellikle Hill-Valley veri setinde standart ELM'nin 0,7003 ve CDELM'nin 0,5213 Ağırlıklı-F1 değerlerine karşılık ReSQu-CELM'in 0,7946 değerine ulaşması, çok stratejili yapının gürültülü ve doğrusal olmayan problemlerde belirgin bir avantaj sağlayabildiğini göstermiştir. Benzer şekilde Madelon veri setinde ReSQu-CELM'in 0,5844 Ağırlıklı-F1 değeri, ELM'nin 0,5440 ve CDELM'nin 0,5724 değerlerinin üzerinde gerçekleşmiştir.

Buna karşılık WaveformEW ve Ecoli veri setlerinde en yüksek ELM tabanlı sonuçlar CDELM modeli tarafından elde edilmiştir. WaveformEW veri setinde CDELM 0,8617, ReSQu-CELM ise 0,8558 Ağırlıklı-F1 değerine ulaşmıştır. Ecoli veri setinde CDELM'nin Ağırlıklı-F1 değeri 0,8740 iken ReSQu-CELM'in değeri 0,8566 olarak ölçülmüştür. Bu sonuçlar, farklı stratejilerin birlikte kullanılmasının her veri setinde aynı düzeyde katkı sağlamadığını ve model başarımının veri setinin yapısal özelliklerine bağlı olduğunu ortaya koymuştur. Dolayısıyla ReSQu-CELM, bütün problemlerde mutlak üstünlük sağlayan bir modelden ziyade, özellikle karmaşık, gürültülü ve yüksek boyutlu veri yapılarında avantaj sağlayabilen esnek bir ELM yaklaşımı olarak değerlendirilmelidir.

Bileşen analizi sonuçları da stratejilerin etkisinin veri setine göre değiştiğini göstermiştir. WaveformEW veri setinde rastgele sıralı ReSQu-CELM yapısı en yüksek sonucu üretirken, Hill-Valley veri setinde bazı tekil toplam temelli stratejiler daha başarılı olmuştur. Digits veri setinde ise sabit sıralı çok stratejili yapı 0,9633 Ağırlıklı-F1 ile bileşenler arasındaki en yüksek sonucu elde etmiştir. Bu bulgular, modelin performansının yalnızca tek bir stratejiden kaynaklanmadığını, ancak strateji düzeninin ve veri yapısının sonuçlar üzerinde belirleyici olduğunu göstermektedir.

Geleneksel makine öğrenmesi modelleriyle yapılan karşılaştırmalarda SVM 2,47 ortalama sıralama değeriyle ilk sırada yer almış, RF 2,60 ve ReSQu-CELM 2,70 ortalama

sıralama değeri elde etmiştir. ReSQu-CELM'in eğitim süresi sıralamasının 1,83 olması, modelin sınıflandırma başarımı ile hesaplama maliyeti arasında dengeli bir yapı sunduğunu göstermiştir. Model bazı veri setlerinde SVM ve RF'nin gerisinde kalırken, özellikle Hill-Valley veri setinde geleneksel yöntemlerin tamamından daha yüksek performans üretmiştir. Böylece önerilen yaklaşımın her veri setinde en başarılı model olmadığı, ancak farklı veri yapıları karşısında rekabetçi ve hesaplama açısından verimli bir alternatif sunduğu görülmüştür.

Wilcoxon İşaretli Sıralar Testi sonuçları da modeller arasındaki farklılıkların veri setine bağlı olduğunu doğrulamıştır. WaveformEW veri setinde ReSQu-CELM ile CDELM, MLP, SVM ve DT arasındaki farklılıklar anlamlı bulunurken, ELM ve RF ile olan farklılıklar anlamlı değildir. Ecoli veri setinde CDELM, MLP ve RF karşılaştırmaları anlamlı sonuç vermiştir. Hill-Valley veri setinde ise ELM dışındaki tüm modellerle yapılan karşılaştırmalarda $p=0,0019$ değeri elde edilmiştir. Bu bulgular, önerilen yapının özellikle gürültülü ve karmaşık veri yapılarında ayırt edilebilir bir performans ortaya koyabildiğini göstermektedir.

Sonuç olarak bu tezde, mevcut ELM varyantlarının farklı görüntü sınıflandırma problemlerindeki davranışları karşılaştırılmış ve bu değerlendirmeler sonucunda çok stratejili bir gizli katman yapısına sahip ReSQu-CELM modeli geliştirilmiştir. Elde edilen sonuçlar, eğitim örnekleri ve sınıf ilişkilerinden yararlanılarak oluşturulan gizli katmanların ELM tabanlı sınıflandırma performansını geliştirebildiğini göstermiştir. ReSQu-CELM özellikle gürültülü, doğrusal olmayan ve yüksek boyutlu veri kümelerinde başarılı sonuçlar üretmiş, buna karşılık daha sade sınıf yapılarında tek stratejili CDELM yaklaşımının da etkili olabildiği görülmüştür. Bu nedenle modelin temel katkısı, bütün veri setlerinde mutlak üstünlük sağlamasından ziyade, farklı sınıf içi ve sınıflar arası ilişkileri tek bir analitik öğrenme yapısı içerisinde birleştiren esnek bir sınıflandırma çerçevesi sunmasıdır.

Gelecek çalışmalarda stratejilerin gizli katmandaki oranlarının veri setinin özelliklerine göre dinamik biçimde belirlenmesi, sabit çeyrek yapısı yerine uyarlanabilir strateji ağırlıklandırma mekanizmalarının geliştirilmesi ve özellik seçimi veya boyut indirgeme yöntemlerinin modele entegre edilmesi değerlendirilebilir. Ayrıca model parametrelerinin optimizasyon ve meta-sezgisel yöntemlerle belirlenmesi ve ReSQu-CELM'in daha büyük ölçekli gerçek yaşam veri setlerinde sınanması, önerilen yaklaşımın genelleme yeteneğinin daha kapsamlı biçimde incelenmesine katkı sağlayacaktır.

KAYNAKÇA

- Al-Dhief, F. T., Baki, M. M., Latiff, N. M. A. A., Malik, N. N. N. A., Salim, N. S., Albader, M. A. A., Mahyuddin, N. M., & Mohammed, M. A. (2021). Voice pathology detection and classification by adopting online sequential extreme learning machine. *IEEE Access*, 9, 77293–77306.
- Baran, B. (2019). Sınır değerler arasında kalan evsel atıksu numune analizi sonucunun aşırı öğrenme makineleri ile sınıflandırılması. *Mühendislik Bilimleri ve Tasarım Dergisi*, 7(1), 18–25.
- Chen, K., Li, J., Liu, K., Bai, C., Zhu, J., Gao, G., Wu, 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*, 11, 51–58.
- De Canditiis, D., & Veglianti, F. (2025). Effective non-random extreme learning machine. *Neural Computing and Applications*, 37(25), 20691–20719.
- 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(3), 549–556.
- Dua, D., & Graff, C. (2019). *UCI machine learning repository*. University of California, Irvine, School of Information and Computer Sciences. <https://archive.ics.uci.edu/ml>
- Gao, Z., & Yi, W. (2025). Prediction of projectile impact points and launch conditions based on extreme learning machine. *Measurement*, 252, 117308.
- Guyon, I., Gunn, S., Ben-Hur, A., & Dror, G. (2004). Result analysis of the NIPS 2003 feature selection challenge. *Advances in Neural Information Processing Systems*, 17, 545–552.
- 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.
- Horton, P., & Nakai, K. (1996). A probabilistic classification system for predicting protein localization sites in eukaryotic cells. *Intelligent Systems in Molecular Biology*, 4, 109–115.
- Huang, G. B., & Chen, L. (2007). Convex incremental extreme learning machine. *Neurocomputing*, 70(16–18), 3056–3062.
- Huang, G. B., Liang, N., 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., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), 489–501.
- 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.
- İsmail Nasri. (2023). *Driver drowsiness dataset (DDD)* [Data set]. Kaggle. <https://www.kaggle.com/datasets/ismailnasri20/driver-drowsiness-dataset-ddd>

- Kadam, S. S., Adamuthe, A. C., & Patil, A. B. (2020). CNN model for image classification on MNIST and fashion-MNIST dataset. *Journal of Scientific Research*, 64(2), 374–384.
- Kaynar, O., Görmez, Y., Yıldız, M., & Albayrak, A. (2016). Makine öğrenmesi yöntemleri ile duygu analizi. *International Artificial Intelligence and Data Processing Symposium (IDAP'16)*, 17–18 Eylül 2016, 234–241.
- Koklu, M., Cinar, I., & Taspınar, Y. S. (2021). Classification of rice varieties with deep learning methods. *Computers and Electronics in Agriculture*, 187, 106285.
- LeCun, Y. (1998). *The MNIST database of handwritten digits* [Data set]. <http://yann.lecun.com/exdb/mnist/>
- 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* [Data set]. Kaggle. <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.
- Mo, D., Wang, S., Fan, Y., Takyi-Aninakwa, P., Zhang, M., Wang, Y., & Fernandez, C. (2024). Enhanced multi-constraint dung beetle optimization-kernel extreme learning machine for lithium-ion battery state of health estimation with adaptive enhancement ability. *Energy*, 307, 132723.
- Naidu, G., Zuva, T., & Sibanda, E. M. (2023). A review of evaluation metrics in machine learning algorithms. In *Computer Science Online Conference* (pp. 15–25). Springer.
- Prakash, S. B., Chandan, K., Karthik, K., Devanathan, S., Kumar, R. V., Nagaraja, K. V., & Prasannakumara, B. C. (2024). Investigation of the thermal analysis of a wavy fin with radiation impact: An application of extreme learning machine. *Physica Scripta*, 99(1), 015225.
- Rasa, G. R. R., Mood, S. E., & Abbasi, E. (2026). Increasing the accuracy of an extreme learning machine using a chaos particle swarm optimization algorithm. *Evolving Systems*, 17(1), 3.
- Serin, Z., Karakuzu, C., & Yuzgec, U. (2026). Meta-constrained extreme learning machines: A novel approach for classification problems. *The Computer Journal*, bxag071.
- Subramanian, M., Walid, M. A. A., Mallick, S. P., Rastogi, R., Chauhan, A., & Vidya, A. (2023). 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. <https://doi.org/10.1109/ICEARS56392.2023.10085489>
- Tosun, O., & Eryiğit, R. (2021). Improved online sequential extreme learning machine: OS-CELM. *Turkish Journal of Electrical Engineering and Computer Sciences*, 29(7), 3092–3106.
- Van Thieu, N., Houssein, E. H., Oliva, D., & Hung, N. D. (2025). IntelELM: A Python framework for intelligent metaheuristic-based extreme learning machine. *Neurocomputing*, 618, 129062.
- 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.
- Wibawa, I. P. D., Machbub, C., Rohman, A. S., & Hidayat, E. (2023). Modified online sequential extreme learning machine algorithm using model predictive control approach. *Intelligent Systems with Applications*, 18, 200191.

- 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*. <https://arxiv.org/abs/1708.07747>
- Yacouby, R., & Axman, D. (2020). Probabilistic extension of precision, recall, and F1 score for more thorough evaluation of classification models. In *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems* (pp. 79–91).
- Yi, Y., He, X., Zhu, Y., Wang, J., Chen, Z., & Li, H. (2026). Hybrid Harris hawks and particle swarm optimized kernel extreme learning machine for battery SOH estimation. *Journal of Power Sources*, 680, 240212.
- Zhang, X., Zhao, H., Yao, J., Wang, Z., Zheng, Y., Peng, T., & Zhang, C. (2025). A multi-scale component feature learning framework based on CNN-BiGRU and online sequential regularized extreme learning machine for wind speed prediction. *Renewable Energy*, 242, 122427.
- 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