

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**AŞIRI ÖĞRENME MAKİNELERİ İLE BETA TALASEMİ VE
DEMİR EKSİKLİĞİ ANEMİSİNİN AYIRT EDİLMESİ**

Betül SAYIN

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Donanım Bilim Dalı

ŞUBAT 2021

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**AŞIRI ÖĞRENME MAKİNELERİ İLE BETA TALASEMİ VE DEMİR
EKSİKLİĞİ ANEMİSİNİN AYIRT EDİLMESİ**

Tez Yazarı
Betül SAYIN

Danışman
Doç. Dr. Taner TUNCER

ŞUBAT 2021
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Aşırı Öğrenme Makineleri ile Beta Talasemi ve Demir Eksikliği Anemisinin Ayırt Edilmesi
Yazarı:	Betül SAYIN
İlk Teslim Tarihi:	04.01.2021
Savunma Tarihi:	05.02.2021

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Taner TUNCER Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Ahmet ALKAN Sütçü İmam Üniversitesi, Müh- Mim Fakültesi	Onayladım
Üye:	Doç. Dr. Ebubekir ERDEM Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Doç. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Aşırı Öğrenme Makineleri ile Beta Talasemi ve Demir Eksikliği Anemisinin Ayırt Edilmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

05.02.2021

Betül SAYIN



ÖNSÖZ

Hastalıkların erken ve doğru teşhis edilmesi riskin büyüklüğünün ve ortaya çıkma süresinin kısaltılmasını sağlamaktadır. Demir eksikliği anemisi ve β -talasemi özelliği gibi genetik hastalıklarında zamanında teşhis edilmesi büyük önem taşımaktadır. Beta talasemi özelliği ve Demir eksikliği anemisi ile arasındaki teşhis, uzun ve maliyetli bir sorundur. Günümüzde bu maliyet daha da artmaktadır. Bu maliyeti azaltmak ve hızlı teşhis edilebilmesi için bir çok literatür çalışması yapılmıştır. Bu tezde ise Beta talasemi özelliği ve Demir eksikliği anemisi ayrımının daha hızlı ve daha az maliyetle tespit edilebilerek daha iyi sonuçlar verebildiği gösterilmek istenmiştir.

Bu tez çalışmasında, ilgisini ve desteğini hiçbir zaman benden esirgemeyen, bilgi ve birikimlerini benimle paylaşan değerli hocam ve tez danışmanım Doç. Dr. Taner TUNCER' e teşekkürü bir borç bilirim. Ayrıca, tez çalışmam boyunca bana destek olan, maddi ve manevi desteğini benden esirgemeyen eşim ve aileme de çok teşekkür ederim.

Betül SAYIN
ELAZIĞ, 2021

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	x
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Beta Talasemi ve Demir Eksikliği Anemisi	1
1.2. Literatürde Yapılan Çalışmalar.....	2
2. MAKİNA ÖĞRENMESİ	6
2.1. Makine Öğrenmesi Yöntemleri	6
2.1.1. Denetimli Öğrenme	6
2.1.2. Denetimsiz Öğrenme(Unsupervised Learning)	8
2.1.3. Takviyeli Öğrenme(Reinforcement Learning)	8
2.2. Makine Öğrenmesi Algoritmaları	10
2.2.1. Yapay sinir ağları (Artificial neural networks-ANN).....	10
2.2.2. Destek vektör makinesi (Support vector machine-SVM).....	10
2.2.3. K- En yakın komşu (k-Nearest neighbor-kNN)	11
2.2.4. K-Means.....	11
2.2.5. Doğrusal Regresyon	11
2.2.6. Derin Öğrenme.....	12
3. AŞIRI ÖĞRENME MAKİNELERİ.....	18
3.1. RELM (Recurrent Extreme Learning Machine)	21
3.2. Artımlı ELM.....	22
3.3. Hata minimize ELM	22
3.4. İki aşamalı ELM	22
3.5. Budamalı ELM	23
3.6. Online sıralı ELM.....	23
3.7. Evrimsel ELM	23
3.8. Oylama tabanlı ELM	24
3.9. Sıralı ELM	24
3.10. Tam kompleks ELM	24
3.11. Simetrik ELM.....	25
3.12. ELM Uygulamaları.....	25
3.12.1. Sınıflandırma	25
3.12.2. Regresyon.....	25
3.12.3. Desen Tanıma.....	26
3.12.4. Tahmin ve Teşhis	26
3.12.5. Görüntü İşleme.....	26
4. MATERYAL VE METOD.....	28
4.1. Materyal.....	28

4.2. Metot	29
4.3. Performans Değerlendirme.....	29
5. BULGULAR VE TARTIŞMA	31
6. SONUÇLAR.....	35
KAYNAKLAR.....	36
ÖZGEÇMİŞ	



ÖZET

Aşırı Öğrenme Makineleri ile Beta Talasemi ve Demir Eksikliği Anemisinin Ayırt Edilmesi

Betül SAYIN

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Şubat 2021, Sayfa: xi + 39

Bilgisayar destekli sistemler yalnızca doktorlara yardımcı olmakla kalmaz, aynı zamanda hata oranlarını da en aza indirir. Bu sistemlerin amacı düşünebilmektir ve karar verebilmektir. Bu amaçla makine öğrenimi ve yapay sinir ağları gibi yöntemler kullanılmıştır. Bu çalışmalar donanım kısıtlamaları nedeniyle bir durgunluk dönemine girdikten sonra, donanımın geliştirilmesiyle derin ağ araştırmaları başladı.

Derin sinir ağları, her bir katman için geri yayılım algoritması uygulayarak büyük boyutlu verilerden gizli olan verileri ayırt ederek çıkartmaktadır. Ayrıca derin öğrenme yöntemlerinde özellik çıkarma ihtiyacı ortadan kalkmıştır. Fonksiyon, sisteme girilen veri setinden otomatik olarak silinir. Diğer bir avantajı da genelleştirilebilmesidir. Bir problem için oluşturulan yöntem başka bir probleme de uygulanabilir. Derin öğrenme yöntemleri, bu avantajları sağlamak için büyük miktarda eğitim verisi gerektirir. Doğal dil işleme, konuşma işleme ve görüntü işleme için gerekli gereksinimler karşılandığında ve derin öğrenme yöntemleri uygulandığında başarılı sonuçlar ve doğru kararlar alınırken, yapay zeka ve makine öğrenimi yöntemlerinin geride kaldığı görülmüştür.

Demir eksikliği anemisi (IDA) vücuda giren demirin hemoglobin üretmek için yetersiz olduğu bir olmasıdır. Bu hastalık ülkemizde ve dünya da en sık görülen anemi türüdür. Demir eksikliği anemisi (IDA) genetik bir hastalık olmasa da talasemi, kırmızı kan hücrelerinin ömrünü kısaltan kalıtsal bir özelliktir. Talasemi, hemoglobin oluşumunu düzenleyen genlerdeki anormalliklerin sonucudur. Talasemi taraması, talasemili çocuğu olabilecek çiftleri bulmayı amaçlayan bir girişimdir. Bu amaca ulaşmak için aynı tip talasemili deneklerin belirlenmesi gerekir. Hastalığın teşhisi için uygun tıbbi tedavinin sağlanması çok önemlidir. Demir eksikliği (IDA) anemisi ve β -talasemi özellikleri gibi genetik hastalıklar, doğru ve zamanında tanı gerektirir.

Tez çalışmasında demir eksikliği anemisi(IDA) ve β -talasemi ayırt etmek amacı ile aşırı öğrenme makineleri(ELM) ve düzenli aşırı öğrenme makineleri(RELM) yöntemleriyle araştırılmıştır. Demir eksikliği anemisini, β -talasemi özelliğinden ayırt etmek için yapılan bu çalışma ile literatürde sinyal işleme yöntemleri ve makine öğrenmesi yöntemleri yazılımsal yöntemlerle sonuçlandırılmıştır. Önerilen yöntemle yapılan bu proje sonucunda yöntemimizin daha hızlı ve daha az maliyetle yüksek performans sağladığı görülmektedir.

Anahtar Kelimeler: Beta Talasemi, Demir Eksikliği Anemisi, ELM, Makine Öğrenmesi, RELM

ABSTRACT

Discrimination of β -Thalassemia and Iron Deficiency Anemia through Extreme Learning Machine and Regularized Extreme Learning Machine Based Decision Support System

Betül SAYIN

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

February 2021, Pages: xi + 39

Computer-aided systems not only assist doctors, but also minimize error rates. The purpose of these systems is to be able to think and make decisions. For this purpose, methods such as machine learning and artificial neural networks have been used. After these studies entered a period of recession due to hardware constraints, deep network research began with the development of the hardware.

Deep neural networks distinguish and extract hidden data from large data by applying a back propagation algorithm for each layer. In addition, the need to extract features in deep learning methods has disappeared. The function is automatically deleted from the data set entered into the system. Another advantage is that it can be generalized. The method created for one problem can be applied to another problem. Deep learning methods require large amounts of training data to provide these benefits. When the necessary requirements for natural language processing, speech processing and image processing are met and when deep learning methods are applied, successful results and correct decisions are taken, while artificial intelligence and machine learning methods are behind.

Iron deficiency anemia (IDA) is one in which iron entering the body is insufficient to produce hemoglobin. This disease is the most common type of anemia in our country and in the world. Although iron deficiency anemia (IDA) is not a genetic disease, thalassemia is an inherited feature that shortens the lifespan of red blood cells. Thalassemia is the result of abnormalities in the genes that regulate hemoglobin formation. Thalassemia screening is an attempt to find couples who may have children with thalassemia. To achieve this goal, subjects with the same type of thalassemia must be identified. It is very important to provide appropriate medical treatment for the diagnosis of the disease. Genetic diseases such as iron deficiency (IDA) anemia and-thalassemia traits require accurate and timely diagnosis.

In this thesis study, in order to distinguish iron deficiency anemia (IDA) and β -thalassemia, excessive learning machines (ELM) and regular extreme learning machines (RELM) were investigated. With this study conducted to distinguish iron deficiency anemia from its-thalassemia feature, signal processing methods and machine learning methods in the literature have been concluded with software methods. As a result of this project made with the proposed method, it is seen that our method provides high performance faster and with less cost.

Keywords: Beta Thalassemia, ELM, Iron Deficiency Anemia, Machine Learning, RELM

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Denetimli öğrenme yaşam döngüsü	7
Şekil 2.2 Destek vektör makinesi çalışma prensibi	10
Şekil 2.3. YSA mimarisi.....	12
Şekil 2.4. Derin öğrenmenin tarihçesi	13
Şekil 2.5. LeNet ağının mimarisi.....	13
Şekil 2.6. 16x16 boyutundaki bir görüntüye 5x5 boyutundaki filtre uygulanması.....	14
Şekil 2.7. Konvolüsyon işleminin uygulanması	14
Şekil 2.8. 4x4 ebatındaki görüntüye 2x2 ebatındaki maksimum ve ortalama havuzlama katmanının uygulanması	15
Şekil 2.9 Görüntü matrisi, çekirdeği veya filtre matrisini çoğaltması	16
Şekil 2.10 Görüntü matrisinin çekirdeği veya filtre matrisini çoğaltması	17
Şekil 2.11 3*3 çıkış matrisi	17
Şekil 3.1. Aşırı öğrenme makinesi modeli	19
Şekil 4.1. Kullanılan yöntemin akış diyagramı	29

TABLÖLER LİSTESİ

	Sayfa
Tablo 3.1. ELM algoritması uygulama alanları	20
Tablo 4.1. Kandaki eritrosit indeks değerlerinin erkek ve kadın için referans değerleri.....	28
Tablo 5.1. Erkek / Kadın için sınıflandırma algoritmalarına göre elde edilen performans parametreleri	31
Tablo 5.2. Erkek için sınıflandırma algoritmalarına göre elde edilen performans parametreleri.....	32
Tablo 5.3. Kadınlar için sınıflandırma algoritmalarına göre elde edilen performans parametreleri	32
Tablo 5.4. Literatürün karşılaştırılması	33

SİMGELER VE KISALTMALAR

Kısaltmalar

β -TT	: Beta Talasemi
ELM	: Extreme Learning Machine
IDA	: Demir Eksikliği Anemisi
kNN	: K-Nearest Neighbors
RELM	: Recurrent Extreme Learning Machine
SVM	: Support Vector Machine
YSA	: Yapay Sinir Ağları
WHO	: Dünya Sağlık Örgütü

1. GİRİŞ

Demir eksikliği (IDA) anemisi ve β -talasemi özelliği gibi genetik hastalıkların doğru ve zamanında teşhis edilmesi gerekir. Demir eksikliği (IDA) anemisi ve β -talasemi özelliği (β -TT) arasındaki ayırım, zaman alıcı ve maliyetli bir sorundur. Bu maliyet gün geçtikçe de artmaktadır. Artan bu maliyetler ve ölümler nedeniyle WHO (Dünya Sağlık Örgütü) hastalıklara yakalanmadan önce hastalıktan korunma yöntemlerine dikkat çekmeye çalışmıştır. Bilinçlenmeye rağmen, genetik, çevresel ve diğer faktörler nedeniyle ortaya çıkan hastalık riskine karşı belirli dönemlerde doktor kontrolünden geçmek kaçınılmazdır. Bu kontroller sonucunda elde edilen bulgular hastalıklara yakalanma riskini ortaya koymakta; riskin büyüklüğü ve ortaya çıkma süresinin kısaltılması da erken tanı ile olmaktadır.

Yapılan çalışmalara göre makine öğrenmesi, hastalıkların erken tanısında en çok kullanılan yöntemlerdendir. İnsan yaşamını birçok alanda kolaylaştıran bilgisayarların, günümüzde insan gibi düşünmesini sağlamak için yapılan çalışmalar, makine öğrenimini ortaya çıkarmıştır. İnsan zekâsını taklit etmeye yönelik olan bu öğrenme şekli, yapay zekâ olarak adlandırılmaktadır. Teknolojik anlamda ortaya çıkan bu gelişme, hastalıkların tedavisinde önemli bir rol oynamaktadır. Ancak insanlar ve makineler evrim geçirirken, hastalıklara neden olan aktörler de evrimleşmektedir ve hastalıkları önlemede ya da tedavisinde kullanılan ilaçlara karşı bağışıklık kazanmaktadırlar.

Sağlık alanında uygulanan Beta talasemi(B-Talasemi) ve Demir eksikliği anemisi(IDA) ayırt etme yöntemlerinin incelendiği bu çalışmada, derin öğrenmenin tanımı yapılmış ve derin öğrenme yöntemleri açıklanarak, bu yöntemlerin hastalık teşhis etme uygulamalarından bahsedilmiştir. Daha sonra hastalık teşhis alanında kullanılan derin öğrenme yöntemleri tanıtılarak, bu yöntemlerin kendi verilerimiz üzerinde farklı yöntemler çalışılarak yapılan uygulamalara değinilmiştir. Sonuç bölümünde ise bu yöntemlerden elde edilen performans değerlendirilmesi yapılarak elde edilen başarı gösterilmektedir.

1.1. Beta Talasemi ve Demir Eksikliği Anemisi

Demir eksikliği anemisi (IDA), hemoglobin üretmek için vücuda giren yetersiz demir olarak tanımlanabilir. Hastalık, ülkemizde ve dünyada en sık görülen anemi türüdür. Demir eksikliği anemisi (IDA) genetik bir hastalık olmamasına rağmen talasemi, kırmızı kan hücrelerinin ömrünü kısaltabilen kalıtsal bir özelliktir [1].

Talasemi, hemoglobin oluşumunu düzenleyen genlerdeki anormalliklerin sonucudur. Talasemi taraması, talasemili çocuğu olabilecek çiftleri bulmayı amaçlayan bir girişimdir. Bu amaca ulaşmak için aynı tip talasemili deneklerin belirlenmesi gerekir. Birkaç çeşit talasemi vardır.

Çocuğun ebeveynleri de aynı talasemiye sahipse, hastalığın özelliği veya normalliği sırasıyla %25, % 50 ve % 25'tir [2,3,4].

Demir eksikliği (IDA) anemisini talasemiden (B-TT) ayırmak zaman alıcı ve pahalı bir sorundur [5]. CBC, hızlı ve ucuz bir tıbbi testtir ve talasemi taraması için ana testtir. CBC indeksinin IDA ve β -TT'deki benzerliği ayırt etmeyi zorlaştırmaktadır [6-7]. Bu nedenle, CBC indeksi ile ifade edilemeyen denekler için, zaman alıcı ve pahalı ek testler gerekli olacaktır. Ek olarak, tüm laboratuvarlar ve hastaneler bu testleri sağlamaz [8].

Bu tez çalışmasında her merkezde yapılabilen ve kolaylıkla ulaşılabilen hemoglobin (HB), hematokrit (HCT), eritrosit sayısı (RBC), ortalama eritrosit hacmi (MCV), ortalama eritrosit hemoglobini (MCH), eritrosit dağılım genişliği (RDW), ortalama eritrosit hemoglobin konsantrasyonu (MCHC) ve cinsiyet değerlerinin kullanılarak demir eksikliği anemisi ile β -talasemi ayırımı yapılmıştır. Bu amaçla, literatürde demir eksikliği anemisi ile β -talasemi ayırımı üzerinde daha önce uygulanmayan Extreme Learning Machine (ELM) algoritması kullanılmıştır. ELM' de giriş katmanı ağırlıkları ve eşik değerleri rastgele atanmakta, çıkış katmanı ağırlıkları ise analitik olarak hesaplanmakta olduğundan geri beslemeli ile öğrenen YSA' dan ve destek vektör makineleri (SVM) gibi birçok yöntemden daha hızlı eğitilebilmekte ve daha az maliyetle yüksek performans göstermektedir.

Bu çalışmada ELM' nin bu avantajları kullanılarak hızlı, başarılı ve kolay kullanılabilir bir şekilde demir eksikliği (IDA) anemisi ve β -talasemi özelliği (β -TT) arasındaki ayırım yapılmıştır. Bu tez çalışmasında alternatif olarak düzenli aşırı öğrenme makinesi (RELM) olarak adlandırılan yinelemeli olmayan aşırı öğrenme makinesi kullanılmıştır. RELM gizli önyargıların rastgele üretilmesi ve girdi ağırlıklarının oluşması nedeniyle birçok sınırlama getirmektedir.

1.2. Literatürde Yapılan Çalışmalar

Demir eksikliği anemisi ve beta talaseminin ayırt edilmesinde kırmızı kan hücresi parametrelerinin etkisinin makine öğrenimi ile belirlenmesi için yapılan çalışmada RBC indeksleri ve Support Vector Machine (SVM) ve K-Nearest Neighbor (KNN) dahil olmak üzere makine öğrenme teknikleri kullanılarak IDA ve β -talasemi ayırıcı tanısı yapılmıştır. RBC indeksleri sınıflandırıcı için girdi parametreleri olarak kullanılmış ve SVM ve KNN performansları ayrı ayrı değerlendirilmiştir. Makine öğrenimi algoritmalarına girdi olarak daha az parametre verilmiş ve daha yüksek performans elde edilmiştir. Öte yandan, veri kümelerinden özellik seçimi için bir özellik seçme tekniği olan Mahalle Bileşen Analizi Özellik Seçimi (NCA) algoritması kullanılmış ve NCA aracılığıyla seçilen parametreler yüksek performans sağlamıştır. Birlikte ele alındığında sonuçlar, çalışmada kullanılan RBC indekslerinin literatürde bildirilenlere göre daha yüksek

performans gösterdiğini göstermiştir. Bu indeksler kullanılarak, yalnızca her bir indeks parametresinin makine öğrenme modeli üzerindeki bireysel etkisi araştırılmış, aynı zamanda literatürde kullanılanlardan farklı bir özellik alt kümesi oluşturulmuştur. Ayrıca bu çalışmada, erkek ve kadın hastalarda IDA ve β -talasemiye ayırt etmede farklı CBC parametrelerinin etkili olduğunu ortaya koyulmuştur [9].

Demir Eksikliği Anemisi (IDA) ve β -Talasemi Özelliği (β -TT) arasındaki ayırım için Model Tabanlı Girdi Seçimi Yapay Sinir Ağı (PBIS-YSA) ile yapılan çalışmada CBC endeksleri sınıflandırıcının girdileri olarak kabul edilmiş ve seçilen mimari model tabanlı girdi seçimi yapay sinir ağı (PBIS-YSA) olmuştur. Önerilen yöntemi değerlendirmek için, geleneksel yöntemler, Mentzer Index (MI) gibi problemler için halen kullanılmakta olan ve yapay sinir ağları (YSA), uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) ve çok katmanlı algılayıcı (MLP) gibi çeşitli otomatik anemi teşhis sistemleri karşılaştırılmıştır. Önerilen yöntemin belirtilen yöntemlerden önemli ölçüde daha iyi performans gösterdiğini ispatlanmaya çalışılmıştır [10].

IDA ve β -talasemi özelliği (β -TT) arasındaki ayırım için yapılan bir diğer çalışmada ise dinamik uyum araştırmasına (DHS) dayalı yeni bir yöntem önerilmiştir. Bu çalışmada yöntem dinamik uyum aramasına (DHS) dayanmaktadır. Hızlı ve ucuz bir laboratuvar testi olan tam kan sayımı (CBC), sistemin girişi olarak kullanılmıştır. Sistem girişi olarak kullanılacak en uygun CBC indekslerinin seçilmesi, model tabanlı bir indeks seçimi (PBIS) algoritması ile gerçekleştirilmiştir. Önerilen yöntem 132 CBC numunesi üzerinde eğitilmiştir. Doğrusal olmayan fonksiyon uydurmada (STROGANOFF) genetik algoritmada yapısal temsil olarak adlandırılan bir genetik programlama yöntemi, yapay bir sinir ağı (ANN), uyarlanabilir bir nöro-bulanık çıkarım sistemi (ANFIS), bir destek vektör makinesi (SVM) gibi diğer modeller), k-en yakın komşu (KNN) ve belirli geleneksel yöntemler önerilen yöntemle karşılaştırılmıştır. Önerilen yöntemin yaklaşık % 98 doğrulukla literatürdeki diğer yöntemlerden daha iyi performans gösterdiğini göstermektedir [11].

Demir eksikliği anemisini beta talaseminin özelliklerinden daha iyi ayırt etmek ve teşhis etmek için yapılan çalışma ise duyarlılık, özgüllük ve Youden indeksi hesaplanarak β -TT'yi IDA'dan ayırmada çeşitli ayrımcılık indekslerinin geçerliliğini karşılaştırmak için yapılmıştır. Çalışmada, küçük hücreli anemili toplam 323 kişi (173 çocuk ve 150 yetişkin) verisi kullanılmıştır. IDA ve β -TT hastalarında on benzersiz gösterge değerlendirilmiştir. Hastalar 10 yaş altı ve 10 yaş üstü olmak üzere iki farklı gruba ayrılarak incelenmiştir [12].

β -TT ve IDA arasındaki ayırım için IDA'lı 26 hasta ve 37 talasemi hastası ile sekiz ayırım indeksi kan hücre sayısı(RBC), kırmızı kan hücresi dağılım genişliği ve kırmızı kan hücresi kan dağılımı genişliği indeksi(RDWI) değerleri hesaplanmıştır. Her bir ayırım için indeksi kullanılarak doğru tanımlanmış hasta sayısı belirlenmiştir. Ayrıca duyarlılık, özgüllük, pozitif ve negatif tahmin değeri ve Youden'ın her ayrımcılık indeksi hesaplanmıştır. Çalışma sonucunda ayırıcı göstergelerin hiçbiri %100 duyarlılık ve özgüllük göstermemiştir. Youden, sırasıyla %82 ve %80 ile en yüksek

RBC sayımı ve RDWI endeksine sahip çıkmıştır. RBC ve RDWI, sırasıyla hastaların %90 ve %92 sini doğru bir şekilde tanımlamıştır. Kırmızı kan hücre sayısı ve RDWI'nın, β -TT ve IDA'yı ayırt etmek için en güvenilir göstergeler olduğu gösterilmiştir [8].

Çocuklarda beta talasemi özelliği ile demir eksikliği ayırt etmek için kırmızı kan hücresi indekslerinin ve formüllerinin güvenilirliği için yapılan çalışmada 1 ile 7 yaşları arasında (ortalama $5,6 \pm 1,7$ yaş) 458 çocuktan oluşan bir kohortta bazı kırmızı kan hücresi (RBC) indekslerinin ve β -TT ile IDA arasındaki ayırma için kullanılan formüllerin güvenilirliğini değerlendirilmiştir. Bu grupta 243 kişi IDA ve 215 kişi ise β -TT ile doğrulanmıştır. Çalışmada kullanılan her bir indeks veya formül için Gauss eğrileri oluşturulmuştur. En yüksek duyarlılık RDWI (% 78,9) ile elde edilirken, en yüksek özgüllük ve Youden İndeksi (sırasıyla % 99,1 ve 64,2), en yüksek verimlilik (% 80,2) Green ve King indeksi ile elde edilmiştir. Sonuç olarak, RBC indekslerinin veya formüllerinin hiçbirisi, β -TT ve IDA denekleri arasında ayırım yapmak için güvenilir görünmediği belirtilmiştir [13].

Beta talasemi minör ve demir eksikliği anemisinin kırmızı kan hücresi indeksleri için tarama testi ile ayırımı için yapılan çalışmada, çalışma popülasyonundaki kırmızı kan hücresi (RBC) endeksleri bir elektronik hücre sayacı (Sysmex K800) ile ölçülmüştür. Çalışmada 444 Beta talasemi ve 457 IDA teşhisi almış kişilere ait veriler kullanılmıştır. Anket, 2 RBC indeksinin, ortalama korpusküler hacmin (MCV) ve ortalama korpusküler hemoglobin (MCH) ölçümünü içermiştir ve sonuçlar İngiltere ve Fraser, Shine ve Lal ile karşılaştırılmıştır. Bulgular sonucunda % 87,2 duyarlılık düzeyiyle İngiltere ve Fraser indeksinin talasemik ve talasemik olmayan hastalar için kabul edilebilir bir ayırıcı olduğunu ortaya koyulmuştur [14].

Geleneksel yöntemlere kıyasla IDA ve β -TT'nin doğru ve zamanında ayırıcı tanısı için sinir ağı tabanlı bir model (Yapay Sinir Ağı) geliştirmek amacı ile yapılan çalışmada IDA ve β -TT ayırıcı tanısı için ilk hassas akıllı yöntem olarak yapay sinir ağı (YSA) modeli geliştirilmiştir. Veri seti, 2018 yılında İran Ahvaz'daki Padad özel klinik laboratuvarına sevk edilen 268 kişinin Tam Kan Sayımı (CBC) test faktörlerinden elde edilmiştir. Farklı topolojilere sahip YSA modelleri geliştirilmiş ve CBC indeksleri IDA ve β -TT tanısı için incelenmiştir. Geliştirilen modelin sonuçları ve değerlendirmesi, önerilen sinir ağı modelinin mevcut yöntemlerle karşılaştırıldığında CBC testinin başlangıç faktörlerine dayalı olarak uygun bir doğruluk ve genelleştirilebilirliğe sahip olduğunu göstermiştir [15].

Beta talasemi minör ve demir eksikliği anemisinin ayırıcı tanısında yapay sinir ağlarının uygulanmasını araştırmak için yapılan çalışmada evlilik öncesi testler için ziyaret eden 395 kişinin CBC sonuçları kullanılmıştır. Sinir ağının geliştirilmesi için MATLAB kullanılmıştır. Sinir ağında hata yayılmasından sonra farklı eğitim algoritmaları karşılaştırılmıştır. Önerilen sistem, 4 giriş, 100 nöron ve 1 gizli katman içeren çok katmanlı bir algılayıcı algoritmasına dayanmaktadır.

Yapılan farklı eğitim yöntemleri arasında, Levenberg-Marquardt geri yayılım algoritması, ağ eğitiminde daha hızlı yakınsama nedeniyle iyi sonuçlar verdiği gösterilmiştir [16].



2. MAKİNA ÖĞRENMESİ

Makine öğrenimi, yapay zekanın bir alt kategorisidir. Makine öğreniminin temel amacı, insan davranışlarını makinelere öğretmek bu insan süreçlerini daha az maliyetle ve daha çok zamanla tanımak, algılamak ve öğrenmektir. Makine öğreniminin kilit noktalarından biri, insan etkileşimini en aza indirerek daha yüksek performans elde etmektir. Bu kararı verirken veri örüntülerini ve yapılarını analiz edip yorumlayabilen bilgisayar bilimi alanıdır. Makine öğrenimi, verileri analiz etmek ve bu analizlerden sonuç çıkarmak için bir algoritma gerektirir. Günümüzde birçok algoritma geliştirilmiştir. Bazıları SVM, KNN' dir. Herhangi bir makine öğrenimi algoritmasını kullanmadan önce, en uygun eğitim veri modelini bulmak gerekir.


2.1. Makine Öğrenmesi Yöntemleri

Son yıllarda, makine öğrenimi ile ilgili araştırmalar patlama yaptı. Bu patlamanın birçok nedeni var: Birincisi, ayrık sembolik makine öğrenimi, hesaplamalı öğrenme teorisi, sinir ağları, istatistik ve örüntü tanımada, araştırma toplulukları birbirlerini keşfettiler ve işbirliği yapmaya başladılar. İkinci olarak, makine öğrenimi teknikleri, veri tabanlarında bilgi keşfi, dil işleme, robot kontrolü ve konuşma tanıma, yüz tanıma, el yazısı tanıma, veri analizi ve oyunlar ve tıbbi tedavi gibi daha geleneksel problemler dahil olmak üzere yeni problem türlerine uygulanır [17].

Makine öğreniminde kullanılan veriler çok önemli bir rol oynar ve verilerin bilgi ve özelliklerini keşfetmek için öğrenme algoritmaları kullanılır [18]. Etiketli veriler ve etiketlenmemiş veriler olmak üzere iki farklı veri türünden oluşur. Etiketli veri seti algoritmayı eğitmek için kullanılırken, etiketlenmemiş veriler eğitilmiş algoritmayı (model veya sistem) test etmek için kullanılır. Bu nedenle, bu veri türlerine eğitim ve test setleri de denir. Makine öğrenimi kullanılarak oluşturulan sistemler genellikle iki farklı öğrenme modeli kullanır. Bu iki modele denetimli ve denetimsiz öğrenme modelleri denir.

2.1.1. Denetimli Öğrenme

Denetimli öğrenme, etiketli verileri kullanarak sistemi eğiterek öğrenmeyi sağlar. Sistemi eğitirken, veri setindeki her bir numunenin girdi ve çıktıları verilir. Test veri seti, sistemi doğrulamak için kullanılır. Sistem doğrulama sırasında, öğrenme algoritması kategorisi, eğitim verilerindeki herhangi bir çıktıyı bilinmeyen test verilerine atar. Denetimli öğrenme makine öğrenme sisteminin algoritması Şekil 2.1' de gösterilmektedir [19].



Şekil 2.1. Denetimli öğrenme yaşam döngüsü

Denetimli öğrenme modelinde, bu problem bir sınıflandırma problemi olarak kabul edilir ve sistemi test setini tahmin etmek ve tanımak üzere eğitmek için kullanılır [18]. Destek vektör makineleri, yapay sinir ağları, lojistik regresyon, Bayesian, k en yakın komşu algoritması ve karar ağacı algoritması, denetimli öğrenme modelleri oluştururken yaygın olarak kullanılan yöntemlerdir.

Bu tür öğrenme, el yazısı harflerin ve sayıların sınıflandırılması, borsa değerinin tahmini, hava durumu tahminleri ve haber ajanslarında haberlerin sınıflandırılması gibi örnekleri içermektedir.

Sınıflandırma

Makine öğreniminde sınıflandırma, temelde veri setlerini sınıflara ayıran denetimli bir öğrenme kavramıdır. En yaygın sınıflandırma sorunlarına konuşma tanıma, yüz tanıma, el yazısı tanıma, belge sınıflandırması vb. olarak örnek verilebilir. Sınıflandırma bir ikili sınıflandırma problemi veya çoklu sınıflandırma problemi olabilir. Makine öğreniminde sınıflandırma için birçok makine öğrenimi algoritması vardır.

Regression

Regresyon, sürekli miktar çıktısını tahmin etmek için kullanılan bir sorundur. Sürekli bir çıktı değişkeni, bir tam sayı veya kayan nokta değeri gibi gerçek bir değerdir.

2.1.2. Denetimsiz Öğrenme(Unsupervised Learning)

Denetimsiz öğrenme modelinde sistem eğitildiğinde, sistem etiketlenmemiş veriler kullanılarak öğrenilecektir. Denetimsiz öğrenmenin amacı tanımlamak veya sınıflandırmak değildir, çünkü veri setindeki örneklerin çıktısı bilinmemektedir. Genellikle kümeleme, olasılık yoğunluğu tahmini, özellikler arasındaki ilişkileri bulma ve boyut azaltma için kullanılır. Ek olarak, denetimsiz öğrenme algoritmaları kullanılarak elde edilen sonuçlar denetimli öğrenme için kullanılabilir [18].

Bu öğrenme yönteminde hiçbir denetçi sistemin öğrenmesine yardımcı olamaz. Sistem yalnızca giriş değerini görüntüler. Sistemin örnekteki parametreler arasındaki ilişkiyi kendi başına öğrenmesi beklenir, ancak doğru çıktı hakkında bilgi vermez.

Denetimsiz öğrenmede, her veri niteliğin değerini içerir, ancak etiketi içermez. Bu tür öğrenme, eğitim verilerinde kurallarla işaretlenmemiştir. Küme etiketini ve bazen küme numarasını bulmaya, çıkarmaya çalışır.

Bu, esas olarak sınıflandırma problemleri için kullanılan bir stratejidir. Sistemi öğrendikten sonra çıktının anlamını gösteren etiket kullanıcı tarafından doldurulmalıdır.

Kümeleme

Kümeleme, benzer verilerin tanımlanan kriterlere göre gruplandırılmasını içerir. Verileri gruplara ayırmak ve kalıpları bulmak için her bir veri kümesini analiz etmek faydalıdır. K-Ortalama algoritması bir kümeleme algoritmasına örnek olarak verilebilir. Buradaki "K", kaç kümeye bölüneceğini temsil eder. Örneğin, K'nin değerini 2 olarak varsayarsak, verilerde 2 ortak merkez noktası bulunmaya çalışılır. Ortak bir nokta bulunduğunda, diğer veriler yakındaki noktalara göre toplanır. Algoritma, ortak nokta en etkili şekli alana kadar devam eder.

Boyut Küçültme

Boyutu küçültme, ihtiyaç duyulan kesin bilgiyi bulmak için düşünülen değişkenlerin sayısını azaltır.

2.1.3. Takviyeli Öğrenme(Reinforcement Learning)

Makine öğrenimi problemlerinde, sistemin mevcut durumuna göre eylemleri seçmek için eylem sürecini öğrenmesi gerekir. Pekiştirmeli öğrenme problemleri bu görevlerin bir alt kümesidir

ve sistem hiçbir zaman doğru davranış örneklerini görmemiştir. Bunun yerine, eylemleri için yalnızca olumlu ve olumsuz ödüller alır.

Takviyeli öğrenmede sistem, giriş verilerine dayanarak ödülü en üst düzeye çıkarmaya çalışır, temelde en iyi sonuca ulaşana kadar bir deneme yanılma sürecinden geçer.

Takviyeli öğrenmeyle ilgili sorun, en çok ödülü almak için ne yapılacağını durumları eylemlerle nasıl eşleştireceğimizi öğrenmektir. Bu stratejide, denetçiler sistemi öğrenmeye yardımcı olabilir. Ancak, denetçi her girdi kümesini oluşturmalıdır. Sistem tarafından ayarlanan çıktıyı göstermez, ancak sistemin çıktısını oluşturmak için görüntülenen girdiye yanıt vermesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösterir. Bir sinyal oluşturur. Sistem, denetçiden gelen sinyalleri dikkate alarak öğrenme sürecine devam eder.



2.2. Makine Öğrenmesi Algoritmaları


2.2.1. Yapay sinir ağları (Artificial neural networks-ANN)

Yapay sinir ağları (YSA), insan beyninin öğrenme yolunu taklit ederek beynin öğrenme, hatırlama, genelleme yapma yolu ile topladığı verilerden yeni veri üretebilme gibi temel işlevlerin gerçekleştirildiği bilgisayar yazılımlarıdır. Yapay sinir ağları uygulamaları en çok tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme işlemlerinde kullanılmaktadır.

YSA mimarisi genellikle, katman sayısına ve her katmanın aktivasyon işlevine göre farklı birimler arasındaki bağlantıları ağırlıklandıran çoklu bir algılayıcıdan (Çoklu Algılayıcı-MLP) oluşur.

2.2.2. Destek vektör makinesi (Support vector machine-SVM)

Destek vektör makinesi (SVM), sınıflandırma için hiper düzlemleri kullanan kontrollü bir makine öğrenme yöntemidir. Genellikle farklı kategorilere ait örnekleri sınıflandırmak için kullanılır. Hiper düzlem, iki farklı kategoriyi birbirinden ayırır ve iç bölgede örnek bulunmayan iki paralel çizginin maksimum genişliği sınır olarak tanımlanır. Destek vektörü, hiper düzleme en yakın veri noktasıdır. SVM'yi destekleyen en iyi hiper düzlem, iki tür arasında en büyük mesafeye sahip olan hiper düzlemdir. Şekil 2.2' de SVM çalışma mantığı verilmiştir.



Şekil 2.2 Destek vektör makinesi çalışma prensibi

2.2.3. K- En yakın komşu (k-Nearest neighbor-kNN)

k-en yakın komşu (kNN) parametrik olmayan bir denetimli sınıflandırma algoritması kullanır. Sınıflandırılacak veri örneğini mevcut eğitim örnekleri ile karşılaştırır ve en yakın örnekleri bulur. Algoritmanın bir sonraki adımında, en yakın k eğitim örneklerinin etiketleri arasındaki çoğunluk sınıfı etiketi belirlenir ve sınıflandırılacak olan veri örneğine atanır.

KNN algoritmasının temel parametresi, özellik bölgesinde sınıflandırmada bulunması gereken en yakın eğitim örnek numarası olan k'dir. Hareket verisinin boyutu arttıkça kNN algoritmasının tahmin performansı da artacaktır. KNN algoritmasının temel dezavantajı, yüksek hesaplama maliyetidir. Klinik karar destek sistemlerinde KNN yöntemi, algoritmasının çok basit olması ve performansının stabil olması nedeniyle tercih edilmektedir [20-21].

K-en yakın-komşu sınıflandırıcı, genellikle bir test numunesi ile belirtilen eğitim numuneleri arasındaki Öklid mesafesine dayanır. Denklem 1'de KNN Öklid mesafe hesaplaması gösterilmiştir.

$$d(\mathbf{x}_i, \mathbf{x}_l) = \sqrt{(x_{i1} - x_{l1})^2 + (x_{i2} - x_{l2})^2 + \dots + (x_{ip} - x_{lp})^2}. \quad (1)$$

2.2.4. K-Means

K-Means, iyi bilinen kümeleme problemini çözen en basit denetimsiz öğrenme algoritmalarından biridir. Prosedür, belirli bir veri kümesini önceden sabitlenmiş belirli sayıda küme (k küme varsayalım) aracılığıyla sınıflandırmanın basit ve kolay bir yolunu izler. K-Means'deki K değeri, küme sayısını belirlediği anlamına gelir ve bu değer bir parametre olarak kullanılmalıdır. Bu durum aslında dezavantajdır.

Algoritmanın basit bir çalışma yöntemi vardır. K değerini belirledikten sonra algoritmada rastgele K merkez noktalarını seçecektir. Her bir veri ile rastgele belirlenen bir merkez noktası arasındaki mesafeyi hesaplar ve verileri en yakın merkez noktasına göre kümelere atar. Ardından, her küme için yeniden bir merkez noktası seçer ve kümeleme işlemini yeni merkez noktasına göre gerçekleştirir. Bu durum sistem kararlı hale gelene kadar devam eder.

2.2.5. Doğrusal Regresyon

Regresyon bir bağımlı değişken ile diğer birkaç bağımsız değişken arasındaki ilişkiyi belirler. Regresyon analizi, bağımsız değişkenlerin bazıları değiştiğinde bağımlı değişkenin nasıl değiştiğini anlamaya yardımcı olmaktadır.

2.2.6. Derin Öğrenme


Derin öğrenme, makine öğreniminin bir alt kategorisidir. Derin öğrenme çok katmanlı doğrusal olmayan işlem birimlerini özellik çıkarma ve dönüştürmede kullanır. Sonraki her katman, önceki katmanın çıktısını girdi olarak alır [22].

Algoritmalar denetimli veya denetimsiz olabilir. Derin öğrenmede, çoklu özellik seviyelerini veya veri temsillerini öğrenmeye dayalı bir yapı vardır. Üst düzey öznitelikler, alt düzey özniteliklerden türetilen hiyerarşik bir temsil oluşturur. Bu temsil öğrenme, farklı soyutlama seviyelerinde çoklu temsil seviyelerine karşılık gelir [23].

Derin öğrenme temelde veri temsiliinin öğrenilmesine dayanır. Bir görüntü için bir temsil çağırısı yaparken; her pikselin yoğunluk değerini veya kenar kümesini, özel şekillerin bir vektörünü ve diğer öznitelikleri dikkate alınabilir. Bu işlevlerden bazıları verileri daha iyi temsil edebilir. Bu aşamada, derin öğrenme yöntemi hala bir avantajdır. Özellikleri manuel olarak çıkarmak yerine, verileri en iyi temsil eden hiyerarşik özellikleri çıkarmak için verimli algoritmalar kullanır [24].


Konvolüsyonel Sinir Ağları (Convolutional neural network-CNN)

Bir sinir ağı, birbirleriyle iletişim kuran nöronlardan oluşur. Her nöronun ağırlıkları vardır ve model bu ağırlıkları güncelleyecek ve ağı doğru sonuçlar verecek şekilde eğitecektir. Şekil 2.2'de gösterildiği gibi, her katman, özellikleri oluşturmak için önceki katmandan gelen bilgileri işler. Tipik bir CNN'de, bu model tanıma katmanları 5 ile 25 arasında olabilir [25]. Şekil 2.3'te YSA mimarisi verilmiştir.




Şekil 2.3. YSA mimarisi

Şekil 2.2'de verilen ilk CNN ağı, 1988'de Yann LeCun tarafından önerilen ve 1998'e kadar geliştirilmiş olan LeNet mimarisidir [26]. Şekil 2.4'te derin öğrenmenin tarihçesi verilmiştir.



Şekil 2.4. Derin öğrenmenin tarihçesi

Tipik bir evrişimli sinir ağı Şekil 2.2'de gösterilmektedir. Bu çalışmada, VGGNET ilk olarak görüntüyü evrişim ve genel sürece dahil etmek için kullanılmıştır. Tam bağlantı yapısında üç yapay sinir ağı katmanı kullanılır. Eğitim aşamasında modeli ezberlememek için "bırakma" yöntemi uygulanmış ve sinir ağındaki bazı düğümler unutulmuştur. Şekil 2.5'te LeNet ağına mimarisi verilmiştir.



Şekil 2.5. LeNet ağına mimarisi


CNN algoritmaları görüntü, ses işleme, doğal dil işleme (NLP) ve biyomedikal gibi birçok farklı alanda kullanılmaktadır.

CNN, çok katmanlı bir yapıya sahiptir ve her yapı bir veya daha fazla düzlem içerir. Bu katmanlara; konvolüsyon, havuzlama ve tam bağlantılı katmanlar denir[27].

Konvolüsyon Katmanı


Konvolüsyon katmanında, her girdi için belirli öznitelikleri çıkaran bir dizi filtre uygulanır [28].

Konvolüsyon katman, görüntü üzerindeki ana katmandır. 2x2, 3x3, 5x5 vb. gibi farklı boyutlarda filtreler uygulama işlemidir. Filtre tüm görüntü üzerinde kaydırma yapılarak gezdirilir. Şekil 2.6'de 16x16 boyutundaki bir görüntüye 5x5 boyutundaki filtrenin uygulanması gösterilmektedir.



Şekil 2.6. 16x16 boyutundaki bir görüntüye 5x5 boyutundaki filtre uygulanması

Konvolüsyon işleminde, filtre çerçevesi içinde kalan piksel değerleri filtre değeri ile çarpılır ve elde edilen değerler, çıktı görüntüsünün piksel değeri olarak eklenir ve kaydedilir. Şekil 2.7, Konvolüsyon işleminin uygulamasını göstermektedir.



Şekil 2.7. Konvolüsyon işleminin uygulanması


Giriş görüntüsüne çoklu konvolüsyon işlemleri uygulanarak ağıın derinliği artırılabilir ve daha doğru sonuçlar elde etmek için bir ızgara sağlanabilir. Her konvolüsyon katmanda filtre, önceki konvolüsyon katmanda elde edilen görüntüye uygulanır. Bu nedenle, giriş görüntüsünün en-

boy oranını azaltmanın yanı sıra derinliği de artırılır ve sonuç olarak görüntünün özellik haritası görüntülenir.

Havuzlama Katmanı

Havuzlama, doğrusal olmayan alt örnekleme gerçekleştirirken ağırlık öğrenmesi gereken parametre sayısını azaltarak çıktıyı kolaylaştırır. Bu nedenle, yalnızca etkinleştirilen özellikler bir sonraki katmana aktarılır. Bu çok katmanlı yapıların özelliklerini öğrendikten sonra sınıflandırmaya geçer [28].

Havuzlama katmanında, önceki konvolüsyon katmanda olduğu gibi, gelen görüntü üzerine farklı boyutlarda filtreler geçirilir. Bu katmandaki filtreler ile konvolüsyon katmanda uygulanan filtreler arasındaki fark, en büyük veya ortalama alana sahip filtreler olmalarıdır [29,30]. Şekil 2.8’de havuzlama katmanındaki filtrelerin uygulanmasını gösterilmiştir.



Şekil 2.8. 4x4 ebatındaki görüntüye 2x2 ebatındaki maksimum ve ortalama havuzlama katmanının uygulanması

Maksimum havuzlamada, ortalama havuzlama işlemi sırasında (filtre penceresindeki kalan piksel değerlerinin en yükseğidir), filtre penceresindeki tüm piksel değerlerinin ortalama değeri, çıkış pikseline tek bir değer olarak kaydedilir. Havuzlama işleminin sonunda görüntünün en boy oranı azalacaktır. Süreçte piksel değerleri kaybolacaktır ancak bu kayıplar bir sonraki katman için daha az hesaplama yükü oluşturacaktır ve sistemin hatırlamasını engellediği için dönüş değeri daha yüksektir.

Tam Bağlı Katman


Son katman, tam bağlı c boyutlu katmandır. Her kategorinin olasılığı bu vektörde saklanır. CNN'in bir başka işlevi de ağırlıkları paylaşmaktır. Bu, görüntünün farklı noktalarında bulunan

piksel setlerinin özellik haritasında aynı ağırlık vektörüne sahip olacağı anlamına gelir. Her özellik haritası, yerel alt örnekleyici katmanı tarafından yürütülür [28].

CNN ağının çalışma prensibini örnek olarak ele alalım. Bilgisayarlar girdi görüntüsünü piksel dizisi olarak görür ve görüntü çözünürlüğüne bağlıdır. Görüntü çözünürlüğüne bağlı olarak, $h*w*d$ (h = Yükseklik, w = Genişlik, d = Boyut) görecektir. Örneğin, $6 \times 6 \times 3$ RGB matris dizisi görüntüsü (3, RGB değerlerine atıfta bulunur) ve $4 \times 4 \times 1$ gri tonlamalı görüntü matris dizisinin bir görüntüsünü inceleyelim.

Teknik olarak, derin öğrenme CNN modellerini eğitmek ve test etmek için her giriş görüntüsünü filtreler. Havuzlama ve tam bağlı katmanlar (FC) içeren bir dizi evrişim katmanından geçirir ve olasılık değerleri 0 arasında olan bir nesneyi sınıflandırmak için Şekil 2.5'te gösterildiği üzere Softmax işlevini uygular ve nesneleri değerlere göre sınıflandırır.

Evrişim katmanı ise giriş görüntüsünden özellikleri çıkaran ilk katmandır. Evrişim, küçük kareler girdi verisi kullanarak görüntü özelliklerini öğrenerek pikseller arasındaki ilişkiyi korur. Görüntü matrisi ve filtre veya çekirdek gibi iki girdi alan matematiksel bir işlemdir. Şekil 2.9'da gösterildiği üzere $h*w*d$ boyutlarında bir resim matrisi, $f_h * f_w * d$ boyutunda bir filtre bulunmaktadır.



Şekil 2.9 Görüntü matrisi, çekirdeği veya filtre matrisini çoğaltması

Şekil 2.10'da gösterildiği üzere görüntü piksel değerleri 0, 1 ve filtre matrisi 3×3 olan bir 5×5 matris ele alalım.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

*

1	0	1
0	1	0
1	0	1

Şekil 2.10 Görüntü matrisinin çekirdeği veya filtre matrisini çoğaltması

Daha sonra 5 x 5 görüntü matrisinin evrişimi, Şekil 2.11’de gösterildiği gibi "Özellik Haritası" olarak adlandırılan 3 x 3 filtre matrisiyle çarpılır.

1	1	1	0	0
0	1	1	1	0
0	0	1_{x1}	1_{x0}	1_{x1}
0	0	1_{x0}	1_{x1}	0_{x0}
0	1	1_{x1}	0_{x0}	0_{x1}

4	3	4
2	4	3
2	3	4

Convolved Feature

Image

Şekil 2.11 3*3 çıkış matrisi

Bir görüntünün farklı filtrelerle evrişimi, filtreler uygulayarak kenar algılama, bulanıklaştırma ve keskinleştirme gibi işlemleri gerçekleştirebilir.

3. AŞIRI ÖĞRENME MAKİNELERİ

Son yıllarda, ileri beslemeli sinir ağları, bariz avantajları nedeniyle birçok alanda yaygın olarak kullanılmaktadır. Bir yandan, karmaşık doğrusal olmayan haritalamayı doğrudan girdi örneklerinden işleyebilir. Öte yandan, çok sayıda doğal ve insan yapımı fenomen için modeller sağlayabilir ve klasik parametreleme tekniklerinin bu problemleri çözmesi zordur. Bununla birlikte, ileri besleme ağının tüm parametrelerinin ayarlanması gerektiğinden, farklı parametre katmanları arasında bağımlılıklar vardır ve bu da ileri beslemeli sinir ağını çok zaman alıcı hale getirir. En popüler olanı, tek gizli katmanlı ileri besleme ağıdır (SLFN). İleri beslemeli sinir ağları, hem teorik hem de pratik açıdan öğrenme yetenekleri ve hata toleransları konusunda kapsamlı bir şekilde araştırılmıştır. Bununla birlikte, SLFN' yi eğitmek için kullanılan en popüler öğrenme algoritmaları hala nispeten yavaştır, çünkü SFLN' nin tüm parametrelerinin yinelemeli bir süreç kullanılarak ayarlanması gerekir ve bu algoritmalar kolayca yerel minimumlara düşebilir.


Son zamanlarda, SLFN için Extreme Learning Machine (ELM) adı verilen yeni bir hızlı öğrenen nöral algoritma geliştirildi. Kontrol parametrelerini (öğrenme oranı, öğrenme dönemleri, vb.) Ve / veya yerel minimi manuel olarak ayarlama zorlukları karşılaşılabilecek sinir ağları (BP algoritmaları gibi) için geleneksel öğrenme algoritmalarından farklı olarak, ELM tekrarlamalı ayarlama olmadan tamamen otomatik olarak uygulanır ve teorik olarak kullanıcılardan herhangi bir müdahale gerekmemektedir.

Dahası, diğer geleneksel yöntemlerle karşılaştırıldığında ELM' nin öğrenme hızı çok hızlıdır. ELM algoritmasında, gizli düğümlerin öğrenme parametreleri (girdi ağırlıkları ve önyargılar dahil) bağımsız olarak rastgele atanabilir ve ağına çıktı ağırlıkları, basit genelleştirilmiş ters işlemlerle analitik olarak belirlenebilir. Sürekli doğrusal olmayan bir dönüşüm kullanmak, zaman alıcı öğrenme süreci olmadan eğitim aşamasını etkili bir şekilde tamamlayabilir. Dahası, ELM algoritması iyi bir genelleme performansı elde edebilir. Ek olarak, ilave veya RBF aktivasyonu ile standart ELM' nin genel metod kabiliyeti kanıtlanmıştır. ELM, sınıflandırma ve regresyon problemleri gibi birçok pratik uygulamada başarıyla kullanılmıştır [29-30].

Bununla birlikte, ELM ile ilgili bir sorun, ELM' nin sınıflandırma sınırının, eğitim bildiriminde değişmeden kalırken, öğrenme parametrelerine rastgele gizli düğümler atamak için en iyi sınır olmamasıdır[32]. Bu nedenle, bazı numuneler, özellikle sınıflandırma limitine yakın olanlar ELM tarafından yanlış sınıflandırılabilir. Çoğu durumda ELM' nin geleneksel ayar tabanlı algoritmalarından daha fazla gizli nöron gerektirdiği de keşfedilmiştir [33].

Geleneksel ileri beslemeli bir YSA da ağına eğitilmesi Şekil 3.1'de $i_{1...n}$ giriş özellik vektörlerini (veri kümesinde her örnek n tane özellik içermektedir), $y_{1...p}$ çıkış vektörlerini (p tane çıkış) ve $\beta_{1...m}$ çıkış katmanı ağırlıklarını (m tane gizli katman nöronu) göstermektedir. Geleneksel ileri beslemeli bir YSA da ağına eğitilmesi iteratif olarak gerekirken, bu süreç ELM' de analitik bir

denkleme dönüştürülmüş ve bu sebeple çok hızlı bir öğrenme yeteneği kazanılmıştır [34]. Şekil 3.1’de aşırı öğrenme makinesi modelinin yapısı verilmiştir.



Şekil 3.1. Aşırı öğrenme makinesi modeli

ELM, gizli nöronların ağırlık larının çok hızlı seçilmesine izin verir. Bu nedenle, bazı klasik yöntemlerle karşılaştırıldığında, model yapısı seçimi ve gerçek model eğitimi için genellikle çok fazla genel hesaplama süresi kazandırabilir. Dahası, algoritma hala oldukça basit ve uygulaması kolaydır. Bununla birlikte, ELM' nin doğasında sınırlamalar vardır. Araştırmalar, çoğu durumda ELM' nin yüksek performansa sahip olduğunu, ancak gizli ELM katmanının ilk parametrelerinin (bağlantı ağırlığı, ofset değeri, düğüm sayısı) sınıflandırma doğruluğunu büyük ölçüde etkileyeceğini göstermektedir. 2010 yılında Deng Xiaoping, yapısal risk azaltma teorisini ve ağırlıklı en küçük kareler yöntemini ELM' ye dahil eden geleneksel bir aşırı öğrenme makinesi (RELM) önerdi. RELM, yalnızca eğitim hatalarını en aza indiren değil, aynı zamanda kenar mesafesini maksimize eden daha iyi genelleme performansına sahiptir. Aykırı değerler için, belirli bir anti-parazit işlevi de vardır [35]. Bu nedenle, bu tezde ELM ve RELM kullanılmıştır.

ELM ve RELM makine öğrenme algoritmaları, IDA ve β -talasemiyi ayırt etmek için kullanılan parametreler seçilerek seçilen parametrelerle kullanılmış. Uzmanların kontrolünde elde edilen sonuçları değerlendirilmiştir.

Sınıflandırma yapmak için birçok makine öğrenmesi algoritması mevcuttur. Eğiticiyi öğrenme yöntemlerinden biri olan SVM' nin amacı, iki sınıf arasındaki uzaklığın en büyük olduğu destek vektör olarak adlandırılan sınıflardaki uç noktaları bulmaktır [36]. Bir diğer algoritma olan k en yakın komşu algoritması (KNN) literatürde sıkça kullanılan bir algoritmadır.

Bu algoritmaya göre, sınıflandırma (özellik çıkarma) sırasında çıkarılan özelliklerden biri, sınıflandırılacak yeni verilerin önceki verilere ne kadar yakın olduğunu görmektir [37]. Karar ağacı, veri madenciliği sınıflandırmasında en sık kullanılan yöntemlerden biridir. Karar ağacının yapısında, her düğüm bir özneliği temsil eder. Dallar ve yapraklar ağaç yapısının unsurlarıdır. Karar ağacının amacı, veriler için basit bir sınıflandırma modeli oluşturmaktır [38].

Bazı araştırmacılar tarafından, yukarıda bahsedilen ELM eksikliklerinin üstesinden gelmek için artımlı ELM(incremental ELM), budama ELM(pruning ELM), hata minimize ELM(error-minimized ELM), iki aşamalı ELM(two-stage ELM), çevrimiçi ardışık ELM(online sequential ELM), evrimsel ELM(evolutionary ELM), oylama tabanlı ELM(voting-based ELM), ordinal ELM [39], tamamen kompleks ELM(fully complex ELM) ve simetrik ELM(symmetric ELM) gibi çeşitli ELM varyantları önerilmiştir.

Yeni bir öğrenme algoritması olarak ELM, yeni sınıflandırıcıları eğitmek için daha az hesaplama süresi gerektirir, çünkü gizli katmanın ağırlıkları ve önyargıları rastgele atanır ve çıktı ağırlıkları basit matematiksel işlemlerle analitik olarak belirlenir. Son yıllarda, ELM gittikçe daha fazla araştırmacının ilgisini çekmiştir ve ELM algoritmalarının performansını iyileştirmek için birçok ELM varyantı önerilmiştir. Ek olarak ELM algoritması, hesaplama zekasını, örüntü yeniden oluşturmayı, makine öğrenimini ve diğer sorunları optimize etmek için kullanılmıştır.

Tablo 3.1'de gösterildiği gibi, ELM algoritmasını ve yöntem adı, yazar ve yıl, kısa açıklama ve uygulama dahil olmak üzere tipik varyantlarını kısaca özetliyor ve açıklıyoruz.

Tablo 3.1. ELM algoritması uygulama alanları

Metod Adı	Kısa açıklama	Uygulamalar
Original ELM	Rastgele atanan SLFN'ler için aşırı bir öğrenme algoritması giriş ağırlıkları ve yanlılıkları. Bilinmeyen tek parametre, matematiksel bir dönüşümle hesaplanabilen çıkış ağırlıklarıdır.	Sınıflandırma ve regresyon problemleri
Artımlı ELM	Gizli katmanın düğümlerinin bulunduğu artımlı bir ELM modeli gizli katmana bir eklendi.	Fonksiyon yaklaşma alanındaki bazı kıyaslama problemleri
Budama ELM	Bir budamış ELM modeli, başlangıçta çok sayıda gizli düğümle başladı ve daha sonra alakasız veya az alakalı olan gizli düğümleri sınıf etiketleriyle alakasızlığından kaldırdı.	8 gerçek sınıflandırma problemi UCI ML deposu

Hata minimize ELM	Genelleştirilmiş SLFN'lerde gizli düğümlerin sayısını otomatik olarak belirlemek için gizli düğümleri birer birer artırabilen ELM için hata azaltma tabanlı bir yöntem.	Bazı gerçek kıyaslama regresyonu ve sınıflandırma problemleri
İki aşamalı ELM	ELM için çok daha küçük bir sistematik iki aşamalı algoritma gizli düğümlerin iki aşamalı ayarlanmasıyla ağ yapısı	UCI ML deposundan altı gerçek regresyon problemi
Online ardışık ELM	Yalnızca geleneksel ELM olarak gizli düğüm sayısının belirtilmesini gerektiren çevrimiçi ardışık ELM algoritması	Sınıflandırma, regresyon ve zaman serisi tahmin problemleri
Evrimsel ELM	Evrimsel ELM'de, giriş ağırlıkları ve gizli yanlılıklar değiştirilmiş diferansiyel evrimsel algoritma ile optimize edildi	Dört gerçek kıyaslama sınıflandırma sorunu
Oylama tabanlı ELM	V-ELM, tek bir ELM eğitimi yerine birden çok bağımsız ELM eğitimi gerçekleştirmiş ve daha sonra çoğunluk oylama yöntemine göre nihai kararı vermiştir.	UCI veri tabanından ve protein bilgi kaynağı merkezinden on dokuz gerçek dünya veri kümesi
Ordinal ELM	Ordinal ELM algoritması ile SLFN, ordinal regresyon problemleri için yeniden tasarlandı ve algoritmalar ELM tarafından eğitildi	Yapay veri, dokuz küçük örnek ve beş büyük regresyon veri seti
Tam kompleks ELM	Tamamen karmaşık ELM algoritmasında, ELM algoritması gerçek alandan karmaşık alana genişletildi	Cha ve Kassam tarafından sunulan karmaşık, minimum faz dışı kanal modeli
Simetrik ELM	Simetrik ELM, gizli nöronların orijinal aktivasyon fonksiyonunu örneklerin giriş değişkenlerine göre simetrik bir hale dönüştürdü	İki oyuncak fonksiyonu yaklaşım problemi ve iki kaotik zaman serisi tahmin görevi

3.1. RELM (Recurrent Extreme Learning Machine)

RELM, tek bir gizli katmanlı sinir ağıdır (SHLRN). Çıktı veya gizli katmanları kullanın (Elman YSA). Bağlam nöronu çıkıştan girişe geri bağlanır. Bu nöronlar, giriş nöronları gibi davranır ve çıkış nöronlarından gecikme değerlerini yakalar.

Tekrarlayan Aşırı Öğrenme Makinesi (RELM), hesaplama çıktısını bir katmanda bir sonraki katmana girdi olarak kullanmak için bir geri bildirim ağı kullanır. Bununla birlikte, RELM, tahmin edilen değerde sınırlamalara neden olacak şekilde, girişlerin ve sapmaların rastgele atanmasını gerektirir. Gizli düğümlerin sayısı da tahmin doğruluğunda önemli bir rol oynar.

3.2. Artımlı ELM

Huang ve arkadaşları, artımlı bir ileri beslemeli ağ oluşturmak için artımlı bir aşırı öğrenme makinesi (I-ELM) önerdiler [40]. I-ELM, gizli katmana her rastgele düğümü ekler ve yeni bir gizli düğüm eklerken mevcut gizli düğümün çıktı ağırlığını dondurur. I-ELM yalnızca sürekli aktivasyon fonksiyonlu (farklılaşma dahil) SLFN için değil, aynı zamanda kısmi sürekli aktivasyon fonksiyonlu (eşik gibi) SLFN için de etkilidir.

3.3. Hata minimize ELM

Feng ve arkadaşları, geliştirilmiş SLFN' deki gizli düğümlerin sayısını otomatik olarak belirlemek için gizli düğümleri tek tek veya gruplandırabilen bir ELM hata minimizasyon yöntemi (EM-ELM) önermişlerdir [41]. Ağın büyümesi sırasında çıktı ağırlıkları kademeli olarak güncellenir ve bu da hesaplama karmaşıklığını büyük ölçüde azaltır. S şeklindeki gizli düğümler üzerindeki simülasyon sonuçları, bu yöntemin ELM' nin hesaplama karmaşıklığını önemli ölçüde azaltabileceğini göstermektedir ve ELM' nin etkili bir şekilde uygulanması önerilmektedir.

3.4. İki aşamalı ELM

Basit bir ELM ızgara çözümü elde etmek için, Lan ve arkadaşları sistematik iki aşamalı bir algoritma (TS-ELM olarak adlandırılır) önerdiler [42]. İlk aşamada, rastgele oluşturulmuş adaylardan gizli düğümleri seçmek ve bunları durdurma kriteri karşılanana kadar ağa eklemek için her adımda ileri özyinelemeli bir algoritma uygulanır. Aynı zamanda, her bir gizli düğümün önemi, ağa eklendiğinde sağladığı net katkı ile ölçülür. İkinci aşamada, ağdaki gereksiz düğümleri ortadan kaldırmak için seçilen gizli düğümler kontrol edilir ve bu, ağın karmaşıklığını büyük ölçüde azaltır. Altı vakanın incelenmesi, daha küçük ağ yapısına sahip TS-ELM' nin EM-ELM aracılığıyla daha iyi veya benzer performans elde edebileceğini göstermektedir.

N veri örneğinin $\{\mathbf{x}_i, t_i\}_{i=1}^N$ verildiğini ve ELM ağındaki gizli düğüm parametrelerinin ($\mathbf{a}_i$ ve b_i) rastgele üretildiğini varsayarsak eğer matematiksel model matris formunda “ $T=H\beta+E$ ” gösterilebilir.

$$t=H\beta+e$$

$$t=[t_1 \cdots t_N]^T_{N \times 1} \text{ ve } e=[e_1 \cdots e_N]^T_{N \times 1}$$

Ve en küçük kareler çözümü için formüller β ve maliyet fonksiyonu J olur. Formüller aşağıda verilmiştir:

$$\beta^{\wedge}=(H^TH)^{-1} H^Tt$$
$$J(\beta^{\wedge})=t^Tt-\beta^{\wedge T}H^Tt$$

3.5. Budamalı ELM

Model sınıflandırmasında aşırı ekleme / ekleme sorununa yol açacak çok az / çok gizli düğüm olduğunu düşünen Rong ve diğerleri, sistematik bir otomatik ELM ağ tasarımı yöntemi olarak kesilmiş bir ELM (P-ELM) algoritması önerdi [29]. P-ELM başlangıçta çok sayıda gizli düğümle başladı ve daha sonra, öğrenme sırasında sınıf etiketleriyle olan ilgileri dikkate alındığında, alakasız veya daha az alakalı gizli düğümler silindi. Sonuç olarak, ELM' nin mimari tasarımı otomatikleştirilebilir. Simülasyon sonuçları, P-ELM' nin standart ELM, BP ve MRAN tarafından görülemeyen veriler için hızlı yanıt ve güçlü tahmin doğruluğu üreten kompakt bir ağ sınıflandırıcısına yol açtığını göstermektedir. P-ELM, esas olarak örüntü sınıflandırma problemleri için uygundur.

3.6. Online sıralı ELM

Geleneksel ELM kullanılırken, tüm eğitim verileri eğitim için hazırlanmalıdır. Bununla birlikte, pratik uygulamalarda, eğitim verileri gruplar halinde veya bireysel olarak elde edilebilir. Liang ve arkadaşları, birleşik bir çerçevede toplamalı ve RBF düğümlerini işleyebilen çevrimiçi sıralı öğrenme makinesi (OS-ELM) adı verilen sıralı bir öğrenme algoritması önermiştir [43]. Ek düğüm OS-ELM' de, giriş düğümünü gizli düğüme bağlayan girdi ağırlığı ve önyargı rastgele oluşturulur ve ardından çıktı ağırlığı, gizli düğümün çıkışına göre analitik olarak belirlenir. Buna karşılık, diğer sıralı öğrenme algoritması OS-ELM yalnızca gizli ELD miktarının geleneksel ELM olarak belirtilmesini gerektirir. OS-ELM' nin performansını iyileştirmek ve sıralı öğrenme modunu topluluk ağına tanıtmak için Lan ve meslektaşları, çevrimiçi sıralı topluluk adı verilen entegre bir ağ yapısı önerdiler [44].

3.7. Evrimsel ELM

Genellikle ELM uygulandığında gizli nöronların sayısı rastgele belirlenir. Bununla birlikte, giriş ağırlıklarının ve gizli yanlılıkların rastgele belirlenmesi nedeniyle ELM' nin daha fazla sayıda gizli nörona ihtiyacı olabilir. Giriş ağırlıklarını ve gizli yanlılıkları optimize etmek ve çıkış ağırlıklarını belirlemek için Zhu ve arkadaşları tarafından evrimsel aşırı öğrenme makinesi (E-ELM) adlı yeni bir öğrenme algoritması önerilmiştir [33]. E-ELM' de, girdi ağırlıklarını ve gizli

yanlılıkları optimize etmek için değiştirilmiş diferansiyel evrimsel (DE) algoritması kullanılmıştır. Çıkış ağırlıklarını analitik olarak belirlemek için Moore – Penrose (MP) genelleştirilmiş tersi kullanıldı.

3.8. Oylama tabanlı ELM

ELM' deki gizli düğümlerin öğrenme parametreleri rastgele atandığından ve eğitim sürecinde değişmeden kaldığından, ELM optimum sınıflandırma sınırına ulaşamayabilir, bu da örneklerin sınıflandırma sınırına yakın yanlış sınıflandırılmasına yol açar. Bu nedenle, Cao ve meslektaşları, sınıflandırma sınırına yakın yanlış sınıflandırılmış örneklerin sayısını azaltmak için Aşırı Motivasyon Öğrenme Makinesi (V-ELM) Oylama adlı gelişmiş bir algoritma önerdiler [32]. V-ELM'nin ana fikri, bir ELM eğitimi yerine birden çok bağımsız ELM eğitimi yürütmek ve ardından nihai kararı çoğunluk oylama yöntemine göre vermektir. V-ELM, yalnızca sınıflandırma performansını iyileştirmekle kalmaz, aynı zamanda yanlış sınıflandırılan örneklerin sayısını da azaltır ve ayrıca farklı uygulamalar arasındaki farkı azaltır. Birçok gerçek sınıflandırma veri setindeki simülasyonlar, V-ELM' nin orijinal ELM algoritmasından ve son sınıflandırma algoritmalarından daha üstün olduğunu göstermektedir.

3.9. Sıralı ELM

Sıralı regresyon problemleri için ELM algoritmasını daha fazla incelemek için Deng ve arkadaşları, kodlamaya dayalı sıralı bir regresyon çerçevesi ve ELM' ye dayalı üç sıralı regresyon algoritması önermişlerdir [45]. Bu makale, sıralı regresyon için aşağıdaki üç kodlama şemasını içeren kodlamaya dayalı bir çerçeve tasarlar: tek birçok çıktı sınıflandırıcı, bir yöntem ve bir ayrıştırma yöntemi ve birden çok ikili sınıflandırma için bir yöntem ve bir yöntem. Bu çerçeve temelinde, SLFN sıralı regresyon problemi için yeniden tasarlandı ve bu algoritmalar, makine öğrenimi tarafından fazla öğrenildi. Üç tür veri kümesi üzerinde yapılan çok sayıda deney, satır içi ELM' nin son derece hızlı eğitim hızı ve iyi genelleme yeteneği elde edebileceğini göstermektedir.

3.10. Tam kompleks ELM

ELM algoritmasının uygulamasını genişletmek için Li ve diğerleri, tamamen karmaşık bir aşırı öğrenme algoritması (C-ELM) önermişlerdir [46]. C-ELM' de ELM algoritması, gerçek alandan karmaşık alana uzanır. ELM' ye benzer şekilde, C-ELM' nin girdi ağırlığı ve gizli katman sapması, bazı sürekli dağıtım olasılıklarına göre rastgele seçilir ve ardından çıktı ağırlığı, çıktı ağırlığını tekrar tekrar ayarlamak yerine analiz yoluyla basitçe hesaplanır. Daha sonra, C-ELM, karmaşık doğrusal olmayan kanalı QAM sinyalleri ile telafi etmek için kullanılır.

3.11. Simetrik ELM

Liu ve arkadaşları, simetrik ELM (S-ELM) adı verilen ve numunenin giriş değişkenine göre gizli nöronun orijinal aktivasyon fonksiyonunu simetrik bir hale dönüştüren geliştirilmiş bir ELM algoritması önerdiler [47]. Teorik olarak, S-ELM N herhangi bir numuneyi sıfır hata ile tahmin etme kabiliyetini sürdürebilir. Simülasyon sonuçları, S-ELM' nin daha iyi genelleme performansına, daha hızlı öğrenme hızına ve daha kompakt efektlere sahip olduğunu göstermektedir.

Yukarıda bahsedilen ELM modeline ek olarak, PCA-ELM, bulanık ELM, sağlam ELM, paralel ELM gibi ELM performansını iyileştirmek için kullanılabilecek bazı gelişmiş yöntemler vardır.

3.12. ELM Uygulamaları

Son zamanlarda ELM algoritması birçok alanda uygulanmıştır. Bu bölüm ELM' nin bazı klasik uygulamalarını listeler.

3.12.1. Sınıflandırma

Wang ve diğerleri, mobil nesnenin kendisinden ziyade işgal edilen alanı indeksleme için R ağacının kullanıldığı ve ELM' nin çevresel değişikliklere uyum sağlamak için alanı dinamik olarak sınıflandırmak için kullanıldığı yeni bir mobil nesne indeksleme mimarisi önerdi [39]. Zheng ve arkadaşları, Tek etiketli ve çok etiketli vakalar dahil olmak üzere RELM algoritması için geliştirilen metin sınıflandırmasına Düzenlenmiş Aşırı Öğrenme Makinesi' ni (RELM) uyguladılar [48]. Karpagachelvi ve meslektaşları, kalp hastalığı araştırmalarında kullanılan kalbin elektriksel kayıtları olan EKG sinyallerini sınıflandırmak için ELM' yi kullandı [49]. Kim ve arkadaşları, kısa bir öğrenme süresinde etkili doğruluğu kanıtlamak için elektrokardiyogramda ELM' yi kullanan bir aritmi sınıflandırma algoritması önermişlerdir [50].

3.12.2. Regresyon

Çok büyük ölçekli veri kümelerinde ELM' nin regresyon problemini çözmek için He ve arkadaşları regresyon için etkili bir paralel ELM (PELM) tasarladı ve uyguladı. Deneyler, PELM' in yalnızca büyük ölçekli veri kümelerini işleyemediğini, aynı zamanda iyi hızlanma, ölçeklendirme ve yeniden boyutlandırma performansına sahip olduğunu göstermektedir [51]. Li ve Niu, pertürbasyon veya çoklu bağlantı doğrusallaşmasının neden olduğu olumsuz etkilerden kaçınmak için, sırt regresyonuna (RRELM) dayalı gelişmiş bir ELM regresyonu önerdi. RR-

ELM'de çıktı ağırlık matrisini analiz etmek için ağırlık regresyon tahmin edici yöntemi kullanılır [52]. Balasundaram ve Kapil, orijinal değişken olarak 2 paradigmasındaki elektrona duyarsız regresyonun kısıtlanmamış optimizasyon problemini hedefleyen ELM çalışmasını önermiştir [53]. Feng ve arkadaşları, evrimsel algoritmalara dayanan yeni bir ELM regresyon çerçevesi önermişlerdir [54].

3.12.3. Desen Tanıma

Zong ve Huang, çok etiketli yüz tanıma uygulamalarında sınıflandırma için hepsi bir arada ve bire bir ELM' nin performansını test etti ve dört kıyaslama yüz görüntüsü veri setini kullanarak performansı doğruladı [55]. Mohammed ve arkadaşları, iki boyutlu temel bileşen analizine (B2DPCA) ve ELM' ye [56] dayalı bir yüz tanıma algoritması geliştirdiler. Minhas ve arkadaşları, görsel kelime bilgisine dayalı ELM kullanan bir insan eylemi tanıma çerçevesi önermiştir [57]. Chacko ve arkadaşları, eğim algoritmasını hızlandırmak için el yazısı karakterlerin niteliklerini sınıflandırmak için ELM' yi kullanan el yazısı karakter tanıma dalgacık enerjisi ve ELM' yi uyguladılar [58]. Lan ve meslektaşları, metinle ilgili konuşmacı doğrulama görevlerini incelemek için ELM' yi kullandı [59].

Nian ve arkadaşları, geometrik topoloji modeline ve 3B nesne tanıma için ELM' ye dayalı olarak her 3B nesnenin doğal dağılımını ve bağımlılık yapısını tanımlayabilen bir yöntem önermiştir [60]. Ek olarak, ELM, yüz cinsiyet tanıma, parmak izi eşleştirme ve metin sınıflandırma gibi diğer alanlarda da uygulanmaktadır.

3.12.4. Tahmin ve Teşhis

Sun ve arkadaşları, satış hacmi ile talebi etkileyen bazı önemli faktörler arasındaki ilişkiyi incelemek için ELM' yi kullanır ve etkisi diğer BPNN tabanlı yöntemlerden daha iyidir [61]. Hu ve arkadaşları, kümelemenin doğruluğunu iyileştirmek için çok aşamalı bir ELM önerdi ve bunu hidrolik boru hattı test cihazı verilerinde kullandı [54]. Daliri, genetik algoritma ile bulanık ELM' yi birleştiren ve klinik olarak kullanılabilen melez bir akciğer kanseri otomatik tanı sistemi önermiştir [55]. Xu ve ark. Güç sistemlerinin gerçek zamanlı frekans kararlılığı değerlendirmesi için ELM tabanlı bir öngörücü geliştirilmiştir [56].

3.12.5. Görüntü İşleme

Zhou ve arkadaşları, pürüzsüz yüzeyleri yüksek doğruluk ve sağlamlıkla yeniden üretmek için çoklu harmonik aşırı öğrenme makinesi (P-ELM) adı verilen gelişmiş bir ELM kullandı [57]. Chen Pan ve arkadaşları, ELM' yi öğrenerek ve görsel sistemi simüle ederek hızlı ve basit bir beyaz

kan hücresi görüntü segmentasyon çerçevesi önermişlerdir [58]. Bu çerçeve altında, ELM sınıflandırıcı, görsel nöron sisteminin bir temsilini sağlamak için çevrimiçi olarak eğitilir ve daha sonra nesnenin görüntüsünden pikseller çıkarılır.



4. MATERYAL VE METOD

4.1. Materyal


Araştırmaya Haziran 01.12.2016 ve 23.05.2019 tarihleri arasında Elazığ Halk Sağlığı Laboratuvarında β -talasemi tanısı alan 1-88 yaş arasında 152 hasta (106 kadın, 46 Erkek) ve 01.03.2018-01.07.2018 tarihinde Elazığ Şehir Hastanesi Biyokimya Laboratuvarında demir eksikliği anemisi tanısı alan 2-88 yaş arasında 190 sayıda hasta (166 Kadın, 24 Erkek) hasta dahil edilmiştir. Araştırmaya MCV değeri 80 fl altındaki hastalar dahil edilmiştir. Demir tedavisi alan hastalar çalışma dışı bırakılmıştır. HPLC ile talasemi taramasında HbA2 düzeyleri %3.5 ve üzeri olan hastalar β -talasemi tanılı hasta grubuna dahil edilmiştir. Ayrıca HbA ve hbF değerleri de kaydedilmiştir. Çalışmada kullanılan tüm Hemogram değerleri "Beckman Coulter Unicell DXH-800" ile (RBC; Coulter İlkesi, HGB; Fotometrik, HCT, MCH, MCHC; Hesaplama, MCV, RDW; RBC Histogramından elde edilmiştir) ve Ferritin değerleri "Beckman Coulter DXI-800" cihazında kemilüminesans yöntemiyle ölçülmüştür. HbA2 ise Biorad D-10 cihazı ile kromatografik olarak ölçülmüştür. Tüm hasta gruplarında sırasıyla Hemoglobin, RBC, MCV, MCH, MCHC ve RDW, cinsiyet değerleri kaydedilmiştir. Tablo 4.1'de kandaki eritrosit indeks değerlerinin erkek ve kadın için referans değerleri verilmiştir.

Tablo 4.1. Kandaki eritrosit indeks değerlerinin erkek ve kadın için referans değerleri

Hemogram	Erkek	Kadın
RBC ($\times 10^6/\text{mm}^3$)	4.6-6.0	4.0-5.4
HB (g/dl)	14.0-18.0	12.0-16.0
HCT (%)	40.0-54.0	35.0-49.0
MCV (fl)	80.0-100.0	80.0-100.0
MCH (pg)	26.0-32.0	26.0-32.0
MCHC (%)	32.0-36.0	32.0-36.0
RDW (%)	11.5-14.5	11.5-14.5

4.2. Metot

Tam kan sayımından elde edilen ortalama eritrosit hacmi (MCV), ortalama eritrosit hemoglobini (MCH), eritrosit dağılım genişliği (RDW) gibi eritrosit indeks değerleri anemi etiyojisinin ortaya konulmasına yardımcı olmaktadır. MCV değerine bakarak anemi morfolojik olarak sınıflandırılmaktadır. Eritrosit dağılım genişliği (RDW) değeri anizositozun göstergesi olup yüksekliği demir eksikliği anemisi için anlamlıdır. Bu eritrosit indeksleriyle RBC, HB ve HCT referans değerleri Tablo 4.1’ de gösterildiği gibidir. Bu çalışmada tüm hasta gruplarında sırasıyla HB, RBC, MCV, RDW, HCT, MCH, MCHC değerleri standart bir forma kaydedilmiştir. Şekil 4.1’de IDA ile β -talasemi ayrımı yapmak için kullanılan yöntemin akış diyagramını göstermektedir.



Şekil 4.1. Kullanılan yöntemin akış diyagramı

4.3. Performans Değerlendirme

Sınıflandırma başarısını belirlemek için Duyarlılık, Özgüllük, Hassasiyet, Negatif Tahmini Değer, Yanlış Pozitif Oran, Yanlış Keşif Oranı, Yanlış Negatif Oran, Doğruluk ve F-Ölçü performans kriterleri kullanılmıştır[62, 63]. Parametreler belirlenirken kullanılan temel tanımlar aşağıdaki gibidir.

Gerçek pozitif (TP) = IDA olup IDA olarak tanımlanmış vaka sayısı

Yanlış pozitif (FP) = IDA olup β -talasemi olarak tanımlanmış vaka sayısı

Gerçek negatif (TN) = β -talasemi olup β -talasemi olarak tanımlanmış vaka sayısı

Yanlış negatif (FN) = β -talasemi olup IDA olarak tanımlanmış vaka sayısı

Duyarlılık (TPR) : TP test sonucunun pozitif çıkma yüzdesini gösterir. Matematiksel olarak denklem 1’ de ki gibi ifade edilir.

$$TPR = TP / (TP+FN) \quad (1)$$

Özgüllük (S): Özgünlük değeri, sağlıklı vakaları doğru bir şekilde belirleme yeteneğidir. Bu sebeple sağlıklı vakalarda gerçek negatif oranını belirlenmelidir. Matematiksel olarak denklem 2’ de ki gibi ifade edilir.

$$S = \frac{TN}{TN+FP} \quad (2)$$

Hassasiyet (P): Bir testin duyarlılığı, hasta vakalarını doğru şekilde belirleme üzerinedir. Hassasiyetin bulunması için, hasta vakalarında gerçek pozitif oranını hesaplanır. Denklem 3’de nasıl hesaplanacağı yer almaktadır.

$$P = \frac{TP}{TP+FN} \quad (3)$$

Doğruluk (Acc): Hastayı ve sağlıklı vakaları doğru bir şekilde ayırt etme kabiliyetidir. Denklem 4’de doğruluk tespiti gösterilmektedir.

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

F₁ Skor (F₁): Hassaslık ve duyarlılık arasındaki harmonik ortalama olup sınıflandırmanın genel doğruluğunu gösterir. Denklem 5’ de ki gibi ifade edilir.

$$F_1 = 2TP / (2TP + FP + FN) \quad (5)$$

5. BULGULAR VE TARTIŞMA

IDA ve β -talasemi ile ilişkili faktörlerin benzerliğinden dolayı bu çalışmada bir karar destek sistemi önerilmiş ve her iki hastalık türünün ayırıcı tanısı incelenmiştir. IDA ve β -talasemi arasındaki ayrım 3 senaryoda yapılmıştır. İlk senaryoda hem erkek hem de kadın hastalar birlikte değerlendirildi ve diğer iki senaryoda erkek ve kadın hastalar ayrı ayrı değerlendirildi. Her bir senaryo için sınıflandırma ELM, RELM, SVM, KNN ve Logistic Regression sınıflandırma algoritmalarına göre yapılmıştır. Tablo 5.1, Tablo 5.2 ve Tablo 5.3, sınıflandırma algoritmalarından elde edilen performans parametrelerini göstermektedir.

İlk senaryoda (Tablo 5.1), RELM sınıflandırma algoritması yardımıyla kadın ve erkek hastalar % 95,59 doğrulukla ayırt edildi. İkinci senaryodaki erkek hastalar (Tablo 5.2) lineer SVM ile % 94,37 doğrulukla sınıflandırıldı. Son senaryoda (Tablo 5.3), kadınlar hem ELM hem de RELM algoritmaları ile % 96,3 doğrulukla sınıflandırılmıştır. Literatürde IDA ve β -talasemi ayırt etmede kullanılmayan ELM ve RELM algoritmaları ile yüksek performans elde edilmiştir. En yüksek doğruluk (% 95,59 ve % 96,3), özellikle senaryo 1 (Erkek / Kadın) ve senaryo 3 (Kadın) için ayarlanan RELM algoritmasıyla elde edildi. En yüksek doğruluk (% 96,3) ELM algoritması ile Senaryo 3'te elde edilmiştir. Senaryo 2 için belirlenen SVM algoritması ile elde edilen en yüksek başarı oranı % 94,37 olmuştur. Elde edilen sonuçlar F1-Skor parametresi açısından değerlendirildiğinde her senaryoda sırasıyla % 96, % 91,3 ve % 96,97 başarı elde edilmiştir. F1 Skoru, doğruluk parametresine benzer. Bu sonuç, sınıflandırma algoritmalarının hastalığı yüksek doğrulukla ayırt ettiğini göstermektedir.

Tablo 5.1. Erkek / Kadın için sınıflandırma algoritmalarına göre elde edilen performans parametreleri

Parametreler	Metod	Sen	Spe	Pre	Acc	F1
RBC, HGB, HCT, MCV, MCH, MCHC, RDW, MF	Quadratic SVM	0.9626	0.9355	0.9474	0.9503	0.9549
RBC, HGB, HCT, MCV, MCH, MCHC, RDW, MF	Cubic SVM	0.9358	0.9032	0.9211	0.9211	0.9284
RBC, HGB, HCT, MCV, MCH, MCHC, RDW, MF	Linear SVM	0.9372	0.9272	0.9421	0.9327	0.9396
RBC, HGB, HCT, MCV, MCH, MCHC, RDW, MF	Fine KNN	0.9202	0.8896	0.9105	0.9064	0.9153
RBC, HGB, HCT, MCV, MCH, MCHC, RDW, MF	Medium KNN	0.9330	0.9392	0.9526	0.9357	0.9427
RBC, HGB, HCT, MCV, MCH, MCHC, RDW, MF	Logistic Regresyon	0.9468	0.9221	0.9368	0.9357	0.9418
RBC, HGB, HCT, MCV, MCH, MCHC, RDW, MF	ELM	0.8684	0.9667	0.9706	0.9118	0.9167

RBC, HGB, HCT, MCV, MCH, MCHC, RDW, MF	RELM	0.9474	0.9667	0.9730	0.9559	0.9600
--	------	--------	--------	--------	--------	--------

Tablo 5.2. Erkek için sınıflandırma algoritmalarına göre elde edilen performans parametreleri

Parametres	Method	Sen	Spe	Pre	Acc	F1
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Quadratic SVM	0.9091	0.9184	0.8333	0.9155	0.8696
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Cubic SVM	0.9048	0.9000	0.7917	0.9014	0.8444
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Linear SVM	0.9545	0.9388	0.8750	0.9437	0.9130
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Fine SVM	0.9130	0.9375	0.8750	0.9296	0.8936
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Medium KNN	0.8947	0.8654	0.7083	0.8732	0.7907
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Logistic Regresyon	0.9500	0.9020	0.7917	0.9155	0.8636
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	ELM	0.8000	1.0000	1.0000	0.9286	0.8869
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	RELM	0.8000	1.0000	1.0000	0.9286	0.8869

Tablo 5.3. Kadınlar için sınıflandırma algoritmalarına göre elde edilen performans parametreleri

Parametres	Method	Sen	Spe	Pre	Acc	F1
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Quadratic SVM	0.9464	0.9320	0.9578	0.9410	0.9521
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Cubic SVM	0.9212	0.8679	0.9157	0.9004	0.9184
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Linear SVM	0.9524	0.9417	0.9639	0.9483	0.9581
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Fine SVM	0.9398	0.9048	0.9398	0.9410	0.9521

RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Medium KNN	0.9464	0.9320	0.9578	0.9410	0.9521
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	Logistic Regresyon	0.9576	0.9245	0.9518	0.9446	0.9547
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	ELM	0.9697	0.9524	0.9697	0.9630	0.9697
RBC, HGB, HCT, MCV, MCH, MCHC, RDW	RELM	0.9697	0.9524	0.9697	0.9630	0.9697

Elde edilen sonuçların literatür ile karşılaştırılması Duyarlılık, Özgünlük ve Doğruluk parametrelerine göre Tablo 5.4'de verilmiştir. Sonuçlara göre başarılı olanlar RELM ve ELM ile elde edildi. Literatüre göre hastalar Erkek, Kadın ve Erkek / Kadın olmak üzere üç farklı sınıfta incelenmiştir. IDA ve β -talasemi arasında yapılan ayırım, her üç sınıf için % 93.5'in üzerinde bir doğrulukla sınıflandırıldı.

Tablo 5.4. Literatürün karşılaştırılması

Reference	Method	Sen%	Spe%	Acc%
[10]	DT	99.30	76.70	-
[14]	K-NN, NB, DT, MLP	98.81	99.47	-
[15]	SVM	-	-	96.343
[16]	SVM	98.00	-	-
[17]	ANN	92.33	93.13	92.50
[18]	PCA, MLP	-	-	91.02
[28]	ANFIS	87.10	95.60	90.70
[29]	MLP	95.00	95.00	93.50
[30]	SVM	95.00	83.00	89.00
[31]	RBF	93.00	91.00	-
[32]	Math	84.70	87.9	94.30
Proposed System	SVM(Male)	95.45	93.88	94.37
	RELM(Male/Female)	94.74	96.67	95.59
	ELM, RELM(Female)	96.97	95.24	96.30

Özellikle Erkek / Kadın sınıfında literatürdeki önceki çalışmalardan daha yüksek doğruluk (% 96.30) elde edilmiştir. Modelin doğru konfigürasyonu, mevcut yöntemlerden daha doğru ve maliyetsiz bir teşhis yöntemi için onu güvenli bir alternatif yöntem olarak kullanmayı mümkün kılar. Ayrıca, önerilen sistemin temel avantajları karar verme sürecini hızlandırması, düşük maliyetli olması ve doğru sonuçlar üretmesidir. Bu nedenle önerilen karar destek sistemine dayalı olarak elde edilecek sonuçlar raporlar, klinik belirti ve semptomlar ile birlikte kullanılabilir. Ayrıca sistem, tıp doktorları tarafından hastalıkların doğru teşhisi için güçlü bir karar destek sistemi olarak kullanılabilir.



6. SONUÇLAR

IDA ile β -talasemi ayrımı, anemi teşhisi ve tedavisi açısından önemli bir problemidir. Ayrımı CBC ile yapmak için literatürde birçok indeks önerilmiş ve bu indekslerin doğrulukları üzerinde akademik çalışmalar yapılmıştır. Bu çalışma IDA ile β -talasemi ayrımını yapan indekslerin kullandığı parametrelerin, makine öğrenmesine etkisini araştırmıştır. Bununla birlikte çalışmada literatürde kullanılmayan aşırı öğrenme makinası algoritması kullanılmıştır. Kullanılan algoritmayla daha hızlı ve daha az maliyetle yüksek performans elde edilmiştir.

Çalışma pratikte uygulandığında, ileride IDA ile β -talasemi ayrımı küçük merkezlerde yapılabilir ve daha hızlı ve düşük maliyetle uygulanabilir. Çalışmanın, biyokimya problemleri üzerinde yapay zeka çalışmalarına ışık tutacağı düşünülmektedir.



KAYNAKLAR

- [1] D.J. Weatherall, J.B. Clegg, "The Thalassemia Syndromes," Malden: MA: Blackwell Science, 2001.
- [2] J.M. England, P.M. Fraser, "Differentiation of iron deficiency from thalassemia trait by routine blood-count," *Lancet*, Vol. 1, No. 7801, pp.447-449, 1973.
- [3] W.C. Mentzer, "Differentiation of iron deficiency from thalassemia trait," *Lancet*, Vol. 1, No. 7808, pp.882, 1973.
- [4] P.C. Srivastava, J.M. Bevington, "No Iron deficiency and-or thalassemia trait," *Lancet*, Vol. 1, No.7807, pp.832, 1973.
- [5] I. Shine, S. Lal, "A strategy to detect beta thalassemia minor," *Lancet*, Vol. 1, No. 8013, pp.692-694, 1977.
- [6] R. Green, R. King, "A new red blood cell discriminant incorporating volume dispersion for differentiating iron deficiency anemia from thalassemia minor," *Blood Cells*, Vol. 15, pp.481-495, 1989.
- [7] S. Ayabose, J. Giavanelli, I.O. Levendoglu-Tuga, C. Sandoval, F. Özkaynak, P. Visintainer, "Differentiating iron deficiency anemia from Thalassemia minor by using an RDW-based index," *J Pediatr Hematol*, Vol. 21, pp.314, 1999.
- [8] A. Demir, N. Yarali, T. Fisgin, F. Duru, A. Kara, "Most reliable indices in differentiation between thalassemia trait and iron deficiency anemia," *Pediatr Int*, Vol. 44, No. 6, pp.612-616, 2002.
- [9] Hakan Ayyıldız, Seda Arslan Tuncer, Determination of the effect of red blood cell parameters in the discrimination of iron deficiency anemia and beta thalassemia via Neighborhood Component Analysis Feature Selection-Based machine learning, *Chemometrics and Intelligent Laboratory Systems*, Volume 196, 15 January 2020, 103886
- [10] Khaki Jamei, M., Mirzaei Talarposhti, K. Discrimination between iron deficiency anaemia (IDA) and β -thalassemia trait (β -TT) based on pattern-based input selection artificial neural network (PBIS-ANN) (2016) *J. Adv. Comput. Res.*, 7 (4), pp. 55-66. Cited 1 time.
- [11] Qasem, S.N.; Mosavi, A. Novel Meta-Heuristic Model for Discrimination between Iron Deficiency Anemia and B-Thalassemia with CBC Indices Based on Dynamic Harmony Search (DHS). *Preprints* **2020**, 2020030071 (doi: 10.20944/preprints202003.0071.v1).
- [12] Fakher Rahim, Bijan Keikhaei. Better differential diagnosis of iron deficiency anemia from beta-thalassemia trait. . 2009; 26(3): 138-145
- [13] M. Ferrara, L. Capozzi, R. Russo, F. Bertocco & D. Ferrara (2010) Reliability of red blood cell indices and formulas to discriminate between β thalassemia trait and iron deficiency in children, *Hematology*, 15:2, 112-115, DOI: 10.1179/102453310X12583347010098
- [14] Batebi, A , Pourreza, A , Esmailian, R . (2012). Discrimination of beta-thalassemia minor and iron deficiency anemia by screening test for red blood cell indices . *Turkish Journal of Medical Sciences* , 42 (2) , 275-280.
- [15] Kabootarizadeh L, Jamshidnezhad A, Koohmareh Z. Differential Diagnosis of Iron-Deficiency Anemia from β -Thalassemia Trait Using an Intelligent Model in Comparison with Discriminant Indexes. *Acta Inform Med*. 2019 Jun;27(2):78-84. doi: 10.5455/aim.2019.27.78-84. PMID: 31452563; PMCID: PMC6688292.

- [16] Hosseini Eshpala R , Langarizadeh M , Kamkar Haghighi M , Tabatabaei B . Designing an expert system for differential diagnosis of β -Thalassemia minor and Iron-Deficiency anemia using neural network, Hormozgan Med J. 2013 ; 20(1):e87905.
- [17] Dietterich, T. G. , 1997. Machine-learning research, AI magazine, 18(4), 97.
- [18] Chao, W. L. , 2011. Machine Learning Tutorial.
- [19] Kotsiantis, S. B. , Zaharakis, I. , Pintelas, P. , 2007. Supervised machine learning: A review of classification techniques.
- [20] Demirhan, A., “Neuroimage-based clinical prediction using machine learning tools”, International Journal of Imaging Systems and Technology, Vol. 27, No. 1, 89-97, 2017.
- [21] Hashemian, M., Pourghassem, H., “Diagnosing autism spectrum disorders based on EEG analysis: A survey”, Neurophysiology, Vol. 46, No. 2, 183-195, 2014.
- [22] L. Deng and D. Yu, “Deep Learning: Methods and Applications,” Found. Trends® Signal Process., vol. 7, no. 3–4, pp. 197–387, 2014.
- [23] Y. Bengio, “Learning Deep Architectures for AI,” Found. trends® Mach. Learn., vol. 2, no. 1, pp. 1–127, 2009.
- [24] H. A. Song and S.-Y. Lee, “Hierarchical Representation Using NMF,” in International Conference on Neural Information Processing., 2013, pp. 466–473
- [25] Hijazi, S., Kumar, R., & Rowen, C. (2015). Using convolutional neural networks for image recognition. Cadence Design Systems Inc.: San Jose, CA, USA.
- [26] Le Cun, Y., Jackel, L. D., Boser, B., Denker, J. S., Graf, H. P., Guyon, I., ... & Hubbard, W. (1989). Handwritten digit recognition: Applications of neural network chips and automatic learning. IEEE Communications Magazine, 27(11), 41-46.
- [27] F.Vazquez,“<https://towardsdatascience.com/a-weird-introduction-to-deep-learning-7828803693b0>”
- [28] Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Chen, T., Recent advances in convolutional neural networks. Pattern Recognition, 2017.
- [29] Rong HJ, Ong YS, Tan AH, Zhu Z (2008) A fast pruned-extreme learning machine for classification problem. Neurocomputing 72:359–366
- [30] Huang GB, Ding X, Zhou H (2010) Optimization method based extreme learning machine for classification. Neurocomputing 74:155–163
- [31] Yamashita, R., Nishio, M., Do, R.K.G. et al. Convolutional neural networks: an overview and application in radiology. Insights Imaging 9, 611–629 (2018).
- [32] Cao JW, Lin ZP, Huang GB, Liu N (2012) Voting based extreme learning machine. Inf Sci 185(1, 15):66–77
- [33] Zhu QY, Qin AK, Suganthan PN, Huang GB (2005) Evolutionary extreme learning machine. Pattern Recognit 38:1759–1763
- [34] Yingchen Zhang, Rui Yang, Jie Zhang, Yang Weng, Bri-Mathias Hodge: “Predictive Analytics for Comprehensive Energy Systems State Estimation”, in: Big Data Application in Power Systems, R. Arghandeh, Y. Zhou (Eds.), Elsevier, 2018.

- [35] Deng WY, Zheng QH, Chen L. Regularized Extreme Learning Machine In Proceedings of IEEE Symposium on Computational Intelligence and Data Mining (CIDM), Nashville, USA, March 30-April 2, 2009, pp.389–395.
- [36] Arslan, T.S., Alkan, A., (2018). A decision support system for detection of the renal cell cancer in the kidney. Measurement
- [37] Arslan Tuncer S., Akilotu B, Toraman S, A deep learning-based decision support system for diagnosis of OSAS using PTT signals, Medical Hypotheses, Volume 127, 2019, Pages 15-22
- [38] Alpaydın, E., —Zeki Veri Madenciliği: Ham Veriden Altın Bilgiye Ulaşma Yöntemleri, Bilişim 2000 Veri Madenciliği Eğitim Semineri Notları, 2000.
- [39] Wang BT, Wang GR, Li JJ, Wang B (2012) Update strategy based on region classification using ELM for mobile object index. Soft Comput 16(9):1607–1615
- [40] Huang GB, Chen L, Siew CK (2006) Universal approximation using incremental constructive feedforward networks with random hidden nodes. IEEE Trans Neural Netw 17(4):879–892
- [41] Feng GR, Huang GB, Lin QP, Gay R (2009) Error minimized extreme learning machine with growth of hidden nodes and incremental learning. IEEE Trans Neural Netw 20(8):1352–1357
- [42] Lan Y, Soh YC, Huang GB (2010) Two-stage extreme learning machine for regression. Neurocomputing 73(16–18):3028–3038
- [43] Liang NY, Huang GB, Saratchandran P, Sundararajan N (2006) A fast and accurate on-line sequential learning algorithm for feedforward networks. IEEE Trans Neural Netw 17(6):1411–1423
- [44] Lan Y, Soh YC, Huang GB (2009) Ensemble of online sequential extreme learning machine. Neurocomputing 72:3391–3395
- [45] Deng WY, Zheng QH, Lian SG, Chen L, Wang X (2010) Ordinal extreme learning machine. Neurocomputing 74(1–3):447–456
- [46] Li MB, Huang GB, Saratchandran P, Sundararajan N (2005) Fully complex extreme learning machine. Neurocomputing 68:306–314
- [47] Liu XY, Li P, Gao CH (2013) Symmetric extreme learning machine. Neural Comput Appl 22(3–4):551–558
- [48] Zheng WB, Qian YT, Lu HJ (2013) Text categorization based on regularization extreme learning machine. Neural Comput Appl 22(3–4):447–456
- [49] Karpagachelvi S, Arthanari M, Sivakumar M (2012) Classification of electrocardiogram signals with support vector machines and extreme learning machine. Neural Comput Appl 21(6): 1331–1339
- [50] Kim J, Shin HS, Shin K, Lee M (2009) Robust algorithm for arrhythmia classification in ECG using extreme learning machine. Biomed Eng. doi:10.1186/1475-925X-8-31
- [51] He Q, Shang TF, Zhuang FZ (2013) Parallel extreme learning machine for regression based on MapReduce. Neurocomputing 102(SI):52–58
- [52] Li GQ, Niu PF (2013) An enhanced extreme learning machine based on ridge regression for regression. Neural Comput Appl 22(3–4):803–810
- [53] Balasundaram S (2013) On extreme learning machine for e-insensitive regression in the primal by Newton method. Neural Comput Appl. doi:10.1007/s00521-011-0798-9

- [54] Feng GR, Qian ZX, Zhang XP (2012) Evolutionary selection extreme learning machine optimization for regression. *Soft Comput* 16(9):1485–1491
- [55] Zong WW, Huang GB (2011) Face recognition based on extreme learning machine. W. Zong, G.-B. Huang *Neurocomput* 74:2541–2551
- [56] Mohammed AA, Minhas R, Jonathan WuQM, Sid-Ahmed MA (2011) Human face recognition based on multidimensional PCA and extreme learning machine. *Pattern Recognit* 44:2588–2597
- [57] Minhas R, Baradarani A, Seifzadeh S, Jonathan WuQM (2010) Human action recognition using extreme learning machine based on visual vocabularies. *Neurocomputing* 73:1906–1917
- [58] Chacko BP, Vimal Krishnan VR, Raju G, Babu Anto P (2012) Handwritten character recognition using wavelet energy and extreme learning machine. *J Mach Learn Cyber* 3:149–161
- [59] Lan Y, Hu ZJ, Soh YC, Huang GB (2013) An extreme learning machine approach for speaker recognition. *Neural Comput Appl* 22(3–4):417–425
- [60] Nian R, He B, Lendasse A (2013) 3D object recognition based on a geometrical topology model and extreme learning machine. *Neural Comput Appl* 22(3–4):427–433
- [61] Sun ZL et al (2008) Sales forecasting using extreme learning machine with applications in fashion retailing. *Decis Support Syst* 46:411–419
- [62] S.A. Tuncer, A. Alkan, “A decision support system for detection of the renal cell cancer in the kidney”, *Measurement*, 2018.
- [63] S.A. Tuncer, B. Akılotu, S. Toraman, “A deep learning-based decision support system for diagnosis of OSAS using PTT signals”, *Medical Hypotheses*, Volume 127, 15-22, 2019.

ÖZGEÇMİŞ

[REDACTED]

KİŞİSEL BİLGİLER

ARAŞTIRMACI BİLGİLERİ

[REDACTED] | [REDACTED]
[REDACTED] | [REDACTED]

EĞİTİM BİLGİLERİ

Lisans : Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 2017
Lise : Kolukısa Anadolu Lisesi, Malatya, 2013

ARAŞTIRMA DENEYİMİ

✓ MATLAB, Python, Java, PHP, Javascript, React.js, React Native, Ionic, Android

İŞ DENEYİMİ

2020 – ... : Proda Danışmanlık Bilişim Şirketi
2020 – 2018 : Fırat Üniversitesi Büyük Veri ve Yapay Zeka Laboratuvarı
2017-2018 : Sentis Yazılım Bilgisayar Bilişim Ar-ge San.

AKADEMİK FAALİYETLER

Makaleler:

1. Discrimination of β -thalassemia and iron deficiency anemia through extreme learning machine and regularized extreme learning machine based decision support system