



**T.C.  
ONDOKUZ MAYIS ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
AKILLI SİSTEMLER MÜHENDİSLİĞİ ANA BİLİM DALI**

**DERİN ÖĞRENME İLE TİROİT HASTALIĞI  
TEŞHİSİNDE ÖZELLİK SEÇME**

Yüksek Lisans Tezi

**Amir MEHRNO**

Danışman  
**Prof.Dr.Mehmet Serhat ODABAŞ**

SAMSUN  
2021

**T.C.  
ONDOKUZ MAYIS ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
AKILLI SİSTEMLER MÜHENDİSLİĞİ ANA BİLİM DALI**



**DERİN ÖĞRENME İLE TİROİT HASTALIĞI  
TEŞHİSİNDE ÖZELLİK SEÇME**

Yüksek Lisans Tezi

**Amir MEHRNO**

Danışman

**Prof.Dr.Mehmet Serhat ODABAŞ**

SAMSUN  
2021

## TEZ KABUL VE ONAYI

Amir MEHRNO tarafından, Prof. Dr. Mehmet Serhat ODABAŞ danışmanlığında hazırlanan “Derin Öğrenme İle Tiroit Hastalığı Teşhisinde Özellik Seçme” başlıklı bu çalışma, jürimiz tarafından 21.6.2021 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	İmza	Sonuç
Başkan	Dr. Öğr. Üyesi Naci MURAT Ondokuz Mayıs Üniversitesi Akıllı sistemler Anabilim Dalı		<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye (Danışman)	Prof.Dr.Mehmet Serhat Odabaş Ondokuz Mayıs Üniversitesi Akıllı sistemler Anabilim Dalı		<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Dr. Öğr. Üyesi Nurettin ŞENYER Samsun Üniversitesi Yazılım Mühendisliği Anabilim Dalı		<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Prof. Dr. XXXX XXXX Ondokuz Mayıs Üniversitesi ..... Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Prof. Dr. XXXX XXXX Ondokuz Mayıs Üniversitesi ..... Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret

Bu tez enstitü yönetim kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

ONAY  
.../.../2021  
Prof.Dr.Ali Bolat  
Enstitü Müdürü

## **BİLİMSEL ETİĞE UYGUNLUK BEYANI**

Ondokuz Mayıs Üniversitesi Eğitim Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki bütün bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

23/06/2021

Amir Mehrno

## **TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI**

**Tez Başlığı : Derin Öğrenme İle Tiroit Hastalığı Teşhisinde Özellik Seçme**

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 30/11/2020 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 21

Tek kaynak oranı : % 1 çıkmıştır.

İmza

23 /06 / 2021

## ÖZET

### DERİN ÖĞRENME İLE TİROİT HASTALIĞI TEŞHİSİNDE ÖZELLİK SEÇME

Amir MEHRNO

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Akıllı Sistemler Mühendisliği Ana Bilim Dalı

Yüksek Lisans, Haziran/2021

Prof.Dr.Mehmet Serhat ODABAŞ

Tiroit bezi, vücudun metabolizmasını düzenlemeye yardımcı olmak için tiroit hormonları üretir. Tiroit hormonlarının üretimindeki anormallikler iki kategoriye ayrılır: tiroit hormonunun yetersiz üretimine bağlı hipotiroitizm ve tiroit hormonunun aşırı üretimine bağlı hipertiroitizm. Bu iki hastalığın ayrılması tiroit teşhisi için çok önemlidir. Tiroit hastalığı, tiroit hastalıklarının zamanında ve doğru teşhisinin laboratuvar tetkiklerine ve semptomlarına göre yaşamsal önem taşıdığı hastalıklardan biridir. Anormal tiroit fonksiyonunun zamanında teşhis edilememesi, hasta için geri dönüşü olmayan komplikasyonlara ve ölümüne yol açabilir. Bu çalışmada amacımız, tiroit bezinin normal, hipertiroitizm veya hipotiroitizm açısından durumunu veri madenciliği teknikleri kullanarak belirlemektir. Bu nedenle sınıflandırma için derin öğrenme algoritması önerilmiştir. Bu yöntemler, gereksiz ve ilgisiz özelliklerle başa çıkmak için daha güçlü sınıflandırma algoritmalarına dayanır. Bu makalede, özellik seçimi, tespit yoluyla önemli bir konu olarak tartışılıyor ve emperyalist rekabet algoritmalarının, algılama oranlarını iyileştiren iyi özellik alt kümelerini seçmek için basit, genel ve güçlü bir çerçeve sağladığını gösteriyor. Bu çalışma bir tanımlayıcı-analitik bir çalışmadır ve veritabanı, 21 risk faktörüne dayanan ve UCI veri referansından alınan 7200 bağımsız kayıt içerir. Bu çalışma önce derin öğrenme sınır ağının tiroit hastalığını teşhis etme işlevini inceliyor ve ardından emperyalist rekabet adı verilen bir algoritma en iyi özellikler eçiliyor. Sonuçlar, veri setinde uygulanan sınıflandırma için derin öğrenme algoritması ve emperyalist rekabetçi algoritmanın daha iyi, daha yüksek performans ve % 97,62 doğruluk oranına sahip olduğunu göstermektedir.

**Anahtar Sözcükler:** Tiroit bozuklukları , Teşhis, Derin Öğrenme, Emperyalist rekabetçi algoritma, Özellik seçimi

## ABSTRACT

### SELECTING FEATURE FOR DIAGNOSIS OF THYROID DISEASE BY DEEP LEARNING

Amir MEHRNO

Ondokuz Mayıs University

Institute Of Graduate Studies

Department Of Intelligent Systems Engineering

Master's Degree June/2021

Prof.Dr.Mehmet Serhat ODABAŞ

The thyroid gland produces thyroid hormones to help regulate the body's metabolism. Abnormalities in the production of thyroid hormones fall into two categories: hypothyroidism due to insufficient production of thyroid hormone and hyperthyroidism due to overproduction of thyroid hormone. Separating these two diseases is very important for thyroid diagnosis. Thyroid disease is one of the diseases in which timely and correct diagnosis of thyroid diseases is vital according to laboratory tests and symptoms. Failure to diagnose abnormal thyroid function in a timely manner can lead to irreversible complications and death for the patient. In this study, our aim is to determine the normal state of the thyroid gland in terms of hyperthyroidism or hypothyroidism using data mining techniques. Therefore, a deep learning algorithm has been proposed for classification. These methods rely on stronger classification algorithms to deal with unnecessary and unrelated features. In this article, feature selection is discussed as a key issue through detection and shows that imperialist competition algorithms provide a simple, general, and powerful framework for selecting good feature subsets that improve detection rates. This study is a descriptive-analytical study, and the database is 21 risk. It contains 7200 independent records based on the UCI data reference. This study first examines the function of the deep learning neural network to diagnose thyroid disease and then best features an algorithm called imperialist competition. The results show that the deep learning algorithm and the imperialist competitive algorithm for the classification applied in the data set have better, higher performance and an accuracy rate of 97.62%.

**Key Words:** Thyroid disorders, Diagnosis, Deep Learning, Imperial competitive algorithm, Feature selection

## ÖNSÖZ VE TEŞEKKÜR

Akademik eğitim sürecimin bir üst noktası olan yüksek lisans tez çalışmalarım boyunca yardım ve desteğini benden esirgemeyen danışman hocam Sayın Prof. Dr. Mehmet Serhat Odabaş'a teşekkürü bir borç bilirim.

Beni bugünlere getirmek için hiçbir fedakârlıktan kaçınmayan anneme, babama ve kardeşlerime sonsuz teşekkür ederim.

Yüksek lisans eğitimim boyunca benden desteklerini esirgemeyen ve iş hayatında bana sonsuz katkıda bulunan çalışma arkadaşlarıma da teşekkür ederim.

Amir MEHRNO

# İÇİNDEKLER

ÖZET .....	iii
ABSTRACT .....	iv
ÖNSÖZ VE TEŞEKKÜR.....	v
İÇİNDEKLER .....	vi
ŞEKİLLER DİZİNİ .....	viii
TABLolar DİZİNİ.....	x
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. TİROİT HASTALIĞI, TEŞHİSİ VE HİPOTROİDİZM</b> .....	<b>5</b>
<b>3. LİTERATÜR TARAMASI</b> .....	<b>11</b>
<b>4. YÖNTEM</b> .....	<b>18</b>
4.1.Özellik Seçimi.....	18
4.1.1.Değerlendirme Kriterlerine Göre Özellik Seçimi .....	20
4.1.1.1.Filtre Yöntemi .....	20
4.1.1.2.Sarıcı Yöntemi .....	20
4.1.1.3.Gömülü Yöntemi .....	21
4.1.2.Sınıflandırma İçin Özellik Seçimi .....	21
4.1.3.Tiroit Hastalığının Teşhisi İçin Özellik Seçimi .....	23
4.2.Yapay Sinir Ağı .....	25
4.2.1.Geri Yayılım Sinir Ağları (Back propagation) .....	26
4.2.2.İleri Besleme (feed forward):.....	28
4.3.Derin Öğrenme Algoritması .....	30
4.3.1.Derin Öğrenme Algoritmasının Sınıflandırılması: .....	33
4.3.1.1.Kısıtlanmış Boltzmann Makinesi.....	33
4.3.1.2.Otomatik Kodlayıcılar .....	34
4.3.1.3.Derin İnanç Ağları .....	35
4.3.1.4.Tekrarlayan Sinir Ağı .....	36
4.3.1.5.Evrilmiş Sinir Ağı .....	36
4.3.2.Derin Öğrenme Uygulaması: .....	37
4.3.2.1.Tıbbi Görüntü Analizi.....	37
4.3.2.2.Robotlar Ve Otonom Araçlar İçin Navigasyon.....	37
4.3.2.3.Resim Yazısı .....	38
4.3.3.Derin Öğrenme Algoritması İle Özellik Seçimi .....	39
4.4.Metasezgisel Algoritmalar .....	40
4.4.1.Sömürge Rekabetçi Algoritması (SRA).....	42
4.4.1.1.Sömürge Rekabet Algoritmasının Yapısı .....	46
4.4.1.2.Sömürge Rekabet Algoritması İle Özellik Seçimi.....	53



<b>5. UYGULAMA .....</b>	<b>55</b>
5.1. Veri Seti .....	55
5.2. Derin Öğrenme Sinir Ağı İle Tiroit Teşhisi .....	56
5.3. Derin Öğrenme Ve Sömürge Rekabetçi Algoritması ile Tiroit Teşhisi .....	60
5.4. Simulasyon Grafikleri .....	61
<b>6. TARTIŞMA VE SONUÇ .....</b>	<b>66</b>
<b>7. KAYNAKÇA .....</b>	<b>67</b>
<b>ÖZGEÇMİŞ .....</b>	<b>74</b>





Şekil 4.20. Emperyalist Rekabetçi Algoritmanın Sahte Kodu.....	53
Şekil 5.1. Hastalığı teşhis etmek için kullanılan yöntem .....	57
Şekil 5.2. 2 * 1 evrişim tabakalı ve 7 * 3 girişli CNN yapısı.....	58
Şekil 5.3. 5 tekrarlı birinci derin öğrenme sinir ağı öğrenme yapılandırmasının sonucu .....	61
Şekil 5.4. 5 tekrarlı ikinci derin öğrenme sinir ağı öğrenme yapılandırmasının sonucu .....	61
Şekil 5.5. 10 tekrarlı birinci derin öğrenme sinir ağı öğrenme yapılandırmasının sonucu .....	62
Şekil 5.6. 10 tekrarlı ikinci derin öğrenme sinir ağı öğrenme yapılandırmasının sonucu .....	62
Şekil 5.7. 40 tekrarlı üçüncü derin öğrenme sinir ağı öğrenme yapılandırmasının doğruluk sonucu.....	63
Şekil 5.8. 40 tekrarlı üçüncü derin öğrenmenin ilk sinir ağı öğrenme yapılandırmasının rmse hatasının sonucu .....	63
Şekil 5.9. 40 tekrarlı üçüncü derin öğrenmenin ilk sinir ağı öğrenme yapılandırmasının fit sonucu.....	64
Şekil 5.10. Farklı yöntemlerin doğruluğunu karşılaştırması.....	65

## TABLolar DİZİNİ

Tablo 5. 1. Tiroit hastalığı veri setinin genel bilgisi .....	55
Tablo 5. 2. Tiroit hastalığı veri setinin öznitelik açıklaması.....	56
Tablo 5. 3. . Birinci derin öğrenme sinir ağı yapılandırma özellikleri.....	59
Tablo 5. 4. İkinci derin öğrenme sinir ağı yapılandırma özellikleri.....	59
Tablo 5. 5. Üçüncü derin öğrenme sinir ağı yapılandırma özellikleri .....	59
Tablo 5. 6. Simulasyon sonuçları.....	60
Tablo 5. 7. 40 imparatorluk ile 3. yapılandırma sonuçları.....	65



# 1. GİRİŞ

Vücuttaki en büyük bezlerden biri olan tiroit bezi, gırtlığın enine bölümünde yer alır. Bu bez tarafından salgılanan tiroit hormonları, vücudun metabolizmasını hızlandırmada derin bir etkiye sahiptir. Tiroit, sırasıyla tiroksin (T4) ve triiodothyronine (T3) olmak üzere iki önemli ve bağımlı hormon salgılar. Tiroit salgılanması esas olarak ön hipofiz bezinden salgılanan tiroit uyarıcı bir hormon (TSH) tarafından kontrol edilir. Tiroit hormonlarının fizyolojik etkileri arasında artan hücrel metabolik aktivite, tiroit hormonunun büyüme üzerindeki etkisi, solunum değişiklikleri, kardiyovasküler sistem üzerindeki etkisi, kas fonksiyonu ve uyku bulunur. Tiroit bezinde, hastada bulunan hormonal salgı miktarı ve semptomlar nedeniyle genellikle iki tip hipotiroitizm ve hipertiroitizm vardır. Tiroit fonksiyonunun, vücudun birçok temel organı üzerinde derin bir etkisi vardır. Tiroit bozukluğu hemen teşhis edilmezse, hasta tiroit atağı veya miksuma geliştirebilir ve ölebilir (Saiti vd, 2009a).

Kanda fazla tiroksin akması ihtimaline karşı hipofiz, oluşturulan Tiroit Uyarıcı Hormon ölçüsünü azaltır ve bu da tiroit hareketinin çok yavaş olmasına neden olur. Ait olmayan etkilerini uygulamak için, tiroksin, bir iyot partikülünün atılmasıyla triiodothyronine dönüştürülür. Bu çoğunlukla karaciğerde ve örneğin zihinde triiodothyroninenin etki ettiği belirli dokularda olur. Tiroit organı tarafından iletilen tiroksinin ölçüsü, serebrumun tabanında bulunan hipofiz organında yapılan başka bir hormon tarafından kontrol edilir ve tiroit canlandırıcı hormon (kısaltılmış Tiroit Uyarıcı Hormon) olarak adlandırılır. Hipofizin dolaşım sistemine gönderdiği Tiroit Uyarıcı Hormon ölçüsü, hipofizin gördüğü tiroksin ölçümüne dayanır. Hipofizin neredeyse hiç tiroksin görmemesi durumunda, tiroit organına daha fazla tiroksin vermesini tavsiye etmek için daha fazla tiroit uyarıcı hormon oluşturur. Dolaşım sistemindeki tiroksin belirli bir seviyenin üzerine çıktığında, hipofizin tiroit uyarıcı hormon üretimi kapatılır. Doğrusu, tiroit ve hipofiz, bir radyatör ve bir iç mekân regülatörü gibi çeşitli açılardan hareket eder. Radyatörün kapalı olduğu ve soğuduğu noktada, iç mekân regülatörü sıcaklığı inceler ve daha sıcak olanı açar. Sıcaklığın uygun bir seviyeye yükseldiği noktada, iç mekân regülatörü bunu algılar ve radyatörü kapatır. Bu şekilde, tiroit ve hipofiz, daha sıcak ve kapalı bir düzenleyiciye benzer şekilde açılır ve kapanır (Razia ve Rao, 2016).

Tiroit bezi sorunları o kadar yaygındır ki, dünya çapında yaklaşık 1,5 milyar

insanın tiroit sorunları vardır. Hipotiroitizm en yaygın olanıdır, ancak hipertiroitizm de mümkündür. Subklinik hipotiroitizm ayrıca 60 yaşın üzerindeki insanların% 20'sini etkileyen önemli bir durumdur. Endokrin Klinisyenleri, subklinik hipotiroitili çoğu hastanın tedaviye ihtiyacı olduğu konusunda hemfikirdir. Bu bozukluğa sahip hastalar asemptomatik olabilmesine rağmen, bazı hastalarda lipid metabolizması, kardiyak bozukluklar, gastrointestinal, sinirsel ve psikolojik bozukluklarda değişiklikler ve üreme ve artan guatr riski dahil olmak üzere hafif semptomlar vardır. Subklinik hipotiroitizmi anlamak için doktor eğitimi ve hasta bilinci çok önemlidir(Sreekanth, 2013).

Araştırmalara göre tiroit bozuklukları vücudun tüm organlarını (hücreleri) ve vücudunuzun kullandığı yağ ve karbonhidrat miktarını etkiler. Bu nedenle, bu hastalar için doğru diyet, vücudun optimal vücut fonksiyonunu sürdürmek için ihtiyaçlarını karşılayan sağlıklı ve dengeli bir diyettir. Bu koşullarda ihtiyaç duyulan enerji miktarı% 60-50 artar. Hipertiroitizm: Vitamin ihtiyacının artması nedeniyle C vitamini takviyeleri, B vitamini kompleksi, özellikle B1, B2 ve B12 vitaminlerinin diyetle birlikte kullanılması oldukça faydalıdır. Genel olarak multivitaminlerin ve multimineralerin kullanılması tavsiye edilir. Bu hastaların diyetine dahil edilmesi gereken yukarıdaki vitaminlerin besin kaynakları: mango, narenciye, kivi, süt ve ürünleri, yeşil sebzeler, baklagiller ve balıktır. Hipotiroitizmin diyet modelinde tüketime uygun besinler şunlardır: ıspanak, çilek, domates, muz, havuç, yumurta, sarımsak, mantar, soğan, patates, bezelye, kabak, baklagiller, turplar, az yağlı yoğurt Ve deniz mahsulleri. Bu besinler guatrojenler tarafından kaybedilen iyotun yerini alabilir. Ispanak gibi bazı yiyeceklerin aslında guiterojenik yiyecekler listesinde olmasına rağmen, iyot içeriğinin guiterojenik etkilerini ortadan kaldırmak için yeterli olduğuna dikkat edin Sonuç: Doğru beslenme, tiroit bozukluklarının semptomlarını iyileştirmede çok olumlu bir etkiye sahiptir. (Tiroksin T-4) ve (Triiyodotironin T-3) protein üretimini kontrol etmeye yardımcı olur, Zn, Cu ve tirozin varlığı iyot emilimini artırmada çok etkilidir (Zeinae, 2016).

- Araştırmanın Amacı ve Hedefi

Tiroit bozukluğu sıklıkla yanlış teşhis edilir ve uzun süre tedavi edilmeden bırakılırsa, acil tiroit hormonu enjeksiyonu gerekir. Tiroit hastalığının teşhisi, kan testleri, görüntüleme testleri ve hastanın sağlık durumu hakkında sorgulama gibi çeşitli faktörleri içeren bir süreçtir. Bu nedenle, bu semptom ve testler listesinden, tiroit tanısı için en bilgilendirici ve faydalı birkaçını tanımlamamız gerekir. Bu yazıda, tiroit hastalığının tanısına maksimum katkı sağlayan en önemli ve temel özellikleri bulmak için Tiroit veri setine Derin Öğrenme yöntemleri uygulanmıştır. Derin öğrenme, örüntü tanımda ve yüksek boyutlu veri kümelerinden kestirim modelleri oluşturmada gösterdiği güçlü yanları nedeniyle, sağlıkla ilgili uygulamalar için sezgisel bir çekiciliğe sahiptir. Bu analitik yetenekler, sağlık disiplinleri arasında temel ve uygulamalı araştırmacılar için oldukça yararlı olmuştur.

Hastalığın teşhisi herhangi bir doktor için önemli bir rol oynar ve esastır. Tiroit hastalığı bu hastalıklardan biridir ve bilgisayar teknolojisi olmadan tahmin etmek zordur. Örüntü tanıma sisteminin nihai hedefi, problem için mümkün olan en yüksek sınıflandırma oranını elde etmektir. Tek başına tüm problemler için tamamen uygun olan bir sınıflandırma algoritması bulunmadığından, bunların etkinliğinin artırılması için bir çözüm olarak önerilmesi önerilmektedir. Derin öğrenme teknikleri, hastalıklardan muzdarip insanların olasılığını tahmin etmek için spesifik hastalıkların teşhisinde bir doktor asistanı olarak kullanılabilir. Şimdiye kadar, derin öğrenmenin klinik uygulamaları radyoloji, radyoterapi, patoloji, oftalmoloji, dermatoloji ve görüntü kılavuzluğunda cerrahi gibi görüntü yoğun alanlarda hızla kullanılmıştır. Görüntülerin derin öğrenme sistemleri tarafından yorumlanması konusunda birçok vakada, bu sistemlerin uzman doktorlara göre çok daha iyi bir performans sergiledikleri görülmüştür. Bu çalışma derin öğrenmenin ne olduğunu, nasıl çalıştığını ve sağlık alanında kullanım potansiyelini ortaya koymaktadır. Bu potansiyel araştırılırken sağlık alanındaki pek çok derin öğrenme çalışması gözden geçirilerek bir araya getirilmiştir. Bu bağlamda çalışmanın alana önemli katkı sağlayacağı öngörülmektedir.

- Araştırmanın Niteliği

İnsanlar sağlıklarına büyük önem vermekte ve maliyeti ne olursa olsun en iyi bakım ve hizmeti talep etmektedir. Bu yüzden bu endüstriye karşı diğerlerinden daha duygusaldırlar. Sağlık endüstrisinin odak noktası, nüfus sağlığının iyileştirilmesi, bakım maliyetlerinin düşürülmesi ve hasta deneyimlerinin iyileştirilmesidir. Makine öğrenme tıbbi görüntüleme alanında kullanılır ve bilgisayar destekli tanı, görüntü bölütleme, görüntü kaydı, görüntü çıkarma ve görüntü kılavuzlu tedavi gibi çeşitli hizmetleri kolaylaştırır. Derin Öğrenme makine öğrenme altında bir dizi yeni algoritmadır. Bu algoritmalar çoklu temsil ve soyutlama seviyelerini otomatik olarak öğrenecek şekilde, veriyi anlamlandırmada yardımcı olmak için tasarlanmıştır. Alan Uzmanları, tıpta derin öğrenme yöntemlerini dikkatle değerlendirmektedir. Derin öğrenme teknolojisinin kullanıldığı belirli uygulamaların başında: Hızlı Teşhis, Genomik Analizler ile Kişiselleştirilmiş Sağlık, Bilgisayar Destekli Teşhis, Sağlık Sigorta Dolandırıcılığı ve İlaç keşfi gelmektedir (Keleş, 2018).

Hipertiroiti graves hastalığı, sıcak nodüller, tiroit bezinin iltihaplanması ve tiroit kanseri gibi nedenlerle oluşabilir. Aşırı iyot alınması, aşırı tiroit hormonu alınması ve genetik faktörler de hipertiroite neden olur. Hipertiroit kadınlarda erkeklere oranla daha sık görülür. Hipertiroiti tedavi edilmezse ya ya geç tedavi edilir ise hastada kilo kaybı devam eder; kalpte ritim bozukluğu, kalp yetmezliği, iltihap veya enfeksiyon sırasında tiroit krizi, şok ve ölüm ile karşı karşıya kalınabilir. Hızlı çalışan tiroit bezleri osteoporoz (kemik erimesi) gibi hastalıklara da neden olabilmektedir. bu nedenle bizim yaptığımız bu projenin farklılığı ve yeniliği teşhisin doğruluğunun artması ve teşhisin hızlı olmasıdır (Covelli ve Salvi, 2018).

Alandaki hangi eksiği nasıl gidereceği veya hangi soruna nasıl bir çözüm getireceği Derin öğrenme tabanlı sistemler tıbbi verilerdeki örüntüyü keşf ederek, karar alma sürecini iyileştirebilir, böylece tedavi maliyetlerini etkileyebilir ve sağlık hizmetlerinin kalitesini artırabilir. Bu yöntemle tasarlanan, ağ sinir ağlarına göre en az hataya sahiptir. Ayrıca, sömürge rekabet algoritması ile birleştirilen derin öğrenme modelinin öngörme hata oranı, performans değerlendirme kriterleri açısından yapay sinir ağı yönteminden daha üstündür. Çalışmamızda sonraki bölümlerde tiroit hastalığı, bu hastalığın teşhisi, teşhisde özellik seçimi ve özellik seçiminde kullanılan algoritmalar ile alakalı kapsamlı ve detaylı anlatımlar olacaktır.



## 2. TİROİT HASTALIĞI, TEŞHİSİ VE HİPOTROİDİZM

Tiroitin görevi, kana salgılanan ve daha sonra vücuttaki her dokuya taşınan tiroit hormonlarını üretmektir. Tiroit hormonu vücudun enerji kullanmasına, sıcak kalmasına ve beynin, kalbin, kasların ve diğer organların olması gerektiği gibi çalışmasını sağlar. Hipotiroitizmin en yaygın nedeni, tiroitit ve tiroit bezinin iltihabı olarak bilinen bir hastalıktır. En sık görülen tiroitit türü Hashimoto hastalığı olarak adlandırılır. Bu hastalıkta, bağışıklık sistemi - vücudunuzun hastalığa karşı doğal savunması - tiroit bezindeki hücreleri zararlı istilacılarla karıştırır. Vücudunuz, tiroit bezini yok etmek için beyaz kan hücreleri gönderir. Hipofiz bezi daha sonra tiroit bezine daha fazla tiroit hormonu üretmesini söylemek için TSH salgılar. Tiroit bezine olan bu talep büyümesine neden olabilir. Bu genişlemeye guatr denir. Hipotiroitizm, yeterli iyot içermeyen bir diyetten de kaynaklanabili (Parvathaneni vd, 2012).

Tiroit bezi hastalığı, dünyada en çok görülen endokrin bozukluklar arasındadır ve sadece şeker hastalarından sonra ikinci sıradadır. Hiperfonksiyon - hipertiroitizm - ve ayrıca hipofonksiyon - hipotroidizm - sırasıyla% 2 ve% 1 civarında ortaya çıkar. Erkeklerde görülme sıklığı, kadınlarınkinin yaklaşık yüzde biri kadardır. Hiper ve hipotroidizm, hipofiz bezinin işlev bozukluğuna ikincil olarak tiroit bezinin hastalığına veya hipotalamustaki işlev bozukluğuna bağlı olabilir. Guatr veya aktif tiroit nodülleri, diyetteki iyot eksikliğine bağlı olarak bazı bölgelerde% 15'e varan bir prevalansla endemik olarak ortaya çıkabilir. Tiroit bezi ayrıca çeşitli tümör türlerinin yeri olabilir ve endojen antikolar (otoantikolar) tarafından hasar görebilir. İyot eksikliğine veya tiroit bloke edici ajanlara bağlı şiddetli maternal hipotiroitizm, tedavi edilmezse yenidoğanlarda kretinizme neden olabilir. Bu durumun tanınması hayati önem taşımaktadır. Pek çok ülkede yenidoğanların tiroit uyarıcı hormonu (TSH) ölçülerek taranması bu nedenle zorunlu hale gelmiştir. Örnekleme doğumdan sonraki ilk ila ikinci veya 5. ila 7. gün arasında yapılmalıdır

(Heuck vd, 2000).

- Hamile kadınlarda tiroit hastalığı

Tiroit, hamilelik sırasında çoğu kadını etkileyen en yaygın hastalıklardan biridir. Tiroit bozukluğu olan sağlıklı kadınlarda gebeliğin tiroit fonksiyonunun düzenlenmesinde önemli etkileri vardır. Bu etkiler iyi bilinmeli, uygun şekilde değerlendirilmeli ve yorumlanmalı ve uygun şekilde yönetilmelidir. İyot eksikliği olan bölgelerde yaşayan kadınlarda gebelik sırasında hipotiroitizm ve guatr oluşma eğilimi ortaya çıkar. Gebeliklerin% 2 ila 3'ünde önemli ölçüde klinik tiroit disfonksiyonu görülür, ancak subklinik vakalar muhtemelen daha yaygındır ve sıklıkla teşhis edilmez. Gebelik sırasında iyot eksikliği, hipertiroitizm veya hipotiroitizm nedeniyle maternal tiroit fonksiyonundaki değişiklikler. Tiroit bezinin fetüs / bebek için önemli sonuçları olacaktır. Hamilelik, bazal metabolizma, kan akışı, kalp atış hızı ve kalp atış hızını artırır ve yorgunluk ve ısı intoleransı dahil birçok semptom hipertiroitizm olasılığını düşündürür. Gebelik sırasındaki diğer metabolik değişiklikler arasında tiroit bezinin İnsan koryonik gonadotropin tarafından uyarılması ve artan plasental deodinaz enzimlerine bağlı olarak tiroksin metabolizmasının hızlanması yer alır, böylece hipotiroitili gebe kadınlarda eksojen tiroksin ihtiyacı% 50'ye kadar artar. Gebelikte tirotoksikozun ana nedenleri Graves hastalığı ve gebelikte geçici hipertiroitizmdir. Graves hastalığının hamilelikteki doğal seyri, hastalığın ilk trimesterde kötüleşme eğilimi, ikinci ve üçüncü trimesterde kademeli olarak iyileşmesi ve doğumdan sonra hastalığın tekrar kötüleşmesidir. Bebeklerde ve fetüslerde hipertiroitizm, maternal T tiroit uyarıcı hormonu reseptörü uyarıcı antikörlerin plasentadan geçişinden kaynaklanabilir. Taşikardi, hızlanan kemik büyümesi ve fetal büyüme geriliği nedeniyle fetal hipertiroitizm tanısı konulabilir. Gebelikte hipertiroitizmin tedavisi etkilidir ancak yeterli özen, bilgi ve beceri ile yapılmalıdır (Azizi, 2008).

- Yaşlılarda ve gençlerde tiroit hastalığı

Yaşlılarda tiroit hastalıkları sıklıkla yaşlanma sürecinin semptomlarına çok benzeyen atipik semptomlarla kendini gösterir. Tiroitit, yaşlılarda sık görülen bir tiroit patolojisidir ve yaşlı hipotiroitizmin ana nedenini temsil eder. Yaşlı hipotiroit hastalarında yorgunluk, kilo alma, kabızlık, kas krampları, cilt değişiklikleri olabilir. Ayrıca, birden fazla kronik hastalığın bir arada bulunması ve ilaçların yan etkileri, hipotiroitizmin semptom ve bulgularını taklit edebilir veya maskeleyebilir. Ayrıca

yaşlılarda hipotiroitizm sıklıkla subklinik olarak ortaya çıkar. Yaşlılarda hipertiroitin klinik tablosu genellikle genç hastalardakinden önemli ölçüde farklıdır. Bu hasta grubunda kardiyovasküler semptomlar ve belirtiler baskındır, ayrıca daha yüksek bir atriyal fibrilasyon riski vardır. Hipertiroitizmi olan yaşlı hastalarda görülen diğer semptomlar arasında yorgunluk, iştahsızlık, kilo kaybı, apati, depresyon yer alır. Bu semptomlar spesifik değildir ve normal yaşlanma ile kolaylıkla karıştırılabilir (Faggiano vd, 2011).

Bunun yerine, genç hastalarda hipertiroitizmin klasik semptomları ve bulguları arasında titreme, sinirlilik, hiperhidroz, hiperaktivite, hipokolesterolemi, zayıflama ve ekzoftalmi bulunur. Yaşlılarda tedavi dikkatlice değerlendirilmelidir. Yaşlı hastalarda tiroit cerrahisinin güvenliği tartışmalıdır. Yaşlılarda asemptomatik hipertiroitizm, tiroit cerrahisi için bir gösterge değildir. Rios vd. hastalar preoperatif dikkatlice hazırlandıklarında ve komorbiditelerin yakın takibi ile ameliyat edildiklerinde yaşlı ve genç gruplar arasında postoperatif morbidite ve mortalitede herhangi bir farklılık olmadığını göstermiştir. Çalışmamızda yaşlılarda ve daha genç hasta gruplarında tiroit hastalıklarının görülme sıklığındaki farklılıkları değerlendirdik. Her iki grupta da guatr en yüksek insidanslı hastalıktır ve bu nedenle tedavi seçimi çok önemlidir. L-tiroksin, tiyonamidler, cerrahi, radyoiodot ve perkütan etanol enjeksiyonu (PEI) seçilmiş hastalarda etkilidir. Ayrıca 65 yaş ve üstü grupta yüksek tiroitit insidansı vardı. Benign neoplastik hastalıklar (adenomlar) ve papiller kanser daha genç grupta bulundu (Cannizzaro vd, 2016).


- Tiroit Hastalığının Teşhisi

Tiroit bozuklukları, çocukluk çağında çok sayıda klinik sunumla birlikte yaygın bir endokrin problemdir. Tiroit fonksiyon testlerinin kolay bulunabilirliğinin artmasıyla, tedavi eden hekim sıklıkla ya klinik profille uyumlu olmayan ya da dahili olarak tutarsız görünen raporlarla karşı karşıya kalır. Test performansında sıklıkla teknik sorunlar olsa da, test sonuçlarının yorumlanmasını karıştırabilecek birçok başka değişken vardır (Schiefer ve Fatourech, 2010).

Günümüzde, hem hipertiroitizm hem de hipotiroitizm teşhisini büyük bir hassasiyetle yerleştirmek için yeterli sayıda hem oldukça hassas hem de spesifik tiroit fonksiyonu ölçüsü mevcuttur. Levotiroksin (T4) ve triiyodotironinin (T3), hipofiz sentezini ve tiroit uyarıcı bir hormon (TSH) olan tirotropinin salınımını

düzenlediği klasik "geri bildirim" döngü mekanizmasına dayanarak, bu mümkündür. esasen her durumda tiroit hastalığı tanısı koymak oldukça hassas bir TSH testi ile mümkündür. Açık hipotiroitizmi olan hastalarda, Levotiroksin (T4) geribildirim eksikliği TSH seviyelerinin > 20 mIU / L'ye yol açarken, daha hafif veya belirti göstermemiş hipotiroitizmde Tiroit Uyarıcı Hormon (TSH) seviyeleri normal Levotiroksin (T4) ve triiyodotironinin (T3) seviyeleri ile 3 ila 20 mIU / L arasındadır. Hipertiroitizmde <0.1 mIU / L'ye kadar bastırılan TSH seviyeleri eşlik eder. Bu nedenle TSH testi, tiroit hastalığından etkilendiği bilinen çeşitli klinik durumlarda tiroit işlev bozukluğunu taramak ve şüpheli bir teşhisi doğrulamak ve tedaviye yanıtı takip etmek için uygun başlangıç testidir. Çeşitli yazarlar, TSH için referans aralığının, özellikle hipotiroitizmin mevcut olabileceği üst sınır açısından daraltılmasını önermişlerdir. Bu konuyla ilgili kapsamlı bir tartışma için Demers ve Spencer'a bakılır (Klein ve Danzi, 2007).

Birincil hipotiroitizm, bireyin hemen hemen asemptomatik olduğu ancak biyokimyasal anormalliklere sahip olduğu çok hafif vakalardan yaşamı tehdit eden miksödem koması ile ortaya çıkan çok şiddetli vakalara kadar değişen dereceli bir durumdur. Hastalığın başlangıcı sinsi olduğu için, bariz belirti ve bulgular hastalık sürecinin geç dönemlerinde ortaya çıkabilir ve nonspesifik olabilir. Hipotiroitizmde neredeyse her zaman mevcut olan en yaygın semptom, genelleşmiş halsizlik veya yorgunluktur. Diğer yaygın semptomlar arasında kuru ve kaba cilt, kilo alımı, uyuşukluk ve kabızlık bulunur (Şekil 2.1). Hipotiroit hastaları tarafından bildirilen semptomlar spesifik değildir ve daha geniş ötiroid yetişkin popülasyonunda yüksek prevalansa sahiptir. Örneğin, örnekleme sırasında tiroit durumlarının farkında olmayan katılımcıların popülasyona dayalı bir anketinde, yorgunluk semptomu, sırasıyla ötiroidizm ve hipotiroitizm hastalarının % 40 ve % 80'inden fazlası tarafından rapor edilmiştir. Hipotiroit semptomların varlığı düşük duyarlılığa ve pozitif tahmin değerine sahiptir. Bununla birlikte, TH eksikliğinin ciddiyetine bağlı olarak bildirilen semptomların sayısının kademeli bir yaygınlığı vardır: açık hipotiroitizmde subklinik hipotiroitizmden daha fazla semptom mevcuttur. Bu nedenle klinik hipotiroit şüphesinin kan testi ile doğrulanması gerekir (Ashraff ve Razvi, 2017).



Şekil 2.1. Yetişkinlerde yaygın hipotiroitizm semptom ve bulgularının yaygınlığı

- Hipotiroitizm teşhisi nasıl yapılır?

Hipotiroitizmin doğru teşhisi aşağıdakilere bağlıdır: (So vd, 2012)

- Belirtileriniz
- Tıbbi geçmişinizin fizik muayenesi (örneğin ilaçlar, önceki tiroit ameliyatı veya boynunuza radyasyon)
- Aile geçmişiniz (örneğin, bir aile üyenizde tiroit hastalığı varsa)
- Tiroit Uyarıcı Hormon (TSH) testi:

Bu test, kanınızdaki **Tiroit Uyarıcı Hormon (TSH)** miktarını ölçer. **Tiroit Uyarıcı Hormon (TSH)**, hipofiz bezi tarafından yapılır. (Hipofiz bezi beyin tabanında bulunur ve bir dizi farklı hormon üretir). **Tiroit Uyarıcı Hormon (TSH)**, tiroitin ne kadar triiodotironinin (T3) ve Levotiroksin (T4) hormonu yapması gerektiğini belirler. Yüksek TSH seviyesi, tiroit bezinin yeterli triiodotironinin (T3) ve Levotiroksin (T4) hormonu üretmediği anlamına gelir (So vd, 2012).

- T4 ve T3 testi.


Hipotiroitizmin bazı nedenleri için, tek başına bir TSH testi hastalığı tespit etmek için yeterli olmayacaktır. **Levotiroksin (T4)** ve **triiodotironinin (T3)** testleri kanınızdaki bu hormonların miktarını ölçer. Son yıllarda hipotiroitizmin teşhisi konusunda bazı tartışmalar olmuştur. Bazı hastaların Tiroit Uyarıcı Hormon (TSH) ve **Levotiroksin (T4)** testleri normal aralıkta olmasına rağmen semptomları var gibi görünmektedir. Bu sorunu çözmek için, TSH için normal aralıklar son on yılda değiştirildi. Ayrıca subklinik hipotiroitizm adı verilen yeni bir hastalık kategorisi oluşturulmuştur. Bu tanı, bir hasta normal kan testlerine sahipken, ancak düzgün çalışmayan bir tiroit bezine sahip olduğunda yapılır (So vd, 2012).

- ve bir veya daha fazla kan testi

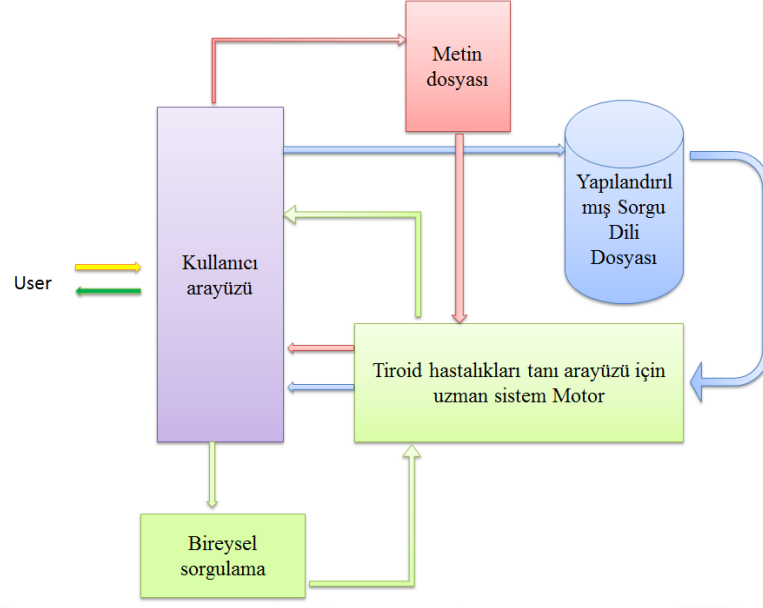
### 3. LİTERATÜR TARAMASI

Tiroit hastalığının teşhisi ile ilgili literatür taraması gösteriyor ki karar ağacı, k-en yakın komşular, genetik algoritma, yapay sinir ağları, bulanık sinir ağları, destek vektör makinesi Vb gibi tiroit tipini belirlemek için farklı veri madenciliği ve yapay zeka yöntemleri kullanılıyor. Araştırmanın bu bölümü, çalışmamızın tiroit bezi teşhisi ile aynı amacı taşıyan mevcut çalışmalarla karşılaştırmasını içermektedir.

Keleş kardeşler 2008 yılında çalışmalarında uzman sistem adı verilen yöntemi tiroit hastalığı tanısı için kullandılar. Tiroit hastalığı tanısı için uzman sistem, endokrinologlara veya öğrencilere sunulan bir araçtır. Uzman sistem, tiroit hastalıkları için% 95.33 doğrulukla bir öngörü teşhisi oluşturabilir. Ayrıca, bu araç daha fazla referans için hasta kayıtlarını veri tabanında saklar. Keleş kardeşlere göre bu uzman sistemi eğitim sürecinde kullanmak, doktorlar için devasa, sert kaplı materyallerden daha renkli bir ortam sağlıyor. Tiroit hastalıkları için endokrinoloji okuyan öğrenciler, tahminlerini uzman sistem ile karşılaştırarak bilgilerini test etmek için bu sistemi kullanabilirler.Keleş kardeşler 2008 yılında Tiroit veri seti için en iyi sınıflandırma modelini incelediler. Sonuç olarak, beş giriş, yirmi kural ve üç çıktı içeren en iyi model ve sınıflandırma doğruluğunda% 95.33 artış (Şekil 3.1), 10 kat doğrulama yöntemi kullanılarak elde etdiler. Bu modelin bulanık kuralları, uzman sistemde bir çıkarım motoru olarak tiroit hastalığını teşhis etmek için kullanıldı (Şekil 3.2) (Keleş ve Keleş, 2008).



Şekil 3.1. Tiroit hastalığı teşhis çıkarım motoru için uzman sistemler için beş giriş, 20 kural ve üç çıktı içeren nöro bulanık model.



Şekil 3.2. Tiroit hastalıkları tanı sistemi için Uzman sistemin çalışma şeması

Saiti vd. 2009 yılında Çalışmalarında Tiroit Hastalığı Teşhisi için Genetik Algoritmalara Dayalı PNN ve SVM kullandılar. Bu çalışmada genetik algoritma ile seçilen özellikler tiroit hastalığını teşhis etmek için klinik özelliklerle aynıdır. Tiroit hastalığı teşhisinde Duyarlılık, gerçek olumlu kararların sayısı / gerçekte olumlu durumların sayısına ve özgüllük, gerçek olumsuz kararların sayısı / gerçekte olumsuz durumların sayısına şeklinde hesaplanmıştır. Sınıflandırıcının pozitif tespiti, hekimin pozitif tespiti ile çakıştığında gerçek bir pozitif karar oluşur. Hem sınıflandırıcı hem de doktor pozitif bir tespitin olmadığını önerdiğinde gerçek bir olumsuz karar verilir. Saiti ve arkadaşları UCI web sitesinden (<http://ics.uci.edu>) almış oldukları 7200 örnek ve normal, hipertiroitizm ve hipotiroitizm olmak üzere 3 sınıftan oluşan 21 özellik içeren veri seti üzerinde uyguladıkları bu yöntem ile Sınıflandırma doğruluğunu 3.1 ve 3.2'inci formül ile 96.8% elde etmişler ki bu formülde  $N$ , sınıflandırılacak veri öğeleri kümesidir (test kümesi),  $n \in N$ ,  $n_c$ ,  $n$  öğesinin sınıfıdır, sınıflandır (n), PNN ve SVM'ye göre n sınıflandırmasını döndürür (Saiti vd, 2009b).

$$\text{Sınıflandırma doğruluğu}(N) = \frac{\sum_{i=1}^{|N|} (n_i) \text{hesaplamak}}{|N|} \quad (3.1)$$

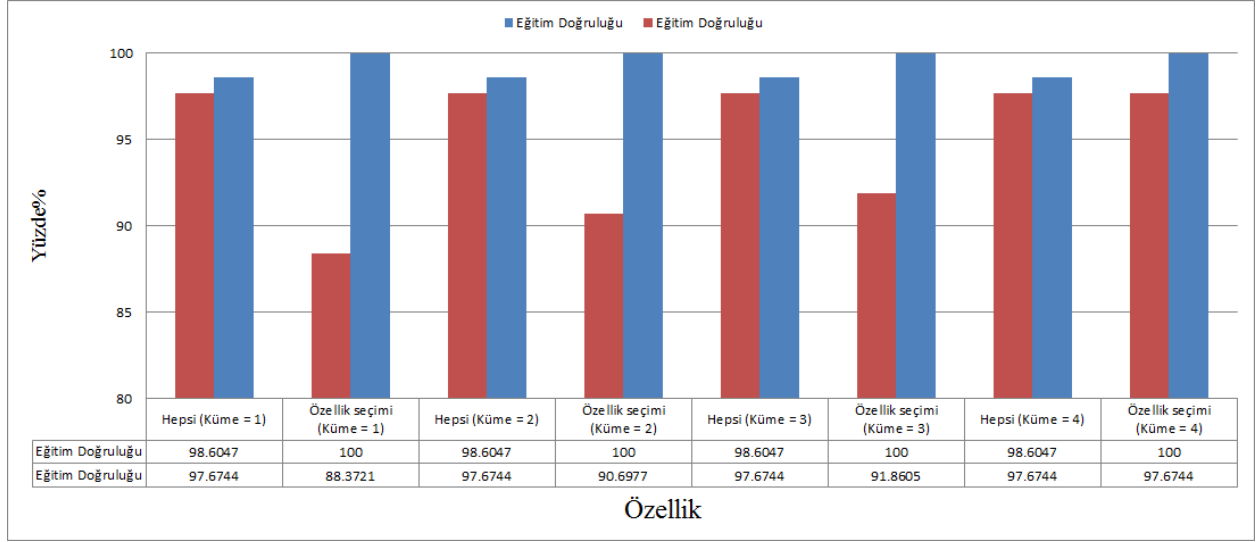
$$n \text{ hesaplaması} = \begin{cases} 1 & \text{eğer } n' \text{inci sınıflandırması} = n_c \\ 0 & \text{aksi taktirde} \end{cases} \quad (3.2)$$

Dr.Sarah Behnam Aziz 2011 yılında tiroit hastalığı teşhisi için genetik algoritma ve sinir ağını Kullandı. Bu çalışmada, ikinci dereceden eğitim algoritması ile sinir ağlarını kullanarak tiroit hastalığı teşhisi üzerine bir çalışma sunmaktadır. Genetik algoritma,



yüksek sınıflandırma doğruluğu ile optimum ağ yapısını bulmak için kullanılmıştır. Üç farklı oranda eğitim / test grupları oluşturulur. Sonuçlara göre sinir ağı yapılarının tiroit hastalığının teşhisine yardımcı olmak için başarıyla kullanılabileceği görüldü. Burada vurgulanan bir diğer önemli husus, ağların genelleme yeteneğidir. Böylece eğitim setinde bulunmayan girdiler için bir sinir ağının performansı görülebilir. genetik sinir ağı tekniklerinin performansını karşılaştırmak için öncelikle UCI veb sitesinden alınmış veri seti normalize edilerek eğitim seti ve test seti gruplarına ayrılmıştır. Bölme işlemi, farklı eğitim / test grupları oluşturmak için her seferinde belirli oranlarda (% 10 ila% 90,% 30 ila% 70 ve% 50 ila% 50) rastgele üç kez yapıldı. Her eğitim / test çifti için genetik algoritma, yüksek doğruluk sağlayan optimum ağ topolojisini bulmak için beş kez uygulandı ki bu yapılandırdan sonra genel doğruluk, eğitim için% 100 ve test için% 97.41 aralığında bulunmuştur (Aziz, 2011).

Bir diğer çalışmada, Ahmad Taher Azar ve Aboul Ella Hassanien 2014 yılında tiroit hastalıklarının teşhisi için dilbilimsel korumalar seçilmiş özelliklere sahip sinir-bulanık sınıflandırıcı sundular. Bu sistemin performans değerlendirmesi, sınıflandırma doğruluğu ve k-kat çapraz doğrulama kullanılarak tahmin edilir. Sonuçlar, özellik seçimi olmadan sınıflandırma doğruluğunun eğitim ve test aşamaları sırasında sırasıyla% 98.6047 ve% 97.6744 olduğunu ve kök ortalama kare sapma 0.02335 olduğunu gösterdi. Özellik seçim algoritması uygulandıktan sonra, dilbilimsel korumalar, seçilen özelliklere sahip sinirsel-bulanık sınıflandırıcıyı eğitim aşamasında tüm küme boyutları için% 100'e ulaştı. Bununla birlikte, test aşamasında, seçilen özelliklere sahip nöral-bulanık sınıflandırıcı, her sınıf için bir küme kullanarak% 88.3721, iki küme kullanarak% 90.6977, üç küme kullanarak% 91.8605 ve her sınıf için dört küme ve 12 bulanık kural kullanarak% 97.6744 elde etmiştir. Elde edilen sınıflandırma doğruluğu, bu problem için literatürdeki diğer sınıflandırma uygulamaları açısından çok umut vericiydi (Taher Azar ve Hassanien, 2014)



Şekil 3.3. Dilbilimsel korumalar seçili özelliklere sahip sinir-bulanık sınıflandırıcı özellik seçimi ve her sınıf için küme boyutuna göre tiroit hastalığının sınıflandırma sonuçları

Diğer çalışma Geetha ve Baboo tarafından 2016 yılında iki panele sahip olacak şekilde tasarlanmıştır. Biri gösterge paneli ve diğeri analiz paneli. Veriler için 21 çalıştırma gerçekleştirildi. Stabilizasyon sağlandıktan sonra veriler 3 sınıfa ayrılır. 1. Hipo Tiroit 2. Hiper Tiroit 3. Normal Sınıflandırma doğruluğu% 97.5 olarak elde edilmiştir. Sınıflandırıcıya erişmek ve çıktı sınıflarını karşılaştırmak amacıyla alıcı çalışma karakteristiği kullanıldı. alıcı çalışma karakteristiği, her bir tiroit sınıfını Gerçek Pozitif oranı ve Yanlış Pozitif oranına göre karşılaştırır. Sonuçlar, önerilen evrimsel çok değişkenli bayisean tahmin sınıflandırıcı modelinin, UCI veri havuzundan elde edilen 7200 tıbbi veri kümesinden dikkate değer boyutlarda azalma sağladığını göstermektedir. Sonuçlar on değerlendirme ölçütüne göre değerlendirilir ve sınıflandırmanın doğruluğu% 97.5'tir (Geetha ve Baboo, 2016b).

Literatüde bi diğer çalışma Sahargerd vd. tarafından 2017 yılında tanımlayıcı-analitik bir çalışma yapılmış ve veritabanı 21 özelliğe dayanan ve UCI veri referansından alınan 7200 bağımsız kayıt içermektedir. Bu çalışmada, sinir ağı yöntemi ve sinir ağlarını genetik algoritma ile birleştirerek tiroit hastalığının teşhisi için yöntem sunulmuştur. Üretilen modelleri modelledikten ve karşılaştırdıktan sonra, sinir ağlarını genetik algoritma ile birleştirme yöntemi ile açıklama katsayısı 0.8299 ve ortalama kare hatası 0.0057 olan değerlendirme kriterlerini kullanarak tiroit hastalığını tahmin edebildiler. Bu yöntemle tasarlanan ağ, sinir ağlarına göre en az hataya sahiptir. Ayrıca, genetik algoritma kullanılarak birleştirilen yapay sinir ağı modelinin tahmin hatası miktarı, performans değerlendirme kriterleri açısından

yapay sinir ağı yönteminden üstünlüğünü gösterilmiştir. Sahagerd vd bu çalışmada vurguladıkları konu ise sinir ağı-genetik algoritma yöntemi, karmaşık süreçler için güçlü bir modelleme-optimizasyon yöntemidir ve çoğu durumda diğer yöntemlerden daha iyi çalışır. Sinir ağlarını ve genetik algoritmaları kullanmanın nedenlerinden biri, seçilen parametreleri tahmin için optimize etmektir, çünkü normalde bu parametreleri bulmak çok zaman alır. Bahsedildiği gibi, bu çalışmada, yapay sinir ağı yöntemleri ve yapay sinir ağlarının genetik algoritma ile kombinasyonu, tiroit hastalığını tahmin etmek için bir faktör olarak kullanılmıştır. Bu çalışmanın sonuçları, genetik algoritma ile birleştirilen sinir ağı modelinin göreceli başarısını göstermektedir. Ayrıca modelleme sonuçlarına göre, genetik algoritma ile birleştirilmiş sinir ağlarının kullanımının 0.82'lik bir açıklama katsayısına sahip olduğu, normal sinir ağı açıklama katsayısı olan 0.76'dan daha iyi bir performansa sahip olduğu söylenebilir (Sahagerd vd, 2017).

2017'de yapılan bir diğert çalışma Pavya ve srinivasan tarafından yapılmış. Pavya ve srinivasan çalışmalarındaki temel amacı, otomatik tiroit hastalığı bilgisayar destekli teşhisinde çeşitli adımlar arasında filtre tabanlı (f-skoru) ve sarıcı tabanlı (özyinelemeli özellik eleme) özellik seçim algoritmalarının hastalık tanımlama ve sınıflandırma üzerindeki etkisini analiz etmektir. Analiz aynı zamanda temel bileşen analizi boyutsallık azaltma algoritmalarıyla da gerçekleştirilir. Performans değerlendirmesi doğruluk, duyarlılık ve özgüllük olmak üzere üç ölçü ile yapılmıştır. Seçilen algoritmaları analiz etmek için çok katmanlı algılayıcı, geri yayılım sinir ağı, destek vektör makinesi ve aşırı öğrenme makinesi olmak üzere dört sınıflandırıcı kullanılmıştır. Deneysel sonuçlar, filtre ve sarıcı tabanlı özellik seçim algoritmalarının dahil edilmesinin tiroit hastalığı teşhisinin performansını artırdığını göstermiştir. Seçilen algoritmaların karşılaştırılması, özyinelemeli özellik eleme sarmalayıcı algoritmasının maksimum verimlilik (% 97.14) ürettiğini ve bunu, aşırı öğrenme makinesi sınıflandırıcısını kullanırken f-skor filtre algoritmasının (% 96.60) izlediğini ortaya koydu. Gelecekteki araştırmalar, özellik seçim sürecini ve sınıflandırıcı performansını iyileştirmeye yöneliktir (Pavya ve Srinivasan, 2017b).

2017 yılının bir diğert çalışması ise Zabbah vd. tarafından tiroit hastalığının teşhisi için hiyerarşik bir şekilde sinir ağlarının bir kombinasyonunu kullandılar. Bu çalışmada, tiroit hastalığının tanısını iyileştirmek için hiyerarşik sinir ağı bileşimi adı verilen yeni bir yöntem kullanılmıştır. Bu çalışmanın verileri, her biri 21 özellik

içeren 7.200 numuneden oluşan UCI veri tabanından elde edildi. Tiroit hastalığı ile ilgili klinik parametreler arasında 5 sürekli parametre kullanıldı; Ortalama tirotropin  $0.22 \pm 0.0048$ , ortalama tetradiothyronine  $0.359 \pm 0.109$ , ortalama TT4  $0.019 \pm 0.097$  ve TFI  $0.36 \pm 0.113$  ve karakteristik için anlamlılık seviyesi Yukarıdaki bağlaçlar sırasıyla 0.416, 0.194, 0.092, 0.139 ve 0.107 idi. Başlangıçta, hastalığın tüm klinik parametreleri dikkate alınarak çok katmanlı bir algılayıcı sinir ağı kullanıldı. 70 veriden yani 5040 hasta ağ eğitimi için kullanıldı ve% 30 yani 2160 hasta test için kullanıldı.İkinci aşamada, bu çalışmada sunulan algoritmayı test ettik. Böylece 7200 numuneden 166'sı sağlıklı ve 7034'ü hastaydı. Sonuçlar, hipotiroit hasta sınıfındaki toplam 368 örnekten yalnızca 12'sinin, yani %3.3'ünün hipertiroit sınıfında yanlış sınıflandırıldığını ve% 96.7'sinin doğru teşhis edildiğini göstermektedir (Zabbah vd, 2017).

Bir diğer çalışma ise 2020 yılında Chaubey vd. tarafından makine Öğrenimi yaklaşımlarını Kullanarak tiroit hastalığı tahmini yapmışlardır. Bu çalışmada, tiroit hastalığının tahmini alanında çalışmak isteyen araştırmacılara bir referans kaynağı sağlamak için yazılmıştır. Farklı makine öğrenimi tekniklerinden, performanslarını doğruluk açısından tahmin etmek ve değerlendirmek için yaygın olarak kullanılan üç algoritma, yani lojistik regresyon, karar ağaçları ve k-en iyi komşu algoritmaları karşılaştırılmıştır. Bu çalışma, tiroit hastalığının nasıl tahmin edileceğine dair sezgiyi temsil etmiş ve lojistik regresyonun, karar ağaçlarının ve k-en iyi komşu'nun bir sınıflandırma aracı olarak nasıl uygulanacağını altını çizmiştir. Bunun için, makine öğrenimi havuzunun tiroit veri seti, veritabanları arşivinde UCI bilgi keşfinden kullanılmıştır (Chaubey vd, 2020).

- Lojistik regresyon

Lojistik sınıflandırma, verileri sigmoid fonksiyonuna göre sınıflandırır.bu çalışmada veriler üç bölüme ayrılmıştır:

- Eğitim seti (% 70)
- Doğrulama seti (% 15)
- Test seti (% 15)

Bu tiroit veri setinde lojistik regresyon sınıflandırıcı değerlendirildiğinde,% 18.75'lik bir doğrulama yanlış sınıflandırma yüzdesi ve% 15.625'lik bir test yanlış

sınıflandırma yüzdesi gösterir. Eğitim verilerinin rastgele seçimi üzerine test verilerinin rastgele seçimi üzerine çizilen karışıklık matrisi, modelin ne kadar doğru olduğunu açıklar. Karışıklık matrisinden doğruluğun hesaplanması için formül şu şekilde verilmiştir:

Doğruluk

$$= \frac{\text{gerçek pozitif} + \text{gerçek olumsuz}}{(\text{gerçek pozitif} + \text{yanlış negatif}) + (\text{yanlış pozitif} + \text{gerçek olumsuz})} \quad (3.3)$$

Dolayısıyla doğruluk% 81.25 elde edilmiş (Chaubey vd, 2020).

- karar ağaçları

Toplam serum tiroksin ve toplam serum triiodotironin, kararların alınmasında özellik isimleri olarak seçilmiştir. Çıktının ürettiği sınıf, sınıf 0 (tiroit içeren) ve sınıf 1 (normal) olacaktır. Modeli hazırlamak için veri seti, eğitim seti (% 70) doğrulama seti (% 15) ve test seti (% 15). Algoritmanın performansını değerlendirirken, doğrulama yanlış sınıflandırma yüzdesini% 12,5 ve test yanlış sınıflandırma yüzdesini% 3,125 gösterir. Bu matrisin doğruluğunu aynı şekilde formül 3.3'ü kullanarak hesaplanmıştır yani burada hesaplanan doğruluk% 87,5'tir.(Chaubey vd, 2020)

- k-en iyi komşu

Algoritmayı rastgele uygularken sorgu noktası olarak bir nokta [4.2 1.2] seçilmiştir. Sorgu noktasının gerçek sınıfı 0'dır. Algoritmanın uygulanmasında, sorgu noktasının en yakın komşuları şunlardır: ([4.2 1.2] [4.2 0.7] [4.7 1.1] [3.6 1.5] [4.7 1.8]), en yakın komşuların sınıfları ise: ([1] [0] [0] [0] [0]) ve sorgu noktası için tahmin edilen sınıf da 0'dır. k-NN sınıflandırıcısının performansını değerlendirirken, testin yanlış sınıflandırma yüzdesi =% 3.125. Matrisin doğruluğunu hesaplamak için Denklem. (1) kullanılır. Burada matrizen değerler koyarak hesaplanan doğruluk% 96.875'tir (Chaubey vd, 2020).

## 4. YÖNTEM

### 4.1. Özellik Seçimi

Veri boyutluluğu hızla büyüyor ve bu da boyutluluk laneti, büyük depolama gereksinimi ve yüksek hesaplama maliyeti gibi mevcut madencilik ve öğrenme algoritmalarının büyük çoğunluğuna zorluklar çıkarıyor. Özellik seçiminin, veri madenciliği ve makine öğrenimi için yüksek boyutlu verileri hazırlamanın etkili ve verimli bir yolu olduğu kanıtlanmıştır. Yeni tekniklerin ve yeni veri ve özellik türlerinin yakın zamanda ortaya çıkışı, yalnızca mevcut özellik seçimi araştırmalarını ilerletmekle kalmaz, aynı zamanda özellik seçimini sürekli olarak geliştirerek daha geniş bir uygulama yelpazesine uygulanabilir hale gelir. Boyut azaltma tekniği olarak özellik seçimi, ilgisiz, gereksiz veya gürültülü özellikleri kaldırarak orijinal özelliklerden ilgili özelliklerin küçük bir alt kümesini seçmeyi amaçlar. Özellik seçimi genellikle daha iyi öğrenme performansı, yani daha yüksek öğrenme doğruluğu, daha düşük hesaplama maliyeti ve daha iyi model yorumlanabilirliği sağlar (Wang vd, 2016).



Şekil 4.1. Özellik seçim kategorileri

Veriler katlanarak arttıkça, Veri madenciliği, Örüntü Tanıma, Görüntü işleme ve diğer Makine Öğrenimi algoritmaları tarafından işlenmesi için gereken verilerin kalitesi kademeli olarak azalır. Bellman bu senaryoyu "Boyutluluk Laneti" olarak adlandırıyor. Daha yüksek boyutlu veriler, gürültülü, ilgisiz ve gereksiz verilerin yaygınlığına yol açar. Hangi stajyer modelin aşırı uyumuna neden olur ve öğrenme algoritmasının hata oranını artırır. Bu sorunların üstesinden gelmek için "Boyut Küçültme" teknikleri uygulanır ve bu, ön işleme aşamasının bir parçasıdır. Bu nedenle, Özellik Seçimi (ÖS) ve Özellik Çıkarma (ÖÇ) en yaygın olarak boyut

azaltma yaklaşımlarını kullanır. Özellik seçimi, gürültülü, gereksiz ve ilgisiz verileri temizlemek için kullanılır. Sonuç olarak, performans artırılır. Değişken seçimi olarak da bilinen özellik seçimi, temelde herhangi bir veri kümesindeki önemsiz ve gereksiz nitelikleri ortadan kaldırarak verilerin azaltılması için kullanılan, veri madenciliğinde yaygın olarak kullanılan bir veri ön işleme tekniğidir. Dahası, bu teknik verilerin anlaşılabilirliğini artırır, verilerin daha iyi görselleştirilmesini kolaylaştırır, öğrenme algoritmasının eğitim süresini kısaltır ve tahmin performansını iyileştirir. Sağlık sektöründe ilgili özellik tanımlama tekniklerinin çok sayıda uygulaması vardır (Jain ve Singh, 2018).

Özellik seçiminin özellikleri arasında şunları yapabiliriz: veri boyutunu ve hacmini küçültebilir, işlemleri hızlandırabilir, veri madenciliği algoritmalarının doğruluğunu iyileştirebilir ve sonuçları öğrenmemizi ve anlamamızı geliştirebiliriz. Veri setimizdeki özellikler üç genel kategoriye ayrılabilir (Mitra ve Mahdiyeh, 2018):

- Alakasız Özellikler: Bilgi ile yüklenmeyen ve veri madenciliği hedefleriyle hiçbir ilgisi olmayan, genellikle veri madenciliği algoritmalarının düşük performansına neden olan özellikler.
- Eklenti Özellikleri: Diğer özellikleri hesaplamak için kullanılabilen özellikler gibi, doğrudan ilgisi olmayan diğer özelliklerle ilgili özellikler.
- İlgili nitelikler: veri madenciliğinin amacı üzerinde büyük etkisi olan niteliklerdir ve nitelik seçim yöntemlerinin temel amacıdır.

Özellik seçimi, verilerin boyutlarını azalttığı için veri işlemede en önemli adımdır. Özellik seçimi, yalnızca PCA yöntemi veya modelleme algoritması gibi ilgili özelliklere odaklanması gereken eleştirinin bir parçası olabilir. Bununla birlikte, özellik seçimi genellikle tüm veri madenciliği sürecinde ayrı bir adımdır. İki farklı özellik seçme yöntemi kategorisi vardır, filtre yaklaşımı ve paketleme yaklaşımı. Filtre yaklaşımı, özellik seçim sürecini öğrenme algoritmalarında çok önemli bir adım olarak görür. Filtre modeli, özellik alt küme sınıflandırmasının performansını değerlendirmek için değerlendirme işlevlerini kullanır. Özniteliğin önemi, cin, bilgi geliştirme, bilgi edinme gibi birçok değerlendirme işlevi vardır. Bu yaklaşımın bir dezavantajı, özellik seçme süreci ile öğrenme algoritmalarının performansı arasında bir ilişki olmamasıdır (Ha ve Nguyen, 2016).

### **4.1.1. Değerlendirme Kriterlerine Göre Özellik Seçimi**

Bu bölümde, değerlendirme kriterlerine bağlı olan Özellik seçim algoritmalarını tartışıyoruz. Değerlendirme kriterlerine ve öğrenme algoritması özellik seçimleriyle etkileşime dayalı olarak üç tipte sınıflandırılır: 1) Filtre yöntemi 2) Sarıcı yöntemi ve 3) Gömülü yöntem (Bachu ve Anuradha, 2019).

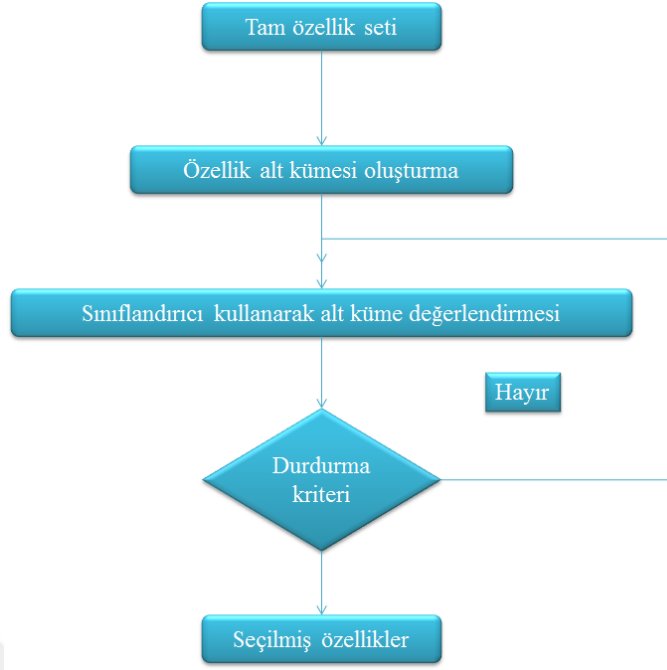
#### **4.1.1.1. Filtre Yöntemi**

Filtre yöntemleri, özellik seçim sürecini, indüksiyon algoritması olmadan bir ön işleme adımı olarak gerçekleştirir. Eğitim verilerinin genel özellikleri, özellikleri seçmek için kullanılır (örneğin, sınıflar arasındaki mesafeler veya istatistiksel bağımlılıklar). Bu model, sarmalayıcı yaklaşımından daha hızlıdır ve tümevarım algoritmasından bağımsız hareket ettiği için daha iyi bir genelleme ile sonuçlanır. Bununla birlikte, çok sayıda özelliğe sahip alt kümeleri seçme eğilimindedir (tüm özellikler bile) ve bu nedenle bir alt küme seçmek için bir eşik (Sánchez-Marono vd, 2007).

#### **4.1.1.2. Sarıcı Yöntemi**

Sarmalayıcı yöntemi Şekil 4.2'te gösterilmektedir. Bu yöntemde özellik, kullanılan sınıflandırıcıya bağlıdır, yani, verilen özelliğin veya niteliğin iyiliğini belirlemek için sınıflandırıcının sonucunu kullanır. Bu yöntemin avantajı, filtre yönteminin dezavantajını ortadan kaldırması, yani sınıflandırıcı ile etkileşimi içermesi ve aynı zamanda özellik bağımlılıklarını da almasıdır ve bu yöntemin dezavantajı, bağımlılıkları da aldığı için filtre yönteminden daha yavaş olmasıdır. . Özelliğin kalitesi doğrudan sınıflandırıcının performansı ile ölçülür (Pavya ve Srinivasan, 2018).





Şekil 4.2. Sarıci Yaklaşımı

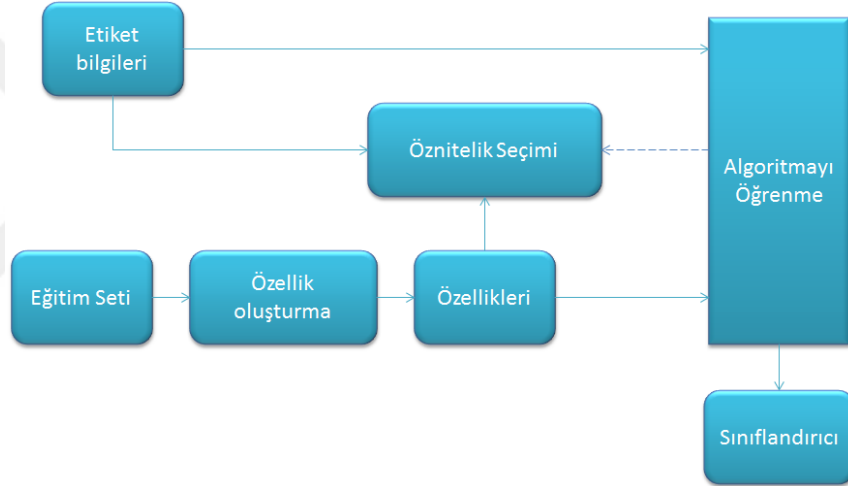
#### 4.1.1.3. Gömülü Yöntemi

Gömülü yöntemler, modelleme algoritmasının yürütülmesi sırasında özellik seçimi gerçekleştirir. Dolayısıyla bu yöntemler, normal veya genişletilmiş işlevselliği olarak algoritmanın içine yerleştirilir. Yaygın gömülü yöntemler arasında çeşitli karar ağacı algoritmaları bulunur: CART, C4.5, rastgele orman, ancak aynı zamanda diğer algoritmalar (örn. Çok terimli lojistik regresyon ve varyantları). Bazı gömülü yöntemler, uydurma hatalarını en aza indiren nesnel işlemlere sahip düzenlilik modellerine dayalı özellik ağırlıklandırması gerçekleştirir ve ortalama süre, özellik katsayılarını küçük veya tam olarak sıfır olmaya zorlar. Kement veya Elastik Ağa dayalı bu yöntemler genellikle doğrusal sınıflandırıcılarla (SVM veya diğerleri) çalışır ve modele katkıda bulunmayan özelliklere ceza verir (Jovic vd, 2015).

#### 4.1.2. Sınıflandırma İçin Özellik Seçimi

Gerçek dünyadaki sınıflandırma problemlerinin çoğu, temel sınıf olasılıklarının ve sınıf koşullu olasılıklarının bilinmediği ve her bir örneğin bir sınıf etiketiyle ilişkilendirildiği denetimli öğrenmeyi gerektirir. Gerçek dünyadaki durumlarda, ilgili özellikler genellikle önceden bilinmemektedir. Bu nedenle, alanı daha iyi temsil etmek için birçok aday özellik tanıtılmıştır. Maalesef bunların çoğu ya kısmen ya da tamamen alakasız / hedef konseptle gereksiz. İlgili bir özellik, hedef kavramla ne

alakasızdır ne de gereksizdir; alakasız bir özellik hedef konsepti hiçbir şekilde etkilemez ve fazlalık bir özellik hedef konseptte yeni bir şey katmaz. Birçok uygulamada, bir veri kümesinin boyutu o kadar büyüktür ki, bu istenmeyen özellikleri kaldırmadan önce öğrenme de işe yaramayabilir. Alakasız / gereksiz özelliklerin sayısını azaltmak, bir öğrenme algoritmasının çalışma süresini büyük ölçüde azaltır ve daha genel bir konsept ortaya çıkarır. Bu, gerçek dünya sınıflandırma probleminin altında yatan kavram hakkında daha iyi bir fikir edinmeye yardımcı olur. Özellik seçim yöntemleri, hedef kavramla ilgili bir özellik alt kümesi seçmeye çalışır. Özellik seçimi, birçok yazar tarafından ona çeşitli açılardan bakılarak tanımlanmaktadır. Ancak beklendiği gibi, bunların çoğu sezgi ve içerik açısından benzer. Aşağıda, kavramsal olarak farklı olan ve bir dizi tanımlı kapsayanlar listelenmektedir (Dash ve Liu, 1997).



Şekil 4.3. Sınıflandırma için Genel Bir Özellik Seçimi Çerçevesi

Hesaplama yöntemlerini kullanarak gerçek dünya nesnelere veya kavramlarına sınıflandırmaya çalışırken, uygun bir temsili seçimi büyük önem taşımaktadır. Klasik örüntü tanıma teknikleri için, örüntüler genellikle özellik değerlerinin bir vektörü olarak temsil edilir. Özelliklerin seçilmesi, ortaya çıkan sınıflandırma algoritmasının etkinliği üzerinde önemli bir etkiye sahip olabilir. Hangi özelliklerin sınıflar arasında en iyi ayrımı sağlayacağı önceden bilinmemektedir ve sınıflandırılan nesnelere tüm olası özelliklerini ölçmek ve temsil etmek genellikle mümkün değildir. Sonuç olarak, özellik seçim yöntemleri otomatik örüntü tanıma, keşifsel veri analizi ve veri madenciliği için önemli teknikler haline geldi. Özellik

seçiminin temel amacı, kabul edilebilir sınıflandırma doğruluğunu korurken, sınıflandırmada kullanılan özelliklerin sayısını azaltmaktır. Sınıflar arasında iyi ayırım yapmak için yeterli bilgiyi tutan orijinal özelliklerin bir alt kümesini bırakarak daha az ayırıcı özellikler ortadan kaldırılır. Özellik seçimi için birçok arama algoritması kullanılmıştır. Optimale yakın özellik alt kümelerini aramak için çeşitli sezgisel yöntemler önerilmiştir. Sıralı ileri seçim ve sıralı geriye doğru seçim dahil sıralı yöntemler, her adımda tek bir özelliğin eklenmesini veya kaldırılmasını içerir (Kousarrizi vd, 2012).

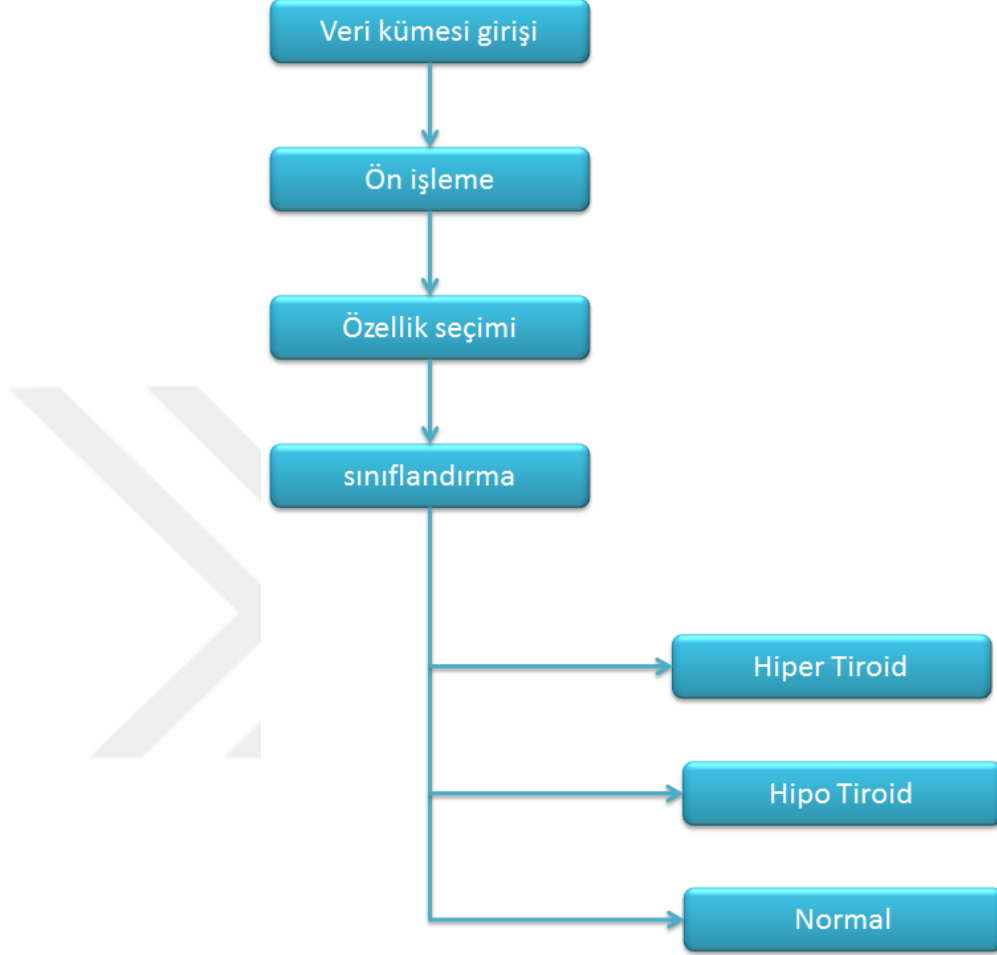
#### **4.1.3. Tiroit Hastalığının Teşhisi İçin Özellik Seçimi**

Doğru ve zamanında tedavi için sağlık sektöründe hastalıkların doğru ve erken teşhisi önemli ve zorunludur. Bu gerçek, semptomları çeşitli hastalıklarla örtüştüğü için tespit edilmesi çok zor olan tiroit gibi hastalıklarda daha önemlidir. Tiroit hastalığı teşhisi için makine öğrenimi algoritmalarının kullanımı öne çıkmaktadır. Tipik bir tiroit hastalığı teşhis sistemi, özellik çıkarma, özellik seçimi ve sınıflandırma olmak üzere üç ana adım kullanır. Bu makalenin temel amacı, filtre tabanlı (F-Puanı) ve sarıcı tabanlı (Özyinelemeli Özellik Eliminasyon) özellik seçim algoritmalarının hastalık tanımlama ve sınıflandırma üzerindeki etkisini analiz etmektir. Analiz aynı zamanda Prensipte Bileşen Analizi boyutsallık azaltma algoritmalarıyla da gerçekleştirilir. Performans değerlendirmesi doğruluk, duyarlılık ve özgüllük olmak üzere üç ölçü ile yapılmıştır. Seçilen algoritmaları analiz etmek için MultiLayer Perceptron, Back Propagation Neural Network, Support Vector Machine ve Extreme Learning Machine olmak üzere dört sınıflandırıcı kullanılmıştır. Deneysel sonuçlar, hem F-Skoru hem de Yinelemeli Özellik Eliminasyonunun tiroit hastalığı teşhisinin performansını iyileştirirken, sarıcı tabanlı algoritmanın ELM sınıflandırıcısı ile maksimum verimlilik ürettiğini ve maksimum% 98.14 doğruluk ürettiğini göstermiştir (Pavya ve Srinivasan, 2017a).

Otomatik Tiroit Hastalığı Bilgisayar Destekli Tanı (ATD-CAD) sistemi, teşhisi üç adımda gerçekleştirir: İlk adım, ultrason gibi çeşitli tıbbi görüntüleme sistemlerinden hastalıkla ilgili ayrıntıları (veya özellikleri) toplayan özellik çıkarımıdır.

İkinci adım, Adım 1'den Tiroit hastalığı teşhisinin doğruluğunu artırabilecek optimal özelliklerin seçilmesine odaklanan özellik seçimidir. Son adım, hastalığın varlığını /

yokluğunu teşhis etmek ve ayrıca hastalığın mevcut evresini analiz etmek için Adım 2'deki optimal özellikler kullanılarak eğitilen makine öğrenme algoritmasını kullanır (Koundal vd, 2012).



Şekil 4.4. Yöntemin çerçevesi

Şekil 4.4'in içeriği:

Alınan veri arşivi, maskeleye yöntemi kullanılarak bir sayı kısıtlamasının değil eksik değerlerin kontrol edildiği ön işleme tabi tutulur. Eksik değer varsa veya bir sayı değeri yoksa, sütunun ortalama değeri ile değiştirilir.

- Ön işlenmiş veriler, Diferansiyel Evrim (DE) olarak adlandırılan bir hibrit algoritmaya beslenir. Bu algoritma, ana kayıtlardan alt küme oluşturmak için kullanılır.

- Veri alt kümeleri, uygunluğu kontrol etmek için Kernel Tabanlı Bayes sınıflandırıcı algoritmasına uygulanır. Uygunluk, hata dengeleme ile ölçülür.
- Stabilizasyon sağlandıktan sonra veriler şu şekilde 3 sınıfa ayrılır (Geetha ve Baboo, 2016a):
  - a) Hipo Tiroit
  - b) Hiper Tiroit
  - c) Normal

## 4.2. Yapay Sinir Ağı

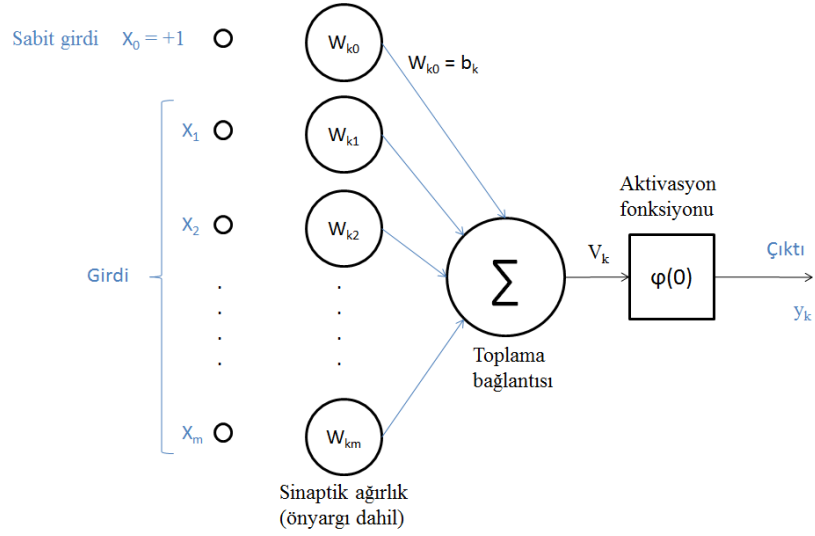
Yapay Sinir Ağı (YSA), aynı zamanda sinir ağı olarak da bilinir, biyolojik sinir ağına dayalı bir hesaplama modelidir. Ana kavramı, bilişsel bilimle bağlantıya dayanmaktadır. Akıllı davranışları göstermek için çok sayıda basit hesaplama bileşeni birbirine bağlıdır. Böyle bir kavram, biyolojik sinir sisteminin nöronlarına ve hesaplama modellerinin hesaplama kısımlarına uygulanabilir. Bu nedenle, sinir sistemi içindeki keşif, organizmanın beyninden akıllı bir sistem geliştirmek için etkilenir ve akıllı sistemdeki organizmanın akıllı davranışıyla ilgilenir (Gallo, 2015).

Beyindeki sinir hücreleri, iki ateş-ateş etmeme moduna (kısıtlama) basitleştirilebilir: Sinyal iletiminin yoğunluğu değişmeden kalır ve yalnızca frekans değişir. Toplam sinyal sayısı belirli bir eşiği aşarsa, sinir hücrelerini uyarır ve etkinleştirir. . Bu durumda sinir sinyalleri diğer sinir hücrelerine gönderilecek ve set sayısı eşiğin altında ise sinir hücreleri herhangi bir sinyal göndermeden sınırlı kalacaktır (Vrahatis vd, 2000).

Şekil 4.5, iki bölümden oluşan standart bir nöron modelini göstermektedir. İlk bölüm, giriş sinyalleri (giriş verileri) bir set için toplanırken sinyallerin birikmesidir. Formül 4.1'de gösterildiği gibi, her ağırlık ( $w_i$ ) bir bilgi boyutuna ( $x_i$ ) karşılık gelirken ( $w_0$ ) bir izleme kelimesine veya sabit bir kelimeye eşdeğer bir önyargı olarak işlev görür.


$$Z = bias + \sum_{i=1}^m x_i * w_i = \sum_{i=0}^m x_i * w_i \quad (4.1)$$

İkinci kısım, fonksiyonun aktivasyonudur, elde edilen aktivasyon değeri ise doğrusal olmayan özel bir değer çıkarmak için doğrusal olmayan sıkıştırma deformasyonu için kullanılır. Yaygın olarak kullanılan aktivasyon fonksiyonları Sigmoid, Relu ve Tanh'dir (Code ve Casella, 2020).



Şekil 4.5. Noren standart modeli

Bir sinir ağı, bir örneği Şekil 4.6'da gösterilen yapay nöronlar arasındaki bağlantılara dayanan bir ağıdır.



Şekil 4.6. Asimetrik yapıya sahip sinir ağı

#### 4.2.1. Geri Yayılım Sinir Ağları (Back propagation)

Geri Yayılma, öğrenmenin algoritması En Derin İniş tekniğine dayanan bir tür YSA'dır. Uygun sayıda Gizli birim ile sağlanırsa, yüksek karmaşıklığa sahip doğrusal olmayan işlevlerin hatasını da en aza indirebileceklerdir. Teorik olarak, basit bir Gizli birimler katmanı ile sağlanan bir BP, herhangi bir  $y = f(x)$  işlevini eşlemek için yeterlidir. Pratik olarak, hesaplama işlevi özellikle karmaşık olduğunda veya BP'yi eğitmek için seçilen veriler özellikle güvenilir olmadığında ve bir seviye filtresi gerekli olduğunda, bu YSA'lara en az 2 Gizli birim katmanı sağlamak gerekir. Giriş özellikleri hakkında. BP, sadece kullanılan ağırlıkların özel düzeltme

algoritması için, öğrenmenin işlevi bağlantılarda "kendini dağıtma" eğiliminde olan ağlardır. Bu, en az bir Gizli birimler katmanı ile sağlanan BP durumunda, bu birimlerin kendi aralarında girdi vektörünün her bir özelliğinin kodlamasını dağıtma eğiliminde olduğu anlamına gelir. Bu, öğrenmeyi daha kompakt ve verimli hale getirir, ancak test sürecinde bir BP'yi belirli bir şekilde yanıtlamaya getiren "muhakemeyi" bilmek daha karmaşıktır. Kısaca, bu YSA'ların eğitim sürecinde edindikleri örtük bilgileri açıklamak zordur (Buscema, 1998).

Geri yayılım algoritması, 1970'den 1980'e kadar birkaç kişi tarafından ayrı ayrı geliştirildi. Başlangıçta 1969'da araştırmacılar tarafından geliştirilen doğrusal bir algoritmaydı. Hinton ve William doğrusal olmayan geri yayılım algoritmasını geliştirdiler, ancak ilk deneyleri hayal kırıklığı yarattığında, onu kullanmayı bırakmaya karar verdiler. 1990'ların sonlarında, çalışan araştırmacıların çoğu geri yayılım algoritmasını uyarlamayı bıraktı ve Destek Vektör Makinesi'nin (DVM) ortaya çıkışı geri yayılım algoritmasının vizyonunu hızlandırdı. Psikolojik bir model olarak, psikologlar tarafından yaygın olarak kullanılmaktadır (Suryanita ve Jingga, 2017).

Geri yayılım algoritmasının popüleritesini kaybetmesinin nedenlerinden biri, bilgisayarın zayıf performansı ve yetersiz eğitim bilgisi miktarıdır. . Sonuç olarak, Geri yayılım algoritması derin ağlarda etkisizdir, bu nedenle gelişimi bugün ertelenmiştir ve bilgisayarların son derece gelişmiş performansı ile veri toplama sorunu çözülmüştür. Bu nedenle, Geri yayılım algoritması, derin öğrenmenin ana eğitim yöntemidir. BP algoritmasının ana kavramı, katmanlı sinir ağı parametrelerinin arkasındaki karşılık gelen eğimleri elde etmek için zincir türetme yasasını kullanmaktır. Ağ eğitimi iki aşamaya ayrılmıştır; İlk aşama, tekdüze dağılım veya Gauss dağılımı, ilk rastgele başlangıçtan itibaren sinir ağı ağırlık parametrelerini onaylar. İkinci adım, sinir ağı modeli için ceza miktarını elde etmek için tekrarlayan eğitim için eğitim verilerini kullanır. Bu ceza miktarı daha sonra zincirlerin ağırlıklarını düzeltmek için kullanılır ve hata gradyanı son katmandan katman katman, giriş katmanına geri aktarılır. Tüm katmanların ağırlık değerleri daha sonra koşullar maksimum yineleme sayısına izin verene veya bu sayıyı aşana kadar azalan gradyan algoritmasına göre güncellenir. Katman "i" ve "n" nin (sıra numarası) her bir çıktı bölümü için, kalan hata formülü 4.2 ile hesaplanır (Leung ve Haykin, 1991).

$$da_i^n = J'(x; w) \quad (4.2)$$

Katman 2'den katman "n-1" e kadar olan artık hatalar ve katman L üzerindeki "i" düğümündeki bir hata formül 4.3'da gösterilmektedir.

$$da_i^l = (\sum_{j=1}^m da_j^{l+1} w_{i,j}^{(l)} f'(\sum_{i=0}^m a_i^{(l-1)} w_{i,j}^{(l-1)})) \quad (4.3)$$

Katman I üzerindeki "i" nöronlarının kısmi türevleri ve I+1 katmanındaki "c" nöronları, Formül 7'de gösterilmektedir. Katman üzerindeki "i" nöronları ile L1 katmanındaki "j" nöronları arasındaki ilişkinin kısmi türev gradyanı, Formül 8'de gösterilmektedir.

$$\frac{\partial J(w)}{\partial w_{i,j}^l} = da_j^{l+1} f'(\sum_{i=0}^m a_i^{(l)} w_{i,j}^{(l)}) a_i^z \quad (4.4)$$

$$\frac{\partial J(w)}{\partial b_j^l} = da_j^{l+1} f'(\sum_{i=0}^m a_i^{(l)} w_{i,j}^{(l)}) \quad (4.5)$$

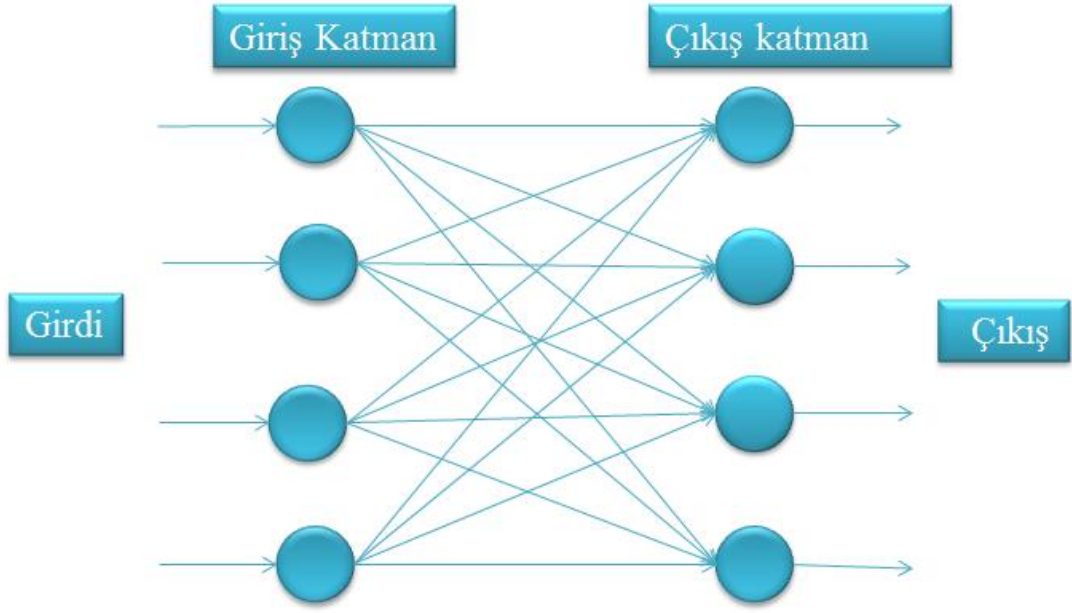
Formül 4.4, ilk ve orta katmanlar ile orta ve son katmanlar için ağırlık değişimini gösterir. Formula 4.5'te, Bice için ağırlık değişimi hesaplanır (Sazli, 2006).

#### 4.2.2.İleri Besleme (feed forward):

Nöronlar arasındaki bağlantıların türüne bağlı olarak iki ana ağ mimarisi kategorisi vardır: "ileri beslemeli sinir ağları" ve "tekrarlayan sinir ağları". Nöronların çıktılarında ağ boyunca girişlere doğru "geri besleme" yoksa, ağ "ileri beslemeli sinir ağı" olarak adlandırılır. Aksi takdirde, eğer böyle bir geri besleme varsa, yani çıktılardan girişlere doğru sinaptik bir bağlantı (kendi girişleri veya diğer nöronların girişleri) varsa, o zaman ağa "tekrarlayan sinir ağı" denir. Genellikle sinir ağları "katman" şeklinde düzenlenir. İleri beslemeli sinir ağları, katman sayısına bağlı olarak "tek katman" veya "çok katmanlı" olmak üzere iki kategoriye ayrılır (Bebis ve Georgiopoulos, 1994).

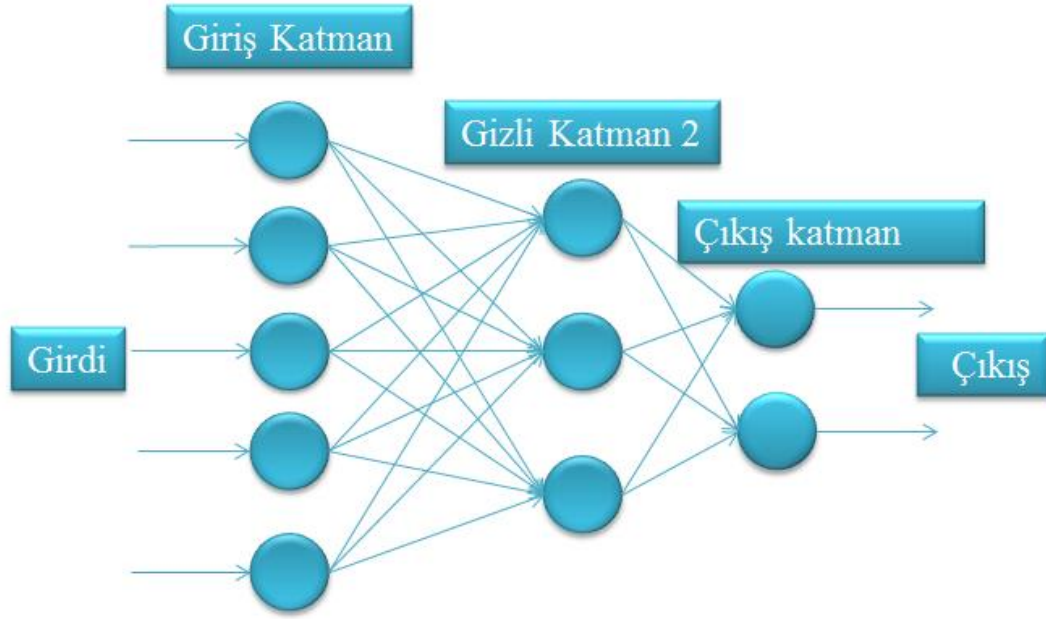
Şekil 4.7'de, tek katmanlı ileri beslemeli bir sinir ağı (tamamen bağlı) gösterilmektedir. Giriş katmanı dahil olmak üzere bu yapıda iki katman vardır. Ancak, bu katmanda herhangi bir hesaplama yapılmadığı için girdi katmanı sayılmaz. Giriş sinyalleri ağırlıklar aracılığıyla çıkış katmanına iletilir ve çıkış katmanındaki nöronlar çıkış sinyallerini hesaplar (Turkson vd, 2016).





Şekil 4.7. Tek katmanlı ileri beslemeli bir sinir ağı

Şekil 4.8'da, bir "gizli" çoklu katmana sahip ileri beslemeli bir sinir ağı katman tasvir edilmiştir. Tek katmanlı bir ağın aksine, giriş ve çıkış katmanları arasında (en az) bir "gizli nöron" katmanı vardır. Haykin'e göre, gizli nöronların işlevi, harici giriş ile ağ çıkışı arasında yararlı bir şekilde müdahale etmektir. Bir veya daha fazla gizli katmanın varlığı, ağın daha yüksek düzeyli istatistikleri çıkarmasını sağlar. Şekil 2'de verilen örnek için, yalnızca bir gizli katman vardır ve ağ, 5 giriş nöronu, 3 gizli nöron ve 2 çıkış nöronu olduğu için 5-3-2 ağı olarak adlandırılır. Hem Şekil 4.7 hem de Şekil 4.8'de, ağlar "tamamen bağlantılıdır" çünkü her katmandaki her nöron, bir sonraki ileri katmandaki diğer her nörona bağlıdır. Sinaptik bağlantılardan bazıları eksik olsaydı, ağ "kısmen bağlı" olarak adlandırılırdı. Bir sinir ağının onu geleneksel bir bilgisayardan ayıran en önemli özelliği, "öğrenme" kabiliyetidir. Bir sinir ağı, çevresinden öğrenebilir ve öğrenme yoluyla performansını artırabilir. Haykin, literatürde sinir ağları bağlamında öğrenmeyi şu şekilde tanımlamıştır: "Öğrenme, bir sinir ağının serbest parametrelerinin, ağın gömülü olduğu ortam tarafından uyarılma süreciyle uyarıldığı bir süreçtir. Öğrenme türü, parametre değişikliklerinin meydana gelme şekline göre belirlenir" (Cilimkovic, 2015).



Şekil 4.8. Çok katmanlı ileri beslemeli bir sinir ağı

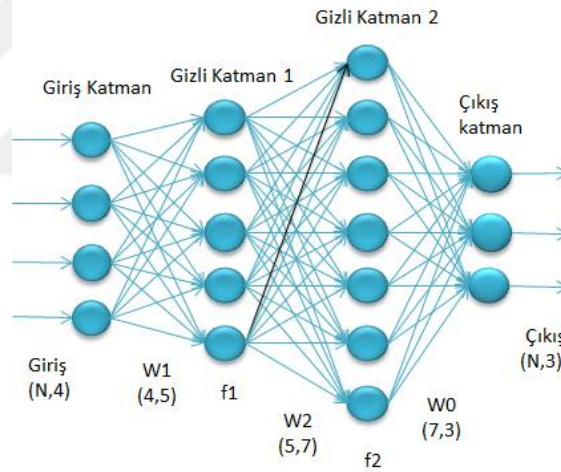
### 4.3. Derin Öğrenme Algoritması

Derin öğrenme hayatımızda giderek daha önemli bir rol oynamaktadır. Kanser teşhisi, hassas tıp, kendi kendine giden arabalar, tahmine dayalı tahmin, konuşma tanıma vb. Alanlarda şimdiden büyük bir etki yarattı. Geleneksel öğrenme, sınıflandırma ve örüntü tanıma sistemlerinde kullanılan özenle el yapımı özellik çıkarıcılar, büyük boyutlu veri kümeleri için ölçeklenemez. Çoğu durumda, sorunun karmaşıklığına bağlı olarak, derin öğrenme, çok boyutlu eğitim verilerinin hiyerarşik temsillerinin soyutlanmasını ve verimli eğitimi engelleyen önceki sığ ağların sınırlamalarının da üstesinden gelebilir. Derin Sinir Ağı , yüksek düzeyde optimize edilmiş algoritmalar ve mimarilere sahip çoklu (derin) birim katmanları kullanır (Shrestha ve Mahmood, 2019).

Son yıllarda büyük verinin çoğalması ve yüksek performanslı bilgi işlem cihazlarının hızlı bir şekilde geliştirilmesi, makine öğreniminde benzeri görülmemiş bir gelişmeye eşlik etti. Özellikle görsel bilgisayar endüstrisindeki derinlemesine öğrenmedeki ilerlemeler, insanları yapay zekayı yeniden tartışmaya yönlendirdi. Görüntü tanıma ile ilgili olarak, bu araştırma, özellikleri yapay olarak çıkarmayı ve bu özellikleri daha küçük boyutlar ve daha az gürültü ile tanımlanan kullanışlı özelliklere sahip bir ana görüntüye dönüştürmeyi amaçlamaktadır. Sınıflandırma problemini çözmek için destek vektör makinesi ve diğer denetimli

öğrenme algoritmaları benimsenmiş veya sınıflandırmaları öğretmek için kullanılmıştır. Bununla birlikte, yapay olarak tasarlanmış öznelik çıkarma yöntemlerinde sınırlamalar vardır, bu da genelleme ve genelleme açısından zayıf oldukları ve yüksek işçilik maliyetlerine sahip oldukları anlamına gelir (Shetty ve Siddiqa, 2019).

Daha kesin bir anlamda, bir sinir ağı, bir derin öğrenme türü olarak tanımlanabilen birkaç gizli katmandan oluşur; daha geniş anlamda, katmanlı özellik çıkarımı ile donatılmış bağlantı tabanlı bir öğrenme modelidir. Verinin ana özelliklerini başlatarak derin öğrenme, özellikleri katman katman çıkararak kayıpları en aza indirebilir. Çok katmanlı özellik dönüştürme yoluyla, görüntülerdeki piksel özellikleri gibi temel veri özellikleri, ağ performansını artırmak için kademeli olarak marjinal ve resmi soyut özelliklere dönüştürülür. Ses tanıma, doğal dil işleme ve bilgisayar görseli gibi çeşitli alanlarda önemli pratik ve teori elde edilmiştir (Zhou vd, 2019).



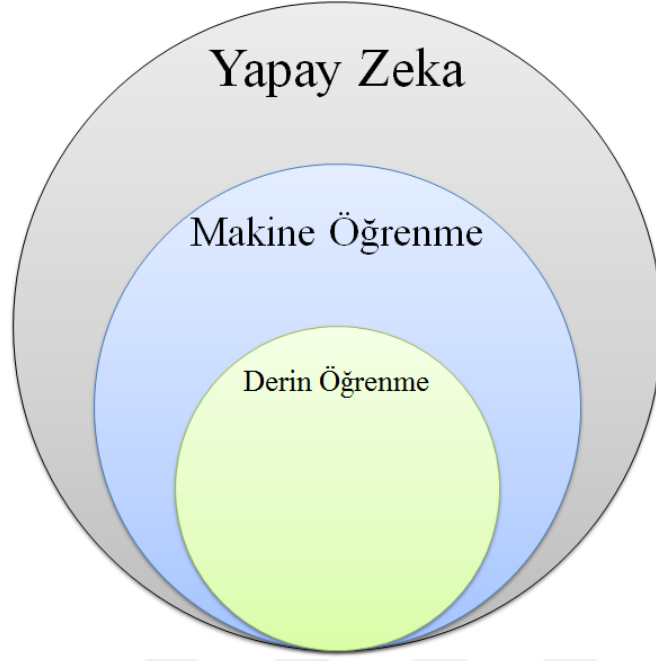
Şekil 4.9. Birbirine bağlı düğümlerden oluşan katmanlar halinde organize edilen sinir ağları. Ağlar onlarca veya yüzlerce gizli katmana sahip olabilir

Derin öğrenme gelişimi üç aşamaya ayrılabilir. 1940'tan 1960'a kadar derin öğrenmeye kontrol teorisi adı verildi. Periton yerleşiminin biyolojik öğrenme teorisinin geliştirilmesi, yapay sinir ağlarında ilk ilgi dalgasını başlatırken, bu algılayıcı, birçok araştırmacı tarafından daha az direnilen bütünsel doğrusal verileri öğrenmek için kullanılmadı. Önce gelir. Bu bağlantının ikinci dalgası 1980'de başladı ve 1995'te sona erdi (Memisevic, 2015). 1914'te Paul Werbos, difüzyon sonrası algoritmayı önerdi ve sinir ağı modelindeki doğrusal olmayan doğrusallık sorununu çözdü. Bununla birlikte, eğitim verilerinin miktarı ne kadar küçükse, o

zaman bilgisayarların performansı o kadar zayıftır. Aşırı uydurma olan çoğu derin öğrenme modelinde ciddi bir sorun var. Aynı zamanda, çekirdek işlevleri, grafik modelleme ve destek vektör makinesi gibi makine öğreniminin diğer alanlarında da birçok önemli görevde olumlu sonuçlar veren birçok ilerleme kaydedildi (Werbos, 1988). Memeli görsel sistemine dayanan evrişimli sinir ağı , yalnızca bir ağ yapısıyla verileri işlemek için kullanılan bir sinir ağıdır. 1959'da Wiesel ve Hubel, memeli optik kortikal hücrelerini keşfettiler ve kısmi zemin konseptini önerdiler (Namatevs, 2017).

1990'da Le Cun ve meslektaşları, Evrişimli sinir ağı'nın modern yapısını tanımlamak ve değiştirmek için ilgili makaleler yayınladılar. El yazısı sayıların sınıflandırılmasıyla ilgili olarak, gerçekte kullanılacak ilk evrişimli ağ olan LeNet-5 oluşturuldu. Biraz öngörüle, ızgara, orijinal piksellerdeki sayıların görüntü sınıflandırmalarını doğrudan öğrenebilir. Ancak eğitim verileri yetersiz ve bilgisayarın hesaplama gücü zayıf. Sonuç olarak, LeNet-5 karmaşık sorunların ele alınmasında etkili olmamıştır (LeCun vd, 2015). 2009'da Lee ve öğrencileri, Derin Evrişim İnanç Ağı'nı oluşturmak için Deep İnanç Ağı ile karmaşık bir sinir ağını entegre ettiler (Lee vd, 2009). 2012'de krizhevsky, görüntü sınıflandırma hatalarını %26,3'ten %15,2'ye düşürmek için Alex ağını onayladı. 2015 yılında, Microsoft MSRA evrişim ağı, hata oranını (5'in üzerinde)% 4,94'e düşürdü, böylece insanları algılama açısından üstün hale getirdi. Bu makalenin ilk adımı, sarsıcı sinir ağının karmaşıklığı, entegrasyonu, kilo kaybı ve kaybı hakkındaki temel bilgilerin yanı sıra grup öğrenme teorileri ve bilgisini tanıtmaktır (LeCun vd, 2015).

Derin öğrenme, şekil 4.10'de gösterildiği gibi makine öğreniminin bir bölümüdür. Derin öğrenme, yapay sinir ağı adı verilen bir insan nöronunun yapısı ve yeteneğinden esinlenmiştir. yapay sinir ağı, çeşitli veri türleri üzerinde denetimli, yarı denetimli ve denetimsiz öğrenmeyi kullanma becerisi nedeniyle diğer makine öğrenme algoritmalarına göre üstünlüğe sahiptir (Shetty ve Siddiqa, 2019).



Şekil 4.10. Derin Öğrenme, Makine Öğrenimi ve Yapay Zeka

Derin öğrenme, çok katmanlı ve geleneksel makine öğrenimi algoritmalarından çok daha fazla veriye sahip derin sinir ağlarını uygulamaktır ve bu nedenle daha büyük modellere ve daha fazla hesaplama ihtiyacı duyar. Ayrıca, geleneksel makine öğrenme algoritmalarının performansı, veri miktarı artırılsa bile bir noktadan sonra geliştirilemeyeceği için yararlıdır, ancak derin öğrenme algoritmalarının performansı, verilerin miktarı ve çeşitliliği ile doğru orantılıdır. Şekil 12'de gösterildiği gibi, derin sinir ağlarının, eğitim için harcanan zamanı etkileyen ve doğruluğu azaltan yok olan gradyan sorunu nedeniyle geri yayılımla eğitilmesi kolay değildir. Yapay sinir ağları, sinir ağının tahmin edilen çıktısı ile eğitim verilerindeki gerçek çıktı arasındaki net farkı temel alarak maliyet fonksiyonunu hesaplar. Maliyete bağlı olarak, her işlemden sonra ağırlıklar ve önyargılar değiştirilir. Maliyeti olabildiğince az olana kadar. Gradyan, maliyetin ağırlıklara ve önyargılara göre değişeceği orandır (Nweke vd, 2018).

### **4.3.1. Derin Öğrenme Algoritmasının Sınıflandırılması:**

#### **4.3.1.1. Kısıtlanmış Boltzmann Makinesi**

Boltzmann makineleri, sinir ağı modelleri olarak yorumlanabilecek, çift yönlü olarak bağlı stokastik işleme birimleri ağları olarak tanıtıldı. Bir Boltzmann makinesi, bu dağılımdan alınan örneklerle dayanarak bilinmeyen bir olasılık

dağılımının önemli yönlerini öğrenmek için kullanılabilir. Genel olarak, bu öğrenme süreci zor ve zaman alıcıdır. Bununla birlikte, öğrenme problemi, ağ topolojisine kısıtlamalar getirerek basitleştirilebilir, bu da bizi bu eğitimin konusunu Kısıtlanmış Boltzmann makinelerine götürür (Fischer ve Igel, 2012).

Kısıtlanmış bir Boltzmann makinesi, çift etkileşimlerin gözlemlenen bir birim kümesi ile gözlenmeyen bir birim kümesi arasında sınırlandırıldığı özel bir Boltzmann makinesi türüdür. Bu modeller, uyum teorisi ve denetimsiz iki katmanlı ağlar bağlamında tanıtıldı. Sınırlandırılmış Boltzmann makineleri, derin katmanlı mimariler için açgözlü katman bazlı öğrenme algoritmalarının geliştirilmesinde önemli bir rol oynadı. Sınırlandırılmış Boltzmann makinelerine önerilen bir giriş. Kısıtlanmış Boltzmann makineleri, optimizasyon, cebirsel geometri, kombinatorik, kodlama teorisi, çok yüzlü geometri ve diğerlerinin yanı sıra bilgi geometrisinden gelen araçlarla yoğun bir şekilde incelenmiştir. Son birkaç yıldaki gelişmelerden bazıları, yaklaşık özellikleri, boyutları, yarı-cebirsal tanımları, temsilin verimliliği, sıralı optimizasyon, istatistiksel karmaşıklık, örnekleme ve eğitim, bilgi geometrisi ile ilgili sonuçları içerir (Montufar, 2018).



Şekil 4.11. Derin öğrenme algoritmalarının sınıflandırılması

#### 4.3.1.2. Otomatik Kodlayıcılar

Otomatik kodlayıcılar, ağ sinyali gürültüsünü yok sayacak şekilde eğiterek bir veri kümesi için bir gösterimi (kodlamayı) öğrenen özel bir Yapay Sinir Ağıdır. Ayrıca, bir gösterimi indirgenmiş kodlamadan ilk girdiyi yeniden oluşturmaya çalışır. Girdinin yeniden oluşturulması süreci, sistem gürültüyü göz ardı etmeyi öğrenirken boyutsallığın azaltılmasına yardımcı olur. Bir otomatik kodlayıcı herhangi bir sayıda gizli katmana sahip olabilir. Hem Kısıtlanmış Boltzmann

makinelere 'ler hem de Otomatik kodlayıcılar denetimsiz öğrenmeyi destekler ve üretken modellerde kullanılır çünkü her iki teknik de girdiyi yeniden oluşturmaya çalışır(Le, 2015).

Otomatik kodlayıcılar, kullanıcı tarafından sağlanan girişi kodlayan ve kodunu çözen 3 katmanlı bir sinir ağıdır. Çıkış katmanı, kullanıcı girdisinin çoklu kodlamasını sağlamak için giriş birimine de bir geri beslemeye sahiptir. Ayrıca, ağın bir özelliği, gizli birimlerin sayısının gerçek giriş ve çıkış birimlerinden çok daha az olmasıdır. Kullanıcı girdisinin sıkıştırılmasını sağlamak için birim sayısı daha azdır. Eğitimin nedeni, kullanıcı verilerinin, çıktı katmanı tarafından istenen çıktıya yeniden yapılandırılabilen doğru şekilde sıkıştırılmasını sağlamaktır. Bu sinir ağının temel amacı, sağlanan veri setinin boyutsallığını azaltmaktır. Esas olarak, farklı yüz ifadelerinin görüntüyü doğrulamak için bir problem oluşturduğu yüz tanıma uygulamasında yapılır(Liu vd, 2019).

#### **4.3.1.3. Derin İnanç Ağları**

Derin İnanç Ağı, birçok kısıtlandırılmış boltzmann makinesi kümesidir, öyle ki her kısıtlandırılmış boltzmann makinesinin gizli katmanı, bir sonraki kısıtlandırılmış boltzmann makinesi için görünür bir katman görevi görür. İlk kısıtlandırılmış boltzmann makinesinin görünür katmanı aynı zamanda derin inanç ağının görünür bir katmanıdır ve diğer tüm katmanlar derin inanç ağının gizli katmanlarıdır. derin inanç ağı, bir seferde tek bir kısıtlı boltzmann makinesi eğitilerek eğitilir. İlk kısıtlı boltzmann makinesi eğitildikten sonra, eğitim örnekleri basitçe onun aracılığıyla iletilir ve bunun gizli bir katmanında üretilen çıktı, bir sonraki kısıtlandırılmış boltzmann makinesi'nin görünür katmanında girdi olarak sunulur ve böyle devam eder. Buna derin inanç ağı'nın katman bazında ön eğitimi denir (Khan vd, 2018).

Derin inanç ağlarının adından da anlaşılacağı gibi, çok katmanlı inanç ağlarıdır. Her katman kısıtlandırılmış Boltzmann makinesidir ve derin inanç ağı oluşturmak için birbirleriyle istiflenirler. Derin inanç ağını eğitmenin ilk adımı, zıtlık farkı algoritmasını kullanarak görünür birimlerden bir özellik katmanı öğrenmektir. Ardından, bir sonraki adım, önceden eğitilmiş özelliklerin etkinleştirmelerini görünür birimler olarak ele almak ve ikinci bir gizli katmandaki özelliklerin özelliklerini öğrenmektir. Son olarak, tüm derin inanç ağı, son gizli katman için öğrenme gerçekleştirildiğinde eğitilir (Abdel-Zaher ve Eldeib, 2016).

#### 4.3.1.4. Tekrarlayan Sinir Ağı

Tekrarlayan ağlar, zamansal durum temsillerine sahip dinamik sistemlerdir. Hesaplama açısından güçlüdürler ve birçok zamansal işlem modeli ve uygulamasında kullanılabilirler. Dahası, tekrarlayan ağlar adi diferansiyel denklem sistemleri tarafından modellendiğinden, adi diferansiyel denklemlerin entegrasyonu için standart yazılım kullanılarak dijital uygulama için de uygundur. Hopfield modeli ve Cohen-Grossberg modeli, iki yaygın tekrarlayan ağ modelidir. Hopfield modeli, bilgileri dinamik olarak kararlı bir yapıda depolayabilir. Boltzmann makinesi, Hopfield modelinin bir genellemesidir (Du ve Swamy, 2014).

#### 4.3.1.5. Evrilmiş Sinir Ağı

Evrilmiş bir sinir ağı, son on yılda görüntü tanıma ile ilgili çeşitli alanlarda çığır açan sonuçlar elde etti; görüntü işlemeden ses tanıma. Evrilmiş sinir ağlarının en faydalı yönü, yapay sinir ağındaki parametre sayısını azaltmaktır. Bu başarı, hem araştırmacıları hem de geliştiricileri, klasik yapay sinir ağlarıyla mümkün olmayan karmaşık görevleri çözmek için daha büyük modellere yaklaşmaya teşvik etti. Evrilmiş bir sinir ağı tarafından çözülen problemlerle ilgili en önemli varsayım, uzamsal olarak bağımlı özelliklere sahip olmamalıdır. Yani örneğin bir yüz algılama uygulamasında, yüzlerin görüntülerde nerede bulunduğu dikkat etmemize gerek yoktur. Tek endişe, verilen görüntülerdeki konumlarından bağımsız olarak onları tespit etmektir. Evrilmiş sinir ağının bir diğer önemli yönü, girdi daha derin katmanlara doğru yayıldığında soyut özellikler elde etmektir. Örneğin, görüntü sınıflandırmada kenar ilk katmanlarda ve daha sonra ikinci katmanda daha basit şekiller ve ardından sonraki katmanlardaki yüzler gibi daha yüksek seviyeli özellikler tespit edilebilir (Albawi vd, 2017).

Çeşitli bilgisayarla görme görevlerinde baskın hale gelen bir yapay sinir ağları sınıfı olan evrilmiş sinir ağı, radyoloji de dahil olmak üzere çeşitli alanlarda ilgi çekiyor. Evrilmiş sinir ağı, evrilmiş katmanları, havuz katmanları ve tamamen bağlı katmanlar gibi birden çok yapı bloğu kullanarak geri yayılım yoluyla özelliklerin uzamsal hiyerarşilerini otomatik ve uyarlamalı olarak öğrenmek için tasarlanmıştır. Bu gözden geçirme makalesi, evrilmiş sinir ağının temel kavramları ve çeşitli radyolojik görevlere uygulanmasına ilişkin bir bakış açısı sunmakta ve radyoloji alanındaki zorluklarını ve gelecekteki yönlerini tartışmaktadır. Konvolüsyonel sinir



ağını radyolojik görevlere uygulamadaki iki zorluk, küçük veri seti ve aşırı uyum da bu makalede ele alınacak ve bunları en aza indirecek teknikler. Konvolüsyonel sinir ağının kavramları ve avantajları ile sınırlamalarına aşına olmak, radyologların performansını artırmak ve hasta bakımını iyileştirmek için tanısall radyolojideki potansiyelinden yararlanmak için çok önemlidir (Yamashita vd, 2018).

### **4.3.2. Derin Öğrenme Uygulaması:**

#### **4.3.2.1. Tıbbi Görüntü Analizi**

Makine öğrenimi algoritmaları, tıbbın uygulanma şeklini önemli ölçüde değiştirerek ilaç keşfinden klinik karar vermeye kadar tıbbın tüm alanlarına derinlemesine yatırım yapma potansiyeline sahiptir. Son yıllarda bilgisayarla görme görevlerinde makine öğrenimi algoritmalarının başarısı, tıbbi kayıtların giderek dijitalleştiği uygun bir zamanda geliyor. Tıbbi görüntüler, bir hastanın elektronik sağlık kaydının ayrılmaz bir parçasıdır ve şu anda insan radyologları tarafından analiz edilmektedir. hız, yorgunluk ve deneyim. Nitelikli bir radyolog yetiştirmek yıllar alır ve büyük mali maliyet gerektirir ve bazı sağlık hizmetleri sistemleri, tele-radyoloji yoluyla Hindistan gibi düşük maliyetli ülkelere radyoloji raporlaması için dış kaynak sağlar. Gecikmiş veya hatalı teşhis hastaya zarar verir. Bu nedenle, tıbbi görüntü analizinin otomatik, doğru ve verimli bir makine öğrenme algoritması ile gerçekleştirilmesi idealdir (Ker vd, 2017).

Tıbbi görüntü analizi, kısmen verilerin nispeten yapılandırılmış ve etiketlenmiş olması nedeniyle makine öğrenimi için aktif bir araştırma alanıdır ve muhtemelen bu, hastaların işlevsel, pratik yapay zeka sistemleriyle ilk etkileşime girdiği alan olacaktır. Bu, iki sebepten dolayı önemlidir, İlk olarak, gerçek hasta ölçümleri açısından, tıbbi görüntü analizi, yapay zeka sistemlerinin gerçekten hasta sonuçlarını ve hayatta kalmayı iyileştirip iyileştirmeyeceğine dair bir turnusol testidir. İkincisi, insan-yapay zeka etkileşimi için, hastaların sağlığı değiştiren seçimlere ne kadar açık olacağına veya insan olmayan bir aktör tarafından destekleneceğine dair bir test ortamı sağlar (Rezaei vd, 2017).

#### **4.3.2.2. Robotlar Ve Otonom Araçlar İçin Navigasyon**

Robotlar veya otonom araçlar için navigasyon, GPS sistemi ve görüntü analizinin bir kombinasyonu olarak uygulanmaktadır. Bu, şeridi / veya içeri girmenin

serbest yolunu tanımlamak için kenar algılama gibi Görüntü işleme teknikleri kullanılarak veya tüm veri türleriyle açık eğitime ihtiyaç duymadıkları için daha iyi Derin öğrenme algoritmaları kullanılarak yapılabilir, aşına olmayan girdilerle daha iyi performans gösterirler (Aziz vd, 2017).

Son zamanlarda, derin öğrenme teknikleri Sermanet ve diğerleri tarafından benimsenen robotik navigasyon görevleri için kullanılmıştır. Robotun önündeki alanı geçilebilirlik için sınıflandırır. Giusti vd. ayrıca bir orman yolunu tanımak için derin bir sinir ağı uyguladı. Diğer araştırma alanlarıyla karşılaştırıldığında, robotik araştırmasının, algı belirsizliği ve gerçek zamanlı operasyon talebi gibi belirli gereksinimleri vardır. Robotik araştırmaları, genellikle kesinlik odaklı değil, görev odaklıdır. Prestijli bir bilgisayar vizyonu tanıma algoritması neredeyse mükemmel bir hassasiyetle sonuçlanabilir. Bununla birlikte, en küçük tespit edilemeyen kusur, tam bir robotik görevin başarısızlığıyla sonuçlanabilir. Bu nedenle, gerçek zamanlı kabiliyet, hassasiyet ve muhakeme güveninin dengesi özellikle robotikte gereklidir. Bilgisayarla görme ve konuşma tanımada derin öğrenme için birkaç kitaplık olmasına rağmen, robotik uygulamalar için hala ultra hızlı ve güvenilir bir kitaplığa ihtiyacımız var (Tai vd, 2017).

#### **4.3.2.3. Resim Yazısı**

Son birkaç yılda, görüntü işleme alanındaki bilgisayar görüşü, görüntü sınıflandırma ve nesne algılama gibi önemli ilerleme kaydetti. Görüntü sınıflandırması ve nesne algılamanın ilerlemelerinden yararlanılarak, bir görüntünün görsel içeriğini anlamak için otomatik olarak bir veya daha fazla cümle oluşturmak mümkün hale gelir, bu da görüntü alt yazısı olarak bilinen problemdir. Tam ve doğal görüntü tanımlarının otomatik olarak üretilmesi, haber görüntülerine eklenen başlıklar, tıbbi görüntülerle ilişkili açıklamalar, metin tabanlı görüntü alma, görme engelli kullanıcılar için erişilen bilgiler, insan-robot etkileşimi gibi büyük potansiyel etkilere sahiptir. Resim altyazılamadaki bu uygulamalar önemli teorik ve pratik araştırma değerlerine sahiptir. Bu nedenle, resim altyazıları yapay zeka çağında daha karmaşık ama anlamlı bir görevdir (Liu vd, 2018).

Resim yazısı, görüntülerin insan benzeri tanımlarını otomatik olarak oluşturma işlemidir. İyi pratik ve endüstriyel öneme sahip çok baskın bir görevdir. Auto Image captioning, endüstri, güvenlik, gözetim, tıp, tarım ve daha birçok ana alanda iyi bir

pratik kullanıma sahiptir. Bilgisayarla görmede sadece çok önemli değil, aynı zamanda çok zorlayıcı bir görevdir. Geleneksel nesne algılama ve görüntü sınıflandırma görevi, yalnızca görüntü içindeki nesnelere tanımlamak için gereklidir, burada otomatik görüntü altyazısı oluşturma görevi yalnızca nesnelere tanımlamak değil, aynı zamanda bunlar arasındaki ilişkiyi ve görüntünün toplam sahne anlayışını da tanımlamaktır. Sahneyi anladıktan sonra, o görüntünün insan benzeri bir tanımını oluşturmak da gerekiyor. Otomasyonun ve Yapay Zekanın artmasından bu yana, makineye insan benzeri yetenekler kazandırmak ve manuel çalışmayı azaltmak için çok sayıda araştırma yapılıyor. Görüntü başlıklandırma probleminde insan kadar iyi sonuçlar ve doğruluk elde eden makineler için her zaman çok zor bir görev olmuştur (Chohan vd, 2020).

### **4.3.3. Derin Öğrenme Algoritması İle Özellik Seçimi**

Duyarlılık analizi tipik olarak girdi bağlantılı ağırlıklarda kesinti ile çıktıdaki bireysel girdi boyutlarının önemini göstermek için kullanılır. Çok katmanlı bir algılayıcı ağının her katmanı için yüksek hassasiyet sınırı, ağda ihtiyaç duyulan optimum nöron sayısını belirler. Bununla birlikte, doğrultulmuş doğrusal birim için bu tür bir analiz genellikle gerekli değildir çünkü inaktif nöronlar hiç eğitilmeyebilir. Derin Sinir Ağı için duyarlılık analizi 1 veya 2 katmanı geçmez. Bu nedenle, bir girdi özelliğinin katkısını doğru bir şekilde analiz etmek için, toplam aktivasyon potansiyeline göre aktivasyon potansiyelini (ortalama olarak, genel girdi eğitim değerleri ve gizli nöronlar) inceliyoruz. Bir girdi boyutunun aktivasyonunun potansiyel katkısı ne kadar büyükse, gizli sinirsel aktiviteye katılma ve sonuç olarak onu sınıflandırma olasılığı o kadar yüksektir (Roy vd, 2015).

Hung ve Wang, sahneleri sınıflandırmak için derin öğrenmeye yönelik bir özellik seçme yöntemi önerdiler. Bir özellik seçimi yaklaşımını bir özellik yeniden yapılandırma problemine dönüştürdüler. Bir sahne sınıflandırma görevinde, ayrımcılıktan daha verimli olan özellikleri seçerler. Bununla birlikte, ayrımcı özelliklerin ortadan kaldırılması, tipik bir sınıflandırma görevinde sınıflandırma doğruluğunu azaltabilir. İbrahim vd. ayrıca gen ifade verilerini işlemek için derin inanç ağı, klasik özellik seçme yöntemleri ve denetimsiz aktif öğrenme yöntemini kullanmıştır. Derin inanç ağı, yüksek boyutlu girdi verilerini modellemek ve girdi verilerinin daha yüksek seviyeli bir temsilini çıkarmak için kullanıldı. Daha sonra, t-

testi yöntemi gibi istatistiksel klasik özellik seçme yöntemleri, daha yüksek düzeyde çıkarılan özelliklerden öznelikleri seçmek için kullanıldı. İbrahim ve diğerlerinin yöntemi, ayrı hesaplama maliyetleri olan üç kademeli bağımsız modül kullanmıştır. Eğitim verilerinin sayısı yüksek olduğunda hesaplama maliyetleri önemli ölçüde artabilir. Derin inanç ağı, çok sayıda eğitim verisi örneğiyle çalışmak üzere tasarlanmıştır ve gereksiz hesaplama maliyetini önlemek için büyük veri kümelerini eğitmeye uygun özellik seçimi işlevselliği gerektirir. Derin boltzmann makineleri gibi derin öğrenme yöntemleri, genellikle çok sayıda eğitim örneğine ihtiyaç duyan çok sayıda doğrusal olmayan işleme ögesinden oluşur. Öte yandan, derin öğrenme yöntemini eğitmek için gerekli gözlemlerin (eğitim örnekleri) sayısı, girdi özelliklerinin sayısı ile birlikte katlanarak artmalıdır (Huang vd, 2020).

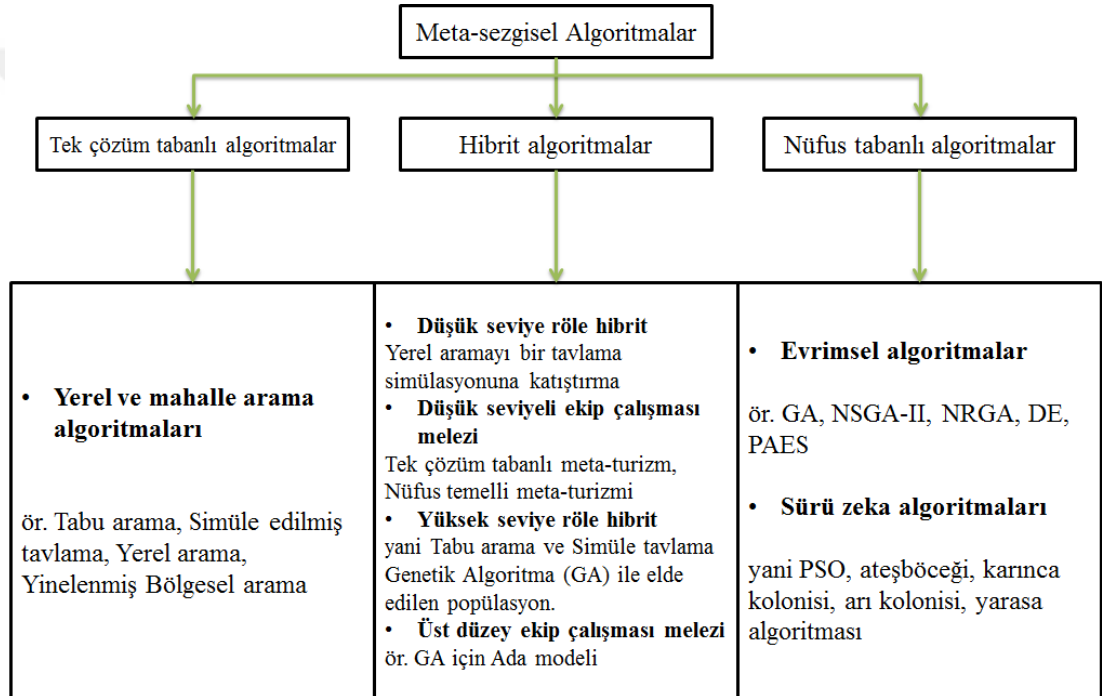
Özellik seçimi yoluyla, girdi özelliklerinin sayısı ve sonuç olarak derin bir boltzmann makinelerinin eğitimi için gerekli eğitim örneği sayısı azaltılabilir. Bu nedenle, derin öğrenme yöntemlerinin daha az eğitim verisi ile eğitilmesine yardımcı olmak için özellik seçimi şiddetle gereklidir. Bu makalede, derin boltzmann makinelerinin işleme yeteneğini geliştirmek ve derin boltzmann makineleri için özellik seçiminin hesaplama maliyetini düşürmek için bir özellik seçme yöntemi önerilmiştir (Taherkhani vd, 2018).

#### **4.4. Metasezgisel Algoritmalar**

Sezgisel, "bulmak" veya "çözümleri deneme yanılma yoluyla keşfetmek" anlamına gelir. Sezgisel yöntemler, büyük ölçekli problemler için uygun çözümler aramayı amaçlar (Yang, 2010). Geleneksel optimizasyon yöntemlerinin birçok eksikliğinin üstesinden geldikleri kanıtlanmıştır, ancak bunlar genellikle deneyime dayalı yöntemlerdir. Sezgisel yöntemler, optimal çözüme yakın olmayı ümit eden çözümü hızla bulur. Ancak sezgisel teknikler, karmaşık problemler için etkili kabul edilmez. Bunun iki ana nedeni var:

- Sezgisel teknikler genellikle (her zaman değil) karmaşık problemlerin çözümünde makul ve kabul edilebilir bir yanıt sağlasa da; karmaşık problemleri çözmek için en uygun çözümü vaat etmezler ve garanti etmezler (Chinneck, 2006).
- Sezgisel teknikler, büyük ölçüde model geliştiricinin deneyimine ve matematik bilgisine bağlıdır (Coello vd, 2007).

Sezgisel algoritmaların gelişimi, metasüristik algoritmalar olarak adlandırılır. "Meta" terimi, "ötesinde" veya "daha yüksek seviye" anlamına gelir. Meta sezgisel yöntemler genellikle basit buluşsal yöntemlere kıyasla daha iyi performans gösterir. Temel olarak, meta-sezgisel algoritmalar, belirli rasgele seçim ve yerel arama değiş tokuşlarını kullanır (Yang, 2010). Meta-sezgisel algoritmalar daha kapsamlı bir arama yaptıkları için, kesin yöntemlerin çözemediği karmaşık gerçek yaşam sorunlarına çözüm üretmek için hızla tercih edilen metodoloji haline geldiler (Glover ve Kochenberger, 2006). Literatürde meta sezgisel algoritmalar için mevcut birkaç sınıflandırma vardır. Şekil 4.12, meta-sezgisel algoritmaların genel bir sınıflandırmasını sunar.



Şekil 4.12. Meta sezgisel algoritmaların genel sınıflandırması

Meta-sezgisel algoritmalar, benzersiz ve dikkat çekici özellikleri ve yetenekleri nedeniyle bilim adamları, bilim adamları ve akademisyenler için ilginç bir alan olmuştur. Çok yönlü alan problemlerini kesin ayrıntı ve problem tanımı olmaksızın çözme ve bunlara en uygun çözümleri sağlama yetenekleri, geleneksel tekniklere göre marjinaldir. Bazı gerçek dünya fenomenlerinden esinlenen çoğu meta-sezgisel algoritma, genellikle doğal bir optimizasyon yöntemidir. Son birkaç yılda, bir dizi meta-sezgisel algoritma tanıtıldı ve farklı alanların farklı problemlerine uygulandı (Rajpurohit vd, 2017).

- Meta-sezgisel bir algoritma tasarlama ihtiyacı:

Hesaplama karmaşıklığı teorisi olarak bilinen hesaplama teorisinin ana dalı, doğal zorluklarıyla ilgili sorunları sınıflandırmayı amaçlamaktadır. Bir problemle ilişkili karmaşıklık, aslında bu problemi çözen en iyi algoritmaya eşdeğerdir. Dahası, karmaşıklık teorisi, her zaman 'evet' veya 'hayır' cevabı verdikleri kararlarla ilgilidir. Bu satırda, bir polinom zaman algoritması çözebiliyorsa, soruna kolay veya izlenebilir denir. Hiçbir polinom zaman algoritması bir sorunu çözemezse, bu zor veya çözülemez bir problem olarak bilinir. Hesaplama teorisindeki diğer bir amaç, sorunları belirli karmaşıklık sınıflarına ayırmaktır. Belirli bir miktardaki hesaplama kaynağı için, bir karmaşıklık sınıfı, çözülebilecek tüm problemler kümesine karşılık gelir. P (polinom zaman) ve NP (nondeterministic polinomial zaman), karmaşıklık sınıflarındaki iki ana problem sınıfıdır (Memari vd, 2017).

#### **4.4.1. Sömürge Rekabetçi Algoritması (SRA)**

Emperyalizm, bir devletin gücünü ve egemenliğini sınırlarının ötesine genişletme politikasıdır. Bir ülke başkalarına doğrudan egemenlik yoluyla ya da malların ve hammaddelerin piyasada kontrolünü ele alma gibi yollarla hükmetmeye çalışabilir: Emperyalizm, ilk haliyle sadece kaynaklarını kullanan diğer ülkeler üzerinde politik bir kontroldü. Ayrıca, bazı durumlarda, başka bir ülkeyi kontrol etmenin nedeni, emperyalist rakibin onu ele geçirmesini önlemektir. Nedeni ne olursa olsun, emperyalist hükümetler sömürgelerini artırmak ve imparatorluklarını dünya çapında genişletmek için şiddetle rekabet ediyorlardı. Bu rekabet güçlü imparatorlukların gelişmesine ve zayıf imparatorlukların çöküşüne yol açtı. Emperyalizm 19. ve 20. yüzyıllarda Batı medeniyetine karşı genel tutumu değiştirdi. Sosyal Darwinistler emperyalizmi yorumladılar ve Batı kültürünün Doğu kültüründen üstün olduğu inancını desteklediler. Emperyalizm, bu tutumun sonucu olarak bir haçlı seferiydi. Daha sonra, tüm etkileriyle emperyalizm, emperyalist ülkelerin kolonilerini geliştirmeye (kültürlerini genişletmeye) neden oldu (Atashpaz-Gargari ve Lucas, 2007).

Emperyalist rekabetten kaynaklanan emperyalist Rekabet Algoritması (ICA), diğer evrimsel algoritmalar gibi, devlet olarak bilinen ilk nüfusla başlar. Bir ülke, birlikte imparatorlukları oluşturan her türlü koloniyi ve emperyalisti içerir. Emperyalist ülkeler diğer ülkeleri fethetmeye ve onları koloni yapmaya çalışıyorlar.

Ayrıca, emperyalist ülkeler diğer ülkeleri fethetmek uğruna şiddetli bir şekilde rekabet ederler. Bu imparatorluklar arasındaki emperyalist rekabet önerilen evrimsel algoritmayı oluşturur. Bu yarışma sırasında en zayıf imparatorluklar düşer ve daha güçlü olan daha fazla güç kazanır. Emperyalist rekabet, yalnızca bir imparatorluğun olduğu ve sömürgelerin emperyalist ile aynı işlev ve değere sahip olduğu koşullara dönüşür, çünkü kolonilerin büyük bir kısmı emperyalistlerin yerini alabilir (Razmjoooy vd, 2013).

Optimizasyon algoritmaları daha önce doğal ve biyolojik olaylardan esinlenmiştir ama Sömürge rekabet algoritması, emperyalist ülkeler arasındaki tarihsel rekabet modelinden ilham alınarak oluşturuldu. Bu algoritma 2007 yılında İsmail Atashpaz ve Profesör Lucas tarafından modelleme süreçleri için evrimsel bir optimizasyon hedefi olarak tanıtıldı. Bu algoritma diğer optimizasyon algoritmalarına göre üstünlük göstermiştir ve elektrik mühendisliği, yazılım, yapay zeka, endüstriler vb. Dahil olmak üzere çeşitli mühendislik alanlarında birçok sorunu çözmüştür. Aslında, bu algoritma matematik dünyasına tamamen insani bakış açısıyla açılan açık bir kapıdır (Naggashi vd, 2012).

Sömürge ülkeler, farklı optimizasyon eksenleri boyunca asimilasyon politikaları uygulayarak sömürge devletlerini kırıyor. Emperyalist rekabet, asimilasyon politikası ile birlikte bu algoritmanın çekirdeğini oluşturur ve devletlerin mutlak minimum seviyeye doğru hareket etmesine neden olur. Asimilasyon politikasının bir sonucu olarak, koloni minimal bir alandan ayrılır ve daha iyi bir konumda olduğu başka bir minimal alana girer. Bu hareketin devam etmesi, sömürge durumunun sömürge durumuna tamamen asimile edilmesine yol açabilir. Bir imparatorluğun hayatta kalması, rakip imparatorluk kolonilerini ele geçirme ve fethetme gücüne bağlıdır. Sonuç olarak, emperyalist rekabet sırasında, daha büyük imparatorlukların gücü kademeli olarak artacak ve zayıf olanları ortadan kalkacaktır. Güçlerini arttırmak için imparatorlukların kolonilerini de genişletmesi gerekecek. Zamanla, sömürgeler güç açısından imparatorluklara yaklaşacak ve bir tür yakınlaşma göreceğiz. Sömürge rekabetinin nihai sınırı, dünyada emperyalist devletin kendisine çok yakın olan kolonilerle tek bir imparatorluğumuz olduğu zamandır. Optimizasyonda amaç, problem değişkenleri açısından en uygun çözümü bulmaktır. Optimize edilmesi gereken bir dizi problem değişkeni oluşturuyoruz. Bu dizinin genetik algoritmasında kromozom denir. İşte buna ülke diyoruz. Sömürge

rekabet algoritması, her şeyden önce, tamamen yeni bir optimizasyon yaklaşımıyla, bir yanda insan ve sosyal bilimler ile diğer yanda teknik ve matematiksel bilimler arasında yeni bir bağ kurar. Sömürge rekabet algoritması, matematiğin daha iyi anlaması ve matematiksel problemleri, beşeri bilimlerin ve sosyal bilimlerin gücünü, yani holizmi ve vizyon genişliğini çözmesi için bir araç görevi görür (Atashpaz-Gargari ve Lucas, 2007).

- Sömürge rekabet algoritmasının avantajları

Sömürge rekabet algoritmasının avantajları aşağıdaki gibi özetlenebilir:

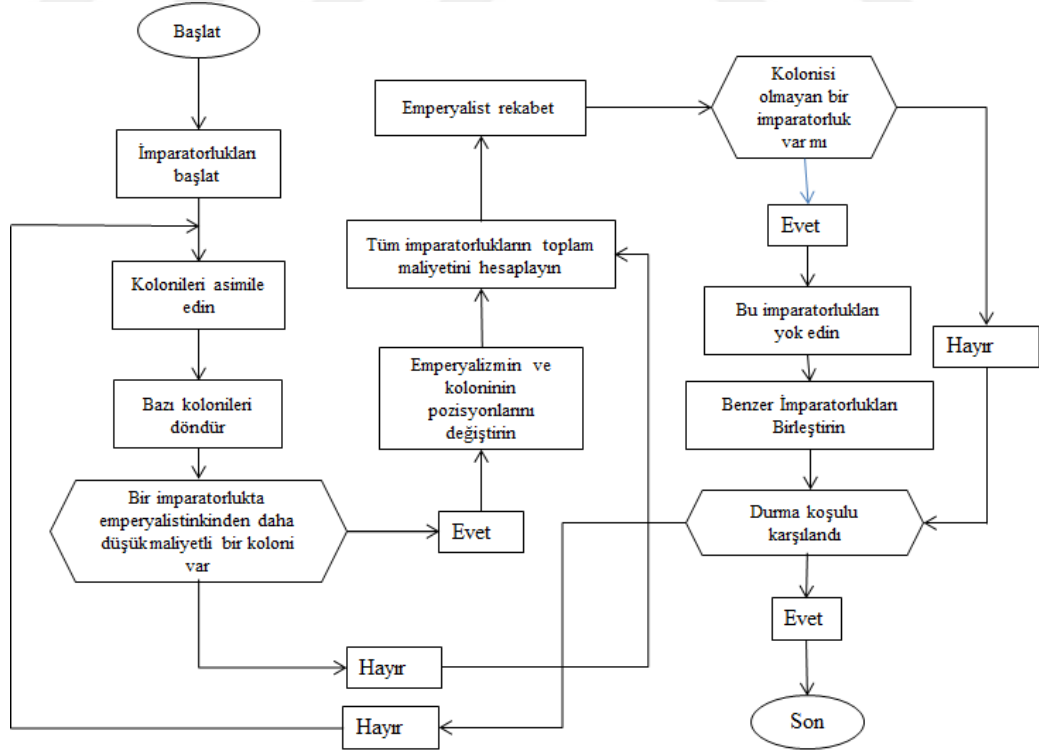
- Algoritmanın yeni temel fikri: sosyal-politik bir sürece dayanan ilk optimizasyon algoritması olması
- Çeşitli optimizasyon problemleri karşısında farklı optimizasyon algoritmalarına kıyasla optimizasyon ve hatta daha yüksek optimizasyon seviyesine sahip olması
- En uygun cevabı bulmakta daha hızlı olması
- Tanınırken yenilik ve yeni olması
- esnek olması
- Sömürge rekabet algoritmasının hedefi

emperyalist Rekabetçi Algoritma (ICA), son zamanlarda farklı optimizasyon görevleriyle uğraşmak için tanıtılan yeni bir sosyo-politik motivasyonlu küresel arama stratejisidir (Atashpaz Gargari ve Lucas, 2007). Bu evrimsel optimizasyon stratejisi hem yakınsama hızında hem de daha iyi küresel optima başarısında büyük performans göstermiştir ((Atashpaz-Gargari ve Lucas, 2007); (Rajabioun vd, 2008b); (Biabangard-Oskouyi vd, 2009); (SEPEHRI, 2008);(Gargari vd, 2008); (Rajabioun vd, 2008a)). Bununla birlikte, çeşitli alanlarda etkinliği, sınırlamaları ve uygulanabilirliği halen kapsamlı bir şekilde araştırılmaktadır. Atashpaz Gargari vd. (2008) emperyalist rekabetçi algoritma, endüstriyel bir Çok Girişli Çok Çıkışlı (ÇGÇÇ) damıtma kolonu işlemini sadece merkezi olmayan bir şekilde değil, aynı zamanda en iyi şekilde kontrol eden optimal bir kontrolör tasarlamak için kullanmışlar. Hemen hemen aynı şey Rajabioun ve ark. (2008 (a)) için 3 \* 3 Evaporatif Tesisi modeli olan daha karmaşık bir Çoklu Giriş Çoklu Çıkış(ÇGÇÇ) sistemi için yapılmış. Biabangard Oskouyi vd. (2008) yapay sinir ağının ters analizi için Imperialist rekabetçi algoritmasını keskin girinti testinden gelen malzemelerin



özelliklerini karakterize etmek için kullanmıştır. Tavsiye sistemlerinde her kullanıcı için en uygun öncelikleri bulmak için Sepehri Rad ve Lucas (2007), tavsiye sistemlerine “Öncelikli kullanıcı profili” yaklaşımında Imperialist rekabetçi algoritmalarını kullanarak, her bir özelliğe farklı öncelik önemi atayarak daha kişiselleştirilmiş bir öneri uygulamaya çalışmaktadır. farklı kullanıcılarda kullanıcı profili. Ayrıca Rajabioun vd. (2008 (b)) farklı oyunların Nash denge noktasını bulmak için Imperialist rekabetçi algoritmalarını kullanmaktadır (Atashpaz-Gargari ve Lucas, 2007).

Şekil 4.13, Imperialist rekabetçi algoritmasını akış şemasını göstermektedir. Diğer evrimsel algoritmalara benzer şekilde, bu algoritma ilk popülasyonla başlar. Nüfusun her bireye ülke denir. En iyi ülkelerden bazıları (optimizasyon terminolojisinde, en düşük maliyete sahip ülkeler) emperyalist devletler olarak seçilir ve geri kalanı da bu emperyalistlerin kolonilerini oluşturur. Tüm kolonileri ilk ülkeler, güçlerine göre, söz konusu emperyalistler arasında bölünmüştür. Her ülkenin gücü, Genetik algoritma'daki kondisyon değerinin karşılığı, maliyeti ile ters orantılıdır. Emperyalist devletler kolonileri ile birlikte bazı imparatorluklar oluştururlar.



Şekil 4.13. Emperyalist-rekabetçi-algoritma-akış şeması

İlk imparatorlukları kurduktan sonra, her birindeki koloniler ilgili emperyalist

ülkelerine doğru ilerlemeye başlarlar. Bu hareket, emperyalist devletlerin bazıları tarafından izlenen basit bir asimilasyon politikası modelidir. Bir imparatorluğun toplam gücü hem emperyalist ülkenin gücüne hem de sömürgelerinin gücüne bağlıdır. Bu gerçek, bir imparatorluğun toplam gücünü emperyalist ülkenin gücü artı kolonilerinin ortalama gücünün yüzdesi olarak tanımlayarak modellenir (Shakhsi-Niaei vd, 2013).

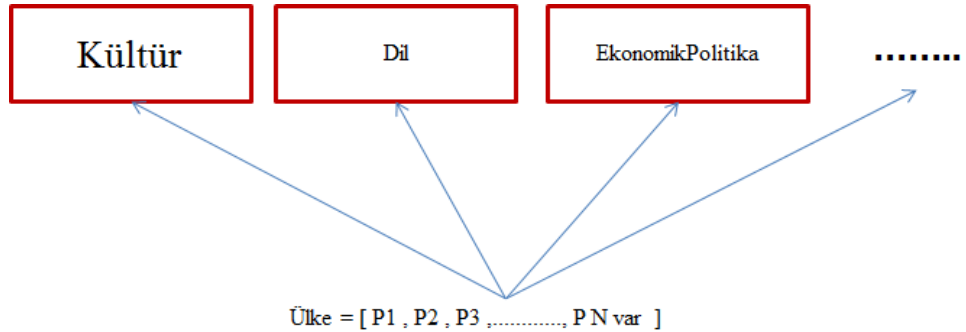
#### 4.4.1.1. Sömürge Rekabet Algoritmasının Yapısı

- İlk imparatorlukların yaratılması

Optimizasyonun amacı, sorunun değişkenleri açısından en uygun çözümü bulmaktır. Optimize edilecek bir değişken değerleri dizisi oluşturuyoruz. GA terminolojisinde bu diziye “kromozom” denir, ancak Sömürge rekabet algoritmasının 'da bu dizi için “ülke” terimi kullanılır.  $N_{var}$  boyutlu bir optimizasyon probleminde, ülke  $1 \times N_{var}$  dizisidir. Bu dizi aşağıdaki gibi tanımlanı:

$$\text{Ülke} = [ P1 , P2 , P3 , \dots, P N \text{ var} ] \quad (4.6)$$

Burada  $p_i$ , optimize edilecek değişkenlerdir. Ülkedeki değişken değerler kayan nokta sayıları olarak gösterilir. Ülkedeki her değişken, bir ülkenin sosyo-politik özelliği olarak yorumlanabilir. Bu açıdan algoritmanın yaptığı tek şey, kültür, dil, ekonomi politikası ve hatta din gibi sosyo-politik özelliklerin en iyi kombinasyonuna sahip ülke olan en iyi ülkeyi aramaktır. Optimizasyon açısından bu, sorunun en uygun çözümünü, en düşük maliyet değerine sahip çözümü bulmasına yol açar. Şekil 4.14, bazı sosyo-politik özellikleri kullanarak ülkenin yorumunu göstermektedir (Abdi vd, 2011).



Şekil 4.14. Ülkenin adı verilen sorunun aday çözümleri, kültür, dil ve din gibi bazı sosyo-politik özelliklerin birleşiminden oluşur

Bir ülkenin maliyeti,  $[ P_1, P_2, P_3, \dots, P_{N_{var}} ]$  değişkenlerdeki f maliyet fonksiyonunun değerlendirilmesi ile bulunur. Yani:

$$\text{Maliyet} = f(\text{Ülke}) = f(P_1, P_2, P_3, \dots, P_{N_{var}}) \quad (4.7)$$

Optimizasyon algoritmasını başlatmak için  $N_{ülke}$  büyüklükteki ülkenin ilk ülkeleri üretilir. İmparatorlukları oluşturmak için en güçlü ülkelerin  $N_{imp}$ 'ini seçiyoruz. İlk ülkelerin kalan  $N_{kol}$ , her biri bir imparatorluğa ait olan koloniler olacak. İlk imparatorlukları oluşturmak için koloniler güçlerine göre emperyalistler arasında bölünür. Yani, bir imparatorluğun ilk kolonilerinin sayısı onun gücü ile doğru orantılı olmalıdır. Kolonileri emperyalistler arasında orantılı olarak bölmek için, bir emperyalistin normalleştirilmiş maliyeti şu şekilde tanımlanır (Niknam vd, 2011):

$$C_n = c_n - \max(c_i) \quad (4.8)$$


$c_n$ , n'inci emperyalizmin maliyeti ve  $C_n$  normalleştirilmiş maliyetidir. Tüm emperyalistlerin normalleştirilmiş maliyetine sahip olan her emperyalizmin normalleştirilmiş gücü, şu şekilde tanımlanır:

$$P_n = \left| \frac{C_n}{\sum_{i=1}^{N_{imp}} C_i} \right| \quad (4.9)$$

İlk koloniler, güçlerine göre imparatorluklar arasında bölünür. Sonra n'inci imparatorluğun ilk kolonileri aşadaki gibi hesaplanacak

$$N.C_n = \text{rastgele}\{P_n.N_{col}\} \quad (4.10)$$

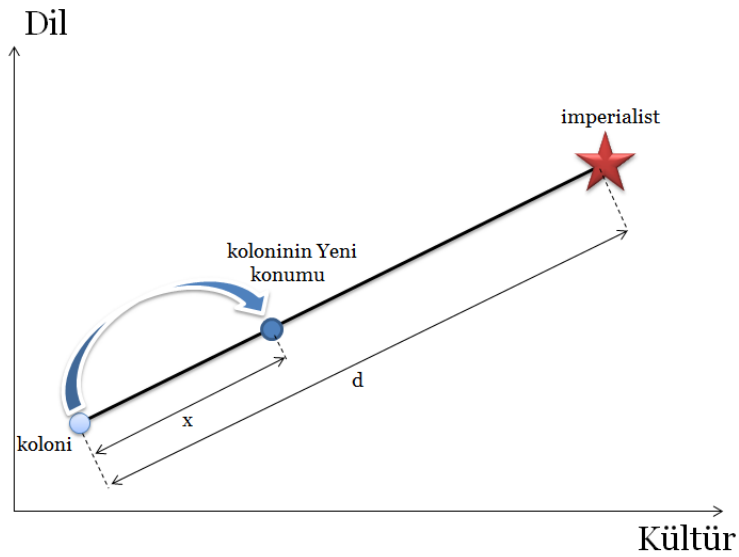
Burada  $N.C_n$ , n'inci İmparatorluğun başlangıçtaki koloni sayısı ve  $N_{col}$ , toplam başlangıçtaki koloni sayısıdır. Kolonileri bölmek için, kolonilerin  $N.C_n$ 'si rastgele seçildi ve n'inci emperyaliste atandı. Bu koloniler n'inci emperyalist ile birlikte n'inci imparatorluğu oluşturur. Şekil 4.15, erken imparatorlukları göstermektedir. Bu şekilde gösterildiği gibi, daha büyük imparatorlukların daha fazla kolonisi varken, zayıf olanların daha az kolonisi vardır. Bu formda Emperyalist 1 en güçlü imparatorluğu oluşturur ve bu nedenle en fazla koloniye sahiptir (Sadati ve Mohasefi, 2014).



Şekil 4.15. İlk imparatorlukların oluşturulması: Bir emperyalist ne kadar çok koloniye sahip olursa, ilgili ★ işareti o kadar büyük olur

- Asimilasyon: Kolonilerin emperyalizme yönelik hareketi

Asimilasyon politikasını takip ederek, emperyalist devletler kolonilerini emmeye ve onları kendilerinin bir parçası yapmaya çalıştılar. Daha doğrusu, emperyalist devletler kolonilerini kültür, dil ve din gibi farklı sosyo-politik eksenler boyunca kendilerine doğru hareket ettirdiler. Imperialist rekabetçi algoritmaların'da bu süreç, tüm kolonilerin farklı optimizasyon eksenleri boyunca emperyalistlere doğru hareket ettirilmesiyle modellenmiştir. Şekil 4.16 bu hareketi göstermektedir. 2 boyutlu bir optimizasyon problemi göz önüne alındığında, bu şekilde koloni emperyalist tarafından kültür ve dil eksenlerinde emilir. Sonra koloni bu eksenlerdeki emperyalistlere yaklaşacaktır. Asimilasyonun devamı, tüm kolonilerin emperyalist olarak tamamen asimile edilmesine neden olacaktır (Kaveh ve Talatahari, 2010).



Şekil 4.16. Kolonilerin ilgili emperyalistlere doğru hareketi

Imperialist rekabetçi algoritmasının'da asimilasyon politikası, tüm sömürgeler emperyalistlere doğru hareket ettirilerek modellenir. Bu hareket Şekil 4.17'te gösterilmiştir; burada bir koloni emperyalistlere  $x$  birimleri ile hareket eder. Koloninin yeni konumu daha koyu renkte gösterilir. Hareketin yönü, koloniden emperyaliste olana vektördür. Şekil 4.17de  $x$ , düzgün (veya herhangi bir uygun) dağılıma sahip rastgele bir değişkendir.


$$X \sim U(0, \beta * d) \quad (4.11)$$

burada  $\beta$ , 1'den büyük bir sayıdır ve  $d$ , koloni ile emperyalist durum arasındaki mesafedir.  $\beta > 1$  kolonilerin her iki taraftan emperyalist duruma yaklaşmasına neden olur (Duan vd, 2010).

Sömürgeleri emperyalist devletler tarafından özümsemek, sömürgelerin emperyalistlere doğru doğrudan hareket etmesiyle sonuçlanmaktadır. Yani, hareket yönü mutlaka vektöre değil'de koloniden emperyalistlere doğru dur. Bu gerçeği modellemek ve emperyalist çevresinde daha fazla alan arama yeteneğini arttırmak için hareket yönüne rastgele miktarda sapma eklenir. Şekil yeni yönü göstermektedir. Bu şekilde  $\theta$  düzgün (veya uygun) dağılımlı bir parametredir. Sonra

$$\theta \sim U(-\gamma, \gamma) \quad (4.12)$$


Burada  $\gamma$ , orijinal yönden sapmayı ayarlayan bir parametredir. Bununla birlikte,  $\beta$  ve  $\gamma$  değerleri isteğe bağlıdır, uygulamaların çoğunda  $\beta$  için yaklaşık 2 ve  $\gamma$  için yaklaşık  $\pi / 4$  (Rad) değeri, Ülkelerin minimum düzeye yaklaşmasına yol açar (Zhang vd, 2009).




Şekil 4.17. Kolonilerin rasgele sapsmış bir yönde ilgili emperyalistlerine doğru

- Emperyalist ve koloninin deęişim pozisyonları

Emperyalistlere doęru ilerlerken, bir koloni emperyalistten daha düşük maliyetli bir konuma ulaşabilir. Bu durumda, emperyalist ve koloni konumlarını deęiştirir. Daha sonra algoritma emperyalist tarafından yeni pozisyonda devam edecek ve koloniler emperyalist tarafından yeni pozisyonunda asimile edilecek. Şekil 4.18(a), bir koloni ile emperyalist arasındaki konum deęişimini göstermektedir. Bu şekilde, imparatorluğun en iyi kolonisi daha koyu bir renkte gösterilmiştir. Bu koloninin emperyalistlerden daha düşük bir maliyeti var. Şekil 4.18(b), emperyalistin ve koloninin konumunu deęiştirdikten sonra imparatorluğu göstermektedir (Duki vd, 2010).



Şekil 4.18(a). Bir koloninin ve emperyalistin pozisyonlarını deęiştirmek



Şekil 4.18(b). Pozisyon deęişiminden sonra tüm imparatorluk

- Bir imparatorluğun toplam gücü

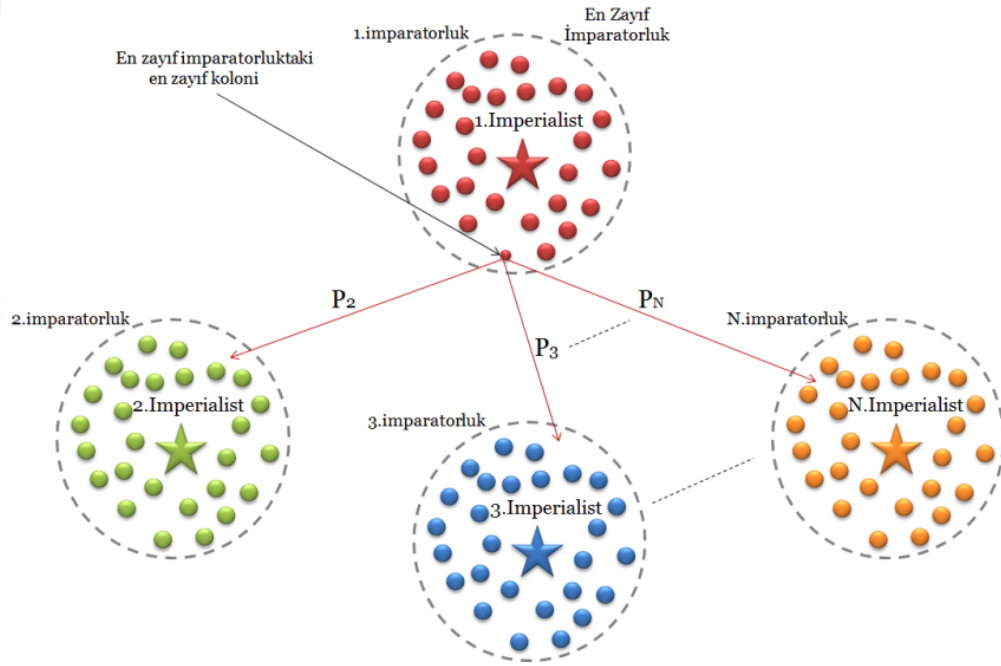
Bir imparatorluğun toplam gücü esas olarak emperyalist ülkenin gücünden etkilenir. Bununla birlikte, bir imparatorluğun kolonilerinin gücünün, ihmal edilebilir de olsa, o imparatorluğun toplam gücü üzerinde bir etkisi vardır. Bu gerçek, bir imparatorluğun toplam maliyetini:

$$T.C = \text{Maliyet}(N. \text{Imparatorluk}) + \varepsilon \text{ ortalama}\{\text{Maliyet}(N. \text{Imparatorluğun kolonisi})\} \quad (4.13)$$

T.C.n, n'inci imparatorluğun toplam maliyeti ve  $\xi$  pozitif küçük bir sayıdır.  $\xi$  için küçük bir deęer, imparatorluğun toplam gücünün sadece emperyalist tarafından belirlenmesine neden olur ve onu arttırmak, bir imparatorluğun toplam gücünü belirlemede kolonilerin rolüne artacaktır.  $\xi$  için 0,1 deęeri, uygulamaların çoğunda iyi sonuçlar göstermiştir (Jalilzadeh vd, 2012).

- Emperyalist rekabet

Tüm imparatorluklar diğer imparatorlukların kolonilerini ele geçirmeye ve kontrol etmeye çalışırlar. Emperyalist rekabet yavaş yavaş zayıf imparatorlukların gücünde bir düşüşe ve daha güçlü olanların gücünde bir artışa neden olur. Emperyalist rekabet, en zayıf imparatorluğun en zayıf kolonilerinden bazılarını (genellikle birini) seçerek ve bu (bu) kolonilere sahip olmak için tüm imparatorluklar arasında bir rekabet yaparak modellenir. Şekil 4.19, modellenmiş emperyalist rekabetin büyük bir resmini göstermektedir. Toplam güçlerine dayanarak, bu yarışmada, imparatorlukların her birinin belirtilen kolonilere sahip olma olasılığı olacaktır. Başka bir deyişle, bu kolonilere kesinlikle en güçlü imparatorluklar sahip olmayacak, ancak bu imparatorluklara sahip olma olasılıkları daha yüksek olacaktır (Behzadpoor vd, 2014).



Şekil 4.19. Emperyalist rekabet: Bir imparatorluk ne kadar güçlü olursa, en zayıf imparatorluğun en zayıf kolonisine sahip olma olasılığı o kadar yüksektir.

Yarışmaya başlamak için önce en zayıf imparatorluğun bir kolonisi seçilir ve daha sonra her imparatorluğun sahip olma olasılığı bulunur. Topa sahip olma olasılığı  $P_p$ , imparatorluğun toplam gücü ile orantılıdır. Bir imparatorluğun normalleştirilmiş toplam maliyeti:

$$N.T.C_n = T.C_n - \max\{T.C_i\} \quad (4.14)$$

Burada,  $T.C_n$  ve  $N.T.C_n$  sırasıyla toplam maliyet ve normalleştirilmiş toplam n'inci imparatorluk maliyetidir. Normalleştirilmiş toplam maliyete sahip olarak, her

imparatorluğun sahip olma olasılığı (Attar vd, 2011).

$$P_{pn} = \left| \frac{N.T.C_n}{\sum_{i=1}^N N.T.C_i} \right| \quad (4.15)$$

Bahsedilen kolonileri imparatorluklar arasında bölmek için P vektörü aşağıdaki gibi oluşturulur:

$$P = [P_{p1}, P_{p2}, P_{p3}, \dots, P_{pn \text{ imp}}] \quad (4.16)$$

Daha sonra, elemanları eşit olarak dağıtılmış rasgele sayılar olan P ile aynı boyutta R vektörü oluşturulur:

$$R = [r_1, r_2, r_3, \dots, r_{pn \text{ imp}}] \quad r_1, r_2, r_3, \dots, r_{pn \text{ imp}} \sim U(0,1) \quad (4.17)$$

Daha sonra D vektörü, R vektörünü P'den çıkartılarak oluşturulur:

$$\begin{aligned} D &= P - R [D_1, D_2, D_3, \dots, D_{pn \text{ imp}}] \\ &= [P_{p1} - r_1, P_{p2} - r_2, P_{p3} - r_3, \dots, P_{pn \text{ imp}} - r_{pn \text{ imp}}] \end{aligned} \quad (4.18)$$

Vektör D'ye referansla, bahsedilen koloni (koloniler), D'deki ilgili indeksi maksimuma çıkarılan bir imparatorluğa verilir (Khabbazi vd, 2009).

Bir imparatorluk seçme süreci, genetik algoritmasının'da ebeveynlerin seçiminde kullanılan rulet tekerleği işlemine benzer. Ancak bu seçim yöntemi geleneksel rulet tekerleğinden çok daha hızlıdır. Birikimli dağılım işlevinin hesaplanması gerekmediğinden ve seçim yalnızca olasılık değerlerine dayalıdır. Dolayısıyla, imparatorlukları seçme süreci yalnızca genetik algoritmasının'daki rulet tekerleğinin yerine geçebilir ve yürütme hızını artırabilir (Lian vd, 2012).

Sömürge rekabet algoritması ana adımları sahte kodda özetlenmiştir. Şekil 4.20'da verilmiştir. Söz konusu adımların devam etmesi, ülkelerin maliyet işlevinin küresel minimumuna yaklaşmasına neden olacaktır. Algoritmayı durdurmak için farklı kriterler kullanılabilir. Bir fikir, algoritmayı durdurmak için algoritmanın maksimum on yıllar olarak adlandırılan birkaç maksimum yinelemesini kullanmaktır. Veya emperyalist rekabetin sonu, sadece bir imparatorluk olduğunda, Sömürge rekabet algoritması'nın durma kriteri olarak düşünülebilir. Öte yandan, farklı on yıllardaki en iyi çözümü birbirini izleyen on yıllar boyunca geliştirilemediğinde algoritma durdurulabilir (Mamaghani ve Meybodi, 2011).



- 1) İşlev üzerinde rastgele noktalar seçin ve imparatorlukları başlatın.
- 2) Kolonileri ilgili emperyalistlere (Asimilasyon) doğru hareket ettirin.
- 3) Bazı kolonilerin konumlarını rastgele değiştirin (Devrim).
- 4) İmparatorluktan emperyalistten daha düşük maliyetli bir koloni varsa, o koloninin ve emperyalistin pozisyonlarını değiştirin.
- 5) Benzer imparatorlukları birleştirin.
- 6) Tüm imparatorlukların toplam maliyetini hesaplayın.
- 7) En zayıf imparatorluklardan en zayıf koloniyi (kolonileri) seçin ve imparatorluklardan birine verin (Emperyalist rekabet).
- 8) Gücsüz imparatorlukları ortadan kaldırın.
- 9) Durma koşulları sağlandıysa, durun, yoksa 2'ye gidin

Şekil 4.20. Emperyalist Rekabetçi Algoritmanın Sahte Kodu

#### 4.4.1.2. Sömürge Rekabet Algoritması İle Özellik Seçimi

Veri sınıflandırma sürecinde, bir dizi özellik gereksiz, gürültülü ve hatta ilgisiz bilgiler içerebilir. Bu bilgi, sınıflandırma doğruluğunu bile azaltabilir. Uygun özelliklerin veya özellik seçiminin seçilmesi, veri madenciliği ve bilgi keşfinin ana adımlarından biridir. N sayıda özelliğe sahip uygun özellikleri bulmak,  $2^N$  olası alt kümeyi değerlendirmelidir. Bu yaklaşım yorucu ve zaman alan bir yöntemdir. Hesaplama karmaşıklığını azaltmaya çalışan sezgisel ve rastgele aramaya dayalı başka yöntemler de vardır (Mousavirad ve Ebrahimpour-Komleh, 2013).

Özellik seçimi, orijinal özellik kümesini temsil etme doğruluğunu azaltmadan bir özellik alt kümesini seçme sorunudur. Özellik seçimi için algoritmalar iki kategoriye ayrılır: özelliklerin kullanılabilirliğini değerlendirmek için öğrenme algoritmasını kullanan sarmalayıcı ve özellikleri verilerin istatistiksel özelliklerine göre değerlendiren filtreler. Özellik seçimi için önerilen çok sayıda yöntem arasında, partikül sürüsü optimizasyonu (SOM), genetik algoritma ve karınca kolonileri optimizasyonu (ACO) gibi popülasyon tabanlı optimizasyon algoritmaları büyük ilgi gördü. Bu yöntemler, önceki yinelemeden elde edilen bilgilerin uygulanmasıyla daha iyi bir çözüm elde etmeye çalışır (Rad vd, 2012).

Bu yazıda, sınıflandırmak için emperyalist rekabet algoritması kullanılarak yeni bir sarmalayıcı özellik seçme tekniği sunulmuştur. Emperyalist rekabet, emperyalist rekabetten esinlenen yeni bir evrimsel optimizasyon yöntemidir. Bütün ülkeler iki türe ayrılır: emperyalist devletler ve koloniler. Emperyalist rekabet, bu algoritmanın ana parçasıdır.

Bu algoritma birkaç ilk popülasyonla başlar. Nüfusun en iyi unsurlarından bazıları koloniciler olarak seçilmiştir. Nüfusun geri kalanı da bir kolonidir. Kolonistler güçleriyle bu kolonileri bir şekilde öldürür. Bir imparatorluğun toplam gücü, onun iki kurucu kısmına, sömürge devlete ve kolonilerine bağlıdır. Erken imparatorlukların kurulmasıyla aralarında sömürge rekabeti başladı. Sömürge rekabetinde başarılı olamayan ve gücünü inşa edemeyen herhangi bir imparatorluk, sömürge rekabetinden çıkarılır, bu nedenle bir imparatorluğun hayatta kalması, rakip kolonileri çekme yeteneğine bağlıdır. Bu nedenle, daha büyük ve daha zayıf imparatorlukların gücü, sömürge rekabeti sırasında yavaş yavaş ortadan kalkar. İlk önce ilk imparatorluklar kuruldu. Tüm imparatorluklar diğer imparatorlukların kolonilerini fethetmeye çalışır. Bu mücadele, zayıf imparatorlukların gücünü kademeli olarak azaltacak ve daha güçlü imparatorlukların gücünü artıracak, en zayıf koloniyi, en zayıf imparatorluğu modellemek için emperyalist rekabeti seçecek ve ardından tüm imparatorluklar arasında kolonizasyon için rekabet yaratacaktır. Her ülkenin, tüm öznitelikleri içeren bir  $n$  boyutlu dizisi vardır ve seçilen öznitelikler bir değerine sahiptir ve seçilmeyenler sıfır değerini alır. Bir dizi öznitelik için bir ikili sayı kümesi oluşturur ve seçilen özniteliklerin bir alt kümesi olarak tanımlanabilir (Magsudi ve Gazvini, 2018).

## 5. UYGULAMA

### 5.1. Veri Seti

Çoğu gerçek yaşam veri seti, önemli ilişkilerin oluşumuna önemli ölçüde katkıda bulunmayan belirli miktarda fazlalık veri içerir. Bu artıklık sadece veri setinin boyutsallığını arttırmakla kalmaz ve veri madenciliği sürecini yavaşlatır, aynı zamanda sonraki sınıflandırma performansını da etkiler. Öznitelik seçimi, veri madenciliği göreviyle ilgisiz olduğu düşünülen fazlalık özniteliklerin kaldırılması işlemidir. Ancak, sınıflandırma için yararlı olmayan özniteliklerin varlığı, sınıflandırma performansını düşürmek için ilgili özniteliklere müdahale edebilir. Bunun nedeni, bu ek özelliklerin katkıda bulunduğu ve zorluk seviyesini yükselten gürültüdür. Bu nedenle öznitelik seçiminin amacı, tüm öznitelikler kullanıldığında durumla karşılaştırılabilir sınıflandırma sonuçları üreten değerli öznitelikler kümesini aramaktır (Geetha ve Baboo, 2016b). En sık görülen tiroit hastalıkları hipotiroitizm (hipotiroitizm) ve hipertiroitizmdir (hipertiroitizm) Bu araştırmanın yapılabilmesi için UCI veritabanındaki 21 özellikli 7.200 örnekten oluşan veritabanı kullanılmıştır. Setin özellikleri, sürekli değerli 6 özellik ve ayrık değerli 15 özellik içeren iki genel kategoriye ayrılabilir Tablo 1 ve 2. Hipertiroitizm, çok fazla tiroksin üretilerek ani kilo kaybına, düzensiz kalp atışına, asabiyete, bağırsak fonksiyonlarında artışa, bağırsak hareketlerinde artışa ve ishale yol açan bir hastalıktır. Ve kilo kaybına yol açan metabolizmayı artırır. Hipotiroitizm ayrıca T3 ve T4 hormonları yeterince üretilmediğinde ortaya çıkar ve tedavi edilmezse yüksek kolesterol, yüksek tansiyon, kardiyovasküler komplikasyonlar, azalmış doğurganlık ve depresyona yol açabilir.

**Tablo 5. 1. Tiroit hastalığı veri setinin genel bilgisi**

<b>Tiroit Hastalığı veri seti</b>			
<b>Tür</b>	Sınıflandırma	<b>Menşei</b>	Gerçek dünya
<b>Özellikler</b>	21	<b>Gerçek / Tam Sayı / Nominal</b>	6/15/0
<b>Örnekler</b>	7200	<b>Sınıflar</b>	3
<b>Kayıp değerler?</b>			Hayır

**Tablo 5. 2. Tiroit hastalığı veri setinin öznitelik açıklaması**

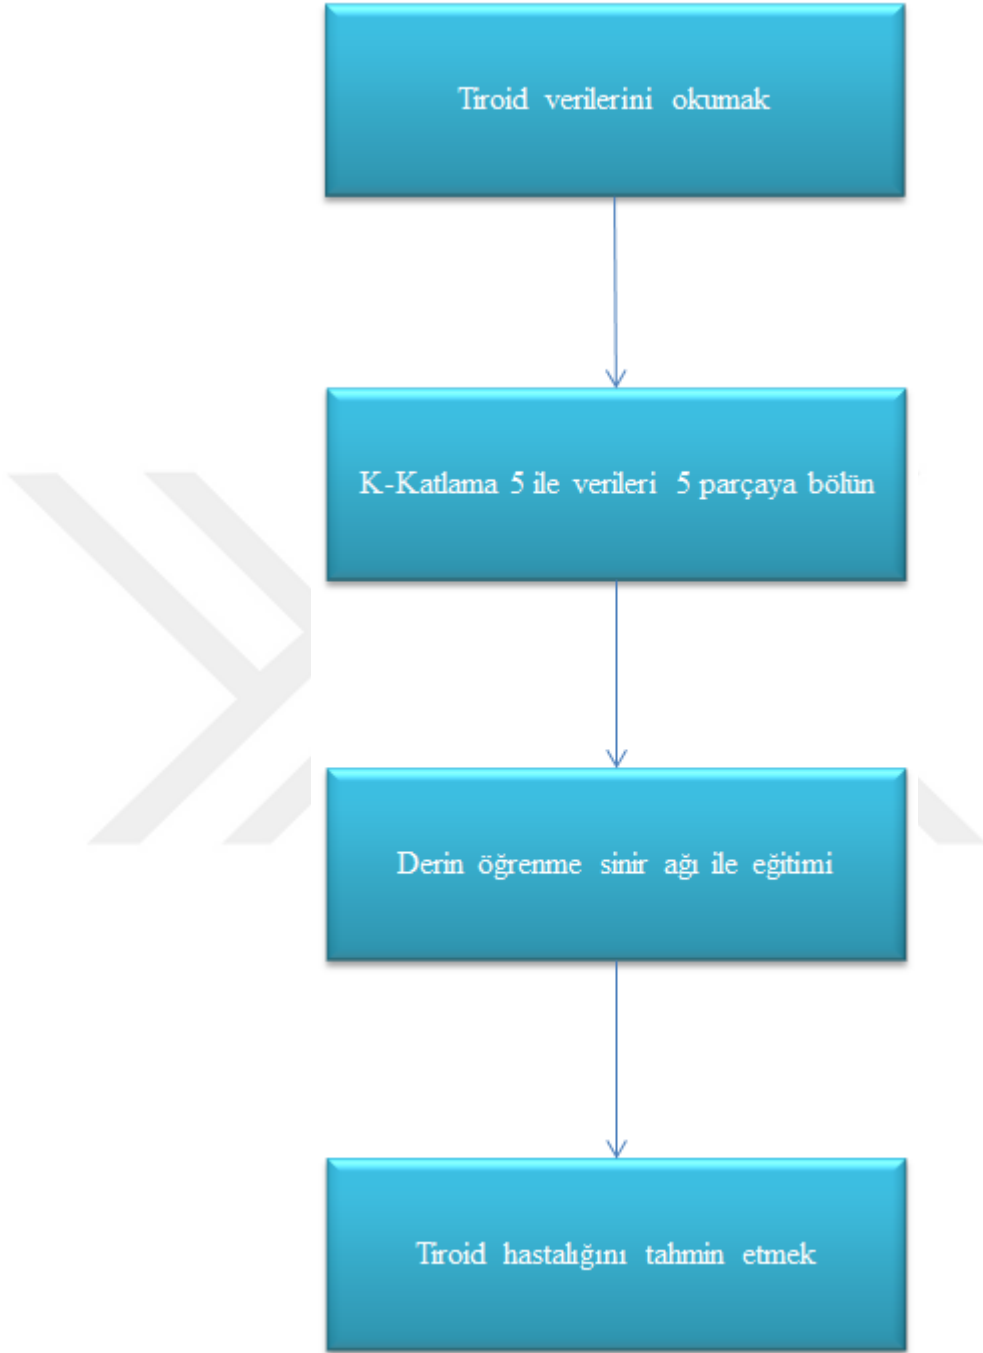
<b>Etki Alanı</b>	<b>Özniteliği Etki</b>	<b>Etki Alanı</b>	<b>Özniteliği Etki</b>	<b>Etki Alanı</b>	<b>Özniteliği Etki</b>
<b>Yaş</b>	[0.01, 0.97]	<b>Hamile</b>	[0, 1]	<b>Guatr</b>	[0, 1]
<b>Cinsiyet</b>	[0, 1]	<b>Tiroit _ cerrahi</b>	[0, 1]	<b>Hipopitüiter</b>	[0, 1]
<b>Tiroksin</b>	[0, 1]	<b>I131 _ tedavi</b>	[0, 1]	<b>TSH</b>	[0.0, 0.53]
<b>Tiroksin üzerinde _ sorgu</b>	[0, 1]	<b>Sorgu _ hipotiroit</b>	[0, 1]	<b>T3</b>	[0.0005, 0.18]
<b>Antitiroit _ ilaç</b>	[0, 1]	<b>Sorgu _ hipertiroit</b>	[0, 1]	<b>TT4</b>	[0.0020, 0.6]
<b>Hasta</b>	[0, 1]	<b>Lityum</b>	[0, 1]	<b>T4U</b>	[0.017, 0.233]
<b>Sınıf</b>	1 (normal) 2 (hipertiroiti) 3 (hipotiroitizm)			<b>FTI</b>	[0.0020, 0.642]
Cinsiyette <b>0</b> (Erkek) , <b>1</b> (Kadın) ve diğerlerinde ise <b>0</b> (Yanlış) , <b>1</b> (Doğru)				<b>Tümör</b>	[0, 1]

## 5.2. Derin Öğrenme Sinir Ağı İle Tiroit Teşhisi

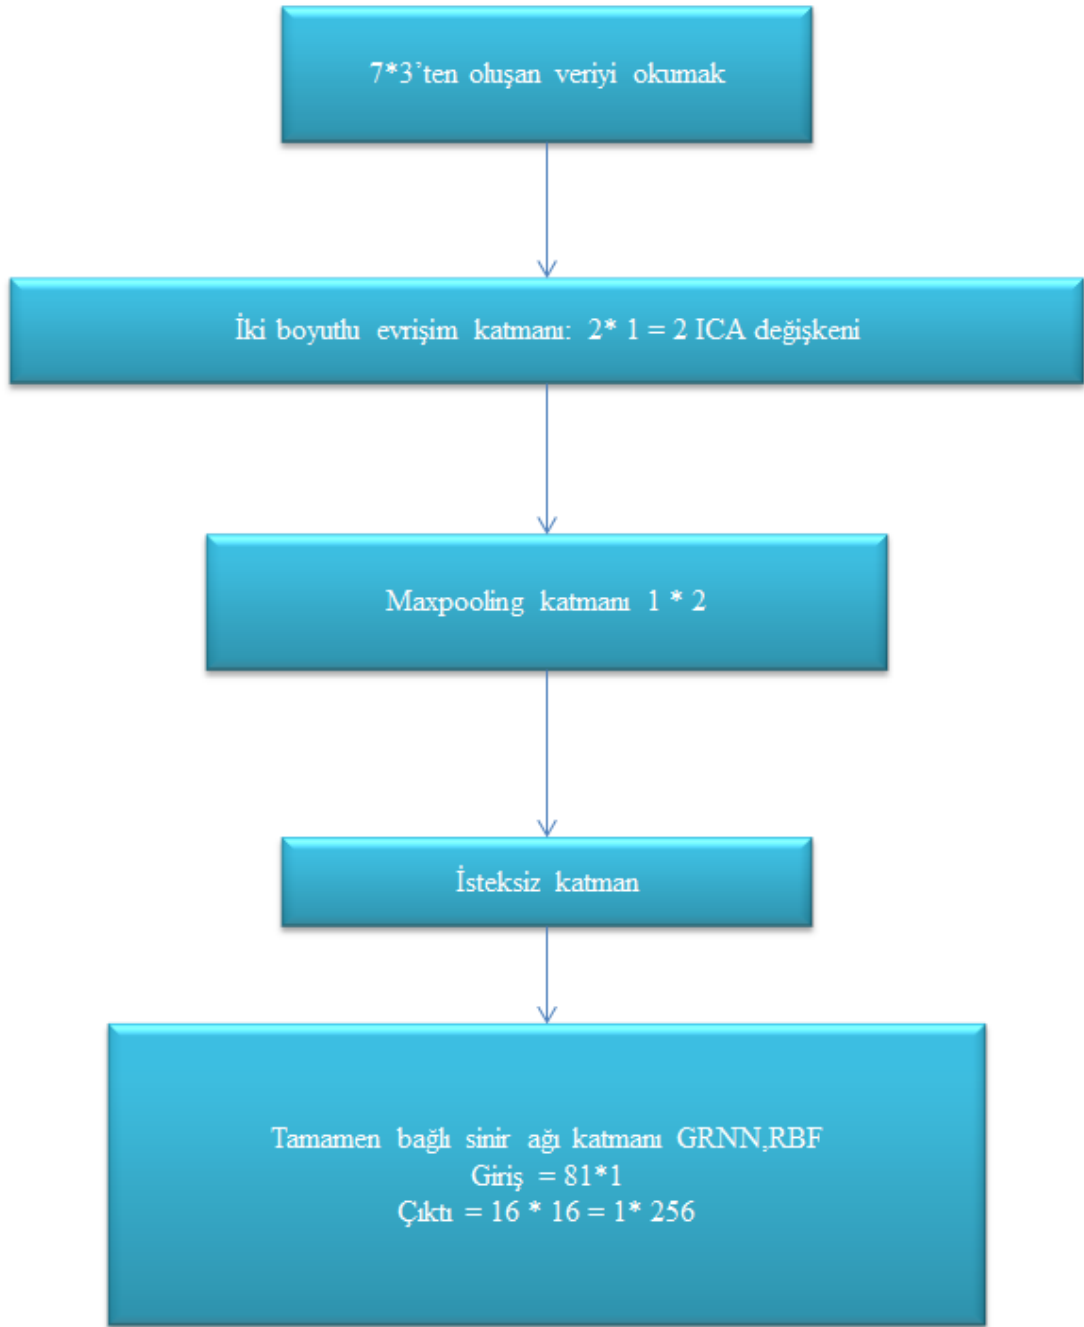
Uygulama için önce evrişim katmanı, ardından maksimum paylaşım katmanı ve ardından RELU katmanı uygulandı. Tam bağlantılı katman, bir algılama sistemidir ve burda çeşitli sinir ağlarını'da kullanabiliriz. Sinir ağlarının türleri arasında radyal sinir ağı, geri yayılım sinir ağı ve gerileme sinir ağı bulunur. Derin öğrenme sinir ağının veritabanı olan bir girdisi vardır ve çıktısı bir veri etiketidir. Derin öğrenme sinir ağını kullanan eğitim ve test aşaması Şekil 5.1 ve 5.2'de gösterilmektedir. Sinir ağı doğruluğunun çıktısı K-Katlama 5'tedir. Veriler 5 bölüme ayrılmıştır Her seferinde bir bölüm test olarak kullanılır ve geri kalanı eğitim verisi olarak kullanılır.

Kullanılan katmanlar Tablo 3 ve 4'de gösterilmektedir. Hastalığı ve doğru yüzdeyi teşhis etmek için doğruluk formüllerini kullanır ve hesaplıyoruz:

$$\text{Doğruluk} = \frac{(\text{Doğru})}{(\text{Doğru} + \text{Yanlış})} \quad (5.1)$$



Şekil 5.1. Hastalığı teşhis etmek için kullanılan yöntem



řekil 5.2. 2 \* 1 evriřim tabakalı ve 7 \* 3 giriřli CNN yapısı

**Tablo 5. 3. . Birinci derin öğrenme sinir ağı yapılandırma özellikleri**

katmanı adı	Profil
Giriş Katmanı	7*3
evrişim 2d Katman	2*1
maxPooling 2d Katman	2*2
tamamen Bağlı Katman	Sınıf 3 – GRNN
softmax Katmanı	-
sınıflandırma Katmanı	-

**Tablo 5. 4. İkinci derin öğrenme sinir ağı yapılandırma özellikleri**

katmanı adı	Profil
Giriş Katmanı	7*3
evrişim 2d Katman	2*2
tamamen Bağlı Katman	Sınıf 3 – GRNN
softmax Katmanı	-
sınıflandırma Katmanı	-

**Tablo 5. 5. Üçüncü derin öğrenme sinir ağı yapılandırma özellikleri**

katmanı adı	Profil
görüntü Giriş Katmanı	7*3
evrişim 2d Katman	İki paralel katman 2*1
tamamen Bağlı Katman	Sınıf 3 – GRNN
softmax Katmanı	-
sınıflandırma Katmanı	-

### 5.3. Derin Öğrenme Ve Sömürge Rekabetçi Algoritması ile Tiroit Teşhisi


Sömürge rekabet algoritmasında, her ülkenin sömürge rekabeti bu soruna tam çözümdür. Her ülke, evrişim katmanının ağırlık katsayılarını içerir. Imperial Competitive Algorithm, emperyalist rekabette esinlenen yeni bir evrimsel optimizasyon algoritmasıdır. Emperyalist rekabetçi algoritmanın, bir devletin iktidarını ve egemenliğini sınırlarının ötesine genişletme politikası olan emperyalizme dayalı güçlü bir yöntem olduğunu belirtmekte fayda var. Bu algoritmada, birincil ülkeler olarak ilk nüfus ile başlıyoruz. Nüfusun en iyi ülkelerinden bazıları emperyalist olarak seçildi. Halkın geri kalanı, söz konusu emperyalistler arasında bir koloni olarak bölünmüştür. Sonra tüm imparatorluklar arasında emperyal rekabet başlar. Gücünü artırmayı başaramayan ve bu rekabette başarılı olan en zayıf imparatorluk rekabette çıkarılacaktır. Sonuç olarak, imparatorluklar rekabet ederken tüm koloniler kendi emperyalistlerine doğru ilerliyor. Son olarak, çöküş mekanizması, tüm ülkeleri, dünyada yalnızca tek bir imparatorluğun olduğu bir ülkeye (sorun alanında) ve kolonileri tek bir imparatorluk olan diğer tüm ülkelere yakınlaştırmayı umuyor. Çözümümüz güçlü bir imparatorluk olacak ve daha sonra istenen cevabı, yani yüksek doğruluk yüzdesini elde etmek için imparator sayısını artırıyoruz. sonuçları Tablo 6'da gösterilmiştir (Abdollahi vd, 2013).

**Tablo 5. 6. Simulasyon sonuçları**

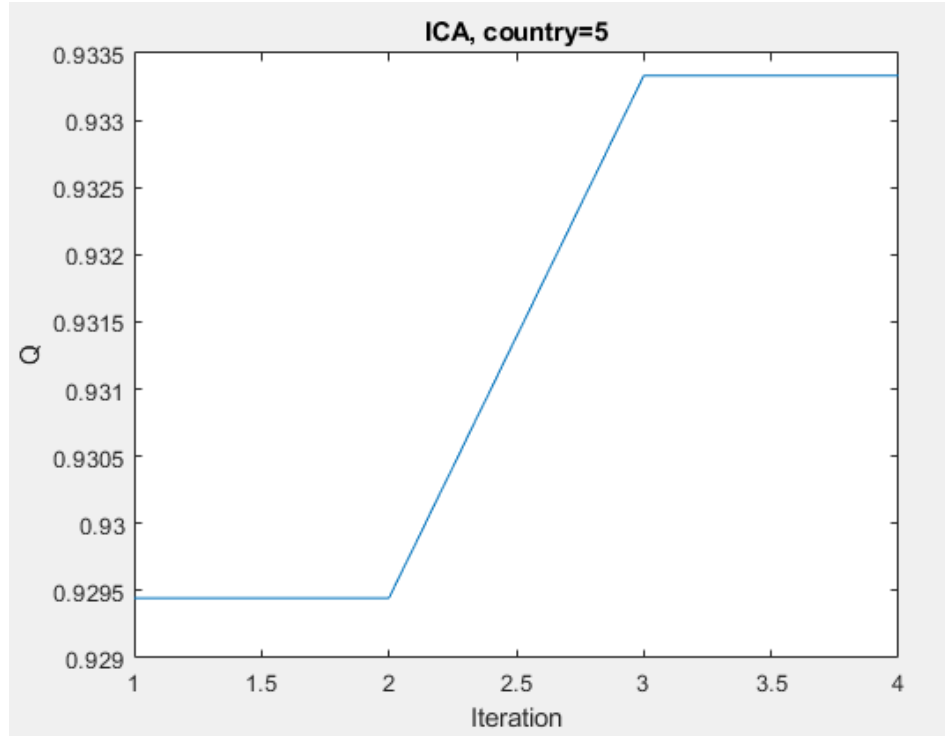
Doğru	Yanlış	Doğruluk	Profil	Yöntemin adı
6708	492	%93.17	5 İmparator	ICA-CNN-GRNN 1
6720	480	%93.305	5 İmparator	ICA-CNN-GRNN 2
6718	482	%93.305	10 İmparator	ICA-CNN-GRNN 1
6720	480	%93.333	10 İmparator	ICA-CNN-GRNN 2
7029	171	%97.625	40 İmparator	ICA-CNN-GRNN 3



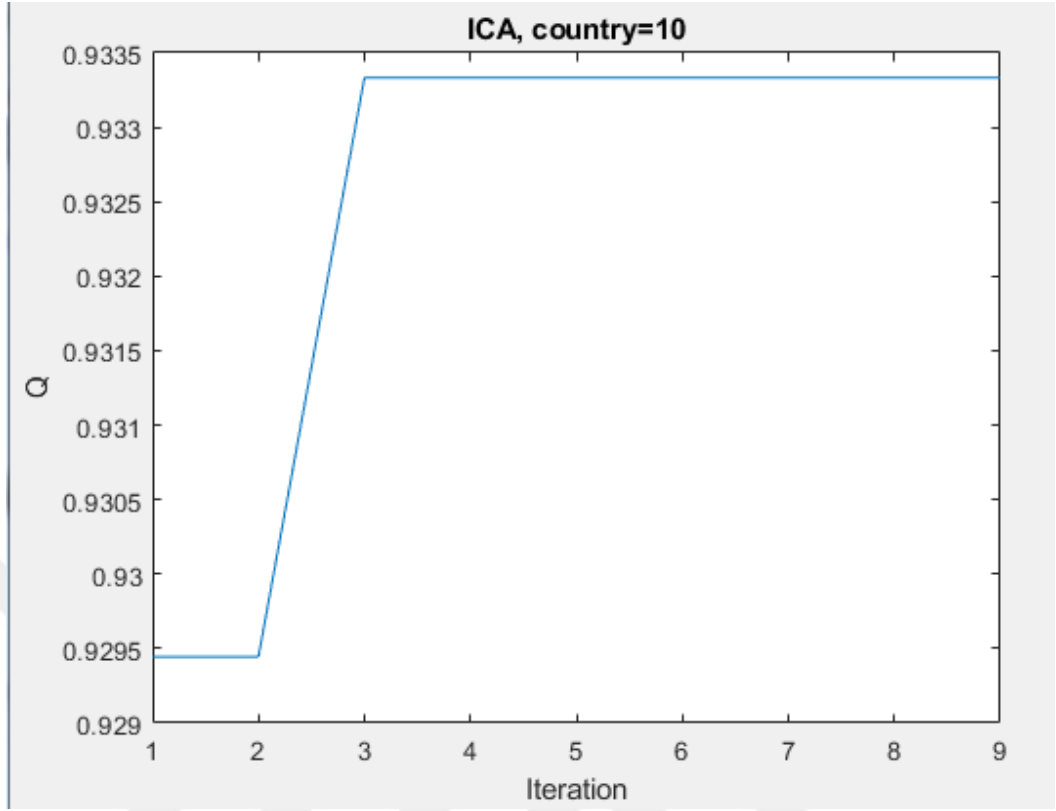
## 5.4. Simulasyon Grafikleri




Şekil 5.3. 5 tekrarlı birinci derin öğrenme sinir ağı öğrenme yapılandırmasının sonucu




Şekil 5.4. 5 tekrarlı ikinci derin öğrenme sinir ağı öğrenme yapılandırmasının sonucu




Şekil 5.5. 10 tekrarlı birinci derin öğrenme sinir ağı öğrenme yapılandırmasının sonucu



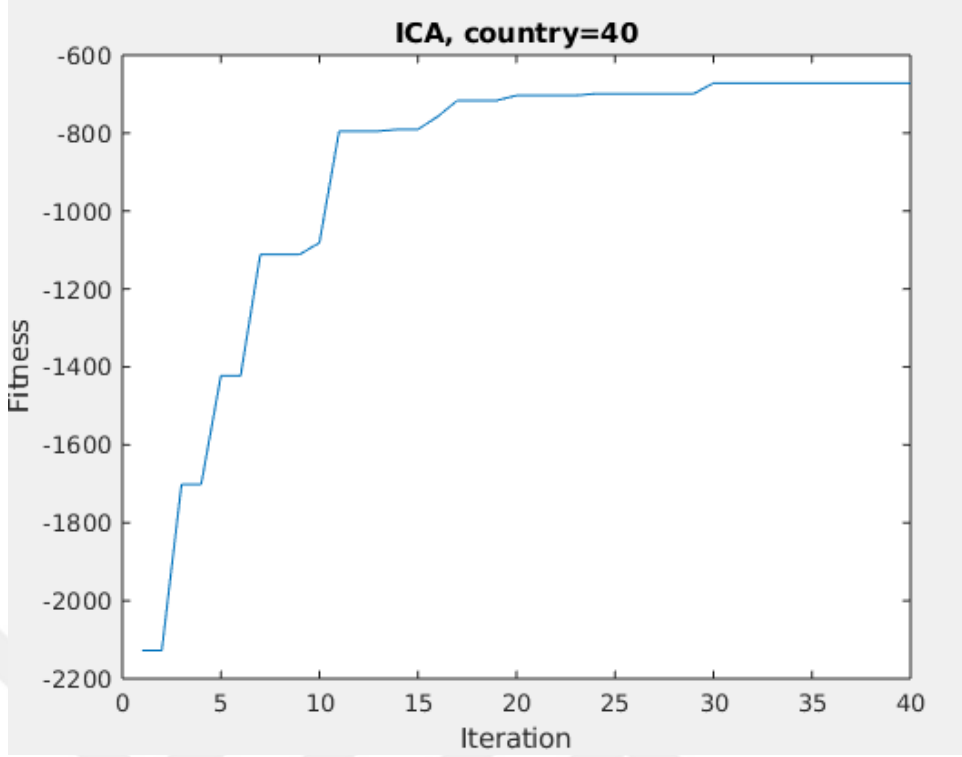
Şekil 5.6. 10 tekrarlı ikinci derin öğrenme sinir ağı öğrenme yapılandırmasının sonucu



Şekil 5.7. 40 tekrarlı üçüncü derin öğrenme sinir ağı öğrenme yapılandırmasının doğruluk sonucu




Şekil 5.8. 40 tekrarlı üçüncü derin öğrenmenin ilk sinir ağı öğrenme yapılandırmasının rmse hatasının sonucu



Şekil 5.9. 40 tekrarlı üçüncü derin öğrenmenin ilk sinir ağı öğrenme yapılandırmasının fit sonucu

İki yöntemin sonuçları karşılaştırıldığında, daha iyi tip 3 konfigürasyonuna sahip derin öğrenme sinir ağının daha iyi sonuçlara sahip olduğu görülebilir. Şekil 5.10, 4 yöntemin sonuçlarını göstermektedir.



Şekil 5.10. Farklı yöntemlerin doğruluğunu karşılaştırması

**Tablo 5. 7. 40 imparatorluk ile 3. yapılandırma sonuçları**

Toplam	Class 1	Class 2	Class 3	
7029	125	297	6607	Doğru
171	41	71	59	Yanlış
7200	166	368	6666	Toplam
%97.625	%75.30	%80.71	%99.11	Doğruluk

## 6. TARTIŞMA VE SONUÇ

Bu çalışmada, tiroit hastalıklarını teşhis etmek için derin öğrenme ve sömürge algoritması ile özellik seçme önerildi ve test edildi. Son yıllarda tiroit hastalığını yeterli ve doğru bir şekilde teşhis etmek için birçok ulaşılabilir analiz çizelgesi oluşturulmuş ve kullanılmıştır. Analiz, farklı doğruluk gösteren tüm makalelerde farklı teknolojilerin kullanıldığını göstermektedir. Çoğu araştırma makalesi, derin öğrenme algoritmasının diğer tekniklerden daha üstün olduğunu göstermiştir. Daha fazla özellik, hastanın hem uygun maliyetli hem de zaman alıcı daha fazla klinik araştırma yapması gerektiği anlamına gelir. Bu nedenle, tiroit hastalığını teşhis etmek ve hastaya zaman ve para kazandırmak için en az birkaç bireysel parametre gerektiren tiroit hastalığını tahmin etmek için bu tür algoritmalar ve modeller geliştirmeye ihtiyaç vardır. Derin öğrenmenin gelecekteki gelişimi, özellikle tıbbi teşhis alanında olmak üzere çeşitli tıbbi alanlarda daha fazla uygulama vaat etmektedir. Ancak mevcut koşullarda, derin öğrenmenin tıbbi tanıda hekimlerin / hekimlerin rolünün yerini alabileceği açık değildir. Şimdiye kadar, derin öğrenme tıp uzmanlarına iyi bir destek sağlıyor..Tiroit hastalığının tanı hatasını azaltmak her zaman araştırmacıların hedeflerinden biri olmuştur. Veri madenciliği yöntemlerini kullanmak bu hatayı azaltmaya yardımcı olabilir. Bu çalışma, derin öğrenme sinir ağı yardımıyla tiroit hastalığını teşhis ederken, derin öğrenme sinir ağını sömürge rekabet algoritması ile birleştirip daha güçlü bir yöntemin kullanılmasının, gelişmiş teşhis doğruluğuna yol açtığını göstermektedir. Sinir ağı farklı şekilde oluşur Ön sinir ağı düşük doğrulukta ve alt tabakadaki sinir ağı yüksek doğruluktadır. Sömürge rekabet algoritması, veritabanındaki özellikleri silerek ve ekleyerek algılama doğruluğunu artırır.Başlangıçta, özelliklerin değerleri rastgele seçilip ve ardından bunları sıralayarak ve en iyi ülkeyi seçerek, derin öğrenme algoritmasının doğruluğunu artıran özellikler seçilir. Genel olarak, hasta teşhisinde hangi özelliklerin etkili olacağı seçimi sömürge rekabet algoritması ile yapılır.Simülasyon için, 16 GB bellek ve G3250 işlemciye sahip bir bilgisayarda kullanılmıştır.Sonuç olarak elimizdeki verilerin üzerinde yaptığımız derin öğrenme ve sömürge rekabetçi algoritması ile özellik seçme simülasyon %97,62 doğruluk oranını elde ettik ki bu diğer çalışmalara nazaran daha iyi bir sonuç ve performans sağladını gösteriyor.

## 7. KAYNAKÇA

- Abdel-Zaher, A. M. and Eldeib, A. M. 2016. Breast cancer classification using deep belief networks. *Expert Systems with Applications*, 46, 139-144.
- Abdi, B., Mozafari, H., Ayob, A. and Kohandel, R. 2011. Imperialist competitive algorithm and its application in optimization of laminated composite structures. *European Journal of Scientific Research*, 55:2, 174-187.
- Abdollahi, M., Isazadeh, A. and Abdollahi, D. 2013. Imperialist Competitive Algorithm for Solving Systems of Nonlinear Equations. *Computers & Mathematics with Applications*, 65, 1894-1908.
- Albawi, S., Abed Mohammed, T. and Alzawi, S. 2017. *Understanding of a Convolutional Neural Network*. The International Conference on Engineering and Technology At: Antalya, Turkey,
- Ashraff, S. and Razvi, S. 2017. *Thyroid Diseases: Pathogenesis, Diagnosis and Treatment*. Springer International Publishing, 1-37, Cham.
- Atashpaz-Gargari, E. and Lucas, C. (2007). Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. 2007 IEEE congress on evolutionary computation, Ieee, 4661-4667.
- Attar, S., Mohammadi, M. and Tavakkoli-Moghaddam, R. 2011. A novel imperialist competitive algorithm to solve flexible flow shop scheduling problem in order to minimize maximum completion time. *International Journal of Computer Applications*, 28:10, 27-32.
- Aziz, M. V. G., Hindersah, H. and Prihatmanto, A. S. (2017). Implementation of vehicle detection algorithm for self-driving car on toll road cipularang using Python language. 2017 4th International Conference on Electric Vehicular Technology (ICEVT), IEEE, 149-153.
- Aziz, S. B. 2011. Thyroid Disease Diagnosis using Genetic Algorithm and Neural Network. *Journal of Al-Qadisiyah for Computer Science and Mathematics*, 3:2, 1-13.
- Azizi, D. H. D. a. D. F. 2008. [Research]. *Thyroid and pregnancy (review article)*. *Scientific Journal of the Medical System Organization of the Islamic Republic of Iran*. 1387; 26 (3): 392-408 URL: <http://jmciri.ir/article-1-1239-fa.html>, 26:3, 392-408.
- Bachu, V. and Anuradha, J. 2019. A Review of Feature Selection and Its Methods. *Cybernetics and Information Technologies*, 19, 3.
- Bebis, G. and Georgiopoulos, M. 1994. Feed-forward neural networks. *IEEE Potentials*, 13:4, 27-31.
- Behzadpoor, S., Rashtchi, V., Hashemi, M. and Rahimpour, E. (2014). Using Imperialist Competitive algorithm for parameter identification of transformer R-L-C-M model. The first Transformers International Conference and Exhibition, Tehran. [https://www.civilica.com/Paper-ITCE01-ITCE01\\_016.html](https://www.civilica.com/Paper-ITCE01-ITCE01_016.html)
- Biabangard-Oskouyi, A., Atashpaz-Gargari, E., Soltani, N. and Lucas, C. 2009. Application of imperialist competitive algorithm for materials property

- characterization from sharp indentation test. *International Journal of Engineering Simulation*, 10:1, 11-12.
- Buscema, M. 1998. Back Propagation Neural Networks. *Substance use & misuse*, 33, 233-270.
- Cannizzaro, M. A., Buffone, A., Lo Bianco, S., Okatyeva, V., Cavallaro, D., Caruso, V. and Caglià, P. 2016. The thyroid disease in the elderly: Our experience. *International Journal of Surgery*, 33, S85-S87.
- Chaubey, G., Bisen, D., Arjaria, S. and Yadav, V. 2020. Thyroid Disease Prediction Using Machine Learning Approaches. *NATIONAL ACADEMY SCIENCE LETTERS-INDIA*.
- Chinneck, J. W. 2006. Practical optimization: a gentle introduction. *Systems and Computer Engineering*, Carleton University, Ottawa. <http://www.sce.carleton.ca/faculty/chinneck/po.html>, 11.
- Chohan, M., Khan, A., Mahar, M., Hassan, S., Ghafoor, A. and Khan, M. 2020. Image Captioning using Deep Learning: A Systematic Literature Review. *International Journal of Advanced Computer Science and Applications*, 11.
- Cilimkovic, M. 2015. Neural networks and back propagation algorithm. *Institute of Technology Blanchardstown, Blanchardstown Road North Dublin*, 15.
- Code, F. and Casella, F. 2020. Neural Network Library in Modelica.
- Coello, C. A. C., Lamont, G. B. and Van Veldhuizen, D. A. 2007. *Evolutionary algorithms for solving multi-objective problems*. Springer,
- Covelli, D. and Salvi, M. 2018.
- Dash, M. and Liu, H. 1997. Feature selection for classification. *Intelligent Data Analysis*, 1:1, 131-156.
- Du, K. L. and Swamy, M. N. s. 2014. 337-353.
- Duan, H., Xu, C., Liu, S. and Shao, S. 2010. Template matching using chaotic imperialist competitive algorithm. *Pattern Recognition Letters*, 31:13, 1868-1875.
- Duki, E. A., Mansoorkhani, H. A., Soroudi, A. and Ehsan, M. (2010). A discrete imperialist competition algorithm for transmission expansion planning. 25th International Power System Conference, 1-10.
- Faggiano, A., Del Prete, M., Marciello, F., Marotta, V., Ramundo, V. and Colao, A. 2011. Thyroid diseases in elderly. *Minerva endocrinologica*, 36, 211-231.
- Fischer, A. and Igel, C. 2012. *An Introduction to Restricted Boltzmann Machines*, 14-36,
- Gallo, C. 2015.
- Gargari, E. A., Hashemzadeh, F., Rajabioun, R. and Lucas, C. 2008. Colonial competitive algorithm. *International Journal of Intelligent Computing and Cybernetics*.
- Geetha, K. and Baboo, S. 2016a. An Empirical Model for Thyroid Disease Classification using Evolutionary Multivariate Bayesian Prediction Method. *Global journal of computer science and technology*.



- Geetha, K. and Baboo, S. S. 2016b. An empirical model for thyroid disease classification using evolutionary multivariate Bayesian prediction method. *Global journal of computer science and technology*.
- Glover, F. W. and Kochenberger, G. A. 2006. *Handbook of metaheuristics*. Springer Science & Business Media,
- Ha, S. and Nguyen, H.-N. 2016. Credit scoring with a feature selection approach based deep learning. *MATEC Web of Conferences*, 54, 05004.
- Heuck, C. C., Kallner, A., Kanagasabapathy, A. S., Riesen, W., World Health Organization. Diagnostic, I. and Laboratory, T. (2000). *Diagnosis and monitoring of diseases of the thyroid / by C. C Heuck ... [et al.]*. Retrieved from Geneva: <https://apps.who.int/iris/handle/10665/66342>
- Huang, Y., Jin, W., Yu, Z. and Li, B. 2020. Supervised feature selection through Deep Neural Networks with pairwise connected structure. *Knowledge-Based Systems*, 204, 106202.
- Jain, D. and Singh, V. 2018. Feature selection and classification systems for chronic disease prediction: A review. *Egyptian Informatics Journal*, 19:3, 179-189.
- Jalilzadeh, S., Behzadpoor, S. and Hashemi, M. 2012. PID Design for AVR System by PSO and Imperialist Competitive Algorithms.
- Jovic, A., Brkić, K. and Bogunovic, N. 2015. *A review of feature selection methods with applications*, 1200-1205,
- Kaveh, A. and Talatahari, S. 2010. Imperialist competitive algorithm for engineering design problems.
- Keleş, A. 2018. DERİN ÖĞRENME VE SAĞLIK ALANINDAKİ UYGULAMALARI. *Electronic Turkish Studies*, 13:21.
- Keleş, A. and Keleş, A. 2008. ESTDD: Expert system for thyroid diseases diagnosis. *Expert Systems with Applications*, 34:1, 242-246.
- Ker, J., Wang, L., Rao, J. and Lim, T. 2017. Deep Learning Applications in Medical Image Analysis. *IEEE Access*, PP, 1-1.
- Khabbazi, A., Atashpaz-Gargari, E. and Lucas, C. 2009. Imperialist competitive algorithm for minimum bit error rate beamforming. *International Journal of Bio-Inspired Computation*, 1:1-2, 125-133.
- Khan, A., Zameer, A., Jamal, T. and Raza, A. 2018. Deep belief networks based feature generation and regression for predicting wind power. *arXiv preprint arXiv:1807.11682*.
- Klein, I. and Danzi, S. 2007. Thyroid disease and the heart. *Circulation*, 116:15, 1725-1735.
- Koundal, D., Gupta, S. and Singh, S. 2012. Computer-Aided Diagnosis of Thyroid Nodule: A Review. *International Journal of Computer Science and Engineering Survey*, 3, 67-83.
- Kousarrizi, M. N., Seiti, F. and Teshnehlal, M. 2012. An experimental comparative study on thyroid disease diagnosis based on feature subset selection and classification. *International Journal of Electrical & Computer Sciences IJECS-IJENS*, 12:01, 13-20.

- Le, Q. V. 2015. A tutorial on deep learning part 2: Autoencoders, convolutional neural networks and recurrent neural networks. *Google Brain*, 1-20.
- LeCun, Y., Bengio, Y. and Hinton, G. 2015. Deep Learning. *Nature*, 521, 436-444.
- Lee, H., Grosse, R., Ranganath, R. and Ng, A. 2009. *Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations*, 77,
- Leung, H. and Haykin, S. 1991. The complex backpropagation algorithm. *IEEE Transactions on Signal Processing*, 39:9, 2101-2104.
- Lian, K., Zhang, C., Gao, L. and Li, X. 2012. Integrated process planning and scheduling using an imperialist competitive algorithm. *International Journal of Production Research*, 50:15, 4326-4343.
- Liu, P., Zheng, P. and Chen, Z. 2019. Deep Learning with Stacked Denoising Auto-Encoder for Short-Term Electric Load Forecasting. *Energies*, 12, 2445.
- Liu, S., Bai, L., Hu, Y. and Wang, H. 2018. Image Captioning Based on Deep Neural Networks. *MATEC Web of Conferences*, 232, 01052.
- Magsudi, M. and Gazvini, M. (2018). Application of meta-heuristic algorithms in dimension reduction and feature selection. 3rd International Conference on Compositions, Cryptography and Computing, Iran University of Science and Technology. <http://i4c.iust.ac.ir/UPL/Paper18/i4c18-1033.pdf>
- Mamaghani, A. S. and Meybodi, M. R. (2011). An application of Imperialist Competitive Algorithm to solve the quadratic assignment problem. 2011 International Conference for Internet Technology and Secured Transactions, IEEE, 562-565.
- Memari, A., Ahmad, R. and Rahim, A. R. A. 2017. Metaheuristic algorithms: guidelines for implementation. *Journal of Soft Computing and Decision Support Systems*, 4:6, 1-6.
- Memisevic, R. (2015). Deep learning: Architectures, algorithms, applications. 2015 IEEE Hot Chips 27 Symposium (HCS), IEEE, 1-127.
- Mitra, M. and Mahdiyeh, G. (2018). Reduce data dimensions using a hybrid feature selection method. Third National Conference on Computer, Information Technology and Artificial Intelligence Applications, Ahvaz. <https://civilica.com/doc/1015574>
- Montufar, G. 2018. *Restricted Boltzmann Machines: Introduction and Review*,
- Mousavirad, S. and Ebrahimpour-Komleh, H. (2013). Feature selection using modified imperialist competitive algorithm. ICCKE 2013, IEEE, 400-405.
- Naggashi, F., Fallah Tarigi, F. and Fallah Rad, M. (2012). Introduction of colonial competition algorithm. The Second National Conference on Software Engineering of Lahijan Azad University, Lahijan. <https://civilica.com/doc/184854>
- Namatevs, I. 2017. Deep Convolutional Neural Networks: Structure, Feature Extraction and Training. *Information Technology and Management Science*, 20.
- Niknam, T., Taherian Fard, E., Pourjafarian, N. and Rousta, A. 2011. An efficient

- hybrid algorithm based on modified imperialist competitive algorithm and K-means for data clustering. *Engineering Applications of Artificial Intelligence*, 24:2, 306-317.
- Nweke, H., Wah, T., Al-Garadi, M. and Alo, U. 2018. Deep Learning Algorithms for Human Activity Recognition using Mobile and Wearable Sensor Networks: State of the Art and Research Challenges. *Expert Systems with Applications*, 105.
- Parvathaneni, A., Fischman, D. and Cheriya, P. 2012. *Hashimoto s Thyroiditis*.
- Pavya, K. and Srinivasan, B. 2017a. *Feature selection algorithms to improve thyroid disease diagnosis*, 1-5,
- Pavya, K. and Srinivasan, B. (2017b). Feature selection algorithms to improve thyroid disease diagnosis. 2017 International Conference on Innovations in Green Energy and Healthcare Technologies (IGEHT), IEEE, 1-5.
- Pavya, K. and Srinivasan, B. 2018. Review of literature on filter and wrapper methods for feature selection. *International journal of engineering sciences & research technology*, 7(1), 137-143.
- Rad, S. M., Tab, F. A. and Mollazade, K. 2012. Application of imperialist competitive algorithm for feature selection: A case study on bulk rice classification. *International Journal of Computer Applications*, 40:16, 41-48.
- Rajabioun, R., Atashpaz-Gargari, E. and Lucas, C. (2008a). Colonial competitive algorithm as a tool for Nash equilibrium point achievement. International Conference on Computational Science and Its Applications, Springer, 680-695.
- Rajabioun, R., Hashemzadeh, F., Atashpaz-Gargari, E., Mesgari, B. and Salmasi, F. R. (2008b). Identification of a MIMO evaporator and its decentralized PID controller tuning using colonial competitive algorithm. be presented in IFAC World Congress.
- Rajpurohit, J., Sharma, T. K., Abraham, A. and Vaishali, A. 2017. Glossary of metaheuristic algorithms. *Int. J. Comput. Inf. Syst. Ind. Manag. Appl*, 9, 181-205.
- Razia, S. and Rao, M. 2016. Machine Learning Techniques for Thyroid Disease Diagnosis - A Review. *Indian Journal of Science and Technology*, 9.
- Razmjoooy, N., Mousavi, B. S. and Soleymani, F. 2013. A hybrid neural network Imperialist Competitive Algorithm for skin color segmentation. *Mathematical and Computer Modelling*, 57:3-4, 848-856.
- Rezaei, M., Yang, H. and Meinel, C. 2017. Deep Learning for Medical Image Analysis. *ArXiv*, abs/1708.08987.
- Roy, D., Kodukula, S. R. M. and Chalavadi, K. M. 2015. *Feature selection using Deep Neural Networks*, 1-6,
- Sadati, M. E. H. and Mohasefi, J. B. 2014. The Application of Imperialist Competitive Algorithm for Fuzzy Random Portfolio Selection Problem. *arXiv preprint arXiv:1402.4834*.
- Sahragerd, K., Marusi, A. and Zabbah, I. (2017). Diagnosis of thyroid disease using the method of combining artificial neural networks with genetic algorithms.

Fifth International Conference on Knowledge-Based Research in Computer Engineering and Information Technology, Tehran.

<https://civilica.com/doc/670749>

- Saiti, F., Naini, A., Aliyari Shoorehdeli, M. and Teshnehlab, M. 2009a. *Thyroid Disease Diagnosis Based on Genetic Algorithms Using PNN and SVM*, 1-4,
- Saiti, F., Naini, A. A., Shoorehdeli, M. A. and Teshnehlab, M. (2009b). Thyroid disease diagnosis based on genetic algorithms using PNN and SVM. 2009 3rd international conference on bioinformatics and biomedical engineering, IEEE, 1-4.
- Sánchez-Marroño, N., Alonso-Betanzos, A. and Tombilla-Sanromán, M. 2007. *Filter Methods for Feature Selection – A Comparative Study*, 178-187,
- Sazli, M. 2006. A brief review of feed-forward neural networks. *Communications, Faculty Of Science, University of Ankara*, 50, 11-17.
- Schiefer, R. and Fatourechi, V. 2010. *Laboratory Diagnosis of Thyroid Disease*, 23-36, Thyroid Disorders with Cutaneous Manifestations.
- SEPEHRI, R. H. (2008). Application of imperialistic competition algorithm in recommender systems. 13th international CSI computer conference (CSICC'08), Kish Island, Iran.
- Shakhsi-Niaei, M., Iranmanesh, S., Sadrabady, M. and Moghadam, M. 2013. A comparison of two approaches for integral purchasing management in an oil-and-gas company (PetroPars). *International Journal of Energy and Statistics*, 1, 1-16.
- Shetty, S. and Siddiqa, A. 2019. Deep Learning Algorithms and Applications in Computer Vision. *International Journal of Computer Sciences and Engineering*, 7, 195-201.
- Shrestha, A. and Mahmood, A. 2019. Review of Deep Learning Algorithms and Architectures. *IEEE Access*, PP, 1-1.
- So, M., Macisaac, R. and Grossmann, M. 2012. Hypothyroidism Investigation and management. *Australian family physician*, 41, 556-562.
- Sreekanth, D. N. 2013. REVIEW ON THYROID DISORDERS. *international journal of pharmaceutical research and bio science*.
- Suryanita, R. and Jingga, H. 2017. *Application of Backpropagation Neural Networks in Predicting Story Drift of Building*,
- Taher Azar, A. and Hassanien, A. E. 2014. Expert System Based on Neural-Fuzzy Rules for Thyroid Diseases Diagnosis. *ArXiv*, arXiv: 1403.0522.
- Taherkhani, A., Cosma, G. and McGinnity, T. M. 2018. Deep-FS: A feature selection algorithm for Deep Boltzmann Machines. *Neurocomputing*, 322, 22-37.
- Tai, L., Li, S. and Liu, M. 2017. Autonomous exploration of mobile robots through deep neural networks. *International Journal of Advanced Robotic Systems*, 14, 172988141770357.
- Turkson, R., Yan, F., Ahmed Ali, M. and Hu, J. 2016. Artificial neural network applications in the calibration of spark-ignition engines: An overview. *Engineering Science and Technology, an International Journal*, 19.

- Vrahatis, M., Magoulas, G., Parsopoulos, K. and Plagianakos, V. 2000. *Introduction to artificial neural network training and applications*,
- Wang, S., Tang, J. and Liu, H. 2016. *Feature Selection*, 1-9.
- Werbos, P. (1988). Backpropagation: Past and future. Proceedings of the Second International Conference on Neural Network, IEEE, 343-353.
- Yamashita, R., Nishio, M., Do, R. and Togashi, K. 2018. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9.
- Yang, X.-S. 2010. *Engineering optimization: an introduction with metaheuristic applications*. John Wiley & Sons,
- Zabbah, I., Yasrebiye naini, S. E., Ramazanpoor, Z. and Sahragerd, K. 2017. Diagnosis of thyroid disease using a combination of neural networks in a hierarchical manner [Article]. *Health and Biomedicine Informatics*, 4:1, 21-31.
- Zeinae, Z. (2016). Thyroid disease and the miraculous effect of the diet. Scientific conference of nutrition students, Tehran. <https://civilica.com/doc/474746>
- Zhang, Y., Wang, Y. and Peng, C. (2009). Improved imperialist competitive algorithm for constrained optimization. 2009 International Forum on Computer Science-Technology and Applications, IEEE, 204-207.
- Zhou, T., Ruan, S. and Canu, S. 2019. A review: Deep learning for medical image segmentation using multi-modality fusion. *Array*, 3-4, 100004.